

**T.C.**  
**ERZİNCAN BİNALİ YILDIRIM ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**  
**YAPAY ZEKA VE ROBOTİK ANABİLİM DALI**

**ÜZÜM YAPRAĞINDA GÖRÜLEN HASTALIKLARIN DERİN ÖĞRENME İLE  
TESPİTİ VE SINIFLANDIRILMASI**

**Umut FIRAT**

**Danışman: Doç. Dr. İsmail AKGÜL**

**TEZ JÜRİ ÜYELERİ**  
**Doç. Dr. Durmuş ÖZDEMİR**  
**Doç. Dr. İsmail AKGÜL**  
**Dr. Öğr. Üyesi Zafer DURAKLI**

**YÜKSEK LİSANS TEZİ**  
**ERZİNCAN, 2026**

© 2026 [Umut FIRAT]. Tüm hakları saklıdır.

## **Kabul ve Onay Sayfası**

Doç. Dr. İsmail AKGÜL danışmanlığında, Umut FIRAT tarafından hazırlanan bu çalışma 22.04.2026 tarihinde aşağıdaki jüri tarafından Yapay Zeka ve Robotik Anabilim Dalı'nda Yüksek Lisans Tezi olarak oybirliği ile kabul edilmiştir.

Başkan : Doç. Dr. Durmuş ÖZDEMİR İmza:

Üye : Doç. Dr. İsmail AKGÜL İmza:

Üye : Dr. Öğr. Üyesi Zafer DURAKLI İmza:

Bu tez Enstitü Yönetim Kurulunun .... / .... / 20.... tarih ve ...../..... sayılı kararı ile onaylanmıştır.

**Prof. Dr. Kemal Volkan ÖZDOKUR**  
Enstitü Müdür V.

**Not:** Bu tezde kullanılan özgün ve başka kaynaklardan yapılan bildirişlerin, şekil ve tabloların kaynak olarak kullanımı, 5846 sayılı Fikir ve Sanat Eserleri Kanunundaki hükümlere tabidir.

## **Bilimsel Etięe Uygunluk Sayfası**

“Üzüm Yaprada Görülen Hastalıkların Derin Öğrenme ile Tespiti ve Sınıflandırılması” isimli “Yüksek Lisans” tezim tarafımda intihal tespit programı ile incelenmiştir. Buna göre tezimde bilimsel etik ihlali ve intihal olarak nitelendirilebilecek herhangi bir durum olmadığını taahhüt ederim.

Bu çalışmadaki tüm bilgilerin, akademik ve etik kurallara uygun bir biçimde elde edildiğini; aynı zamanda bu kural ve davranışların gerektirdiği gibi, bu çalışmanın özünde olmayan tüm materyal ve sonuçları tam olarak aktardığımı ve referans gösterdiğimi beyan ederim. 22/04/2026

(İmza)

**Umut FIRAT**

## ÖZET

# ÜZÜM YAPRAĞINDA GÖRÜLEN HASTALIKLARIN DERİN ÖĞRENME İLE TESPİTİ VE SINIFLANDIRILMASI

**Umut FIRAT**

**Yüksek Lisans Tezi**

**Erzincan Binali Yıldırım Üniversitesi, Fen Bilimleri Enstitüsü,**

**Yapay Zeka ve Robotik Anabilim Dalı**

**Danışman: Doç. Dr. İsmail AKGÜL**

**2026, 155 sayfa**

Beslenme, tüm canlılar için temel bir gereksinim olup Maslow'un ihtiyaçlar hiyerarşisinde en temel fizyolojik ihtiyaçlardan biri olarak tanımlanmaktadır. İnsan beslenmesinde önemli bir yere sahip olan üzüm, yüksek besin değeri ve güçlü antioksidan bileşenleri ile dikkat çekmektedir. Bununla birlikte, diğer bitkilere benzer şekilde üzüm bitkisi de çevresel ve biyolojik etkenlere bağlı olarak çeşitli hastalıklara yakalanabilmektedir. Bu nedenle hastalıkların erken dönemde tespit edilmesi, gerekli müdahalelerin zamanında yapılmasına olanak sağlayarak bitki sağlığının korunması açısından büyük önem taşımaktadır. Bu çalışmada, üzüm yaprak görüntülerinin analiz edilmesi yoluyla hastalıkların erken aşamada tespit edilmesi ve farklı hastalık türlerinin otomatik olarak sınıflandırılması amaçlanmıştır. Bu doğrultuda, derin öğrenme tabanlı Convolutional Neural Network (CNN) mimarileri kullanılmıştır. Üzüm yapraklarına ait görüntülerden oluşan bir veri seti Python tabanlı Google Colab ortamında işlenmiş ve AlexNet, DenseNet121, EfficientNetB3, MobileNetV2 ve ResNet50 mimarileri kullanılarak hastalık tespiti ve sınıflandırılması gerçekleştirilmiştir. Modeller 20, 50 ve 100 epoch değerleri ile eğitilmiş ve performansları doğruluk, kesinlik, duyarlılık ve F1-skor metrikleri kullanılarak değerlendirilmiştir. Elde edilen sonuçlara göre, 100 epoch eğitim sonucunda AlexNet modeli %88.75 doğruluk oranı ile en düşük performansı gösterirken, DenseNet121 modeli %99.94 doğruluk oranı ile en yüksek performansı göstermiştir. Ayrıca, EfficientNetB3 modeli %99.39, MobileNetV2 modeli %99.11 ve ResNet50 modeli %99.67 doğruluk oranına ulaşmıştır. Sonuç olarak, CNN tabanlı yöntemlerin üzüm yaprağı hastalıklarının tespiti ve sınıflandırılmasında yüksek doğruluk ve güvenilirlik

sağladığı, özellikle DenseNet121 mimarisinin en başarılı ve en stabil model olduğu belirlenmiştir.

**Anahtar Kelimeler:** Üzüm yaprağı hastalığı, Derin öğrenme, Konvolüsyonel sinir ağıları, AlexNet, DenseNet121, EfficientNetB3, MobileNetV2, ResNet50, Görüntü sınıflandırma

## **ABSTRACT**

# **DETECTION AND CLASSIFICATION OF GRAPE LEAF DISEASES USING DEEP LEARNING**

**Umut FIRAT**

**Master's Thesis**

**Erzincan Binali Yıldırım University, Institute of Science and Technology,**

**Department of Artificial Intelligence and Robotics**

**Advisor: Assoc. Prof. Dr. İsmail AKGÜL**

**2026, 155 pages**

Nutrition is a fundamental requirement for all living organisms and is defined as one of the most basic physiological needs in Maslow's hierarchy of needs. Grapes, which are widely consumed by humans, attract attention due to their high nutritional value and strong antioxidant components. However, similar to other plants, grapevines are susceptible to various diseases caused by environmental and biological factors. Therefore, early detection of these diseases is of great importance in order to enable timely intervention and to maintain plant health. In this study, it was aimed to detect grape leaf diseases at an early stage and automatically classify different disease types by analyzing leaf images. For this purpose, deep learning-based Convolutional Neural Network (CNN) architectures were employed. A dataset consisting of grape leaf images was processed in a Python-based Google Colab environment, and disease detection and classification were performed using AlexNet, DenseNet121, EfficientNetB3, MobileNetV2, and ResNet50 architectures. The models were trained with 20, 50, and 100 epochs, and their performances were evaluated using accuracy, precision, recall, and F1-score metrics. According to the results obtained, after 100 epochs of training, the AlexNet model showed the lowest performance with an accuracy of 88.75%, while the DenseNet121 model showed the highest performance with an accuracy of 99.94%. Furthermore, the EfficientNetB3 model achieved 99.39% accuracy, the MobileNetV2 model 99.11% accuracy, and the ResNet50 model 99.67% accuracy. In conclusion, it was determined that CNN-based methods provide high accuracy and reliability in the detection and classification of grape leaf diseases, and that the DenseNet121 architecture was the most successful and stable model.

**Keywords:** Grape leaf disease, Deep learning, Convolutional neural networks, AlexNet, DenseNet121, EfficientNetB3, MobileNetV2, ResNet50, Image classification

## TEŐEKKÜR

Yüksek lisans tez çalışmamın planlanması, yürütülmesi ve sonuçlandırılması sürecinde değerli bilgi ve deneyimleriyle bana yol gösteren, her aşamada destek ve teşviklerini esirgemeyen saygıdeğer danışmanım Doç. Dr. İsmail AKGÜL hocama en içten teşekkürlerimi sunarım.

Çalışmam boyunca sunduğu bilimsel katkılar, yapıcı eleştiriler ve yönlendirmeler, araştırma sürecimin daha nitelikli ve sistemli bir şekilde ilerlemesine önemli ölçüde katkı sağlamıştır. Ayrıca, akademik gelişimime vermiş olduğu destek ve motive edici yaklaşımı, bu çalışmanın ortaya çıkmasında belirleyici olmuştur.

Bunun yanı sıra, öğrenim hayatım boyunca bana her zaman destek olan aileme ve emeği geçen tüm hocalarıma teşekkür eder, bu çalışmanın bilim dünyasına ve uygulamaya katkı sağlamasını temenni ederim.

Umut FIRAT

04,2026

# İÇİNDEKİLER

ÖZET .....	i
ABSTRACT .....	iii
TEŞEKKÜR .....	v
İÇİNDEKİLER.....	vi
TABLolar DİZİNİ.....	ix
ŞEKİLLER DİZİNİ .....	xi
SİMGELER VE KISALTMALAR DİZİNİ .....	xiv
1. GİRİŞ.....	15
1.1. Araştırmanın Amacı.....	17
1.2. Araştırmanın Önemi .....	19
2. KAVRAMSAL ÇERÇEVE.....	20
2.1. Yapay Zeka .....	20
2.2. Yapay Sinir Ağları .....	21
2.3. Yapay Sinir Ağı Katmanları .....	23
2.4. Makine Öğrenmesi.....	24
2.5. Derin Öğrenme .....	26
2.6. Makine Öğrenmesi ve Derin Öğrenme Arasındaki Farklar .....	27
2.7. Derin Öğrenmenin Önemli Katman Mimarileri .....	29
2.7.1. Evrişimsel sinir ağı (convolutional neural network – CNN).....	29
2.7.1.1. CNN mimarisinin temel katmanları .....	30
2.7.1.1.1. Evrişim (convolution) katmanı.....	30
2.7.1.1.2. Havuzlama (pooling) katmanı .....	32
2.7.1.1.3. Tam bağlantı katmanı (fully connected).....	33
2.7.1.2. CNN mimari çeşitleri .....	34
2.7.1.2.1. AlexNet.....	34
2.7.1.2.2. ResNet50 .....	35
2.7.1.2.3. DenseNet121 .....	36
2.7.1.2.4. MobileNetV2.....	36
2.7.1.2.5. EfficientNetB3 .....	37
2.7.1.3. CNN’lerin avantajları .....	37
2.7.1.4. Tarımsal uygulamalarda CNN kullanımı .....	38
2.7.1.5. CNN’in bu çalışmadaki önemi .....	38

2.7.2. Tekrarlayan sinir ađı (recurrent neural network – RNN).....	38
2.7.2.1. RNN mimarisi ve öğrenme mekanizması.....	39
2.7.2.2. Gelişmiş RNN türleri: LSTM ve GRU.....	39
2.7.2.3. RNN uygulama alanları.....	40
2.7.2.4. RNN avantajlar ve sınırlılıkları.....	40
2.8. Literatür Taraması.....	41
3. MATERYAL VE YÖNTEM.....	48
3.1. Veri Seti.....	48
3.1.1. Üzüm çürük yaprak sınıfı.....	48
3.1.2. Üzüm siyah kızamık hastalığı sınıfı.....	49
3.1.3. Üzüm Isaripopsis yaprak lekesi sınıfı.....	50
3.1.4. Sağlıklı üzüm yaprağı sınıfı.....	51
3.2. Kullanılan Yazılımlar ve Çalışma Ortamı.....	52
3.2.1. Python.....	52
3.2.2. Google Colab.....	53
3.3. Veri Ön İşleme.....	54
3.4. Normalizasyon.....	55
3.5. Model Tanımlama.....	56
3.6. Modelin Derlenmesi (Compile).....	57
3.7. Karmaşıklık Matrisi.....	59
3.8. Performans Deđerlendirme Kriterleri.....	59
3.8.1. Doğruluk (accuracy).....	60
3.8.2. Kesinlik / hassasiyet (precision).....	60
3.8.3. Duyarlılık (recall).....	60
3.8.4. Özgünlük (specificity).....	60
3.8.5. F1-skoru (F1-score).....	61
3.9. ROC Eğrisi.....	61
3.10. Kayıp Fonksiyonları (Loss Functions).....	61
3.11. Çoklu Sınıf (Multi-Class) Durumları.....	62
4. BULGULAR.....	63
4.1. CNN Modellerinin 20 Epoch Eğitim Sonuçları.....	63
4.1.1. AlexNet modelinin 20 epoch eğitim sonuçları.....	63
4.1.2. DenseNet121 modelinin 20 epoch eğitim sonuçları.....	68
4.1.3. EffecientNetB3 modelinin 20 epoch eğitim sonuçları.....	72

4.1.4. MobileNetV2 modelinin 20 epoch eğitim sonuçları .....	76
4.1.5. ResNet50 modelinin 20 epoch eğitim sonuçları .....	80
4.1.6. CNN modellerinin 20 epoch eğitim sonuçlarının karşılaştırması .....	84
4.2. CNN Modellerinin 50 Epoch Eğitim Sonuçları.....	86
4.2.1. AlexNet modelinin 50 epoch eğitim sonuçları.....	87
4.2.2. DenseNet121 modelinin 50 epoch eğitim sonuçları .....	91
4.2.3. EfficientNetB3 modelinin 50 epoch eğitim sonuçları.....	95
4.2.4. MobileNetV2 modelinin 50 epoch eğitim sonuçları .....	99
4.2.5. ResNet50 modelinin 50 epoch eğitim sonuçları .....	103
4.2.6. CNN modellerinin 50 epoch eğitim sonuçlarının karşılaştırması .....	107
4.3. CNN Modellerinin 100 Epoch Eğitim Sonuçları.....	110
4.3.1. AlexNet modelinin 100 epoch eğitim sonuçları.....	110
4.3.2. DenseNet121 modelinin 100 epoch eğitim sonuçları .....	115
4.3.3. EfficientNetB3 modelinin 100 epoch eğitim sonuçları.....	119
4.3.4. MobileNetV2 modelinin 100 epoch eğitim sonuçları .....	123
4.3.5. ResNet50 modelinin 100 epoch eğitim sonuçları .....	127
4.3.6. CNN modellerinin 100 epoch eğitim sonuçlarının karşılaştırması .....	131
4.4. CNN Modellerinin 20, 50 ve 100 Epoch Eğitim Sonuçlarının Karşılaştırması.....	134
5. TARTIŞMA.....	140
6. SONUÇ ve ÖNERİLER.....	142
KAYNAKÇA .....	147

## TABLolar DİZİNİ

Tablo 1. CNN katman türleri, temel işlevleri ve örnek parametreler .....	57
Tablo 2. CNN model derleme bileşenleri .....	58
Tablo 3. Karmaşıklık matrisi tablosu .....	59
Tablo 4. AlexNet modelinin 20 epoch eğitimi sonucunda elde edilen sınıflandırma performansı .....	65
Tablo 5. DenseNet121 modelinin 20 epoch eğitimi sonucunda elde edilen sınıflandırma performansı .....	69
Tablo 6. EfficientNetB3 modelinin 20 epoch eğitimi sonucunda elde edilen sınıflandırma performansı .....	73
Tablo 7. MobileNetV2 modelinin 20 epoch eğitimi sonucunda elde edilen sınıflandırma performansı .....	77
Tablo 8. ResNet50 modelinin 20 epoch eğitimi sonucunda elde edilen sınıflandırma performansı .....	81
Tablo 9. CNN modellerinin 20 epoch eğitimine ait doğruluk ve kayıp grafiklerinin karşılaştırması .....	84
Tablo 10. CNN modellerinin 20 epoch eğitimine ait sınıflandırma performansı F1-score metriklerinin karşılaştırması .....	85
Tablo 11. AlexNet modelinin 50 epoch eğitimi sonucunda elde edilen sınıflandırma performansı .....	88
Tablo 12. DenseNet121 modelinin 50 epoch eğitimi sonucunda elde edilen sınıflandırma performansı .....	92
Tablo 13. EfficientNetB3 modelinin 50 epoch eğitimi sonucunda elde edilen sınıflandırma performansı .....	96
Tablo 14. MobileNetV2 modelinin 50 epoch eğitimi sonucunda elde edilen sınıflandırma performansı .....	100
Tablo 15. ResNet50 modelinin 50 epoch eğitimi sonucunda elde edilen sınıflandırma performansı .....	104
Tablo 16. CNN modellerinin 50 epoch eğitimine ait doğruluk ve kayıp grafiklerinin karşılaştırması .....	107
Tablo 17. CNN modellerinin 50 epoch eğitimine ait sınıflandırma performansı F1-score metriklerinin karşılaştırması .....	108

Tablo 18. AlexNet modelinin 100 epoch eğitimi sonucunda elde edilen sınıflandırma performansı.....	111
Tablo 19. DenseNet121 modelinin 100 epoch eğitimi sonucunda elde edilen sınıflandırma performansı.....	116
Tablo 20. EfficientNetB3 modelinin 100 epoch eğitimi sonucunda elde edilen sınıflandırma performansı.....	120
Tablo 21. MobileNetV2 modelinin 100 epoch eğitimi sonucunda elde edilen sınıflandırma performansı.....	124
Tablo 22. ResNet50 modelinin 100 epoch eğitimi sonucunda elde edilen sınıflandırma performansı.....	128
Tablo 23. CNN modellerinin 100 epoch eğitimine ait doğruluk ve kayıp grafiklerinin karşılaştırması.....	131
Tablo 24. CNN modellerinin 100 epoch eğitimine ait sınıflandırma performansı F1-score metriklerinin karşılaştırması.....	132

## ŞEKİLLER DİZİNİ

Şekil 1. Yapay sinir ağı modeli (Kod5, 2025).....	22
Şekil 2. Yapay sinir ağı katmanları (Medium, 2025a) .....	24
Şekil 3. Makine öğrenmesi akış şeması.....	27
Şekil 4. Derin öğrenme akış şeması .....	27
Şekil 5. CNN mimarisinin genel çalışma şeması (Medium, 2025c) .....	30
Şekil 6. Evrişim katmanı (Medium, 2025d) .....	31
Şekil 7. Maksimum havuzlama yöntemi örneği .....	32
Şekil 8. Ortalama havuzlama yöntemi örneği .....	33
Şekil 9. Tam bağlantı katmanı.....	34
Şekil 10. AlexNet mimari yapısı (Medium, 2025e) .....	35
Şekil 11. Üzüm çürük yaprak sınıfına ait örnek görseller .....	49
Şekil 12. Üzüm siyak kızamık hastalığı sınıfına ait örnek görseller .....	50
Şekil 13. Üzüm Isariopsis yaprak lekesi sınıfına ait örnek görseller.....	51
Şekil 14. Sağlıklı üzüm yaprağı sınıfına ait örnek görseller .....	52
Şekil 15. AlexNet modelinin 20 epoch eğitimi sonucunda elde edilen kayıp ve doğruluk grafikleri .....	64
Şekil 16. AlexNet modelinin 20 epoch eğitimi sonucunda elde edilen karmaşıklık matrisi....	66
Şekil 17. AlexNet modelinin 20 epoch eğitimi sonucunda elde edilen ROC eğrisi.....	67
Şekil 18. DenseNet121 modelinin 20 epoch eğitimi sonucunda elde edilen kayıp ve doğruluk grafikleri .....	68
Şekil 19. DenseNet121 modelinin 20 epoch eğitimi sonucunda elde edilen karmaşıklık matrisi .....	70
Şekil 20. DenseNet121 modelinin 20 epoch eğitimi sonucunda elde edilen ROC eğrisi .....	71
Şekil 21. EffecientNetB3 modelinin 20 epoch eğitimi sonucunda elde edilen kayıp ve doğruluk grafikleri.....	72
Şekil 22. EffecienNetB3 modelinin 20 epoch eğitimi sonucunda elde edilen karmaşıklık matrisi .....	74
Şekil 23. EffecienNetB3 modelinin 20 epoch eğitimi sonucunda elde edilen ROC eğrisi .....	75
Şekil 24. MobileNetV2 modelinin 20 epoch eğitimi sonucunda elde edilen kayıp ve doğruluk grafikleri .....	76
Şekil 25. MobileNetV2 modelinin 20 epoch eğitimi sonucunda elde edilen karmaşıklık matrisi .....	78

Şekil 26. MobileNetV2 modelinin 20 epoch eğitimi sonucunda elde edilen ROC eğrisi .....	79
Şekil 27. ResNet50 modelinin 20 epoch eğitimi sonucunda elde edilen kayıp ve doğruluk grafikleri .....	80
Şekil 28. ResNet50 modelinin 20 epoch eğitimi sonucunda elde edilen karmaşıklık matrisi..	82
Şekil 29. ResNet50 modelinin 20 epoch eğitimi sonucunda elde edilen ROC eğrisi .....	83
Şekil 30. AlexNet modelinin 50 epoch eğitimi sonucunda elde edilen kayıp ve doğruluk grafikleri .....	87
Şekil 31. AlexNet modelinin 50 epoch eğitimi sonucunda elde edilen karmaşıklık matrisi....	89
Şekil 32. AlexNet modelinin 50 epoch eğitimi sonucunda elde edilen ROC eğrisi.....	90
Şekil 33. DenseNet121 modelinin 50 epoch eğitimi sonucunda elde edilen kayıp ve doğruluk grafikleri .....	91
Şekil 34. DenseNet121 modelinin 50 epoch eğitimi sonucunda elde edilen karmaşıklık matrisi .....	93
Şekil 35. DenseNet121 modelinin 50 epoch eğitimi sonucunda elde edilen ROC eğrisi .....	94
Şekil 36. EfficientNetB3 modelinin 50 epoch eğitimi sonucunda elde edilen kayıp ve doğruluk grafikleri .....	95
Şekil 37. EfficientNetB3 modelinin 50 epoch eğitimi sonucunda elde edilen karmaşıklık matrisi .....	97
Şekil 38. EfficientNetB3 modelinin 50 epoch eğitimi sonucunda elde edilen ROC eğrisi.....	98
Şekil 39. MobileNetV2 modelinin 50 epoch eğitimi sonucunda elde edilen kayıp ve doğruluk grafikleri .....	99
Şekil 40. MobileNetV2 modelinin 50 epoch eğitimi sonucunda elde edilen karmaşıklık matrisi .....	101
Şekil 41. MobileNetV2 modelinin 50 epoch eğitimi sonucunda elde edilen ROC eğrisi .....	102
Şekil 42. ResNet50 modelinin 50 epoch eğitimi sonucunda elde edilen kayıp ve doğruluk grafikleri .....	103
Şekil 43. ResNet50 modelinin 50 epoch eğitimi sonucunda elde edilen karmaşıklık matrisi	105
Şekil 44. ResNet50 modelinin 50 epoch eğitimi sonucunda elde edilen ROC eğrisi .....	106
Şekil 45. AlexNet modelinin 100 epoch eğitimi sonucunda elde edilen kayıp ve doğruluk grafikleri .....	110
Şekil 46. AlexNet modelinin 100 epoch eğitimi sonucunda elde edilen karmaşıklık matrisi	112
Şekil 47. AlexNet modelinin 100 epoch eğitimi sonucunda elde edilen ROC eğrisi.....	114
Şekil 48. DenseNet121 modelinin 100 epoch eğitimi sonucunda elde edilen kayıp ve doğruluk grafikleri .....	115

Şekil 49. DenseNet121 modelinin 100 epoch eğitimi sonucunda elde edilen karmaşıklık matrisi .....	117
Şekil 50. DenseNet121 modelinin 100 epoch eğitimi sonucunda elde edilen ROC eğrisi ....	118
Şekil 51. EfficientNetB3 modelinin 100 epoch eğitimi sonucunda elde edilen kayıp ve doğruluk grafikleri.....	119
Şekil 52. EfficientNetB3 modelinin 100 epoch eğitimi sonucunda elde edilen karmaşıklık matrisi .....	121
Şekil 53. EfficientNetB3 modelinin 100 epoch eğitimi sonucunda elde edilen ROC eğrisi..	122
Şekil 54. MobileNetV2 modelinin 100 epoch eğitimi sonucunda elde edilen kayıp ve doğruluk grafikleri .....	123
Şekil 55. MobileNetV2 modelinin 100 epoch eğitimi sonucunda elde edilen karmaşıklık matrisi .....	125
Şekil 56. MobileNetV2 modelinin 100 epoch eğitimi sonucunda elde edilen ROC eğrisi....	126
Şekil 57. ResNet50 modelinin 100 epoch eğitimi sonucunda elde edilen kayıp ve doğruluk grafikleri .....	127
Şekil 58. ResNet50 modelinin 100 epoch eğitimi sonucunda elde edilen karmaşıklık matrisi .....	129
Şekil 59. ResNet50 modelinin 100 epoch eğitimi sonucunda elde edilen ROC eğrisi .....	130

## SİMGELER VE KISALTMALAR DİZİNİ

%	Yüzde
Adam	Adaptive Moment Estimation
AlexNet	AlexNet CNN Architecture
AUC	Area Under Curve
CNN	Convolutional Neural Network
DenseNet	Densely Connected Convolutional Network
EfficientNet	Efficient CNN Architecture
ESA	Evrimsel Sinir Ağı
FN	False Negative
FP	False Positive
GRU	Gated Recurrent Unit
KNN	K-Nearest Neighbor
MobileNet	Mobile CNN Architecture
MSE	Mean Squared Error
ReLU	Rectified Linear Unit
ResNet	Residual Neural Network
RF	Random Forest
RNN	Recurrent Neural Network
ROC	Receiver Operating Characteristic
SVM	Support Vector Machine
TN	True Negative
TP	True Positive
YOLO	You Only Look Once
YSA	Yapay Sinir Ağı
YZ	Yapay Zeka

## 1. GİRİŞ

Tarım, insanlık tarihinin en köklü dönüşümlerinden birini temsil etmekte olup, yalnızca besin üretiminde bir değişim değil, aynı zamanda toplumsal, ekonomik ve kültürel yapının yeniden şekillenmesini sağlayan bir devrim niteliği taşımaktadır. İnsanlık tarihinin erken dönemleri incelendiğinde, ilk insan topluluklarının yaşamlarını büyük ölçüde avcılık ve toplayıcılık faaliyetlerine dayandırdığı görülmektedir. Bu yaşam biçimi, doğrudan çevresel koşullara ve mevcut doğal kaynaklara bağımlı olmayı gerektirmiş; bu nedenle bireyler ve topluluklar, besin kaynaklarını takip edebilmek amacıyla sürekli hareket hâlinde olmak zorunda kalmıştır (Harari, 2015).

Tarım, yalnızca insanların beslenme biçimini değiştiren bir faaliyet değil; düşünsel gelişimi, teknolojik ilerlemeyi ve toplumsal örgütlenmeyi derinden etkileyen çok boyutlu bir dönüşüm süreci olarak değerlendirilmelidir. Tarım sayesinde insanlık, doğaya bağımlı bir yaşam biçiminden, doğayı dönüştüren ve yöneten bir konuma geçmiştir. Bu yönüyle tarım, insanın üretkenliğini artıran, düşünme kapasitesini geliştiren ve modern uygarlıkların temelini oluşturan en önemli tarihsel kırılma noktalarından biri olarak kabul edilmektedir.

Tarım kavramsal olarak; toprağın işlenmesi, tohum ve fidanların kullanılması, bitkisel ve hayvansal üretimin gerçekleştirilmesi ve bu üretim sonucunda elde edilen ham ürünlerin işlenerek daha yüksek katma değerli mamullere dönüştürülmesi sürecini ifade etmektedir. Bu bağlamda tarım, yalnızca birincil üretim faaliyetleriyle sınırlı olmayıp, aynı zamanda işleme, depolama ve pazarlama aşamalarını da kapsayan çok yönlü bir ekonomik faaliyet alanıdır (Tokatlıoğlu vd., 2018). Tarımsal faaliyetlerin bu çok boyutlu yapısı, kırsal kalkınma, gıda güvenliği ve ekonomik sürdürülebilirlik açısından stratejik bir öneme sahip olduğunu göstermektedir.

Üzüm, özellikle eski çağlardan itibaren şarap ve sirke üretiminde yaygın biçimde kullanılmış; bu ürünler birçok uygarlıkta ekonomik, kültürel ve dinsel anlamlar taşımıştır. Anadolu coğrafyasında bağcılığın önemli bir yere sahip olduğu, özellikle Hititler döneminde üzüm ve bağcılıkla ilgili gelişmiş uygulamaların bulunduğu bilinmektedir. Hititlerin bağların korunmasına yönelik özel yasal düzenlemelere sahip olmaları, bağcılığın bu dönemde yalnızca bir tarımsal faaliyet değil, aynı zamanda ekonomik ve stratejik bir değer olarak görüldüğünü göstermektedir (Sağlam ve Sağlam, 2018).

Anadolu’da İslamiyet’in yayılmasıyla birlikte şarap üretimi önemini büyük ölçüde yitirmiş olsa da üzüm tarımı varlığını sürdürmüş ve sirke, pekmez ile kuru üzüm gibi farklı ürünlerin üretiminde kullanılmaya devam etmiştir. Bu durum, üzümün farklı kültürel ve dini bağlamlara uyum sağlayabilen çok yönlü bir tarım ürünü olduğunu göstermektedir. Günümüzde üzüm, hem taze tüketim hem de işlenmiş ürünlere dönüştürülme açısından tarım ve gıda sektöründe önemli bir yere sahiptir. Anadolu’da bağcılığın yoğun olarak yapıldığı bölgelerden biri olan Erzincan ili, özellikle Üzümlü ilçesi ile dikkat çekmektedir. Tarihsel olarak “Cimin” adıyla anılan bu ilçe, bağcılık faaliyetlerinin yaygınlığı ve yüksek üretim kapasitesi ile öne çıkmaktadır. Bölgede yetiştirilen üzümler, yalnızca tarımsal üretim açısından değil, aynı zamanda yerel halkın ekonomik sürdürülebilirliği ve kırsal kalkınma açısından da büyük önem taşımaktadır.

Tarımsal üretimin sürdürülebilirliği, ekimden hasada kadar olan tüm süreçlerin bilinçli ve planlı bir şekilde yürütülmesine bağlıdır. İklim koşulları, sulama, yetiştirme dönemi ve bakım uygulamaları, ürün verimi ve kalitesi üzerinde belirleyici rol oynamaktadır. Bu süreçte karşılaşılan en önemli sorunlardan biri bitki hastalıkları ve zararlılardır. Mantar, bakteri ve virüs kaynaklı hastalıklar ile çevresel faktörler, özellikle bağcılıkta ciddi verim kayıplarına yol açabilmektedir. Üzüm bitkisi her ne kadar bazı çevresel koşullara dayanıklı olsa da mantar ve pas hastalıklarına karşı hassasiyet göstermektedir. Bu nedenle hastalıkların erken teşhisi kritik bir öneme sahiptir. Yapraklarda meydana gelen renk değişimleri, lekelenmeler ve deformasyonlar gibi belirtilerin düzenli olarak izlenmesi, hastalıkların erken dönemde tespit edilmesini sağlayarak müdahale sürecini kolaylaştırmakta, ürün kaybını azaltmakta ve tarımsal üretimin sürdürülebilirliğine önemli katkılar sunmaktadır.

Erken teşhis, üzüm hastalıklarıyla mücadelede en kritik unsurlardan biri olarak öne çıkmaktadır. Hastalık belirtilerinin başlangıç aşamasında tespit edilmesi, kimyasal ve biyolojik mücadele yöntemlerinin daha etkin ve ekonomik bir şekilde uygulanmasına olanak tanımaktadır. Özellikle yaprak yüzeylerinde ortaya çıkan renk değişimleri, lekeler ve doku bozulmaları, hastalıkların erken evrede belirlenmesinde önemli göstergeler arasında yer almaktadır. Bu nedenle üzüm bağlarında düzenli gözlem ve izleme faaliyetlerinin yürütülmesi, sürdürülebilir tarımsal üretim açısından büyük önem taşımaktadır.

Günümüz, teknolojik gelişmelerin hız kazandığı ve bu gelişmelerin tarım sektörüne doğrudan entegre edildiği bir dönem olarak değerlendirilmektedir. Teknolojinin ilerlemesiyle birlikte

tarımsal üretimde verimlilik artmış, üretim süreçleri daha sistematik ve kontrollü hâle gelmiştir. Özellikle tarım makinelerinin yaygın olarak kullanılması, üretim kapasitesini artırırken insan gücüne duyulan ihtiyacı önemli ölçüde azaltmıştır. Bu durum hem üretim maliyetlerinin düşmesine hem de daha geniş alanlarda tarımsal faaliyetlerin yürütülmesine olanak sağlamıştır.

Son yıllarda yapay zekâ teknolojilerinin tarım sektöründe kullanılmaya başlanması, tarımsal üretimde yeni bir dönemin kapılarını aralamıştır. Yapay zekâ tabanlı sistemler, hastalıkların hızlı ve doğru bir şekilde tespit edilmesine, üretim süreçlerinin optimize edilmesine ve karar destek mekanizmalarının güçlendirilmesine olanak tanımaktadır. Bu süreçte görüntü işleme ve derin öğrenme yöntemleri önemli bir rol oynamaktadır. Özellikle bitki yapraklarının görüntülerinin analiz edilmesi yoluyla hastalığa özgü belirtiler tespit edilmekte; derin öğrenme tabanlı modeller sayesinde bu belirtiler sınıflandırılarak hastalık teşhisi gerçekleştirilmektedir. Bu yaklaşımlar, geleneksel yöntemlere kıyasla daha hızlı, nesnel ve yüksek doğruluk oranına sahip teşhis imkânları sunarak tarımsal üretimin sürdürülebilirliğine önemli katkılar sağlamaktadır.

Bu çalışmada, üzüm yapraklarında görülen hastalıkların erken ve doğru bir şekilde tespit edilmesi amacıyla derin öğrenme tabanlı convolutional neural network (CNN) mimarileri kullanılmıştır. Bu kapsamda, üzüm yaprağı görüntülerinden elde edilen veriler üzerinden AlexNet, DenseNet121, EfficientNetB3, MobileNetV2 ve ResNet50 modelleri ile sınıflandırma işlemleri gerçekleştirilmiş ve modellerin performansları doğruluk, kesinlik, duyarlılık, F1-skor, karmaşıklık matrisi ve ROC eğrileri gibi farklı değerlendirme ölçütleri kullanılarak karşılaştırmalı olarak analiz edilmiştir. Elde edilen sonuçlar doğrultusunda, üzüm hastalıklarının erken teşhisinde en yüksek performansı gösteren modelin belirlenmesi hedeflenmiş olup, bu çalışma ile yapay zekâ destekli sistemlerin tarım sektöründe etkin kullanımına katkı sağlanması ve gelecekte geliştirilebilecek gerçek zamanlı hastalık tespit uygulamalarına temel oluşturulması amaçlanmıştır.

### **1.1. Araştırmanın Amacı**

Tarım, toplumların ekonomik sürdürülebilirliği ve gıda güvenliğinin sağlanması açısından stratejik öneme sahip temel sektörlerden biridir. Tarımsal üretimde verimliliğin korunması, yalnızca üretim miktarının artırılmasıyla değil, aynı zamanda bitkilerin sağlıklı bir şekilde yetiştirilmesi ve hastalıklara karşı korunmasıyla mümkündür. Sulama, gübreleme ve ilaçlama

gibi tarımsal uygulamaların zamanında ve doğru şekilde gerçekleştirilmemesi, bitkilerde stres faktörlerini artırarak hastalık oranlarının yükselmesine neden olmaktadır. Bu durum hem ürün kalitesini hem de verimliliği olumsuz yönde etkilemektedir (Ferentinos, 2018). Bu nedenle, bitki hastalıklarının erken dönemde tespit edilmesi, tarımsal kayıpların önlenmesi açısından büyük önem taşımaktadır.

Bu çalışmanın temel amacı, üzüm bitkisinin yapraklarında görülen hastalıkların derin öğrenme tabanlı yöntemler kullanılarak otomatik biçimde tespit edilmesi ve sınıflandırılmasıdır. Son yıllarda görüntü işleme ve yapay zekâ alanlarında yaşanan hızlı gelişmeler, tarım sektöründe de akıllı ve otomatik karar destek sistemlerinin yaygınlaşmasına olanak sağlamıştır. Özellikle CNN tabanlı modeller, görsel verilerden ayırt edici özneliklerin otomatik olarak çıkarılması konusunda sundukları yüksek doğruluk oranları sayesinde bitki hastalıklarının belirlenmesinde yaygın olarak kullanılmaktadır (Mohanty vd., 2016; Ferentinos, 2018). Bu bağlamda, üzüm yaprağı görüntülerinden hastalıkların erken evrede tespit edilmesi, hastalık türlerinin doğru bir biçimde sınıflandırılması ve tarımsal üretimde verim kayıplarının azaltılması hedeflenmiştir.

Bu çalışmada kullanılan yaklaşım, yalnızca üzüm bitkisiyle sınırlı kalmayıp, uygun veri setlerinin sağlanması durumunda farklı bitki türlerine ait yaprak hastalıklarının tespiti ve sınıflandırılması için de uyarlanabilir niteliktedir. Literatürde, CNN tabanlı derin öğrenme modellerinin farklı bitki türleri üzerinde başarılı sonuçlar verdiği ve geleneksel görüntü işleme yöntemlerine kıyasla daha yüksek genelleme yeteneği sergilediği çeşitli çalışmalarla ortaya konmuştur (Sladojevic vd., 2016; Barbedo, 2019). Bu yönüyle kullanılan yöntem ile tarım alanında akıllı izleme ve erken uyarı sistemlerinin geliştirilmesine katkı sağlamayı amaçlamaktadır.

Gelişen teknoloji ile birlikte, bitki hastalıklarının tespitinde insan gözlemine dayalı yöntemlerin yerini, otomatik ve veri temelli yaklaşımlar almaya başlamıştır. Görsel tabanlı derin öğrenme modelleri, yaprak yüzeyinde oluşan renk değişimleri, lekeler ve doku bozulmaları gibi hastalık belirtilerini yüksek doğrulukla ayırt edebilmektedir (Mohanty vd., 2016). Bu çalışma kapsamında, üzüm bitkisine ait yaprak görüntüleri kullanılarak CNN tabanlı modellerin, hastalıkları erken aşamada tespit etmesi ve hastalık türünü doğru bir şekilde sınıflandırması amaçlanmıştır.

## 1.2. Araştırmanın Önemi

Bu çalışmada, görüntü tabanlı sınıflandırma problemlerinde yaygın olarak kullanılan CNN mimarileri tercih edilmiştir. Çalışma kapsamında AlexNet, DenseNet121, EfficientNetB3, MobileNetV2 ve ResNet50 modelleri kullanılarak üzüm yapraklarında görülen hastalıkların tespiti ve sınıflandırılması gerçekleştirilmiştir. Seçilen bu mimariler, derinlik, parametre sayısı ve mimari yapı bakımından birbirinden farklı özellikler taşımakta olup, bu çeşitlilik sayesinde modellerin sınıflandırma performansları kapsamlı bir şekilde karşılaştırılabilmiştir.

Çalışmada kullanılacak veri seti, sağlıklı ve hastalıklı üzüm yaprağı görüntülerinden oluşan geniş kapsamlı bir görüntü koleksiyonunu içermektedir. Veri seti içerisinde farklı üzüm yaprağı çeşitlerine ait örnekler, çeşitli hastalık türleri, farklı yaprak dokuları ve farklı açılardan çekilmiş yaprak görüntüleri yer almaktadır. Bu çeşitlilik, derin öğrenme modellerinin genelleme yeteneğini artırmak ve gerçek tarımsal koşullara daha yakın sonuçlar elde etmek amacıyla tercih edilmiştir. Literatürde, farklı ışık, açı ve yaprak çeşitliliği içeren veri setlerinin, model performansını artırmada önemli bir rol oynadığı belirtilmektedir (Mohanty vd., 2016; Ferentinos, 2018).

Üzüm yaprağı hastalıklarının tespit edilmesi amacıyla, her bir CNN mimarisi aynı veri seti üzerinde eğitilmiş ve test edilmiştir. Eğitim sürecinin ardından, modellerin hastalık tespiti ve sınıflandırmadaki başarı düzeyleri karşılaştırmalı olarak analiz edilmiştir. Bu değerlendirme sürecinde doğruluk (accuracy), kesinlik (precision), duyarlılık (recall) ve F1-skoru (F1-score) gibi yaygın olarak kullanılan performans ölçütleri dikkate alınmıştır. Önceki çalışmalarda, bu metriklerin sınıflandırma problemlerinde model başarısını nesnel bir biçimde ortaya koyduğu vurgulanmaktadır (Barbedo, 2019).

Farklı CNN mimarilerinin karşılaştırılması sayesinde, üzüm yaprağı hastalıklarının tespitinde hangi modelin daha yüksek doğruluk ve kararlılık sunduğu belirlenerek tarımsal uygulamalar için en uygun derin öğrenme yaklaşımı ortaya konulmuştur. Böylece, kullanılan modellerin gerçek dünya tarım uygulamalarında kullanılabilirliği değerlendirilerek gelecekte yapılacak benzer çalışmalara yol gösterici nitelikte sonuçlar elde edilmiştir.

## 2. KAVRAMSAL ÇERÇEVE

### 2.1. Yapay Zeka

Yapay zekâ, genellikle insan zekâsı ve bilişsel süreçleri gerektiren algılama, öğrenme, akıl yürütme, problem çözme ve karar verme gibi işlemlerin, bir makine veya bilgisayar sistemi tarafından yerine getirilmesini amaçlayan disiplinler arası bir araştırma alanı olarak tanımlanmaktadır. Bu kavram, bilgisayarların insan benzeri düşünme ve davranış yetenekleri sergilemesini sağlamak üzere geliştirilen algoritmalar, modeller ve yöntemleri kapsamaktadır. Yapay zekâ terimi ilk kez resmî olarak 1956 yılında, Amerika Birleşik Devletleri'nde New Hampshire eyaletinde bulunan Dartmouth College'da düzenlenen Dartmouth Yaz Araştırma Konferansı sırasında ortaya atılmış ve bu konferans, yapay zekânın bağımsız bir bilimsel alan olarak kabul edilmesinde dönüm noktası olmuştur (Lewis, 2014). Bu tarihten itibaren yapay zekâ, teorik temellerinin yanı sıra uygulama alanlarını da hızla genişleterek günümüzde sağlık, tarım, finans, savunma ve görüntü işleme gibi birçok alanda etkin biçimde kullanılmaya başlanmıştır.

Yapay zekânın tarihsel gelişimi, insanlığın düşünme, öğrenme ve karar verme gibi bilişsel süreçleri anlama ve bu süreçleri taklit edebilen yapay sistemler geliştirme arzusuna dayanmaktadır. İnsanlık tarihinin en erken dönemlerinden itibaren beynin nasıl çalıştığına yönelik duyulan merak, insan benzeri davranışlar sergileyebilen araçlar ve makineler geliştirme çabalarını beraberinde getirmiştir. Ateşin keşfi, tarımsal üretimin başlaması ve mekanik sistemlerin icadıyla hız kazanan teknolojik ilerlemenin temelinde, insan gücünü destekleyen ve insan benzeri işlevleri yerine getirebilen sistemler oluşturma isteğinin bulunduğu ifade edilmektedir (Öztemel, 2020). Bu bağlamda, otomasyon ve mekanik düzenekler alanında gerçekleştirdiği yenilikçi çalışmalarla bilinen ve yapay zekânın tarihsel temellerini atan öncü isimlerden biri olarak kabul edilen El-Cezeri (1136–1206), geliştirdiği su saatleri, otomatik çalışan makineler ve kontrol mekanizmaları ile insan müdahalesi olmadan işlev görebilen sistemlerin ilk örneklerini sunmuştur. Benzer şekilde, Rönesans döneminin önde gelen sanatçılarından Leonardo da Vinci'nin (1452–1519) insan anatomisi ve mekanik yapıların birleşimini ele alan çizimleri, insan-makine etkileşimine yönelik erken düşünsel yaklaşımlar olarak değerlendirilmektedir. Modern anlamda yapay zekâ kavramı ise İkinci Dünya Savaşı sonrasında, matematik, mantık ve bilgisayar bilimlerindeki gelişmelerin etkisiyle daha sistematik bir biçimde ele alınmaya başlanmış; özellikle bilgisayar teknolojilerinin ortaya çıkışı

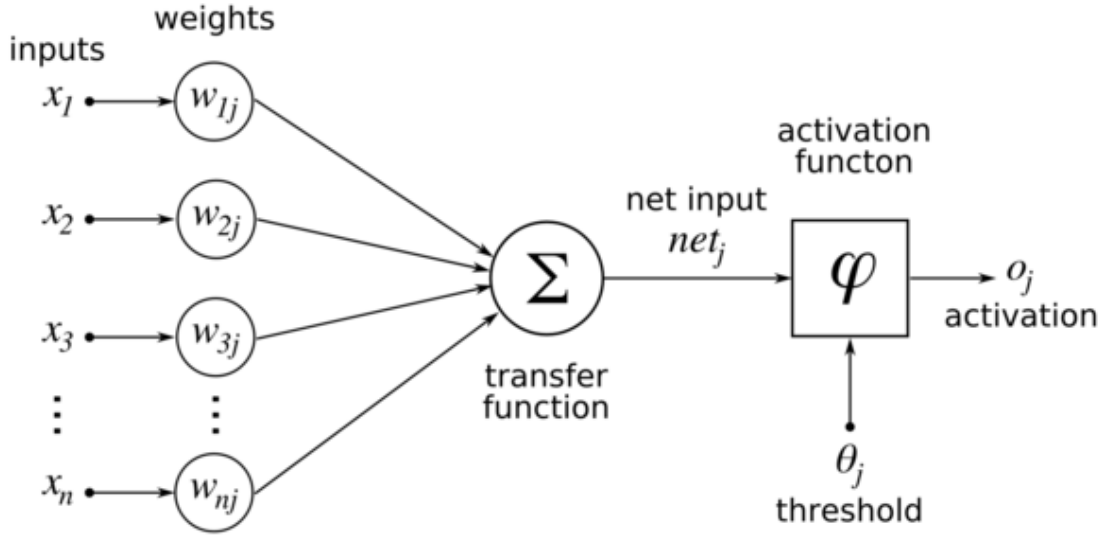
ve yaygınlaşmasıyla birlikte teorik ve uygulamalı bir araştırma alanı olarak önemli bir ivme kazanmıştır. Bu süreçte yapay zekâ, yalnızca felsefi bir düşünce olmaktan çıkarak, hesaplama temelli yöntemler ve algoritmalar aracılığıyla gerçek dünya problemlerine çözüm üreten disiplinler arası bir alan hâline gelmiştir (Coşkun ve Gülleroğlu, 2021).

Yapay zekâ, bir bilgisayarın veya bilgisayar destekli bir makinenin, insan zekâsını taklit ederek problem çözme, çözüm üretme sürecinde içinde bulunduğu durumu algılama, öğrenme ve deneyim kazanma yeteneklerini gerçekleştirmesini ifade eden bir kavram olarak tanımlanmaktadır (Nabiyev, 2012). Bu yaklaşım, yalnızca önceden tanımlanmış kurallara dayalı işlem yapmayı değil, aynı zamanda elde edilen verilerden çıkarım yapabilen ve zamanla performansını artırabilen sistemlerin geliştirilmesini de kapsamaktadır. Günümüzde yapay zekâ, teknolojik gelişmelerin etkisiyle günlük yaşamın vazgeçilmez bir parçası hâline gelmiş; akıllı telefonlardan ev otomasyon sistemlerine, sağlık uygulamalarından tarım ve endüstriyel üretim süreçlerine kadar pek çok alanda etkin bir şekilde kullanılmaya başlanmıştır. Farklı cihaz ve sistemlerde yapay zekâ teknolojilerinin kullanılması, işlemlerin daha hızlı ve kolay bir biçimde gerçekleştirilmesini sağlarken, aynı zamanda elde edilen sonuçların doğruluğunu ve verimliliğini artırmaktadır (İşler ve Kılıç, 2021).

## **2.2. Yapay Sinir Ağları**

Yapay sinir ağları (YSA), insan beyninin bilgi işleme, öğrenme ve karar verme mekanizmalarından esinlenilerek geliştirilen ve verilerden öğrenme yeteneğine sahip bilgisayar tabanlı modeller olarak tanımlanmaktadır. Bu modeller, insan benzeri bir şekilde öğrenme, keşfetme, analiz etme ve elde edilen verilerden anlamlı sonuçlar üretme amacıyla tasarlanmıştır (Öztürk ve Şahin, 2018). Yapay sinir ağlarının temelinde, biyolojik sinir sisteminin çalışma prensipleri yer almakta olup, insan beynindeki sinir hücrelerinin (nöronların) birbiriyle etkileşimi, yapay ağ yapılarında matematiksel ve hesaplamalı bileşenler aracılığıyla modellenmektedir. Biyolojik sinir sisteminde yer alan nöron, dendrit, hücre gövdesi, akson ve sinaps gibi yapısal bileşenler, yapay sinir ağlarında sırasıyla işlem elemanı (yapay nöron), giriş bağlantıları, toplam (toplama) fonksiyonu, aktivasyon fonksiyonu, eleman çıkışı ve ağırlıklar olarak temsil edilmektedir. Bu yapı içerisinde her bir yapay nöron, kendisine gelen giriş sinyallerini belirli ağırlıklar ile çarparak toplamakta, elde edilen sonucu bir aktivasyon fonksiyonundan geçirerek çıktıyı üretmektedir (Şekil 1). Öğrenme süreci ise, ağın ürettiği çıktı ile hedef çıktı arasındaki hata miktarına bağlı olarak ağırlıkların güncellenmesiyle

gerçekleştirilmektedir. Bu sayede yapay sinir ağı, deneyim yoluyla performansını artırabilen, doğrusal olmayan ilişkileri modelleyebilen ve karmaşık veri yapıları üzerinde etkili çözümler sunabilen sistemler hâline gelmektedir (Öztürk ve Şahin, 2018).



Şekil 1. Yapay sinir ağı modeli (Kod5, 2025)

Yapay sinir ağı arasında en yaygın olarak kullanılan modellerden biri, çok katmanlı algılayıcı (multi-layer perceptron – MLP) yapısıdır. MLP modeli, temel olarak girdi katmanını, bir veya daha fazla ara (gizli) katman ve çıktı katmanından oluşan katmanlı bir mimariye sahiptir. Girdi katmanını, dış ortamdan alınan verilerin ağına aktarılmasını sağlarken; gizli katmanlar, bu verilerden anlamlı özniteliklerin çıkarıldığı ve doğrusal olmayan ilişkilerin öğrenildiği temel hesaplama katmanlarıdır. Çıktı katmanını ise problemin türüne bağlı olarak sınıflandırma veya tahmin sonuçlarını üretmektedir. MLP modelinin eğitimi sırasında genellikle geri yayılım (backpropagation) temelli bir öğrenme algoritması kullanılmakta olup, bu algoritma ağına ürettiği çıktı ile gerçek hedef değerler arasındaki farktan kaynaklanan hata değerini temel almaktadır. Eğitim sürecinde amaç, hata fonksiyonunu —çoğunlukla hata kareler ortalaması (mean squared error – MSE) — minimum seviyeye indirmek ve bu doğrultuda ağıdaki ağırlık değerlerini ( $w$ ) yinelemeli olarak güncellemektir. Bu süreç sayesinde MLP modeli, veriler arasındaki karmaşık ilişkileri öğrenebilmekte ve farklı problem türlerinde yüksek doğruluklu sonuçlar üretebilmektedir (Kaynar vd., 2017).

$$y_i = f\left(\sum_{j=1}^n x_j \cdot w_{ji}\right) \quad (1)$$

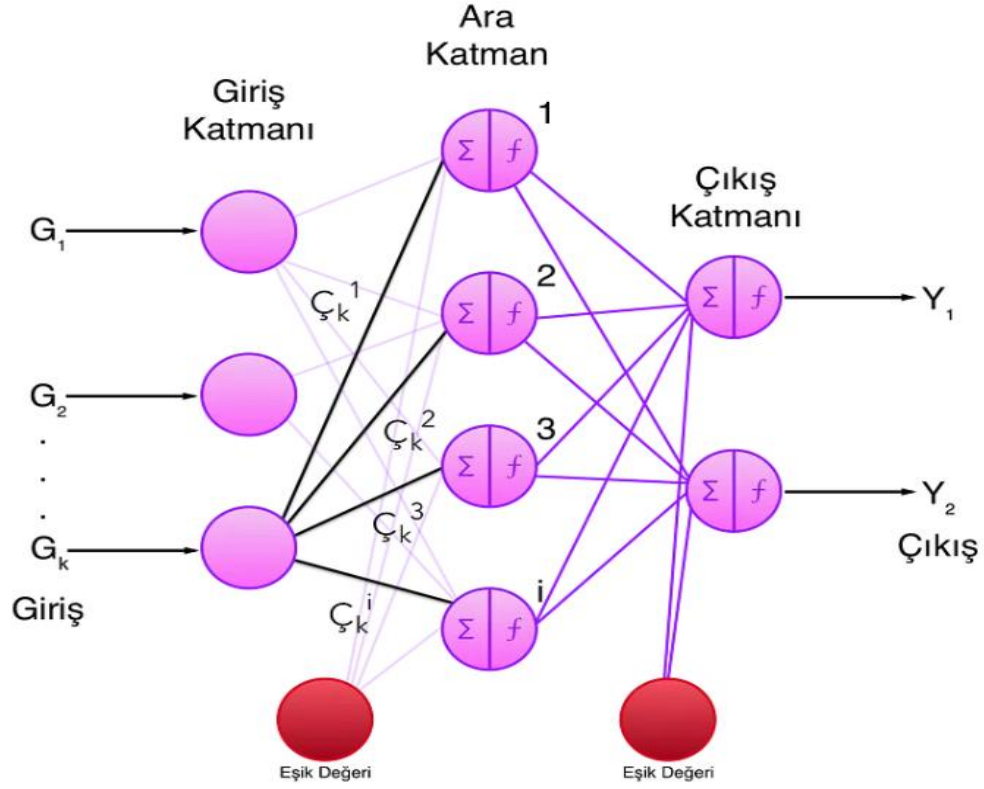
$$E(w) = \frac{1}{2} \sum_{k \in \text{outputs}} (t_k - O_k) \quad (2)$$

Denklem 1 ile ileri besleme, Denklem 2 ile geri besleme formüle edilmektedir. Denklem 1’de bulunan  $x_j$ , mevcut bulunan katmandaki j. nöronun değerini gösterir. Formül sonucu bulunan  $y_i$ , bir sonraki katmandaki nörona aktarılan değeri gösterir. Formülde bulunan n ise mevcut katmandaki nöron sayısını belirtir. Denklem 2’de bulunan k, veri seti sayısını;  $t_k$ , verilerin gerçek sınıfını ve  $O_k$ , üretilen sınıf değerini gösterir (Kaynar vd., 2017).

### 2.3. Yapay Sinir Ağı Katmanları

Yapay sinir ağları, mimari yapılarına bağlı olarak genel olarak Şekil 2’deki gibi giriş katmanı, gizli (ara) katmanlar ve çıkış katmanı olmak üzere üç temel katmandan oluşmaktadır.

- **Giriş katmanı**, dış ortamdan elde edilen verilerin ağa aktarıldığı ilk katman olup, bu katmanda herhangi bir hesaplama veya veri işleme işlemi gerçekleştirilmemektedir. Giriş katmanında yer alan nöron sayısı, problemin sahip olduğu öznitelik sayısına bağlı olarak belirlenmektedir. Giriş katmanından alınan veriler, ağın temel öğrenme sürecinin gerçekleştiği gizli (ara) katmanlara iletilmektedir.
- **Gizli katmanlar**, yapay sinir ağının en önemli bileşenlerinden biri olup, ağın öğrenme kapasitesini ve problem çözme yeteneğini doğrudan etkilemektedir. Bu katmanların sayısı ve her bir katmandaki nöron sayısı, problemin karmaşıklığına bağlı olarak değişkenlik gösterebilmekte; bazı basit problemlerde tek bir gizli katman yeterli olurken, daha karmaşık problemlerde birden fazla gizli katman kullanılabilir. Gizli katmanlardaki nöron sayısının artırılması, ağın karmaşık örüntüleri öğrenmesine olanak sağlamakla birlikte, hesaplama maliyetini ve eğitim süresini de artırmaktadır (Kotan, 2025).
- **Çıkış katmanı**, yapay sinir ağının son katmanı olup, giriş katmanından alınarak gizli katmanlarda işlenen bilgilerin nihai çıktıya dönüştürüldüğü bölümdür. Bu katmandaki nöron sayısı, problemin türüne göre belirlenmekte ve sınıflandırma ya da tahmin sonuçları bu katman aracılığıyla dış dünyaya aktarılmaktadır.



Şekil 2. Yapay sinir ağı katmanları (Medium, 2025a)

Girdi ve çıktı katmanlarında yer alacak nöron sayıları, ele alınan problemin yapısına göre belirlenmekte olup, bu sayıların belirlenmesine yönelik kesin bir yöntem bulunmamaktadır. Giriş katmanındaki tüm nöronlar gizli katmanlardaki nöronlara, gizli katmanlardaki nöronlar ise çıkış katmanındaki nöronlara bağlantılı şekilde çalışmakta ve bu katmanlar arasındaki ilişkiler ağı öğrenme sürecini oluşturmaktadır (Öztemel, 2012).

## 2.4. Makine Öğrenmesi

Makine öğrenmesi, bilgisayar sistemlerinin açıkça programlanmadan, verilerden öğrenerek bilgi üretmesini ve bu bilgiler doğrultusunda tahmin veya kararlar vermesini sağlayan, yapay zekânın temel alt disiplinlerinden biri olarak tanımlanmaktadır. Geleneksel programlama yaklaşımında, bir problemin çözümü için gerekli tüm kurallar insan tarafından önceden tanımlanırken, makine öğrenmesinde bu kurallar veriler aracılığıyla sistem tarafından otomatik olarak çıkarılmaktadır. Bu yönüyle makine öğrenmesi, insan zekânının deneyim yoluyla öğrenme ve genelleme yeteneğini modellemeyi amaçlamaktadır (Mitchell, 1997; Eker vd., 2023).

Makine öğrenmesi kavramı ilk kez sistematik olarak 1950’li yıllarda ele alınmış olup, alanın öncülerinden biri olarak kabul edilen Arthur Samuel, makine öğrenmesini “bilgisayarlara açıkça programlanmadan öğrenme yeteneği kazandıran bir araştırma alanı” olarak tanımlamıştır (Samuel, 1959). Samuel’in dama oyunu üzerine yaptığı çalışmalar, bilgisayarların geçmiş deneyimlerden faydalanarak performanslarını artırabileceğini göstermiş ve makine öğrenmesinin teorik temellerinin atılmasında önemli bir rol oynamıştır. Bu dönemi takip eden yıllarda istatistik, olasılık teorisi ve bilgisayar bilimlerindeki gelişmeler, makine öğrenmesinin bağımsız bir bilimsel alan hâline gelmesini sağlamıştır.

Makine öğrenmesinin temelinde, büyük miktardaki verinin analiz edilerek bu verilerden anlamlı örüntülerin çıkarılması yer almaktadır. Bu süreçte, sisteme sunulan veri setleri aracılığıyla modeller eğitilmekte ve elde edilen modeller, daha önce karşılaşmadıkları yeni veriler üzerinde genelleme yapabilme yeteneği kazanmaktadır. Bu yaklaşım, özellikle karmaşık ve doğrusal olmayan problemlerin çözümünde geleneksel algoritmalara kıyasla önemli avantajlar sunmaktadır (Bishop ve Nasrabadi, 2006). Günümüzde makine öğrenmesi; sınıflandırma, regresyon, kümeleme, boyut indirgeme ve anomali tespiti gibi çok çeşitli problem türlerinde etkin bir şekilde kullanılmaktadır.

Makine öğrenmesi yöntemleri genel olarak denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenme olmak üzere üç ana grupta incelenmektedir. Denetimli öğrenmede, modelin eğitimi sırasında giriş verileri ile bu verilere karşılık gelen doğru çıktılar (etiketler) birlikte sunulmakta ve modelin bu eşleşmeler üzerinden öğrenmesi sağlanmaktadır. Sınıflandırma ve regresyon problemleri bu öğrenme türüne örnek olarak verilebilir. Denetimsiz öğrenmede ise veri seti etiketli değildir ve modelin veriler arasındaki gizli yapıları, benzerlikleri veya kümeleri keşfetmesi beklenmektedir. Kümeleme ve ilişki kuralı çıkarımı, denetimsiz öğrenmenin yaygın kullanım alanları arasında yer almaktadır. Pekiştirmeli öğrenmede ise bir ajan, çevre ile etkileşime girerek ödül–ceza mekanizması aracılığıyla en uygun davranışları öğrenmektedir (Russell ve Norvig, 2021).

Makine öğrenmesi algoritmaları arasında karar ağaçları, destek vektör makineleri, k-en yakın komşu algoritması, rastgele ormanlar ve yapay sinir ağları gibi pek çok yöntem bulunmaktadır. Bu algoritmaların her biri, farklı problem türleri ve veri yapıları için çeşitli avantajlar sunmaktadır. Özellikle yapay sinir ağları, çok katmanlı yapıları sayesinde karmaşık veri

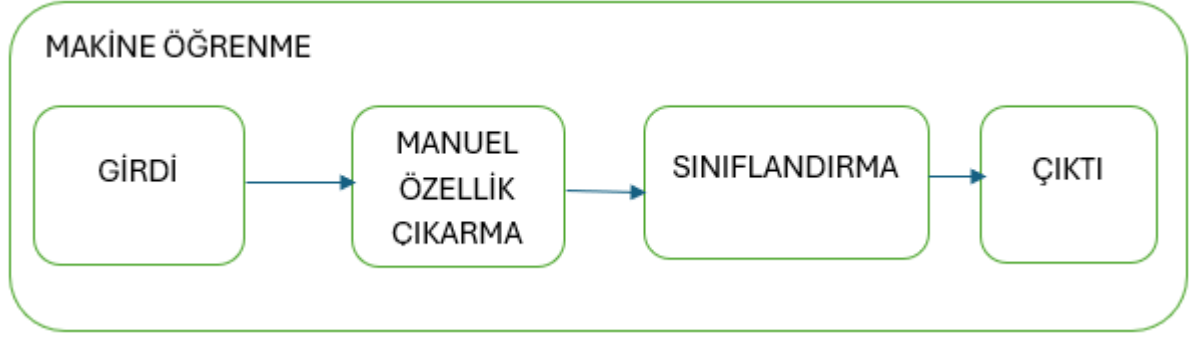
ilişkilerini modelleyebilme yeteneğine sahiptir ve makine öğrenmesi alanında önemli bir yer tutmaktadır (Haykin, 2009).

Makine öğrenmesi, veriye dayalı öğrenme yaklaşımı sayesinde modern yapay zekâ uygulamalarının temelini oluşturan disiplinlerden biri hâline gelmiştir. Gelişen algoritmalar, artan veri miktarı ve donanım olanakları ile birlikte makine öğrenmesinin etki alanı giderek genişlemekte ve birçok farklı disiplinde yenilikçi çözümler sunmaya devam etmektedir.

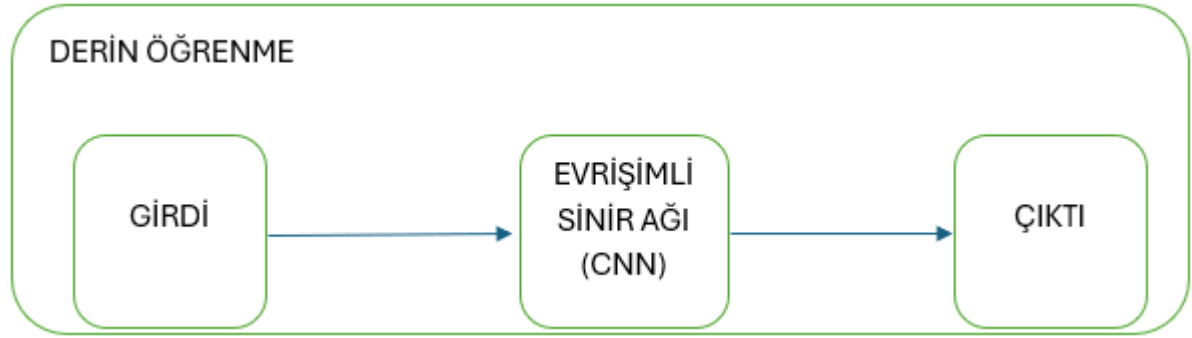
## 2.5. Derin Öğrenme

Derin öğrenme makine öğrenmenin bir yöntemidir. İnsan beyninin çalışma sistemi örnek alınarak tasarlanmış bir makine öğrenme şeklidir. Büyük miktarda veriyi işleyerek yapay zekanın en güçlü ve en hızlı gelişen yapılarından biridir. Elimizde bulunan veri kümesi ve bu veri kümesine ait çıktıları bulacak yapay zekayı eğitmemizi sağlar. Burada da makine öğrenmedeki gibi denetimli ve denetimsiz öğrenme kullanılabilir (Medium, 2025b). Derin öğrenme yapay zeka ve makine ait sistemlerin bir alt kümesi olarak nitelendirilmiştir. Aynı yapay zeka ve makine öğrenmesindeki gibi insan müdahalesi yoktur. İnsan müdahalesi olmadan kendisi anlamlı sonuçlar üretir. Öğrenme aşamasında derin kavramı vardır. Bunun ifade edilmesinin nedeni makine öğrenmenin bir alt kolu olmasına rağmen büyük veriler üzerinde daha başarılı sonuçlar vermesidir (Ateş, 2021). Derin öğrenme, görüntü işleme, konuşma tanıma ve anlamlandırılmasında veri analizi yaparak öğrenen ve karar vererek sonuç çıkaran bir yapay sinir ağı simülatörüdür (Chowdhary, 2020). Derin öğrenmede diğer geleneksel yöntemlere göre hiyerarşik bir yapı vardır. Bu öğrenme yönteminde öznitelikleri otomatik olarak oluşması için denetimli ve denetimsiz öğrenme teknikleri de kullanılır (Yu ve Deng, 2010).

Makine öğrenmesi ve derin öğrenme arasında hem veri işleyişi hem de veri çıktısı açısından Şekil 3 ve Şekil 4'teki akış şemalarında görüldüğü gibi bazı farklılıklar vardır. Makine öğrenmesi genel olarak istatistiksel metotlar kullanırken, derin öğrenme daha çok sinir ağları ile hesaplama işlemleri yapar. Makine öğrenmesinde öznitelik çıkarımları manuel olurken, derin öğrenmede öznitelik çıkarımları otomatik olur (Goodfellow vd., 2016).



Şekil 3. Makine öğrenmesi akış şeması



Şekil 4. Derin öğrenme akış şeması

## 2.6. Makine Öğrenmesi ve Derin Öğrenme Arasındaki Farklar

Makine öğrenmesi ve derin öğrenme, yapay zekâ alanı içerisinde birbiriyle ilişkili ancak yöntemsel ve yapısal açıdan farklı yaklaşımlar sunan iki temel disiplindir. Makine öğrenmesi, bilgisayarların açıkça programlanmadan, verilerden öğrenmesini ve bu öğrenme süreci sonucunda tahmin veya kararlar üretebilmesini sağlayan yöntemler bütünü olarak tanımlanmaktadır (Mitchell, 1997). Derin öğrenme ise, makine öğrenmesinin bir alt alanı olup, çok katmanlı yapay sinir ağları kullanarak verilerden otomatik olarak öznelik çıkarımı gerçekleştirebilen gelişmiş bir öğrenme yaklaşımıdır (LeCun vd., 2015).

Makine öğrenmesi yöntemlerinde, modelin başarısı büyük ölçüde özellik çıkarımı (feature extraction) aşamasına bağlıdır. Bu süreçte, ham verilerden anlamlı özneliklerin çıkarılması genellikle insan uzmanlar tarafından gerçekleştirilmekte ve bu öznelikler modele girdi olarak sunulmaktadır. Buna karşılık, derin öğrenme yaklaşımlarında öznelik çıkarımı süreci otomatik olarak ağı katmanları içerisinde öğrenilmekte, böylece insan müdahalesine duyulan ihtiyaç önemli ölçüde azalmaktadır (Goodfellow vd., 2016). Bu durum, özellikle görüntü, ses ve metin

gibi yüksek boyutlu ve karmaşık verilerin analizinde derin öğrenmeyi daha avantajlı hâle getirmektedir.

Algoritmik yapı açısından değerlendirildiğinde, makine öğrenmesi kapsamında karar ağaçları, destek vektör makineleri, k-en yakın komşu algoritması, naive bayes ve rastgele ormanlar gibi yöntemler yaygın olarak kullanılmaktadır. Derin öğrenme ise, çok katmanlı YSA, CNN, tekrarlayan sinir ağları (RNN) ve uzun kısa süreli bellek (LSTM) gibi derin ağ mimarilerine dayanmaktadır (Haykin, 2009). Derin öğrenme modelleri, sahip oldukları çok katmanlı yapı sayesinde doğrusal olmayan ve karmaşık veri ilişkilerini daha etkili bir şekilde öğrenebilmektedir.

Veri gereksinimi bakımından makine öğrenmesi yöntemleri, genellikle sınırlı veri setleri ile kabul edilebilir performanslar sunabilmektedir. Buna karşılık, derin öğrenme modelleri yüksek sayıda parametre içermeleri nedeniyle büyük veri setlerine ihtiyaç duymaktadır. Ancak yeterli veri ve hesaplama gücü sağlandığında, derin öğrenme modelleri geleneksel makine öğrenmesi yöntemlerine kıyasla daha yüksek doğruluk ve genelleme başarısı elde edebilmektedir (LeCun vd., 2015).

Hesaplama maliyeti açısından değerlendirildiğinde, makine öğrenmesi yöntemleri genellikle daha düşük hesaplama gücü gerektirirken, derin öğrenme modellerinin eğitimi yüksek işlem gücü ve çoğu zaman GPU veya TPU gibi özel donanımlara ihtiyaç duymaktadır. Buna rağmen, derin öğrenmenin sunduğu otomatik öğrenme ve yüksek doğruluk avantajları, bu maliyeti birçok uygulama alanında kabul edilebilir hâle getirmektedir (Goodfellow et al., 2016).

Uygulama alanları bakımından, makine öğrenmesi finansal tahminler, risk analizi, müşteri segmentasyonu ve anomali tespiti gibi yapılandırılmış veri problemlerinde sıklıkla tercih edilmektedir. Derin öğrenme ise özellikle görüntü işleme, doğal dil işleme, konuşma tanıma ve otonom sistemler gibi karmaşık ve yüksek boyutlu verilerin analizinde öne çıkmaktadır. Ayrıca tarımsal uygulamalarda bitki hastalıklarının görüntü tabanlı tespiti gibi problemlerde de derin öğrenme tabanlı yaklaşımların daha başarılı sonuçlar sunduğu literatürde vurgulanmaktadır (Ferentinos, 2018). Makine öğrenmesi ve derin öğrenme birbirinin alternatifi değil, aksine farklı problem türlerine yönelik tamamlayıcı yaklaşımlar olarak değerlendirilmelidir. Veri miktarı, problem karmaşıklığı ve hesaplama kaynakları göz önünde bulundurularak uygun yöntemin seçilmesi, model başarısını doğrudan etkileyen temel faktörlerden biridir.

## 2.7. Derin Öğrenmenin Önemli Katman Mimarileri


Derin öğrenme problem türlerine ve çözümlerine göre farklı katman türleri ve mimari yapıları kullanır. Yaygın olarak kullanılanlar; evrişimsel sinir ağları (convolutional neural networks – CNN) ve tekrarlayan sinir ağları (Recurrent Neural Networks – RNN) mimarileridir.

### 2.7.1. Evrişimsel sinir ağı (convolutional neural network – CNN)

Evrişimsel sinir ağları (convolutional neural networks – CNN), özellikle görüntü işleme, nesne tanıma ve sınıflandırma problemlerinde yüksek başarı sağlayan, derin öğrenme tabanlı yapay sinir ağı mimarileridir. CNN'ler, klasik çok katmanlı yapay sinir ağlarından farklı olarak, görüntü verilerinin uzamsal (spatial) yapısını koruyarak öğrenme gerçekleştirmekte ve bu sayede görsel özniteliklerin otomatik olarak çıkarılmasını sağlamaktadır (LeCun vd., 2015). Bu özellikleri nedeniyle CNN mimarileri, günümüzde tıbbi görüntü analizi, yüz tanıma, otonom araçlar ve tarımsal hastalık tespiti gibi birçok alanda yaygın olarak kullanılmaktadır.

CNN mimarilerinin temel amacı, görüntülerde yer alan kenar, köşe, doku ve şekil gibi düşük ve yüksek seviyeli özellikleri, katmanlar aracılığıyla hiyerarşik bir biçimde öğrenmektir. Geleneksel makine öğrenmesi yöntemlerinde bu tür özelliklerin manuel olarak çıkarılması gerekirken, CNN'lerde bu süreç tamamen ağ tarafından otomatik olarak gerçekleştirilmektedir (Goodfellow vd., 2016). Bu durum, özellikle büyük ve karmaşık veri setleri üzerinde çalışan sistemler için önemli bir avantaj sağlamaktadır.

CNN'ler görüntü işleme ve sınıflandırma işlemlerinde başarıyla kullanılan bir algoritmadır. CNN algoritmalarının temel niteliği gelen veri görüntülerdeki öznitelikler çıkarılarak bu öznitelikler vasıtasıyla doğru bir sınıflandırma yapılması işlemidir. Bu ağlar kullanılırken görüntü işleme, dil işleme gibi birçok yöntem kullanılır. CNN ağları girdileri tanımlamak için özel olarak tasarlanmışlardır. CNN algoritmalarında filtreler ya da çekirdekler denilen matrisler kullanılarak işlemler yapılır. Girdiler bu filtrelerden geçerek çıktı oluşur bu işlem sırasında verilerdeki nitelikler öğretilir. Bu öğretiler katmanlar arasında bulunan parametrelerde bileşerek öğrenme süreci hızlanır. Bu yöntem görüntü işlemede ve başka görüntü işlemlerinde algoritmalar için en iyi derin öğrenme yöntemlerinden biridir (DataKapital, 2025).



Şekil 5. CNN mimarisinin genel çalışma şeması (Medium, 2025c)

Şekil 5’te CNN mimarisinin genel çalışma şeması verilmiştir. Şekilde de görüldüğü üzere, CNN algoritmalarında girdiye öncelikle öznitelik çıkarımı yapılır. Burada bir dizi filtreleme işlemleri kullanılır. Filtreler görüntülerin pikselleri arasında matematiksel işlemler yaparak bunları uygun şekilde öznitelik çıkarımını yapar. Havuzlama katmanları görüntülerin boyutlarını azaltarak önemli özelliklerini korur. Filtreleme sonucu öznitelikleri çıkarılan girdiler tam bağlantılı katmanlar aracılığıyla sınıflandırma işlemi yapar böylece istenilen sonuca en yakın başarı elde edilmeye çalışılır.

### 2.7.1.1. CNN mimarisinin temel katmanları

Bir CNN mimarisi temel olarak evrişim (convolution) katmanları, aktivasyon fonksiyonları, havuzlama (pooling) katmanları ve tam bağlantılı (fully connected) katmanlardan oluşmaktadır.


#### 2.7.1.1.1. Evrişim (convolution) katmanı

CNN’in en temel yapı taşıdır ve görüntü üzerinde küçük boyutlu filtreler (kernel) gezdirilerek yerel özniteliklerin çıkarılmasını sağlar. Bu filtreler, görüntüdeki belirli desenlere duyarlı olacak şekilde eğitim sürecinde öğrenilmektedir. Evrişim işlemi sonucunda elde edilen öznitelik haritaları (feature maps), görüntünün farklı bölgelerinde bulunan görsel bilgileri temsil etmektedir (LeCun vd., 2002).

Evrişim katmanlarının ardından genellikle aktivasyon fonksiyonları kullanılmaktadır. En yaygın kullanılan aktivasyon fonksiyonlarından biri rectified linear unit (ReLU) olup, doğrusal

olmayan ilişkilerin öğrenilmesine olanak tanımaktadır. ReLU fonksiyonu, eğitim sürecini hızlandırması ve gradyan kaybolması problemini azaltması nedeniyle CNN mimarilerinde tercih edilmektedir (Nair ve Hinton, 2010).

Bu katman gelen görüntü ya da resmi filtreden geçirmesi sonucunda özneliğini çıkarır. CNN'nin en önemli katmanıdır. Bu katmanda yapılan işlemler ile görüntü sadeleşir. Matris şeklinde işlem yapılır. Kullanılan filtrelerin boyutları CNN yapısına göre değişir. Genellikle kullanılan filtreler 3x3, 5x5 olurken bazıları 7x7'lik filtrelerde kullanılabilir. Şekil 6'da evrişim katmanı gösterilmiştir.



Şekil 6. Evrişim katmanı (Medium, 2025d)

Şekil 6'da görüldüğü gibi girdi olarak gelen görüntü ya da resim 4x4 şeklinde matris olarak boyutlandırılmıştır. Daha sonra 2x2'lik filtre ile işlem yapılarak özneliği çıkarılmıştır. Bu işlem tüm satır ve sütunlara uygulanmaktadır. Bu şekilde filtrelene yapılması girdi sayısı çok olan karmaşık verilerde basit bir düzeye indirmeyi sağlar. Böylece veri kullanılan algoritmanın anlamlandıracağı şekle gelir. Kullanılan filtre sayısı arttıkça uygulanma sayısı da artar, yani her filtre için ayrı ayrı işlem uygulanır.

Çıkış matrisi matematiksel olarak Denklem 3'te formüle edilmiştir.


$$F = (a - b + 1) \times (a - b + 1) \quad (3)$$

Denklem 3’te, a giriş matrisinin boyutu, b ise filtre boyutunu ifade eder.

### 2.7.1.1.2. Havuzlama (pooling) katmanı


Evrişim katmanlarından elde edilen öznitelik haritalarının boyutunu küçültmek ve hesaplama maliyetini azaltmak amacıyla kullanılmaktadır. En yaygın havuzlama yöntemleri maksimum havuzlama (max pooling) ve ortalama havuzlama (average pooling) yöntemleridir. Bu katmanlar, aynı zamanda küçük konumsal değişimlere karşı ağına daha dayanıklı olmasını sağlamaktadır (Goodfellow vd., 2016).

Evrişim katmanından sonra filtreden geçen verilerin bir sonraki geldiği katman havuzlama (pooling) katmanıdır. Bu katmanda matrislerin öznitelikleri çıkarılır. Havuzlama işleminde girdide gelen verilerin evrişim katmanında sadeleştirilen matris girdilerin ortalamalarını ya da maksimum değerlerini bulur. Bu bulunan değerler ile girdiler parçalara ayrılarak evrişim katmanına göre daha az maliyet ile tek bir sabit veriye indirilir (Dumoulin ve Visin, 2016). Şekil 7’de maksimum havuzlama yöntemine ait bir örnek gösterilmiştir.



Şekil 7. Maksimum havuzlama yöntemi örneği

Şekil 7’de görüldüğü gibi evrişim katmanından çıkan 4x4 matris çıktı parçalara ayrılıp her bir parçadaki matrisin en yüksek değerinin alındığı havuzlama yöntemine maksimum havuzlama yöntemi denir (Kurt, 2018). Şekilde gösterilen 4x4 matris sarı, kırmızı, mavi ve yeşil renklerde 2x2 matrislere bölünmüştür. Maksimum havuzlama yöntemi ile bu matrislerden sarı renk en büyük değeri olarak 4, kırmızı renk matris en büyük değeri olarak 5, mavi renk matris en büyük değeri olarak 3 ve yeşil renk matris en büyük değeri olarak 6 alınmıştır. Böylece girdi değeri daha sade ve anlaşılır olmuştur.




Şekil 8. Ortalama havuzlama yöntemi örneği

Maksimum havuzlama yöntemindeki gibi Şekil 8’de gösterilen 4x4 matris her bölme 2x2 olacak şekilde parçalara ayrılıp bu parçadaki matrislerin ortalamaları alınır. Bu havuzlama yöntemine ortalama havuzlama yöntemi denir (Güler, 2022). Şekil de gösterilen 4x4 matris sarı, kırmızı, mavi ve yeşil renklerde 2x2 matrislere bölünmüştür. Ortalama havuzlama yöntemi ile bu matrislerden sarı renk matris ortama değeri olarak 2,5, kırmızı renk matris ortalama değeri olarak 2,75, mavi renk matris ortalama değeri olarak 1,2 ve yeşil renk matris ortalama değeri olarak 2,25 alınmıştır. Böylece girdi değeri daha sade ve anlaşılır olmuştur.

#### 2.7.1.1.3. Tam bağlantı katmanı (fully connected)

Evrişim ve havuzlama katmanlarından geçirilen öznitelik haritalarından elde edilen değerler, CNN mimarisinin son bölümünde yer alan tam bağlantılı (fully connected) katmana aktarılmaktadır. Bu katman, klasik bir YSA yapısına benzer şekilde çalışmakta olup, sınıflandırma veya tahmin işleminin gerçekleştirildiği aşamayı temsil etmektedir. Bu bölümde yer alan her bir nöron, önceki katmandaki tüm nöronlar ile bağlantılıdır ve bu sayede çıkarılan özniteliklerin bütüncül bir değerlendirmesi yapılmaktadır (Güler, 2022). Tam bağlantılı katmana geçiş öncesinde, havuzlama katmanlarından elde edilen çok boyutlu öznitelik haritaları düzleştirme (flatten) işlemi ile tek boyutlu vektör hâline getirilmektedir (Şekil 9). Bu işlem, verilerin YSA tarafından daha etkin bir şekilde işlenmesini sağlamakta ve sınıflandırma sürecinin daha anlamlı ve hesaplama açısından daha hızlı gerçekleştirilmesine olanak tanımaktadır.



Şekil 9. Tam bağlantı katmanı

### 2.7.1.2. CNN mimari çeşitleri

CNN mimarileri, birbirinden farklı katmanlardan oluşan, derin öğrenme modelleridir. AlexNet, DenseNet121, EfficientNetB3, MobileNetV2 ve ResNet50 gibi popüler CNN mimarileri bulunmaktadır. Bu mimariler, farklı sayıda katmanlar ve parametreler kullanarak, farklı boyutlardaki veriler üzerinde iyi sonuçlar vermektedir. CNN mimarilerinin avantajları arasında, özellikle görüntü işleme alanında yüksek performans ve özellik çıkarma yetenekleri, veri büyütme teknikleri ve ölçeklenebilirlik sayılabilir. Ancak, daha karmaşık modellerin eğitilmesi daha uzun sürebilir ve daha fazla hesaplama gücü gerektirebilir.

Derin öğrenme tabanlı görüntü sınıflandırma çalışmalarında kullanılan Convolutional Neural Network (CNN) mimarileri, yıllar içerisinde artan veri miktarı ve hesaplama gücü ile birlikte önemli gelişim göstermiştir. Bu çalışmada üzüm yaprağı hastalıklarının sınıflandırılması amacıyla farklı mimari özelliklere sahip beş CNN modeli kullanılmıştır: AlexNet, DenseNet121, EfficientNetB3, MobileNetV2 ve ResNet50. Bu modeller, CNN mimarilerinin tarihsel gelişimini ve farklı tasarım yaklaşımlarını temsil etmektedir.

#### 2.7.1.2.1. AlexNet


AlexNet, 2012 yılında Alex Krizhevsky ve arkadaşları tarafından geliştirilmiş ve ImageNet Large Scale Visual Recognition Challenge (ILSVRC) yarışmasını büyük farkla kazanarak derin öğrenmenin görüntü işleme alanında yaygınlaşmasını sağlamıştır (Krizhevsky vd., 2012). AlexNet mimarisi toplamda 8 katmandan oluşmaktadır (5 konvolüsyon + 3 tam bağlantılı

katman) (Şekil 10). Modelde ReLU aktivasyon fonksiyonunun kullanılması eğitim süresini önemli ölçüde azaltmış ve öğrenme hızını artırmıştır. Ayrıca dropout tekniği kullanılarak aşırı öğrenmenin azaltılması hedeflenmiştir.

AlexNet'in temel katkıları şunlardır:

- Derin CNN mimarilerinin pratikte uygulanabilir olduğunu göstermesi
- GPU ile eğitim kullanımını yaygınlaştırması
- ReLU aktivasyonunun standart hâle gelmesini sağlaması.

Ancak parametre sayısının yüksek olması ve daha derin mimarilere göre sınırlı özellik çıkarımı yapabilmesi nedeniyle günümüzde daha çok referans model olarak kullanılmaktadır.



Şekil 10. AlexNet mimari yapısı (Medium, 2025e)

### 2.7.1.2.2. ResNet50

Residual Neural Network (ResNet), 2015 yılında He ve arkadaşları tarafından geliştirilmiştir (He vd., 2016). ResNet50, 50 katmandan oluşan derin bir CNN mimarisidir. Bu mimarinin en önemli yeniliği artık (residual) bağlantılardır. Geleneksel derin ağlarda katman sayısı arttıkça gradyan kaybolması problemi ortaya çıkarken, residual bağlantılar sayesinde giriş bilgisi doğrudan ileri katmanlara aktarılabilmektedir. Bu durum daha derin ağların etkin şekilde eğitilmesini sağlamıştır.

ResNet'in temel avantajları şunlardır:

- Çok derin ağların eğitilebilmesi
- Gradyan kaybolması probleminin azaltılması
- Karmaşık görsel özelliklerin öğrenilebilmesi

Bu nedenle ResNet mimarileri uzun süre görüntü sınıflandırma çalışmalarında standart modellerden biri olmuştur.

### **2.7.1.2.3. DenseNet121**

Densely Connected Convolutional Network (DenseNet), 2017 yılında Huang ve arkadaşları tarafından önerilmiştir (Huang vd., 2017). DenseNet121 modeli 121 katmandan oluşmaktadır. DenseNet mimarisinde her katman kendisinden önceki tüm katmanların çıktısını girdi olarak alır. Bu yapı, ağ içerisinde yoğun bilgi akışı sağlayarak özelliklerin tekrar kullanılmasına imkân tanır.

DenseNet'in temel avantajları şunlardır:

- Özellik tekrar kullanımı (feature reuse)
- Daha az parametre ile yüksek performans
- Güçlü özellik aktarımı sayesinde yüksek sınıflandırma başarısı

DenseNet121 mimarisi güçlü temsil kapasitesine sahiptir.

### **2.7.1.2.4. MobileNetV2**

MobileNetV2, 2018 yılında Sandler ve arkadaşları tarafından mobil ve gömülü sistemler için geliştirilmiştir (Sandler vd., 2018). Bu model, düşük hesaplama maliyeti ve az parametre sayısı ile dikkat çekmektedir.

MobileNetV2'nin temel yenilikleri şunlardır:

- Derinlemesine ayrılabilir konvolüsyon
- Inverted residual blokları
- Linear bottleneck yapısı

Bu yapı sayesinde model, hesaplama maliyetini ciddi şekilde azaltırken performans kaybını minimum seviyede tutmaktadır. Daha az parametre içermesi, küçük veri setlerinde aşırı öğrenme riskini azaltarak genelleme başarısını artırmaktadır. Bu nedenle MobileNetV2 özellikle gerçek zamanlı ve mobil tabanlı görüntü işleme uygulamalarında tercih edilmektedir.

### 2.7.1.2.5. EfficientNetB3

EfficientNet mimarisi, 2019 yılında Tan ve Le tarafından geliştirilmiştir (Tan ve Le, 2019). EfficientNet modelleri, ağ derinliği, genişliği ve giriş görüntü çözünürlüğünü dengeli şekilde ölçeklendiren bileşik ölçeklendirme (compound scaling) yaklaşımını kullanmaktadır.

Geleneksel CNN modellerinde yalnızca ağ derinliği artırılırken, EfficientNet mimarisi üç parametreyi birlikte optimize etmektedir:

- Ağ derinliği (depth),
- Kanal genişliği (width),
- Görüntü çözünürlüğü (resolution).

EfficientNetB3 modeli bu ölçekleme yaklaşımının orta seviyede dengelenmiş bir versiyonudur ve yüksek doğruluk ile nispeten düşük hesaplama maliyeti sunmaktadır.

### 2.7.1.3. CNN'lerin avantajları

CNN mimarilerinin en önemli avantajlarından biri, parametre paylaşımı ve yerel bağlantılar sayesinde geleneksel sinir ağlarına kıyasla daha az parametre ile daha etkili öğrenme gerçekleştirebilmesidir. Bu sayede, yüksek boyutlu görüntü verileri üzerinde aşırı öğrenme (overfitting) riski azaltılmakta ve modelin genelleme yeteneği artırılmaktadır (Krizhevsky vd., 2012).

Ayrıca CNN'ler, görüntü verilerinde bulunan uzamsal ilişkileri koruyarak öğrenme gerçekleştirdiği için, klasik makine öğrenmesi yöntemlerine kıyasla daha yüksek doğruluk oranları sunmaktadır. Bu özellik, özellikle bitki yapraklarında görülen hastalık belirtilerinin tespitinde büyük önem taşımaktadır. Yaprak üzerindeki leke, renk değişimi ve doku bozulmaları gibi görsel ipuçları, CNN mimarileri tarafından etkin bir şekilde öğrenilebilmektedir (Ferentinos, 2018).

#### **2.7.1.4. Tarımsal uygulamalarda CNN kullanımı**

Son yıllarda CNN tabanlı derin öğrenme yaklaşımları, tarım alanında bitki hastalıklarının otomatik olarak tespit edilmesi ve sınıflandırılması amacıyla yaygın biçimde kullanılmaktadır. Görüntü tabanlı CNN modelleri, yaprak yüzeyindeki hastalık belirtilerini yüksek doğrulukla ayırt edebilmekte ve erken teşhis imkânı sunmaktadır. Bu durum, hastalıkların yayılmasının önlenmesi ve verim kayıplarının azaltılması açısından önemli avantajlar sağlamaktadır (Mohanty vd., 2016).

Özellikle üzüm yaprağı gibi geniş yapraklı bitkilerde görülen mantar, pas ve leke hastalıklarının tespitinde CNN mimarilerinin başarılı sonuçlar verdiği literatürde sıklıkla rapor edilmektedir. CNN'lerin otomatik öznelik çıkarımı yeteneği, farklı ışık koşulları, yaprak açıları ve doku çeşitlilikleri altında dahi yüksek sınıflandırma performansı elde edilmesini mümkün kılmaktadır (Ferentinos, 2018).

#### **2.7.1.5. CNN'in bu çalışmadaki önemi**

Bu çalışma kapsamında, üzüm yapraklarında görülen hastalıkların tespiti ve sınıflandırılması amacıyla CNN tabanlı derin öğrenme mimarilerinin kullanılması tercih edilmiştir. CNN'lerin görüntü verileri üzerindeki yüksek başarıları ve genelleme yetenekleri sayesinde, farklı hastalık türlerinin doğru ve güvenilir bir şekilde ayırt edilmesi hedeflenmektedir. Böylece, tarımsal üretimde erken teşhis ve hızlı müdahale imkânı sunan otomatik bir karar destek sistemi geliştirilmesi amaçlanmaktadır.

#### **2.7.2. Tekrarlayan sinir ağı (recurrent neural network – RNN)**

Günümüzde yapay zekâ ve derin öğrenme alanındaki gelişmeler, özellikle zamana bağlı verilerin analizinde önemli ilerlemeler sağlamıştır. Geleneksel YSA'lar çoğunlukla bağımsız örnekler üzerinde çalışırken, birçok gerçek dünya problemi zamansal bağımlılık içeren ardışık verilerden oluşmaktadır. Konuşma tanıma, doğal dil işleme, zaman serisi tahmini ve biyomedikal sinyal analizi gibi alanlarda, geçmiş bilgilerin gelecekteki çıktıları etkilemesi söz konusudur. Bu tür problemler için geliştirilmiş en önemli derin öğrenme mimarilerinden biri tekrarlayan sinir ağları (recurrent neural networks – RNN)'dir (Goodfellow vd., 2016).

RNN'ler, klasik ileri beslemeli ağlardan farklı olarak, gizli katmanlarında döngüsel bağlantılar içermektedir. Bu yapı sayesinde ağ, önceki zaman adımlarındaki bilgiyi bir tür “bellek” olarak tutabilmekte ve böylece sıralı veriler arasındaki bağımlılıkları modelleyebilmektedir (Elman, 1990). Matematiksel olarak bir RNN hücresi, mevcut giriş vektörü ile birlikte bir önceki gizli durumun birleşimini kullanarak yeni bir gizli durum üretir. Bu durum, ağın zamansal bağlamı öğrenmesine olanak tanır.

### 2.7.2.1. RNN mimarisi ve öğrenme mekanizması

Bir RNN modelinde her zaman adımında aynı ağırlıklar kullanılmakta ve bu durum parametre paylaşımı yoluyla modelin genelleme yeteneğini artırmaktadır. Temel RNN yapısında, gizli durum güncellemesi Denklem 4'teki gibi ifade edilebilir.

$$h_t = f(W_{xh}x_t + W_{hh}h_{t-1} + b_h) \quad (4)$$

Burada,  $x_t$  giriş vektörünü,  $h_t$  gizli durumu,  $W_{xh}$  ve  $W_{hh}$  ağırlık matrislerini,  $b_h$  ise bias terimini temsil etmektedir (Bishop, 2006). Çıkış katmanı ise genellikle gizli durum üzerinden hesaplanır.

RNN'lerin eğitimi, zaman boyunca geri yayılım (backpropagation through time – BPTT) algoritması ile gerçekleştirilir. Bu yöntem, klasik geri yayılımın zamansal boyuta genişletilmiş bir versiyonudur (Werbos, 1990). Ancak, uzun dizilerde gradyanların çok küçük (vanishing gradient) veya çok büyük (exploding gradient) hale gelmesi, temel RNN modellerinin önemli bir sınırlılığıdır (Hochreiter ve Schmidhuber, 1997).

### 2.7.2.2. Gelişmiş RNN türleri: LSTM ve GRU

Temel RNN modellerindeki problemlerin üstesinden gelmek amacıyla, long short-term memory (LSTM) ve gated recurrent unit (GRU) gibi kapılı RNN mimarileri geliştirilmiştir. LSTM, giriş, unutma ve çıkış kapıları sayesinde uzun vadeli bağımlılıkları daha etkin bir şekilde öğrenebilmektedir (Hochreiter ve Schmidhuber, 1997). GRU ise daha sade bir yapı sunarak benzer performansı daha az parametre ile elde etmeyi amaçlamaktadır (Cho vd., 2014).

Literatürde yapılan çok sayıda çalışma, LSTM ve GRU tabanlı modellerin konuşma tanıma, makine çevirisi ve zaman serisi tahmini gibi alanlarda klasik RNN'lere kıyasla daha yüksek doğruluk ve kararlılık sağladığını göstermektedir (Yu ve Deng, 2010; LeCun vd., 2015).

### **2.7.2.3. RNN uygulama alanları**

RNN'lerin en yaygın kullanım alanlarından biri doğal dil işleme (natural language processing – NLP)'dir. Dil modelleme, duygu analizi ve makine çevirisi gibi görevlerde, kelimeler arasındaki sıralı ilişkilerin öğrenilmesi kritik öneme sahiptir (Mikolov vd., 2010). Benzer şekilde, konuşma tanıma sistemlerinde ses sinyallerinin zamansal yapısı RNN mimarileri ile etkin biçimde temsil edilebilmektedir.

Zaman serisi analizinde ise finansal tahmin, meteorolojik veri modelleme ve biyomedikal sinyallerin yorumlanması gibi uygulamalar ön plana çıkmaktadır (Chowdhary, 2020). Bu alanlarda RNN'ler, geçmiş gözlemleri dikkate alarak geleceğe yönelik öngörülerde bulunabilmektedir.

Ayrıca, görüntü ve video analizi gibi uzamsal-zamansal problemlerde, RNN'ler genellikle CNN ile birlikte hibrit modeller şeklinde kullanılmakta ve hem mekânsal hem de zamansal özelliklerin birlikte öğrenilmesine olanak tanımaktadır (Donahue et al., 2015).

### **2.7.2.4. RNN avantajlar ve sınırlılıkları**

RNN'lerin en temel avantajı, sıralı verilerde bağlam bilgisini koruyabilmesidir. Bu özellik, klasik ileri beslemeli ağların yetersiz kaldığı birçok problemi çözebilir hale getirmektedir. Ancak, eğitim sürecinin karmaşıklığı, uzun dizilerde performans düşüşü ve hesaplama maliyeti, RNN tabanlı modellerin önemli dezavantajları arasında yer almaktadır (Goodfellow vd., 2016).

Son yıllarda dikkat mekanizmaları (attention) ve dönüştürücü (transformer) tabanlı mimariler, bazı alanlarda RNN'lerin yerini almaya başlamış olsa da, RNN ve özellikle LSTM/GRU modelleri hâlen birçok zaman serisi ve sinyal işleme probleminde etkin biçimde kullanılmaktadır.

## 2.8. Literatür Taraması

Literatürde üzümün, erken uygarlıklardan itibaren bereket, yaşam, bolluk ve kutsallıkla ilişkilendirildiği vurgulanmaktadır. Arkeolojik bulgular ve sanat eserleri, üzüm figürlerinin Mezopotamya, Anadolu ve Akdeniz havzasında yaygın biçimde kullanıldığını göstermektedir. Orta Çağ ve sonraki dönemlere ait çalışmalar, üzümün hem ekonomik hem de kültürel değerini koruduğunu ortaya koymaktadır. Bağcılık faaliyetleri, toplumsal yaşamın önemli bir parçası haline gelmiş; üzüm ve şarap, ticaret, mimari ve günlük yaşam pratikleriyle bütünleşmiştir. Modern araştırmalar ise üzümün tarihsel öneminin yanı sıra, kültürel sürekliliğini ve sembolik gücünü koruduğunu vurgulamaktadır (Sağlam ve Sağlam, 2018).

Tokatlıoğlu vd. (2018) tarafından yapılan çalışmada tarım sektörü, ülkelerin ekonomik ve toplumsal sürdürülebilirliği açısından stratejik bir alan olarak değerlendirilmektedir. Nüfus artışıyla birlikte gıda talebinin yükselmesi, gıda güvenliği sorunlarının ön plana çıkması ve doğal kaynakların sınırlı olması, tarımın yalnızca ekonomik değil, aynı zamanda ulusal güvenlik boyutu olan bir sektör haline gelmesine neden olmuştur. Bu bağlamda, tarımsal arzın sürekliliğinin sağlanması, pek çok çalışmada temel bir kamu sorumluluğu olarak ele alınmaktadır. Tarım sektörünün stratejik niteliği gereği, devlet müdahalesinin kaçınılmaz olduğunu; üretim planlaması, destekleme politikaları ve gıda güvenliği odaklı düzenlemelerin bütüncül ve uzun vadeli bir yaklaşımla ele alınması gerektiğini ortaya koymaktadır. Tarımsal arz güvenliğinin sağlanması, yalnızca ekonomik bir hedef değil, aynı zamanda toplumsal refah ve ulusal güvenlik açısından da temel bir gereklilik olarak değerlendirilmektedir (Tokatlıoğlu, vd., 2018).

Eker vd. (2023) tarafından yapılan çalışmada teknolojik gelişmelerin ormancılık disiplinine yansımalarıyla birlikte, geleneksel ormancılık uygulamalarının daha ekonomik, hızlı, etkin ve sürdürülebilir biçimde yürütülmesine yönelik dijital ve akıllı yaklaşımların önemi giderek artmaktadır. Bu dönüşüm süreci içerisinde ormancılık bilişimi, hassas ormancılık, akıllı ormancılık, Ormancılık 4.0, iklim-akıllı ormancılık ve sayısal ormancılık gibi kavramlar öne çıkmakta; ormancılık faaliyetlerinin veri temelli ve teknoloji destekli olarak yürütülmesini ifade etmektedir. Son yıllarda yapılan çalışmalar, makine öğrenmesi tabanlı yöntemlerin ormancılıkta planlama, izleme, envanter, risk analizi ve karar destek süreçlerinde etkin biçimde kullanılabildiğini ortaya koymaktadır. Özellikle büyük veri kaynaklarının yaygınlaşmasıyla

birlikte, otomatik makine öğrenmesi (AutoML) yaklaşımlarının da bu alana entegre edildiği ve model geliştirme süreçlerini hızlandırdığı vurgulanmaktadır (Eker vd., 2023).

Atalay ve Çelik (2017) tarafından yapılan çalışmada bilgi teknolojilerindeki hızlı gelişim ve internet kullanımının yaygınlaşmasıyla birlikte, farklı dijital platformlarda üretilen verinin hacmi ve çeşitliliğinin önemli ölçüde arttığı vurgulanmaktadır. Bu durum, “büyük veri” kavramının ortaya çıkmasına ve veri işleme yöntemlerinin yeniden ele alınmasına neden olmuştur. Büyük verinin etkin biçimde analiz edilmesi, yalnızca ham verinin işlenmesi değil, aynı zamanda bu verilerden anlamlı ve karar destekleyici bilgilerin üretilmesi açısından kritik öneme sahiptir. Büyük veri ortamlarında yapay zekâ ve makine öğrenmesi tekniklerinin, veriden bilgiye dönüşüm sürecini hızlandıran ve daha isabetli öngörüler yapılmasına olanak tanıyan temel yöntemler olduğunu ortaya koymaktadır (Atalay ve Çelik, 2017)

Aylak vd. (2021) tarafından yapılan çalışmada lojistik sektörü, küresel ticaretin temel bileşenlerinden biri olarak hızla büyüyen ve teknolojik yeniliklere en açık alanlardan biri olarak değerlendirilmektedir. Artan rekabet koşulları ve müşteri beklentileri, lojistik faaliyetlerin daha hızlı, hatasız ve verimli yürütülmesini zorunlu kılmaktadır. Bu süreçte Endüstri 4.0 yaklaşımı, lojistik sektörünü derinden etkilemiş ve dijital dönüşümü kaçınılmaz hale getirmiştir. Bu çerçevede yapılan araştırmalar, yapay zekâ destekli lojistik uygulamalarının yalnızca teknolojik bir yenilik değil, aynı zamanda rekabet üstünlüğü sağlayan stratejik bir unsur haline geldiğini göstermektedir. Küresel ölçekte, yapay zekânın lojistik ve tedarik zinciri yönetiminde giderek daha merkezi bir rol üstleneceği öngörülmektedir (Aylak vd., 2021).

Özdemir ve Türkoğlu (2022) tarafından yapılan çalışmada yazılım güvenliği, bilgi sistemlerinin gizlilik, bütünlük ve erişilebilirliğini korumaya yönelik temel bir disiplin olarak ele alınmaktadır. Yazılım sistemlerinde bulunan güvenlik açıklarının, kötü niyetli saldırılara zemin hazırladığı ve ciddi operasyonel riskler oluşturduğu yaygın biçimde vurgulanmaktadır. Bu nedenle güvenlik açıklarının erken tespiti ve etkin yönetimi, modern yazılım geliştirme süreçlerinin vazgeçilmez bir unsuru haline gelmiştir. Evrişimli sinir ağlarının (ESA) metin tabanlı güvenlik verileri üzerinde yüksek ayırt edicilik sağladığı ve güvenlik açığı kategorilerinin otomatik belirlenmesinde başarılı sonuçlar verdiği rapor edilmektedir. NVD gibi büyük ölçekli güvenlik veri tabanları üzerinde gerçekleştirilen çalışmalar, derin öğrenme modellerinin hem doğruluk hem de ölçeklenebilirlik açısından avantaj sağladığını göstermektedir. Bu kapsamda yapılan araştırmalar, derin öğrenme destekli otomatik

sınıflandırma sistemlerinin, yazılım güvenliği süreçlerini daha proaktif ve etkin hale getirdiğini ortaya koymaktadır (Özdemir ve Türkoğlu, 2022).

İnik ve Ülker (2017) tarafından yapılan çalışmada klasik makine öğrenmesi yaklaşımlarının en temel sınırlılıklarından birinin, özellik çıkarım sürecinin uzman bilgisine dayalı ve zaman alıcı olması olduğu vurgulanmaktadır. Geleneksel yöntemler, ham verinin doğrudan işlenmesine olanak tanımamakta ve model başarımı büyük ölçüde manuel olarak tasarlanan özellik vektörlerine bağımlı kalmaktadır. ESA, derin öğrenmenin en yaygın kullanılan mimarileri arasında yer almakta; konvolüsyon, havuzlama, aktivasyon (ReLU), dropout, tam bağlantılı ve sınıflandırma katmanları ile hiyerarşik bir öğrenme yapısı sunmaktadır. AlexNet, ZFNet, GoogLeNet, ResNet ve R-CNN gibi mimariler, literatürde temel ve öncü modeller olarak kabul edilmekte ve pek çok uygulama alanında referans alınmaktadır. Bu çerçevede yapılan çalışmalar, derin öğrenmenin, klasik makine öğrenmesine kıyasla daha otomatik, esnek ve yüksek doğruluk sağlayan bir yaklaşım olduğunu ortaya koymaktadır (İnik ve Ülker, 2017).

Tüfekçi ve Karpaz (2019) tarafından yapılan çalışmada insan ve bilgisayar etkileşimi alanındaki teknolojik gelişmelerle birlikte, derin öğrenme yöntemlerinin kullanıcı ile sistem arasındaki etkileşimi daha akıllı ve uyarlanabilir hale getirdiği ifade edilmektedir. Literatürde, derin öğrenmenin çok katmanlı yapısı sayesinde karmaşık örüntüleri öğrenebildiği ve farklı veri türlerinde yüksek başarı sağladığı belirtilmektedir. Bu kapsamda CNN, RNN, LSTM, RBM ve oto-kodlayıcı (AE) mimarileri temel derin öğrenme yaklaşımları arasında yer almaktadır. Özellikle CNN'lerin, görüntü işleme alanında öne çıktığı; nesne tanıma, sınıflandırma, anlamsal ayrıştırma ve tahmin problemlerinde başarılı sonuçlar verdiği literatürde geniş biçimde rapor edilmektedir. Ayrıca CNN tabanlı yöntemlerin ses, metin ve biyomedikal veriler üzerinde de etkin biçimde kullanıldığı belirtilmektedir. Bu bağlamda yapılan derleme çalışmaları, CNN tabanlı görüntü işleme ve sınıflandırma uygulamalarının yüksek doğruluk oranlarına ulaştığını ve insan-bilgisayar etkileşimi alanında güvenilir çözümler sunduğunu ortaya koymaktadır (Tüfekçi ve Karpaz, 2019).

Gürbüz ve Yılmaz (2023) tarafından yapılan çalışmada teknolojik gelişmelerin ve dijital sistemlerin yaygınlaşmasıyla birlikte, yüz tanıma tabanlı uygulamaların günlük yaşamda giderek daha fazla yer edindiği vurgulanmaktadır. Akıllı telefon güvenliği, erişim kontrol sistemleri, personel ve öğrenci devam takibi ile güvenlik uygulamaları, yüz tanıma teknolojilerinin en yaygın kullanım alanları arasında gösterilmektedir. Yüz tanıma probleminin

çözümünde farklı yöntemler bulunmakla birlikte, son yıllarda derin öğrenme tabanlı yaklaşımların özellikle öne çıktığı belirtilmektedir. ESA'ların, görüntü içerisindeki ayırt edici özellikleri otomatik olarak öğrenebilmesi ve yüksek tanıma doğruluğu sağlaması nedeniyle yüz tanıma sistemlerinde etkin biçimde kullanıldığı ifade edilmektedir. Bu çerçevede yapılan araştırmalar, ESA tabanlı yüz tanıma sistemlerinin güvenilir, hızlı ve uygulanabilir çözümler sunduğunu ve biyometrik tanıma teknolojilerinde önemli bir yere sahip olduğunu ortaya koymaktadır (Gürbüz ve Yılmaz, 2023).

Karhan (2011) tarafından gerçekleştirilen tez çalışmasında, görüntü işleme tabanlı algoritmalar kullanılarak kayısı yapraklarında görülen *Yaprak Delen (Çil) Hastalığı* sonucunda oluşan lekelerin tespiti amaçlanmıştır. Çalışma kapsamında, yaprak yüzeyinde meydana gelen hastalık kaynaklı lezyonların belirlenmesi ve bu lezyonlara bağlı kalite değerlendirmesinin yapılabilmesi için görüntü işleme tekniklerinden yararlanılmıştır. Bu doğrultuda, gerçek zamanlı olarak çalışan bir sınıflandırma sistemi geliştirilmiş ve sistemin başarımını artırmak amacıyla görüntü iyileştirme yöntemleri ile birlikte renk tabanlı bölütleme işlemleri uygulanmıştır. Bununla birlikte, yaprağın doğal olgunlaşma süreci veya farklı çevresel etkenler nedeniyle oluşan ve hastalıkla doğrudan ilişkili olmayan lekelerin, sınıflandırma sürecinde yanıltıcı sonuçlara yol açabileceği göz önünde bulundurularak, ikili görüntüler üzerinde ortaya çıkan bu tür yanılmalara lekeler morfolojik işlemlerle azaltılmıştır. Uygulanan morfolojik filtreleme adımları sonucunda elde edilen çıkış görüntülerinde, hastalığa bağlı leke bölgelerinin daha belirgin hale geldiği ve böylece leke tespitinde daha yüksek doğruluk oranlarına ulaşıldığı rapor edilmiştir (Karhan, 2011).

Türkoğlu (2019) tarafından gerçekleştirilen tez çalışmasında, bitki hastalıkları ve zararlılarının tespiti amacıyla görüntü işleme tabanlı derin ESA tekniği kullanılmış ve bu kapsamda VGG16, GoogLeNet, VGG19, AlexNet, ResNet101, ResNet50, SqueezeNet, Inception-ResNetV2 ve InceptionV3 olmak üzere dokuz farklı ve güçlü derin ağ mimarisi değerlendirilmiştir. Çalışmada, söz konusu mimariler transfer öğrenimi yaklaşımıyla kullanılarak derin öznitelik çıkarımı gerçekleştirilmiş, elde edilen özniteliklerin bitki hastalıkları ve zararlılarının sınıflandırılmasındaki etkinliği karşılaştırmalı olarak analiz edilmiştir. Tez çalışmasının sonuçlarında, önceden eğitilmiş derin öğrenme ağlarından elde edilen derin özelliklerin, geleneksel sınıflandırıcılarla birleştirilmesiyle yeni bir sınıflandırma mimarisi oluşturulduğu ve bu mimarinin bitki hastalıklarının tespitinde başarılı sonuçlar sunduğu ortaya konulmuştur (Türkoğlu, 2019).

Altaş vd. (2021) tarafından gerçekleştirilen tez çalışmasında, bağ yapraklarında görülen uyuz hastalığının neden olduğu hasarın belirlenmesi amacıyla MATLAB Image Processing Toolbox modülü kullanılmıştır. Çalışma kapsamında, bağ yapraklarına ait 50 farklı görüntü üzerinde gerçekleştirilen görüntü işleme işlemleri sonucunda, hastalığın yol açtığı zarar oranlarının en düşük %10 ve en yüksek %87 arasında değiştiği tespit edilmiştir. Ayrıca, görüntü işleme teknikleri kullanılarak elde edilen hasar oranları ile uzman değerlendirmeleri sonucunda belirlenen oranların büyük ölçüde birbiriyle örtüştüğü görülmüş, bu durum geliştirilen görüntü işleme tabanlı yaklaşımın bağ yaprağı hastalıklarının nicel olarak değerlendirilmesinde güvenilir ve uygulanabilir bir yöntem sunduğu sonucunu ortaya koymuştur (Altaş vd., 2021).

Doğan (2019) tarafından gerçekleştirilen tez çalışmasında, elma ve domates yapraklarında görülen hastalıkların tespiti üzerine kapsamlı bir inceleme yapılmıştır. Çalışma kapsamında, domates yapraklarına ait görüntüler PlantVillage veri tabanından temin edilirken, elma yapraklarına ait görüntüler Yalova ilinde araştırmacının ekibi tarafından oluşturulan özgün bir veri seti kullanılarak elde edilmiştir. Uygulanan yöntemler sonucunda, domates yapraklarındaki hastalıkların tespiti için tek bir filtreleme yaklaşımı kullanılmış ve bu yöntemle %86 doğruluk oranına ulaşılmıştır. Buna karşılık, elma yapraklarındaki hastalıkların tespitinde dört farklı filtreleme tekniğinin birlikte kullanıldığı ve bu sayede sınıflandırma başarısının %98,5'e yükseldiği rapor edilmiştir. Elde edilen sonuçlar, kullanılan filtre sayısının ve görüntü işleme sürecinin kapsamının hastalık tespit performansı üzerinde belirleyici bir etkiye sahip olduğunu göstermektedir (Doğan, 2019).

Aksoy vd. (2020) tarafından gerçekleştirilen tez çalışmasında, elma yapraklarında görülen hastalıkların yapay zekâ yöntemleri kullanılarak tespit edilmesi amacıyla CNN tabanlı mimarilerden yararlanılmıştır. Çalışma kapsamında VGG16-BN, AlexNet, DenseNet-121, ResNet34 ve SqueezeNet mimarileri kullanılarak hastalık tespiti ve sınıflandırma işlemleri gerçekleştirilmiş, her bir mimari için F1-skoru, duyarlılık, doğruluk ve özgüllük gibi performans ölçütleri hesaplanmış ve karşılaştırılmıştır. Elde edilen sonuçlar doğrultusunda, sırasıyla %98,62 F1-skoru, %97,64 duyarlılık, %99,52 doğruluk ve %99,54 özgüllük değerleri ile ResNet34 mimarisinin diğer modellere kıyasla en yüksek performansı sergilediği tespit edilmiştir. Bu bulgular, derin CNN mimarilerinin bitki yapraklarındaki hastalıkların tespitinde yüksek doğruluk ve güvenilirlik sunduğunu ortaya koymaktadır (Aksoy vd., 2020).

Yaman ve Tuncer (2022) tarafından yapılan çalışmada derin öğrenme yöntemlerinin gelişimiyle birlikte akıllı tarım uygulamalarında önemli bir dönüşüm yaşandığı ifade edilmektedir. Bitki sağlığının izlenmesi, yaprak hastalıklarının erken teşhisi ve tarımsal verimliliğin artırılması amacıyla makine öğrenmesi ve özellikle derin öğrenme tabanlı yaklaşımların yaygın biçimde kullanıldığı görülmektedir. Yapılan çalışmalar, ağaç ve bitki yapraklarındaki hastalıkların görüntü işleme teknikleriyle otomatik olarak tespit edilebildiğini ve bu sayede hem zaman hem de maliyet açısından önemli kazanımlar sağlandığını ortaya koymaktadır. Ayrıca, meyve ve sebze rekoltesi tahmininde de derin öğrenme modellerinin yüksek doğruluk sunduğu vurgulanmaktadır. Özellikle derin öğrenme tabanlı özellik çıkarımı ve klasik makine öğrenmesi algoritmalarının birlikte kullanıldığı hibrit yaklaşımların, sınıflandırma performansını artırdığı literatürde belirtilmektedir. ReliefF gibi özellik seçme algoritmaları ile ayırt edici özneliklerin belirlenmesi, destek vektör makineleri (SVM) gibi güçlü sınıflandırıcılarla birleştirildiğinde, yüksek doğruluk oranlarına ulaşıldığı rapor edilmektedir. Bu kapsamda yapılan araştırmalar, DarkNet53 ve ResNet101 gibi derin ağ mimarilerinin yaprak hastalığı tespitinde %99,58 doğruluk oranı ile etkili sonuçlar verdiğini ve derin öğrenme destekli sistemlerin akıllı tarım uygulamaları için güvenilir ve uygulanabilir çözümler sunduğu ifade edilmiştir (Yaman ve Tuncer, 2022).

Demir vd. (2021) tarafından gerçekleştirilen çalışmada ise, domates zararlılarının tespitine yönelik yapılan araştırmalar karşılaştırmalı olarak incelenmiş ve literatürde yer alan farklı yöntemler üzerinden kapsamlı bir değerlendirme yapılmıştır. Araştırmacılar, özellikle son yıllarda geliştirilen yeni modelleri analiz ederek, bu modellerin güçlü ve zayıf yönlerini ortaya koymuş ve elde edilen bulgular doğrultusunda daha gelişmiş bir yaklaşım önermiştir. Yapılan incelemeler sonucunda, bitki hastalıkları ve zararlılarının görsel tabanlı tespitinde mevcut yöntemlerin belirli sınırlılıklara sahip olduğu vurgulanmış ve bu alanda daha kapsamlı ve yenilenebilir modellerin geliştirilmesine ihtiyaç olduğu ifade edilmiştir (Demir vd., 2021).

Bütüner vd. (2023) tarafından gerçekleştirilen araştırmada, dört farklı mısır hastalığına ait görüntüler ile sağlıklı mısır yapraklarından oluşan bir veri seti kullanılarak hastalık tespiti problemi ele alınmıştır. Çalışma kapsamında, toplanan görüntülerin analizinde k-en yakın komşu (KNN), rastgele orman (random forest) ve YSA algoritmaları kullanılmış, bu algoritmalar aracılığıyla eğitilen modellerin mısır yaprağı hastalıklarını tahmin etme yetenekleri karşılaştırmalı olarak değerlendirilmiştir. Elde edilen bulgulara göre, geliştirilen yapay sinir ağı modelinin eğitim aşamasında %97 ve test aşamasında %89 doğruluk oranına

ulaştığı; KNN algoritmasının %97, rastgele orman algoritmasının %97,6 ve YSA yaklaşımının ise %97,7 başarı oranı sağladığı rapor edilmiştir. Çalışma sonuçları, yapay zekâ tabanlı yöntemlerin, geleneksel yaklaşımlara kıyasla mısır yaprağı hastalıklarının tespitinde daha yüksek doğruluk ve etkinlik sunduğunu ortaya koymaktadır (Bütüner vd., 2023).

Çetiner (2021) tarafından gerçekleştirilen tez çalışmasında, elma yapraklarında görülen hastalıkların tespitinde ön işleme adımlarının sınıflandırma başarısı üzerindeki etkisini incelemek ve en başarılı derin öğrenme mimarisini belirlemek amaçlanmıştır. Bu doğrultuda ResNet101V2, ResNet50V2, MobileNetV2, DenseNet121 ve ResNet152V2 gibi CNN tabanlı yöntemler kullanılmış, veri setleri homojen hale getirilmeden, yüksek zorluk derecesine sahip bir yapı altında test edilmiştir. Uygulanan deneyler sonucunda, kullanılan CNN mimarilerinin hastalık tespitinde %97'ye varan başarı oranlarına ulaştığı rapor edilmiştir. Eğitim sürecinin ardından gerçekleştirilen sınıflandırma doğrulama ve doğruluk analizlerinde ise, DenseNet201 mimarisinin diğer modellere kıyasla daha yüksek performans sergilediği ve elma yaprağı hastalıklarının tespitinde öne çıkan mimari olduğu görülmüştür (Çetiner, 2021).

Sazak vd. (2025) tarafından gerçekleştirilen çalışmada bitki hastalıklarının erken teşhisinin tarımsal verimlilik üzerindeki kritik rolü vurgulanmış ve yapay zekâ tabanlı yöntemlerle otomatik hastalık tespiti gerçekleştirilmiştir. Çalışmada, 12 farklı sağlıklı bitki ve 30 farklı hastalıkla enfekte olmuş bitki yaprağı görüntülerinden oluşan bir veri seti kullanılmıştır. Bitki hastalıklarının geleneksel yöntemlerle, özellikle yalnızca görsel incelemeye dayalı olarak belirlenmesinin zorlukları göz önünde bulundurularak, makine öğrenmesi ve derin öğrenme yaklaşımlarının bu alandaki potansiyeli ortaya konulmuştur. Bu kapsamda, VGG16, VGG19, AlexNet, MobileNetV1 ve MobileNetV2 olmak üzere beş farklı ESA mimarisi eğitilmiş ve performansları doğruluk ölçütü üzerinden karşılaştırılmıştır. Deneysel sonuçlar, MobileNetV1 modelinin %99,20 doğruluk oranı ile en yüksek başarıyı sağladığını göstermiştir. Önerilen yöntem, çeşitli performans analizleriyle doğrulanmış ve ayrıca, son kullanıcıların pratik kullanımına yönelik yapay zekâ tabanlı bir web uygulaması geliştirilmiştir (Sazak vd., 2025).

### 3. MATERYAL VE YÖNTEM

#### 3.1. Veri Seti


Araştırmada kullanılan veri seti, Kaggle platformunda yer alan *PlantifyDr Dataset* içerisinde bulunan üzüm yaprağı görüntülerinden oluşmaktadır. Veri seti dört ayrı sınıftan oluşmakta olup her bir sınıfta yaklaşık üç bine yakın görüntü bulunmaktadır. Bu kapsamlı ve dengeli veri yapısı, derin öğrenme modellerinin eğitim ve değerlendirme süreçleri için uygun bir temel oluşturmaktadır (Kaggle, 2024).

Veri seti aşağıdaki sınıflardan oluşmaktadır:

- Üzüm çürük yaprak (grape black rot)
- Üzüm siyah kızamık hastalığı (grape black measles)
- Üzüm Isariopsis yaprak lekesi (grape Isariopsis leaf spot)
- Sağlıklı üzüm yaprağı (grape healthy)

##### 3.1.1. Üzüm çürük yaprak sınıfı

Bu çalışmada kullanılan veri setindeki birinci sınıf, yaklaşık 2360 adet üzüm yaprağı görüntüsünden oluşmakta olup, susuzluk, düşük sıcaklık koşulları (üşütme) veya çevresel stres faktörleri sonucunda ortaya çıkan çürüme belirtilerini içermektedir. Söz konusu belirtiler, yalnızca üzüm bitkisine özgü olmayıp, birçok bitki türünde, özellikle geniş yapraklı bitkilerde, sonbahar mevsiminde daha sık gözlemlenen fizyolojik bir süreçtir. Yaprakların yeterli düzeyde su ve besin alamaması durumunda, hücrelerin canlılığını yitirmesiyle birlikte dokularda kararma meydana gelmekte ve bu durum yaprak yüzeyinde leke oluşumu şeklinde ortaya çıkmaktadır. Bu kapsamda, veri setinde yer alan üzüm çürük yaprak görüntüleri, çevresel etkenlere bağlı olarak gelişen bu tür lezyonların görsel özelliklerini temsil edecek şekilde seçilmiştir (Şekil 11).



Şekil 11. Üzüm çürük yaprak sınıfına ait örnek görseller

### 3.1.2. Üzüm siyah kızamık hastalığı sınıfı


Bu çalışmada kullanılan veri setindeki ikinci sınıf, yaklaşık 2400 adet üzüm yaprağı görüntüsünden oluşmakta olup, incelenen hastalık belirtisinin yaprak yüzeyinde siyah noktalar şeklinde ortaya çıkması nedeniyle literatürde ve halk arasında “kızamık” olarak adlandırılan hastalık türüne odaklanılmıştır. Üzüm bitkisinde görülen bu hastalığın, insanlarda gözlemlenen kızamık hastalığına benzer biçimde yaprak üzerinde belirgin leke oluşumlarıyla karakterize edilen bir pas hastalığı türü olduğu ifade edilmektedir. Söz konusu hastalığın ortaya çıkmasında ve yayılımında, özellikle toprakta bulunan mineral eksikliklerinin önemli bir etken olduğu ve bu koşullar altında hastalığın daha hızlı çoğaldığı belirtilmektedir. Bu bağlamda, veri setinde yer alan üzüm siyah kızamık hastalığı görüntüleri, hastalığın yaprak üzerindeki görsel belirtilerini ayrıntılı biçimde yansıtabilecek şekilde seçilmiştir (Şekil 12).



Şekil 12. Üzüm siyak kızamık hastalığı sınıfına ait örnek görseller

### 3.1.3. Üzüm Isariopsis yaprak lekesi sınıfı


Bu çalışmada kullanılan veri setindeki üçüncü sınıf, yaklaşık 2150 adet üzüm yaprağı görüntüsünden oluşmakta olup, üzüm bitkisinde görülen ve Isariopsis hastalığı olarak bilinen bir mantar kaynaklı yaprak hastalığının belirtilerini içermektedir. Mantar hastalıkları, üzüm başta olmak üzere birçok bitki türü için ciddi bir tehdit oluşturmakta; enfeksiyonun yayılması durumunda bitkilerde ağır hasara, üretim miktarında düşüşe ve ürün kalitesinde belirgin bozulmalara yol açmaktadır. Bu hastalıkların bitkiler arasında son derece bulaşıcı bir yapıya sahip olduğu ve uygun koşullar altında ölümcül etkilere neden olabildiği bilinmektedir. Özellikle mantar enfeksiyonunun bulunduğu tarla veya bağlarda yapılan sulama işlemlerinin, patojenin diğer bitkilere hızla yayılmasına zemin hazırladığı belirtilmekte olup, bu tür durumlarda erken tespit ve hızlı müdahalenin büyük önem taşıdığı vurgulanmaktadır (Şekil 13).



Şekil 13. Üzüm Isariopsis yaprak lekesi sınıfına ait örnek görseller

#### 3.1.4. Sağlıklı üzüm yaprağı sınıfı

Bu çalışmada kullanılan veri setindeki dördüncü sınıf, yaklaşık 2115 adet üzüm yaprağı görüntüsünden oluşmakta olup, hastalık belirtisi göstermeyen, sağlıklı ve dinç yaprak örneklerini içermektedir. Veri setinde yer alan yaprak görüntüleri, farklı boyut ve morfolojik yapıya sahip olacak şekilde seçilmiştir; modelin genelleme yeteneğini artırmak amacıyla yapraklar çeşitli açılardan fotoğraflanmıştır. Bu çeşitlilik sayesinde, kullanılacak sınıflandırma modelinin farklı yaprak yapıları ve çekim koşulları altında da sağlıklı yaprakları doğru bir biçimde tanıyabilmesi hedeflenmiştir (Şekil 14).



Şekil 14. Sağlıklı üzüm yaprağı sınıfına ait örnek görseller

## 3.2. Kullanılan Yazılımlar ve Çalışma Ortamı

### 3.2.1. Python

Python, Guido van Rossum tarafından 1991 yılında geliştirilen, ücretsiz ve açık kaynaklı bir programlama dilidir. Açık kaynak yapısı ve esnek söz dizimi sayesinde kısa sürede geniş bir kullanıcı kitlesine ulaşmış ve farklı disiplinlerde yaygın olarak kullanılmaya başlanmıştır (Göçgün ve Onan, 2021). Günümüzde Python; Java, JavaScript, C ve C++ gibi programlama dilleriyle birlikte yazılım geliştirme süreçlerinde etkin bir biçimde kullanılmaktadır. Özellikle kullanım kolaylığı, okunabilir sözdizimi ve zengin kütüphane desteği sayesinde Python, yapay zekâ, makine öğrenmesi ve derin öğrenme uygulamalarında en çok tercih edilen programlama dillerinden biri hâline gelmiştir. NumPy, Pandas, Scikit-learn, TensorFlow ve PyTorch gibi güçlü kütüphaneler, Python'un bu alanlardaki etkinliğini artırmaktadır. Python tabanlı geliştirme ortamları arasında yer alan Anaconda ve Spyder bütünleşik geliştirme ortamları (IDE), kurulum sırasında Python'un otomatik olarak sisteme entegre edilmesini sağlayarak kullanıcıya önemli kolaylıklar sunmaktadır.

Bu çalışma kapsamında, derin öğrenme tabanlı üzüm yaprağı sınıflandırma işlemleri için Google Colab platformu tercih edilmiş olup, bu ortam yüksek hesaplama gücü ve GPU desteği sağlamaktadır. Kullanılan görüntü veri setleri ise Kaggle platformu üzerinden temin edilmiştir. Google Colab ve Kaggle platformlarının her ikisi de Python tabanlı yapılar üzerine inşa edilmiş olup, veri bilimi ve derin öğrenme uygulamaları için yaygın olarak kullanılmaktadır.

### 3.2.2. Google Colab

Google Colaboratory (Google Colab), Google tarafından sunulan ve özellikle makine öğrenmesi, veri analizi ve bilimsel hesaplamalar için tasarlanmış bulut tabanlı bir Python programlama ortamıdır. Kullanıcılara herhangi bir yazılım kurulumu gerektirmeden, yalnızca bir internet tarayıcısı aracılığıyla kod yazma ve çalıştırma imkânı sunmaktadır. Önceden yapılandırılmış bir Jupyter Notebook altyapısı üzerinde çalışan Google Colab, etkileşimli ve esnek bir geliştirme ortamı sağlaması nedeniyle akademik ve uygulamalı çalışmalarda yaygın olarak tercih edilmektedir.

Google Colab'ın en önemli avantajlarından biri, yerel bilgisayar donanımına ihtiyaç duymaksızın GPU (Grafik İşlemci Birimi) ve TPU (Tensor İşlemci Birimi) gibi yüksek performanslı donanımlara ücretsiz erişim imkânı sunmasıdır. Bu donanım hızlandırıcıları, özellikle derin öğrenme modellerinin eğitimi sırasında ihtiyaç duyulan yoğun hesaplama gücünü sağlamada büyük avantaj sunmaktadır. Yerel bilgisayar kaynaklarının yetersiz kaldığı durumlarda, Colab ortamı üzerinden bu güçlü donanımlara erişilerek büyük veri setleri ve karmaşık modeller etkin bir şekilde eğitilebilmektedir.

Platformun kurulum gerektirmeyen yapısı sayesinde kullanıcıların yerel bilgisayarlarına herhangi bir yazılım yüklemelerine gerek kalmamaktadır. Bir Google hesabı ile giriş yapılması yeterli olup, PyTorch, TensorFlow, Pandas ve NumPy gibi veri bilimi ve derin öğrenme alanında yaygın olarak kullanılan kütüphaneler ortamda önceden yüklü olarak sunulmaktadır. Bu durum, kurulum sürecinde yaşanabilecek teknik sorunları ortadan kaldırmakta ve kullanıcıların doğrudan uygulama geliştirme sürecine odaklanmasına olanak tanımaktadır.

Bu çalışma kapsamında, derin öğrenme tabanlı üzüm yaprağı sınıflandırma işlemleri için Google Colab platformu tercih edilmiştir. Yüksek hesaplama gücü, kurulum gerektirmeyen yapısı, hazır kütüphane desteği ve bulut tabanlı çalışma imkânları sayesinde Google Colab, hem

öğrenme aşamasında olan kullanıcılar hem de akademik araştırmalar yürüten araştırmacılar için etkili ve verimli bir geliştirme ortamı sunmaktadır.

### 3.3. Veri Ön İşleme

Bu aşama, kullanılacak modelin yalnızca eğitim verisi üzerinde başarılı olmasını değil, aynı zamanda daha önce görülmemiş yeni veriler üzerinde de doğru tahminler yapabilmesini sağlamak açısından büyük önem taşımaktadır. Özellikle aşırı öğrenme (overfitting) riskinin azaltılması ve modelin genellenebilirliğinin artırılması, veri hazırlama ve ön işleme adımlarının doğru ve tutarlı bir şekilde uygulanmasına doğrudan bağlıdır. CNN tabanlı modeller, kullanılan verinin kalitesine ve çeşitliliğine son derece duyarlı olduğundan, bu aşamada gerçekleştirilen işlemlerin açık, sistematik ve anlaşılır biçimde yürütülmesi gerekmektedir (Goodfellow vd., 2016).

Görüntü tabanlı derin öğrenme uygulamalarında, ham veriler çoğu zaman farklı çözünürlük, ölçek ve renk uzaylarına sahip olabilmektedir. Bu tür farklılıklar, modelin öğrenme sürecinde tutarsızlıklara yol açabileceğinden, görüntülerin modele uygun hâle getirilmesi zorunlu bir adımdır. Bu çalışmada, üzüm yaprağı görüntüleri boyut, ölçek ve renk özellikleri bakımından ön işleme tabii tutulmuş ve tüm görüntüler model girişine uygun bir formatta standartlaştırılmıştır.

Veri setinde yer alan üzüm yaprakları görüntülerinin farklı çözünürlüklerde olması nedeniyle, tüm görüntüler aynı boyuta yeniden ölçeklendirilmiştir. Bu işlem, CNN modellerinin sabit giriş boyutu gereksinimini karşılamakta ve katmanlar arası hesaplamaların tutarlı bir biçimde gerçekleştirilmesini sağlamaktadır. Literatürde, birçok önceden eğitilmiş CNN mimarisinin giriş boyutu olarak  $224 \times 224$  piksel çözünürlüğü kullandığı bilinmektedir (He vd., 2016). Bu çalışmada birden fazla CNN mimarisi kullanılarak karşılaştırmalı analiz yapılacağından, tüm modellerin aynı veri girişi koşulları altında eğitilmesi hedeflenmiştir. Bu doğrultuda, görüntü boyutu  $224 \times 224$  piksel olarak belirlenmiş ve eğitim sürecinde kullanılan batch size değeri 32 olarak seçilmiştir. Bu parametreler, hem model performansının dengeli bir şekilde değerlendirilmesini hem de hesaplama maliyetinin kontrol altında tutulmasını sağlamaktadır.

Veri seti, model performansının güvenilir bir şekilde değerlendirilebilmesi amacıyla %80 eğitim (train) ve %20 test (test) olmak üzere iki temel alt kümeye ayrılmıştır. Klasör yapısı,

TensorFlow ve Keras gibi derin öğrenme kütüphanelerinin gereksinimlerine uygun olarak düzenlenmiş ve veri setinin otomatik olarak modele tanıtılması sağlanmıştır. Bu yapı sayesinde veri ön işleme, eğitim ve değerlendirme süreçleri bütüncül bir şekilde gerçekleştirilmiş; modelin öğrenme süreci ile performans analizi birbirinden bağımsız olarak yürütülerek elde edilen sonuçların geçerliliği artırılmıştır. Oluşturulan veri altyapısı ve çalışma ortamı, üzüm yaprak hastalıklarının derin öğrenme tabanlı modeller ile etkin bir şekilde sınıflandırılmasına olanak sağlayan sağlam bir temel oluşturmuştur.

### **3.4. Normalizasyon**

Normalizasyon, CNN tabanlı modellerin doğru ve kararlı bir biçimde öğrenebilmesi açısından en temel ve kritik ön işleme adımlarından biridir. Uygun şekilde gerçekleştirilmeyen bir normalizasyon işlemi, modelin öğrenme sürecini olumsuz yönde etkileyerek hiç öğrenememesine ya da hatalı ve tutarsız sonuçlar üretmesine neden olabilmektedir. Bu durum, özellikle görüntü tabanlı derin öğrenme uygulamalarında, giriş verilerinin sayısal aralıklarının doğrudan ağırlık güncellemelerini etkilemesinden kaynaklanmaktadır (Goodfellow vd., 2016).

Bu çalışmada kullanılan CNN algoritmaları, giriş olarak verilen görüntülere karşı son derece hassas olup, piksel değerlerindeki büyük ölçek farklılıkları öğrenme sürecini zorlaştırabilmektedir. Normalizasyon işleminin temel amacı; modelin sayısal açıdan daha dar ve dengeli bir aralıkta çalışmasını sağlamak, farklı kaynaklardan elde edilen görüntü verilerinin tutarlılığını artırmak ve eğitim sürecinde gerçekleşen ağırlık güncellemelerini daha kararlı hâle getirmektir. Bu sayede, modelin öğrenme hızı artmakta ve daha stabil bir optimizasyon süreci elde edilmektedir (LeCun vd., 1998).

Sayısal görüntüler genellikle Red–Green–Blue (RGB) renk uzayında temsil edilmekte olup, her bir renk kanalı 0 ile 255 arasında değişen piksel değerlerine sahiptir. Bu kapsamda, kırmızı (R), yeşil (G) ve mavi (B) kanalları, görüntünün renk ve parlaklık bilgisini oluşturan temel bileşenlerdir. Ancak bu geniş aralık, derin öğrenme modelleri için hesaplama açısından dezavantaj oluşturabilmekte ve gradyan tabanlı öğrenme algoritmalarının etkinliğini azaltabilmektedir.

Bu nedenle, çalışmada kullanılan CNN modellerine girdi olarak verilen görüntülerin piksel değerleri daha küçük ve yönetilebilir bir aralığa dönüştürülmüştür. Normalizasyon işlemiyle, 0–255 aralığındaki RGB piksel değerleri genellikle 0–1 ya da –1 ile 1 aralığına ölçeklendirilerek modele sunulmaktadır. Bu yaklaşım, özellikle çok katmanlı CNN mimarilerinde gradyanların dengeli biçimde yayılmasına katkı sağlamakta ve öğrenme sürecinin daha hızlı ve etkili gerçekleşmesini mümkün kılmaktadır (Goodfellow vd., 2016). CNN modellerinde tüm piksel değerleri 0-1 aralığına getirilmiştir (Denklem 5).

$$x_{norm} = \frac{x}{255} \quad (5)$$

Denklem 5’te, x giriş görüntüsünü temsil etmektedir.

### 3.5. Model Tanımlama

Bu aşamada, çalışmada kullanılan CNN modelinin görsel verilerden nasıl öğrenme gerçekleştireceği ve bu öğrenme sürecini hangi yapısal bileşenler aracılığıyla yürüteceği belirlenmektedir. Önceki adımlarda normalize edilerek modele hazır hâle getirilen görüntü verileri, CNN mimarisi aracılığıyla işlenerek anlamlı özniteliklere dönüştürülmektedir. Bu süreç, modelin yalnızca ham piksel değerlerini değil, bu değerler arasındaki uzamsal ilişkileri de öğrenmesini mümkün kılmaktadır (Goodfellow vd., 2016).

CNN mimarisi temel olarak birden fazla katmandan oluşan hiyerarşik bir yapıya sahiptir ve her katman öğrenme sürecinde farklı bir işlev üstlenmektedir. Bu katmanlar birlikte çalışarak, giriş görüntüsünden başlayıp nihai sınıflandırma kararına kadar uzanan bir bilgi akışı oluşturmaktadır. Özellikle görüntü tabanlı problemlerde, CNN’lerin bu çok katmanlı yapısı, görsel verilerdeki karmaşık örüntülerin etkin bir şekilde modellenmesini sağlamaktadır (LeCun vd., 1998). Bir CNN mimarisi temel olarak evrişim, havuzlama, düzleştirme, tam bağlantı ve unutma katmanlarından oluşmaktadır (Goodfellow vd., 2016; LeCun vd., 1998; Bishop, 2006; Bishop, 2006). CNN mimarisinde kullanılan katman türleri, bu katmanların temel işlevleri ve örnek parametreleri Tablo 1’de sunulmuştur.

Tablo 1. CNN katman türleri, temel işlevleri ve örnek parametreler

Katman Türü	Temel İşlevi	Örnek Parametreler
Conv2D	Görüntüde özellik (feature) çıkarır.	filters=32, kernel_size=(3,3)
MaxPooling2D	Boyutu yarıya indirir.	pool_size=(2,2)
Dropout	Rastgele nöron kapatır (overfitting önler).	rate=0.3/0.4
Dense	Öğrenilen özellikleri sınıflara ayırır.	units=256

CNN mimarisinde yer alan bu katmanlar birlikte çalışarak, üzüm yaprağı görüntülerinden hastalıklara özgü ayırt edici özelliklerin öğrenilmesini ve doğru sınıflandırma kararlarının verilmesini mümkün kılmaktadır. Model mimarisinin bu şekilde yapılandırılması hem öğrenme sürecinin etkinliğini artırmakta hem de elde edilen sonuçların güvenilirliğini desteklemektedir.

### 3.6. Modelin Derlenmesi (Compile)

Modelin derlenmesi (compile) aşaması, oluşturulan CNN mimarisinin öğrenme sürecinin nasıl işleyeceğini tanımlayan en kritik adımlardan biridir. Bu aşamada modelin, eğitim sırasında hatayı nasıl hesaplayacağı, bu hataya göre ağırlıkları nasıl güncelleyeceği ve performansının hangi ölçütler üzerinden değerlendirileceği belirlenmektedir. Başka bir ifadeyle, derleme işlemi, modelin öğrenme stratejisinin resmî olarak tanımlandığı aşamayı temsil etmektedir (Goodfellow vd., 2016).

Derleme sürecinde tanımlanan en önemli parametrelerden biri öğrenme oranı (learning rate) parametresidir. Öğrenme oranı, modelin eğitim sırasında ağırlıklarını ne kadar hızlı ve hangi adımlarla güncelleyeceğini belirleyen temel bir hiperparametredir. Çok yüksek öğrenme oranları modelin kararsız öğrenmesine ve minimum noktayı kaçırmaya neden olurken, çok düşük öğrenme oranları öğrenme sürecini yavaşlatmakta ve modelin optimum çözüme ulaşmasını zorlaştırabilmektedir (Bishop, 2006).

Bu çalışmada kullanılan CNN modelleri için öğrenme oranı 0.0001 olarak belirlenmiştir. Bu değer, derin ve karmaşık mimarilerde daha kararlı bir öğrenme süreci sağlamak ve özellikle önceden eğitilmiş ağlar (pretrained models) kullanıldığında ağırlıkların aşırı güncellenmesini önlemektedir. Literatürde, küçük öğrenme oranlarının görüntü tabanlı derin öğrenme uygulamalarında daha istikrarlı sonuçlar verdiği sıklıkla vurgulanmaktadır (He vd., 2016).

Tablo 2. CNN model derleme bileşenleri

Bileşen	Temel İşlevi
Optimizasyon (Optimizer) Algoritması	Modelin ağırlıklarını güncelleme yöntemini belirler.
Kayıp Fonksiyonu (Loss Function)	Tahmin edilen değerle gerçek değer arasındaki farkı ölçer.
Ölçütler (Metrics)	Eğitim ve test sürecinde başarıyı ölçmek için kullanılır.

Modelin derlenmesi aşamasında tanımlanan bileşenler, CNN mimarisinin öğrenme sürecini doğrudan etkileyen temel unsurlar arasında yer almaktadır. Bu bileşenler; optimizasyon (optimizer) algoritması, kayıp fonksiyonu (loss function) ve performans ölçütleri (metrics) olarak üç ana başlık altında ele alınmaktadır (Tablo 2).

Optimizasyon algoritması, modelin eğitim sürecinde ağırlıklarını her iterasyonda güncelleyerek kayıp fonksiyonunu minimize etmeyi amaçlamaktadır. Bu çalışmada, derin öğrenme uygulamalarında yaygın olarak tercih edilen adaptive moment estimation (Adam) optimizasyon algoritması kullanılmıştır. Adam algoritması, adaptif öğrenme oranı ve momentum kavramlarını bir araya getirerek hem hızlı hem de dengeli bir öğrenme süreci sunmaktadır. Bu özellikleri sayesinde özellikle karmaşık ve derin CNN mimarilerinde daha kararlı sonuçlar elde edilmesini sağlamaktadır (Kingma ve Ba, 2014)

Kayıp fonksiyonu, modelin tahmin ettiği çıktı değerleri ile gerçek etiketler arasındaki farkı nicel olarak ölçen matematiksel bir fonksiyondur. Kayıp fonksiyonu, modelin ne ölçüde hata yaptığını belirleyerek ağırlık güncellemelerinin yönünü tayin etmektedir. CNN tabanlı görüntü sınıflandırma problemlerinde kullanılan kayıp fonksiyonu, problemin sınıf sayısına ve yapısına bağlı olarak değişiklik göstermektedir. Özellikle çok sınıflı sınıflandırma problemlerinde categorical cross-entropy gibi fonksiyonlar yaygın olarak tercih edilmektedir (Goodfellow vd., 2016).

Optimizer, loss fonksiyonu ve metriklerin doğru şekilde seçilmesi, CNN tabanlı üzüm yaprağı hastalık tespiti modelinin hem eğitim sürecindeki kararlılığını hem de elde edilen sonuçların güvenilirliğini doğrudan etkilemektedir. Bu bileşenlerin birlikte ve dengeli bir biçimde tanımlanması, model performansının sağlıklı bir şekilde değerlendirilmesine olanak tanımaktadır.

### 3.7. Karmaşıklık Matrisi

Bir sınıflandırma modelinin performansı Tablo 3'te verilen karışıklık matrisi tablosundaki dört temel sonuç üzerinden değerlendirilir.

Tablo 3. Karmaşıklık matrisi tablosu

	<b>Gerçek Pozitif</b>	<b>Gerçek Negatif</b>
<b>Tahmin Pozitif</b>	True Positive (TP)	False Positive (FP)
<b>Tahmin Negatif</b>	False Negative (FN)	True Negative (TN)

Tablo 3'teki, Doğru Pozitif (True Positive – TP) gerçek pozitif bir örneğin doğru tahmin edilmesini, Yanlış Pozitif (False Positive – FP) gerçek negatif bir örneğin pozitif olarak tahmin edilmesini, Yanlış Negatif (False Negative – FN) gerçek pozitif bir örneğin negatif olarak tahmin edilmesini, Doğru Negatif (True Negative – TN) gerçek negatif bir örneğin doğru tahmin edilmesini göstermektedir (Kohavi ve Provost, 1998).

### 3.8. Performans Değerlendirme Kriterleri

Performans ölçütleri, modelin eğitim ve değerlendirme sürecindeki başarısını izlemek amacıyla kullanılan göstergelerdir. Bir çalışmada farklı derin öğrenme algoritmalarını karşılaştırabilmek için bazı metrik yapılar bulunması ve bunların hesaplamaları yapılması gerekmektedir. Bunlar; doğruluk, keskinlik ve duyarlılıktır. Bulunan bu değerler hesaplama ile F1-skoru hesaplamasında kullanılır. Yapay zekâ performans ölçütleri” (özellikle makine öğrenmesi ve derin öğrenme modellerinde) bir modelin doğruluk, kesinlik, duyarlılık, F1-skoru, ROC eğrisi gibi metriklerle ne kadar iyi çalıştığını değerlendirmek için kullanılır (Sokolova ve Lapalme, 2009; Fawcett, 2006).

Bu çalışmada kullanılan CNN modellerinin performansı, accuracy başta olmak üzere precision, recall, F1-score ve ROC eğrileri gibi temel metrikler üzerinden değerlendirilmektedir. Eğitim süreci sırasında, hesaplama maliyetini azaltmak ve öğrenme sürecini daha net gözlemleyebilmek amacıyla yalnızca doğruluk metriği takip edilmiştir. Diğer performans ölçütleri ise model eğitimi tamamlandıktan sonra test verisi üzerinde hesaplanarak, modelin genellenebilirliği ve sınıflandırma başarısı daha ayrıntılı biçimde analiz edilmiştir.

### 3.8.1. Doğruluk (accuracy)

Doğruluk, tüm bulunan sonuçlar ile gerçek değerlerin oranı sonucunda bulunur. Doğru pozitif (TP) ve doğru negatif (TN) değerlerinin toplamının, doğru pozitif (TP), yanlış pozitif (FP), doğru negatif (TN) ve yanlış negatif (FN) toplamına bölümü ile bulunur (Denklem 6). Basit ve genel performans için uygundur (Han vd., 2012).

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (6)$$

### 3.8.2. Kesinlik / hassasiyet (precision)

Kesinlik, doğru pozitif (TP) tahmin edilen durumların, doğru pozitif (TP) tahmin edilen durumlar ve yanlış pozitif (FP) tahmin edilen durumların toplamına bölümü ile bulunur (Denklem 7). Modelin pozitif olarak tahmin ettiklerinin gerçek pozitif olma oranlarını gösterir. Yanlış pozitiflerin (FP) önemli olduğu durumlarda kullanılır (Powers, 2020).

$$Precision = \frac{TP}{TP+FP} \quad (7)$$

### 3.8.3. Duyarlılık (recall)

Duyarlılık, doğru pozitif (TP) tahmin edilen durumların, doğru pozitif (TP) tahmin edilen durumlar ve yanlış negatif (FN) tahmin edilen durumların toplamına oranı ile bulunur (Denklem 8). Gerçek pozitiflerin ne kadarının doğru tahmin edildiğini gösterir. Yanlış negatiflerin (FN) önemli oldukları zamanlarda kullanılır (Powers, 2020).

$$Recall = \frac{TP}{TP+FN} \quad (8)$$

### 3.8.4. Özgünlük (specificity)

Özgünlük, gerçek negatiflerin ne kadarının doğru tahmin edildiğini ölçer (Denklem 9). Sağlıklı örnekleri doğru tanıma başarısını gösterir (Sokolova ve Lapalme, 2009).

$$Specificity = \frac{TN}{TN+FP} \quad (9)$$

### 3.8.5. F1-skoru (F1-score)

F1-skoru, bulunan kesinlik (precision) ile duyarlılık (recall) değerlerinin harmonik ortalaması alınması sonucunda bulunur (Denklem 10). Dengesiz veri kümelerinde doğruluktan (accuracy) daha güvenilir bir ölçüt olduğu görülmektedir (Sokolova ve Lapalme, 2009).

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (10)$$

### 3.9. ROC Eğrisi

Receiver operating characteristic (ROC) eğrisi, bir sınıflandırma modelinin farklı eşik (threshold) değerleri altında gösterdiği performansı değerlendirmek amacıyla kullanılan grafiksel bir ölçüttür. Bu eğri, doğru pozitif oranı (true positive rate – TPR) (Denklem 11) ile yanlış pozitif oranı (false positive rate – FPR) (Denklem 12) arasındaki ilişkiyi ortaya koyar. Eşik değerinin değiştirilmesiyle birlikte TPR ve FPR değerleri değişmekte, böylece modelin ayırt edicilik gücü kapsamlı biçimde analiz edilebilmektedir. ROC eğrisi altında kalan alan (AUC), modelin genel sınıflandırma başarısını özetleyen önemli bir performans göstergesi olarak kabul edilmektedir (Fawcett, 2006).

$$TPR = \frac{TP}{TP+FN} \quad (11)$$

$$FPR = \frac{FP}{FP+TN} \quad (12)$$

### 3.10. Kayıp Fonksiyonları (Loss Functions)

Kayıp fonksiyonları, bir modelin tahmin ettiği çıktılar ile gerçek etiketler arasındaki farkı nicel olarak ölçen matematiksel fonksiyonlardır. Modelin eğitim sürecinde yaptığı hatanın büyüklüğünü ifade eden bu fonksiyonlar, öğrenme sürecinin yönlendirilmesinde kritik bir rol oynar. Eğitim sırasında model parametreleri, kayıp fonksiyonunun minimize edilmesi amacıyla

güncellenir. Dolayısıyla seçilen kayıp fonksiyonu, modelin öğrenme davranışını ve nihai performansını doğrudan etkilemektedir (Goodfellow vd., 2016).

### 3.11. Çoklu Sınıf (Multi-Class) Durumları

Çok sınıflı sınıflandırma problemlerinde, performans ölçütleri her bir sınıf için ayrı ayrı hesaplanmakta ve genel model başarısını yansıtabilmek amacıyla bu değerler çeşitli ortalama alma yöntemleri kullanılarak birleştirilmektedir. Bu kapsamda en yaygın kullanılan ortalama türleri aşağıda açıklanmıştır (Sokolova ve Lapalme, 2009):

- **Makro Ortalama (Macro Average):** Her bir sınıf için hesaplanan performans ölçütlerinin aritmetik ortalamasını alır. Bu yöntemde tüm sınıflara eşit ağırlık verildiğinden, sınıf dengesizliğinin bulunduğu veri setlerinde azınlık sınıflarının performansı daha belirgin biçimde yansıtılmaktadır.
- **Mikro Ortalama (Micro Average):** Tüm sınıflara ait doğru ve yanlış sınıflandırmalar toplu olarak değerlendirilerek performans ölçütleri hesaplanır. Bu yaklaşım, örnek sayısı fazla olan sınıfların modele olan etkisini artırmakta ve genel sınıflandırma başarısını ön plana çıkarmaktadır.
- **Ağırlıklı Ortalama (Weighted Average):** Her bir sınıfın performans ölçütü, o sınıfa ait örnek sayısı dikkate alınarak ağırlıklandırılır. Bu yöntem, sınıf dağılımının dengesiz olduğu durumlarda daha gerçekçi bir genel performans değerlendirmesi sunmaktadır.

## 4. BULGULAR

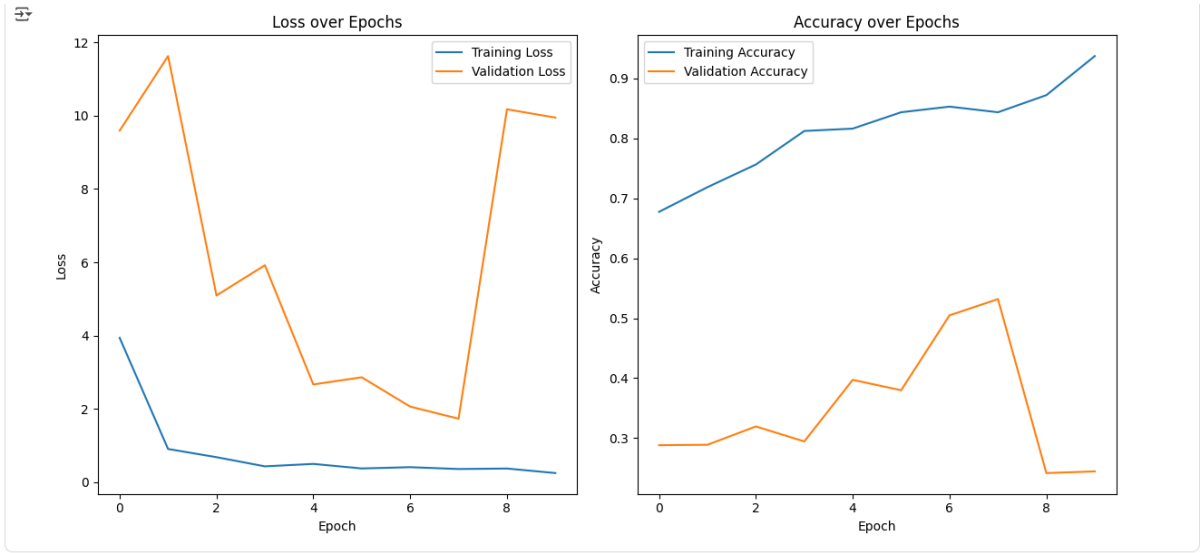
Bu bölümde, üzüm yapraklarında görülen hastalıkların tespiti ve sınıflandırılması, AlexNet, DenseNet121, EfficientNetB3, MobileNetV2 ve ResNet50 gibi CNN tabanlı derin öğrenme modelleri kullanılarak analiz edilmiştir. Kullanılan tüm CNN mimarileri için epoch değeri sırasıyla 20, 50 ve 100 olarak denenmiştir. Epoch sayısının artırılması, modelin eğitim süresini ve öğrenme kapasitesini artırabilmekle birlikte, Google Colab ortamının kullanım süresini de uzatmaktadır. Bu nedenle, model performansı ile hesaplama maliyeti arasında dengeli bir seçim yapılması amaçlanmıştır. Doğruluk ve kayıp grafikleri, accuracy, precision, recall, F1-score değerlendirme ölçütleri, karmaşıklık matrisi ve ROC eğrisi kullanılarak CNN modellerinin üzüm yaprağı hastalıklarını öğrenme ve sınıflandırma performansı analiz edilmiştir. Bu metrikler doğrultusunda, çalışmada kullanılan CNN mimarilerine ait elde edilen sonuç değerleri sırasıyla sunulmuş ve modellerin performansları karşılaştırmalı olarak yorumlanmıştır.

### 4.1. CNN Modellerinin 20 Epoch Eğitim Sonuçları

Bu bölümde, çalışmada ele alınan CNN modellerinin 20 epoch süresince eğitilmesi sonucunda elde edilen performans bulguları ayrı ayrı sunulmuş ve karşılaştırmalı olarak değerlendirilmiştir.

#### 4.1.1. AlexNet modelinin 20 epoch eğitim sonuçları

Üzüm yaprağı hastalığı tespiti için AlexNet modeli ile 20 epoch eğitimler yapılmıştır. Eğitim sonuçlarına ait kayıp ve doğruluk grafikleri Şekil 15'te verilmiştir.



Şekil 15. AlexNet modelinin 20 epoch eğitimi sonucunda elde edilen kayıp ve doğruluk grafikleri

Şekil 15 incelendiğinde, eğitim kaybı (training loss) epoch ilerledikçe düzenli biçimde azalmaktadır. Bu durum modelin eğitim verisi üzerindeki hatasını giderek azalttığını ve temel özellikleri öğrenmeye başladığını göstermektedir. Ancak doğrulama kaybı (validation loss) grafiği incelendiğinde düzensiz ve yüksek dalgalanmalar görülmektedir. Özellikle bazı epochlarda doğrulama kaybının ani şekilde yükselmesi, modelin eğitim verisine uyum sağlarken doğrulama verisi üzerinde aynı başarıyı gösteremediğini ortaya koymaktadır. Bu durum modelin henüz yeterli seviyede genelleme yapamadığını ve öğrenmenin stabil olmadığını göstermektedir. Eğitim doğruluğu (training accuracy) epoch sayısı arttıkça sürekli artış göstermiş ve modelin eğitim verisini giderek daha iyi öğrendiğini ortaya koymuştur. Buna karşılık doğrulama doğruluğu (validation accuracy) düşük seviyelerde kalmış ve belirli epochlardan sonra düşüş göstermiştir. Eğitim ve doğrulama doğruluğu arasındaki farkın giderek açılması, modelin gerçek veri dağılımını tam öğrenemediğini ve sınıflar arası ayrımı yeterince gerçekleştiremediğini göstermektedir. Bu durum AlexNet mimarisinin 20 epoch eğitim süresinde veri setinin karmaşıklığını öğrenmek için yeterli süreye ulaşmadığını göstermektedir.

Ayrıca, AlexNet modelinin 20 epoch eğitimi sonucunda elde ettiği sınıflandırma performansı, accuracy, precision, recall ve F1-score metrikleri temelinde değerlendirilmiş olup, elde edilen sonuçlar Tablo 4'te sınıf bazlı olarak sunulmuştur.

Tablo 4. AlexNet modelinin 20 epoch eğitimi sonucunda elde edilen sınıflandırma performansı

Sınıf	Precision	Recall	F1-Score	Support
Üzüm çürük yaprak	0.41	0.59	0.48	472
Üzüm siyah kızamık hastalığı	1.00	0.09	0.17	480
Üzüm Isariopsis yaprak lekesi	0.75	0.60	0.67	430
Sağlıklı üzüm yaprağı	0.58	1.00	0.73	423
<b>Accuracy</b>			0.56	1805
<b>Macro Avg</b>	0.69	0.57	0.51	1805
<b>Weighted Avg</b>	0.69	0.56	0.50	1805

Tablo 4 incelendiğinde, AlexNet modelinin 20 epoch eğitimi sonucunda %56 doğruluk oranına ulaşıldığı görülmektedir. Elde edilen F1-skorları modelin sınıflar arasında dengeli bir performans sergileyemediğini göstermektedir. Özellikle *üzüm siyah kızamık hastalığı* sınıfında recall değerinin oldukça düşük olması nedeniyle F1-skorunun 0.17 seviyesinde kaldığı dikkat çekmektedir. Buna karşılık sağlıklı yaprak sınıfında yüksek recall değeri elde edilmiş olsa da diğer hastalık sınıflarındaki düşük performans genel başarıyı düşürmüştür. Macro F1-skorunun 0.51 ve weighted F1-skorunun 0.50 olması, modelin tüm sınıfları dengeli şekilde öğrenemediğini ve erken epoch aşamasında yeterli genelleme yeteneğine ulaşamadığını göstermektedir.


AlexNet modelinin 20 epoch eğitimi sonucunda elde ettiği sınıflandırma performansını daha ayrıntılı değerlendirebilmek amacıyla oluşturulan karmaşıklık matrisi sonuçları Şekil 16'da sunulmuştur.

Gerçek Sınıf	Üzüm Çürük Yaprak	Üzüm Siyah Kızamık Hastalığı	Üzüm Isariopsis Yaprak Lekesi	Sağlıklı
Üzüm Çürük Yaprak	280	0	74	118
Üzüm Siyah Kızamık Hastalığı	397	45	12	26
Üzüm Isariopsis Yaprak Lekesi	7	0	260	163
Sağlıklı	0	0	0	423
	Üzüm Çürük Yaprak	Üzüm Siyah Kızamık Hastalığı	Üzüm Isariopsis Yaprak Lekesi	Sağlıklı
	Tahmin Edilen Sınıf			

Şekil 16. AlexNet modelinin 20 epoch eğitimi sonucunda elde edilen karmaşıklık matrisi

Şekil 16’da verilen karmaşıklık matrisi incelendiğinde, AlexNet modelinin bazı sınıfları doğru şekilde ayırt etmekte zorlandığı görülmektedir. *sağlıklı üzüm yaprağı* sınıfında tüm örneklerin doğru sınıflandırılması (423/423) modelin sağlıklı yaprakları yüksek doğrulukla tanıyabildiğini göstermektedir. Buna karşılık hastalıklı sınıflar arasında belirgin karışmalar olduğu dikkat çekmektedir. Özellikle *üzüm siyah kızamık hastalığı* sınıfına ait örneklerin büyük bir kısmının (397 adet) *üzüm çürük yaprak* sınıfı olarak tahmin edilmesi, modelin bu iki hastalık arasındaki görsel özellikleri yeterince ayırt edemediğini göstermektedir. Benzer şekilde *üzüm Isariopsis yaprak lekeli* sınıfına ait bazı örneklerin sağlıklı yaprak olarak sınıflandırılması, modelin hastalık belirtilerini erken epoch aşamasında tam olarak öğrenemediğini ortaya koymaktadır.

Bununla birlikte, AlexNet modelinin 20 epoch eğitimi sonucunda elde edilen ROC eğrisi incelenmiştir. Şekil 17’de modelin sınıflar arasındaki ayırt edicilik performansını gösteren ROC eğrileri sunulmuştur.




Şekil 17. AlexNet modelinin 20 epoch eğitimi sonucunda elde edilen ROC eğrisi

Şekil 17’de verilen AlexNet modeline ait ROC eğrisi incelendiğinde, sınıflar arasında ayırt edicilik performansının farklılık gösterdiği görülmektedir. ROC eğrisi altında kalan alan (AUC) değerleri değerlendirildiğinde, *healthy* (sağlıklı üzüm yaprağı) sınıfı için AUC değerinin 1.00 olması, modelin sağlıklı yaprakları diğer sınıflardan yüksek doğrulukla ayırt edebildiğini göstermektedir. Buna karşılık *black\_measles* (üzüm siyah kızamık hastalığı) sınıfında AUC değerinin 0.94 olması modelin bu sınıfta iyi bir ayırım performansı sergilediğini ortaya koymaktadır. Ancak *Isariopsis\_leaf\_spot* (üzüm *Isariopsis* yaprak lekesi) sınıfında AUC değerinin 0.82 ve *black\_rot* (üzüm çürük yaprak) sınıfında 0.74 seviyesinde kalması, modelin bu hastalık türlerini diğer sınıflardan ayırt etmekte zorlandığını göstermektedir. ROC eğrilerinin ideal sol üst köşeye yeterince yaklaşmaması, modelin özellikle hastalık sınıflarında yanlış pozitif ve yanlış negatif tahminler ürettiğini ortaya koymaktadır.

Genel olarak değerlendirildiğinde, AlexNet modelinin 20 epoch eğitimi sonucunda bazı sınıflarda kabul edilebilir ayırt edicilik performansı göstermesine rağmen tüm sınıflarda dengeli bir sınıflandırma başarısına ulaşamadığı görülmektedir. Eğitim sonucunda elde edilen sınıflandırma performans metrikleri, karmaşıklık matrisi ve ROC eğrisi sonuçlarının birbiri ile uyumlu olarak modelin erken epoch aşamasında yeterli genelleme performansı sağlayamadığını göstermektedir.

#### 4.1.2. DenseNet121 modelinin 20 epoch eğitim sonuçları

Üzüm yaprağı hastalığı tespiti için DenseNet121 modeli ile 20 epoch eğitimler yapılmıştır. Eğitim sonuçlarına ait doğruluk ve kayıp grafikleri Şekil 18’de verilmiştir.



Şekil 18. DenseNet121 modelinin 20 epoch eğitimi sonucunda elde edilen kayıp ve doğruluk grafikleri

Şekil 18 incelendiğinde hem eğitim doğruluğunun hem de doğrulama doğruluğunun ilk epochlardan itibaren hızlı bir artış gösterdiği görülmektedir. Özellikle ilk birkaç epoch içerisinde doğrulama doğruluğunun %90 seviyesine ulaşması, DenseNet121 mimarisinin veri setindeki ayırt edici özellikleri erken aşamada öğrenebildiğini göstermektedir. Epoch ilerledikçe eğitim ve doğrulama doğruluk eğrilerinin birbirine yakın seyretmesi, modelin yalnızca eğitim verisini ezberlemediğini, aynı zamanda doğrulama verisi üzerinde de başarılı bir genelleme gerçekleştirdiğini göstermektedir. Bu durum modelin dengeli bir öğrenme sürecine sahip olduğunu ifade etmektedir. Eğitim kaybı ve doğrulama kaybı değerlerinin epoch ilerledikçe düzenli ve paralel biçimde azalması, öğrenme sürecinin stabil olduğunu göstermektedir. Doğrulama kaybının eğitim kaybından daha düşük seviyelerde seyretmesi, modelin aşırı öğrenme (overfitting) eğilimi göstermediğini ve genelleme yeteneğinin güçlü olduğunu ortaya koymaktadır. Loss eğrilerinde ani sıçramaların bulunmaması, DenseNet121 mimarisinin öğrenme sürecinin kararlı olduğunu desteklemektedir. DenseNet121 modeli 20 epoch gibi nispeten düşük bir eğitim süresinde dahi yüksek doğruluk ve düşük kayıp değerlerine

ulaşarak hızlı ve dengeli bir öğrenme davranışı sergilemiştir. Eğitim ve doğrulama eğrilerinin birbirine yakın ilerlemesi, modelin güçlü genelleme kabiliyetine sahip olduğunu göstermekte ve DenseNet121 mimarisinin çalışmada elde edilen yüksek performansının temel nedenlerinden biri olarak değerlendirilmektedir.

Ayrıca, DenseNet121 modelinin 20 epoch eğitimi sonucunda elde ettiği sınıflandırma performansı, accuracy, precision, recall ve F1-score metrikleri temelinde değerlendirilmiş olup, elde edilen sonuçlar Tablo 5’te sınıf bazlı olarak sunulmuştur.

Tablo 5. DenseNet121 modelinin 20 epoch eğitimi sonucunda elde edilen sınıflandırma performansı

Sınıf	Precision	Recall	F1-Score	Support
Üzüm çürük yaprak	0.98	0.93	0.95	472
Üzüm siyah kızamık hastalığı	0.94	0.98	0.96	480
Üzüm Isariopsis yaprak lekesi	0.99	1.00	1.00	430
Sağlıklı üzüm yaprağı	1.00	1.00	1.00	423
<b>Accuracy</b>			0.98	1805
<b>Macro Avg</b>	0.98	0.98	0.98	1805
<b>Weighted Avg</b>	0.98	0.98	0.98	1805

Tablo 5 incelendiğinde, DenseNet121 modelinin 20 epoch eğitim sonucunda %98 doğruluk oranına ulaştığı görülmektedir. Elde edilen F1-skorları modelin tüm sınıflarda yüksek ve dengeli bir performans sergilediğini göstermektedir. Özellikle *üzüm Isariopsis yaprak lekesi* ve *sağlıklı üzüm yaprağı* sınıflarında F1-skorunun 1.00 seviyesine ulaşması, modelin sınıflar arasındaki ayırt edici özellikleri erken epoch aşamasında dahi başarılı şekilde öğrenebildiğini göstermektedir. Macro ve weighted F1-skorlarının her ikisinin de 0.98 seviyesinde olması, modelin sınıf dengesinden bağımsız olarak tüm sınıflarda benzer performans gösterdiğini ve güçlü bir genelleme yeteneğine sahip olduğunu ortaya koymaktadır.

DenseNet121 modelinin 20 epoch eğitimi sonucunda elde ettiği sınıflandırma performansını daha ayrıntılı değerlendirebilmek amacıyla oluşturulan karmaşıklık matrisi sonuçları Şekil 19’da sunulmuştur.

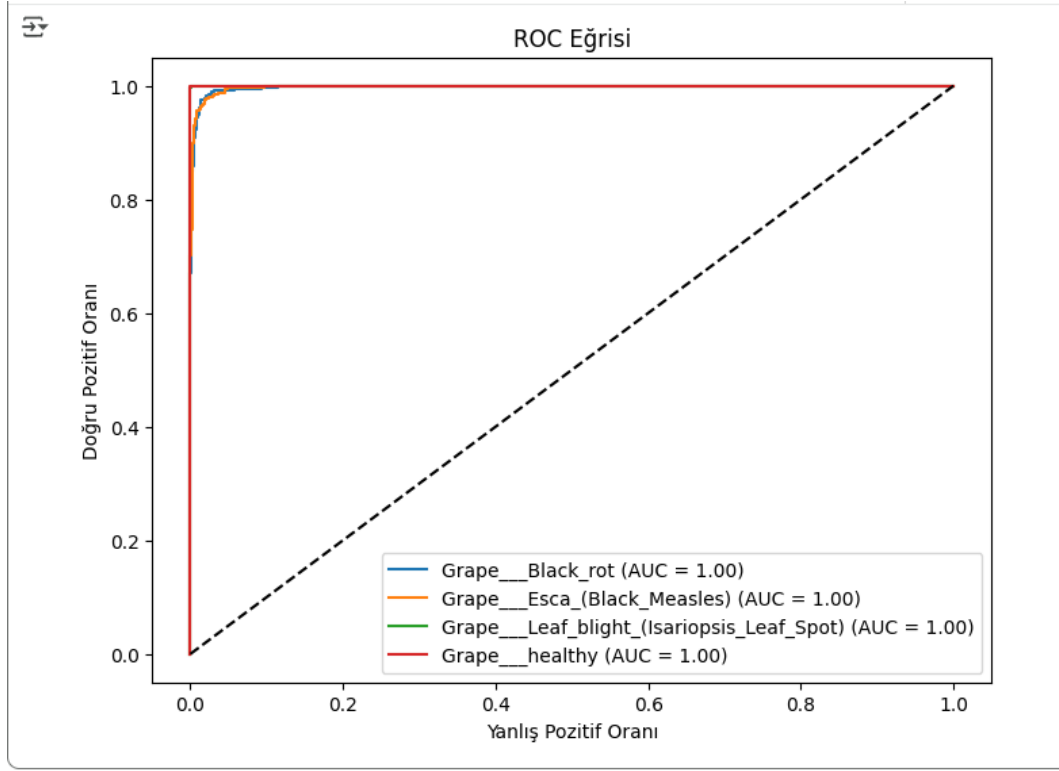
**Karmaşıklık Matrisi**

Gerçek Sınıf	Üzüm Çürük Yaprak	440	29	3	0
	Üzüm Siyah Kızamık Hastalığı	10	470	0	0
	Üzüm Isariopsis Yaprak Lekesi	0	0	430	0
	Sağlıklı	0	0	0	423
		Üzüm Çürük Yaprak	Üzüm Siyah Kızamık Hastalığı	Üzüm Isariopsis Yaprak Lekesi	Sağlıklı
		Tahmin Edilen Sınıf			

Şekil 19. DenseNet121 modelinin 20 epoch eğitimi sonucunda elde edilen karmaşıklık matrisi

Şekil 19’da verilen karmaşıklık matrisi incelendiğinde, DenseNet121 modelinin sınıflar arasında oldukça başarılı bir ayırım gerçekleştirdiği görülmektedir. Diyagonal üzerinde yer alan yüksek değerler, modelin büyük çoğunlukla doğru sınıflandırma yaptığını göstermektedir. Özellikle *üzüm Isariopsis yaprak lekesi* ve *sağlıklı üzüm yaprağı* sınıflarında tüm örneklerin doğru tahmin edilmesi, modelin bu sınıflara ait ayırt edici özellikleri yüksek doğrulukla öğrendiğini ortaya koymaktadır. *üzüm çürük yaprak* sınıfına ait örneklerin küçük bir kısmının (29 adet) *üzüm siyah kızamık hastalığı* olarak sınıflandırılması ve *üzüm siyah kızamık hastalığı* sınıfında sınırlı sayıda yanlış tahmin bulunması, hastalık belirtilerinin görsel olarak benzer özellikler taşımasından kaynaklanabilecek doğal bir karışma olarak değerlendirilebilir. Bununla birlikte diyagonal dışındaki değerlerin oldukça düşük olması, modelin güçlü bir genelleme yeteneğine sahip olduğunu ve sınıflar arası ayırımı yüksek başarıyla gerçekleştirdiğini göstermektedir.

Bununla birlikte, DenseNet121 modelinin 20 epoch eğitimi sonucunda elde edilen ROC eğrisi incelenmiştir. Şekil 20’de modelin sınıflar arasındaki ayırt edicilik performansını gösteren ROC eğrileri sunulmuştur.



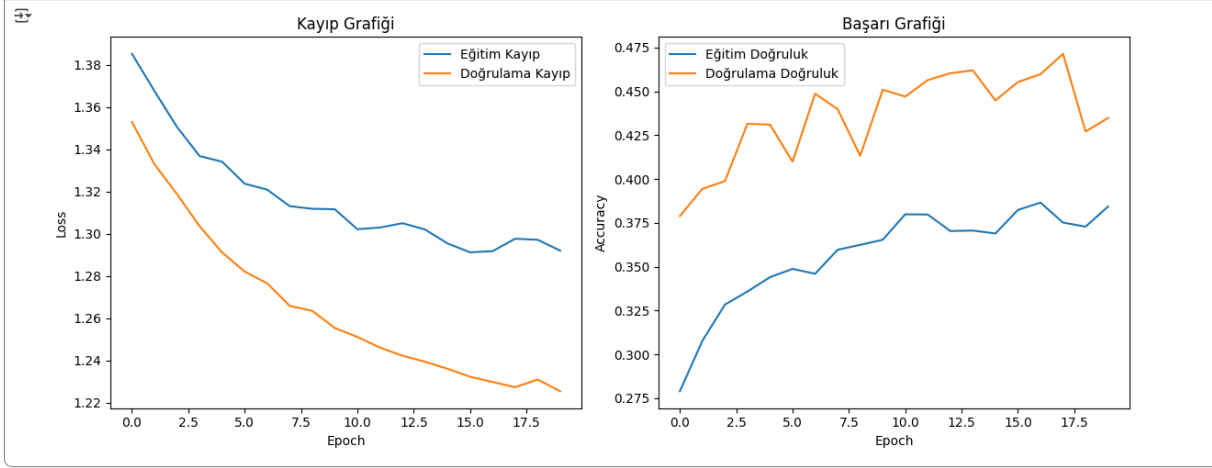
Şekil 20. DenseNet121 modelinin 20 epoch eğitimi sonucunda elde edilen ROC eğrisi

Şekil 20’de verilen DenseNet121 modeline ait ROC eğrisi incelendiğinde, tüm sınıflar için ROC eğrilerinin grafiğin sol üst köşesine çok yakın seyrettiği görülmektedir. ROC eğrisi altında kalan alan (AUC) değerlerinin tüm sınıflar için 1.00 seviyesinde olması, modelin hem pozitif hem de negatif sınıfları ayırt etme konusunda oldukça yüksek bir başarıya ulaştığını göstermektedir. Bu durum modelin yanlış pozitif ve yanlış negatif oranlarını minimum seviyeye indirerek güçlü bir sınıf ayrımı gerçekleştirdiğini ortaya koymaktadır. Özellikle hastalıklı yaprak sınıflarında ROC eğrilerinin hızlı bir şekilde maksimum doğru pozitif oranına ulaşması, modelin ayırt edici özellikleri erken epoch aşamasında dahi başarılı şekilde öğrenebildiğini göstermektedir. ROC eğrilerinin ideal sınıflandırmayı temsil eden üst sınıra çok yakın ilerlemesi, DenseNet121 mimarisinin yüksek genelleme yeteneğine sahip olduğunu desteklemektedir.

Genel olarak değerlendirildiğinde, DenseNet121 modelinin 20 epoch eğitimi sonucunda elde edilen sınıflandırma performans metrikleri, karmaşıklık matrisi ve ROC eğrisi sonuçlarının birbiri ile uyumlu olarak modelin tüm sınıflarda dengeli ve yüksek performans gösterdiğini ortaya koymaktadır.

### 4.1.3. EffecientNetB3 modelinin 20 epoch eğitim sonuçları

Üzüm yaprağı hastalığı tespiti için EffecientNetB3 modeli ile 20 epoch eğitimler yapılmıştır. Eğitim sonuçlarına ait kayıp ve doğruluk grafikleri Şekil 21’de verilmiştir.



Şekil 21. EffecientNetB3 modelinin 20 epoch eğitimi sonucunda elde edilen kayıp ve doğruluk grafikleri

Şekil 21 incelendiğinde, eğitim kaybı ve doğrulama kaybı değerlerinin epoch ilerledikçe düzenli biçimde azaldığı görülmektedir. Bu durum modelin eğitim süreci boyunca öğrenmeye devam ettiğini göstermektedir. Doğrulama kaybının eğitim kaybından daha düşük seviyelerde seyretmesi, modelin aşırı öğrenme (overfitting) eğilimi göstermediğini ve genelleme performansının kabul edilebilir seviyede olduğunu göstermektedir. Ancak kayıp değerlerindeki azalma hızının sınırlı olması, modelin daha yüksek epoch değerlerinde daha iyi performans gösterebileceğine işaret etmektedir. Eğitim doğruluğu epoch ilerledikçe kademeli olarak artarken doğrulama doğruluğunun daha yüksek seviyelerde ancak dalgalı bir yapı gösterdiği görülmektedir. Eğitim doğruluğunun doğrulama doğruluğuna göre daha düşük kalması, modelin henüz veri setinin tüm ayırt edici özelliklerini öğrenme aşamasında olduğunu göstermektedir. Doğrulama doğruluğundaki dalgalanmalar, modelin öğrenme sürecinin tamamen stabilize olmadığını ancak genel olarak artış eğiliminde olduğunu ortaya koymaktadır.

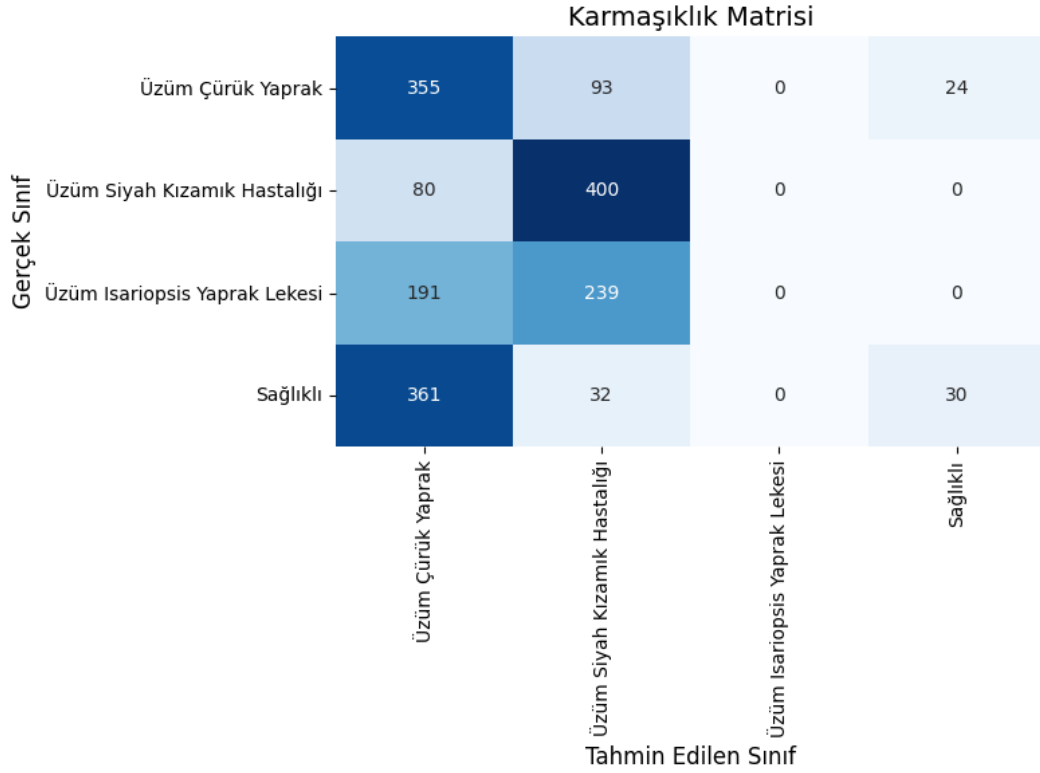
Ayrıca, EffecientNetB3 modelinin 20 epoch eğitimi sonucunda elde ettiği sınıflandırma performansı, accuracy, precision, recall ve F1-score metrikleri temelinde değerlendirilmiş olup, elde edilen sonuçlar Tablo 6’da sınıf bazlı olarak sunulmuştur.

Tablo 6. EfficientNetB3 modelinin 20 epoch eğitimi sonucunda elde edilen sınıflandırma performansı

Sınıf	Precision	Recall	F1-Score	Support
Üzüm çürük yaprak	0.36	0.75	0.49	472
Üzüm siyah kızamık hastalığı	0.52	0.83	0.64	480
Üzüm Isariopsis yaprak lekesi	0.00	0.00	0.00	430
Sağlıklı üzüm yaprağı	0.56	0.07	0.13	423
<b>Accuracy</b>			0.43	1805
<b>Macro Avg</b>	0.36	0.41	0.31	1805
<b>Weighted Avg</b>	0.36	0.43	0.33	1805

Tablo 6 incelendiğinde, EfficientNetB3 modelinin 20 epoch eğitimi sonucunda %43 doğruluk oranına ulaşıldığı görülmektedir. Elde edilen F1-skorları modelin sınıflar arasında dengeli bir performans sergileyemediği göstermektedir. Özellikle *üzüm Isariopsis yaprak lekesi* sınıfında modelin doğru sınıflandırma yapamaması nedeniyle F1-skorunun 0.00 seviyesinde kaldığı dikkat çekmektedir. Benzer şekilde *sağlıklı üzüm yaprağı* sınıfında recall değerinin oldukça düşük olması, modelin bu sınıfı yeterince öğrenemediğini göstermektedir. Macro F1-skorunun 0.31 ve weighted F1-skorunun 0.33 seviyesinde kalması, modelin erken epoch aşamasında veri setinin ayırt edici özelliklerini yeterince öğrenemediğini ve öğrenme sürecinin henüz başlangıç aşamasında olduğunu göstermektedir.


EfficientNetB3 modelinin 20 epoch eğitimi sonucunda elde ettiği sınıflandırma performansını daha ayrıntılı değerlendirebilmek amacıyla oluşturulan karmaşıklık matrisi sonuçları Şekil 22’de sunulmuştur.



Şekil 22. EffecienNetB3 modelinin 20 epoch eğitimi sonucunda elde edilen karmaşıklık matrisi

Şekil 22’de verilen karmaşıklık matrisi incelendiğinde, EfficientNetB3 modelin sınıflar arasında belirgin karışmalar yaptığı ve özellikle bazı hastalık sınıflarını ayırt etmekte zorlandığı görülmektedir. *üzüm çürük yaprak* sınıfına ait örneklerin önemli bir kısmının *üzüm siyah kızamık hastalığı* olarak tahmin edilmesi ve benzer şekilde *üzüm Isariopsis yaprak lekesi* sınıfına ait örneklerin büyük bölümünün diğer hastalık sınıfları ile karışması, modelin erken epoch aşamasında ayırt edici özellikleri yeterince öğrenemediğini göstermektedir. Özellikle *üzüm Isariopsis yaprak lekesi* sınıfında doğru tahmin değerinin bulunmaması, bu sınıfa ait özelliklerin model tarafından henüz öğrenilemediğini ortaya koymaktadır. Ayrıca sağlıklı yaprak sınıfının da büyük oranda hastalıklı sınıflar ile karışması, modelin genel genelleme performansının düşük olduğunu göstermektedir.

Bununla birlikte, EfficientNetB3 modelinin 20 epoch eğitimi sonucunda elde edilen ROC eğrisi incelenmiştir. Şekil 23’te modelin sınıflar arasındaki ayırt edicilik performansını gösteren ROC eğrileri sunulmuştur.



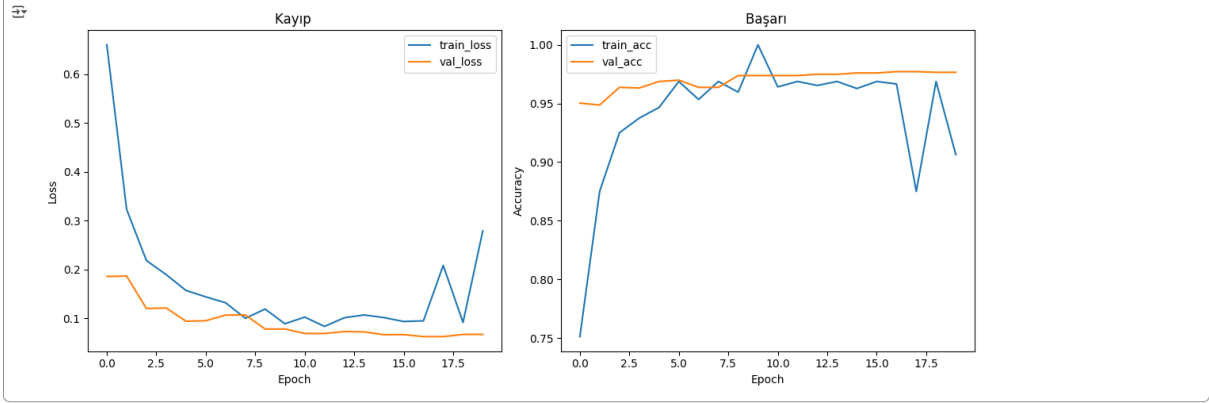
Şekil 23. EffecienNetB3 modelinin 20 epoch eğitimi sonucunda elde edilen ROC eğrisi

Şekil 23'te verilen EfficientNetB3 modeline ait ROC eğrisi incelendiğinde, sınıflar arasında ayırt edicilik performansının farklı seviyelerde olduğu görülmektedir. ROC eğrisi altında kalan alan (AUC) değerleri değerlendirildiğinde, *black\_measles* (üzüm siyah kızamık hastalığı) sınıfı için AUC değerinin 0.824 ve *healthy* (sağlıklı üzüm yaprağı) sınıfı için 0.810 seviyesinde olması, modelin bu sınıfları diğer sınıflara göre daha başarılı şekilde ayırt edebildiğini göstermektedir. Buna karşılık *black\_rot* (üzüm çürük yaprak) sınıfında AUC değerinin 0.687 ve *Isariopsis\_leaf\_spot* (üzüm Isariopsis yaprak lekesi) sınıfında 0.651 seviyesinde kalması, modelin bu hastalık türlerinde yeterli ayırım performansına ulaşamadığını göstermektedir. ROC eğrilerinin ideal sınıflandırmayı temsil eden sol üst köşeye yeterince yaklaşmaması ve eğrilerin diyagonal çizgiye göre sınırlı bir iyileşme göstermesi, modelin erken epoch aşamasında yanlış pozitif ve yanlış negatif oranlarının yüksek olduğunu ortaya koymaktadır.

Genel olarak değerlendirildiğinde, EfficientNetB3 modelinin 20 epoch eğitimi sürecinde öğrenme aşamasında olduğu, sınıflandırma performans metrikleri, karmaşıklık matrisi ve ROC eğrisi sonuçlarının birbiri ile uyumlu olarak modelin daha yüksek epoch değerlerinde performansını artırabileceğini gösterdiği sonucuna ulaşılmıştır.

#### 4.1.4. MobileNetV2 modelinin 20 epoch eğitim sonuçları

Üzüm yaprağı hastalığı tespiti için MobileNetV2 modeli ile 20 epoch eğitimler yapılmıştır. Eğitim sonuçlarına ait kayıp ve doğruluk grafikleri Şekil 24'te verilmiştir.



Şekil 24. MobileNetV2 modelinin 20 epoch eğitimi sonucunda elde edilen kayıp ve doğruluk grafikleri

Şekil 24 incelendiğinde, eğitim kaybının ilk epochlarda hızlı bir şekilde düşmesi, modelin veri setindeki temel özellikleri kısa sürede öğrenebildiğini göstermektedir. İlerleyen epochlarda eğitim kaybının düşük seviyelerde stabil hale gelmesi, öğrenmenin büyük ölçüde tamamlandığını ifade etmektedir. Doğrulama kaybının eğitim kaybına yakın ve daha düşük seviyelerde seyretmesi, modelin aşırı öğrenme (overfitting) eğilimi göstermediğini ve genelleme performansının güçlü olduğunu göstermektedir. Son epochlarda görülen küçük dalgalanmalar ise eğitim sürecinde normal kabul edilen değişimlerdir. Eğitim doğruluğu ilk epochlardan itibaren hızlı bir artış göstermiş ve kısa sürede yüksek seviyelere ulaşmıştır. Doğrulama doğruluğunun eğitim doğruluğuna oldukça yakın seyretmesi, modelin eğitim verisini ezberlemek yerine genel özellikleri öğrenebildiğini göstermektedir. Epoch ilerledikçe doğruluk değerlerinin belirli bir seviyede sabitlenmesi, modelin erken aşamada optimum öğrenme seviyesine yaklaştığını ifade etmektedir.

Ayrıca, MobileNetV2 modelinin 20 epoch eğitimi sonucunda elde ettiği sınıflandırma performansı, accuracy, precision, recall ve F1-score metrikleri temelinde değerlendirilmiş olup, elde edilen sonuçlar Tablo 7'de sınıf bazlı olarak sunulmuştur.

Tablo 7. MobileNetV2 modelinin 20 epoch eğitimi sonucunda elde edilen sınıflandırma performansı

Sınıf	Precision	Recall	F1-Score	Support
Üzüm çürük yaprak	0.9635	0.9513	0.9574	472
Üzüm siyah kızamık hastalığı	0.9510	0.9708	0.9608	480
Üzüm Isariopsis yaprak lekesi	1.0000	0.9907	0.9953	430
Sağlıklı üzüm yaprağı	1.0000	1.0000	1.0000	423
<b>Accuracy</b>			0.9773	1805
<b>Macro Avg</b>	0.9786	0.9782	0.9784	1805
<b>Weighted Avg</b>	0.9774	0.9773	0.9773	1805

Tablo 7 incelendiğinde, MobileNetV2 modelinin 20 epoch eğitimi sonucunda %97.73 doğruluk oranına ulaşıldığı görülmektedir. Elde edilen F1-skorları modelin tüm sınıflarda yüksek ve dengeli bir performans sergilediği görülmektedir. Özellikle *üzüm Isariopsis yaprak lekesi* ve *sağlıklı üzüm yaprağı* sınıflarında F1-skorlarının 0.99 ve 1.00 seviyelerine ulaşması, modelin sınıflar arası ayırt edici özellikleri erken epoch aşamasında başarıyla öğrendiğini göstermektedir. Macro ve weighted F1-skorlarının sırasıyla 0.9784 ve 0.9773 seviyelerinde olması, sınıf dengesinden bağımsız olarak modelin genelleme yeteneğinin güçlü olduğunu ortaya koymaktadır.

MobileNetV2 modelinin 20 epoch eğitimi sonucunda elde ettiği sınıflandırma performansını daha ayrıntılı değerlendirebilmek amacıyla oluşturulan karmaşıklık matrisi sonuçları Şekil 25'te sunulmuştur.

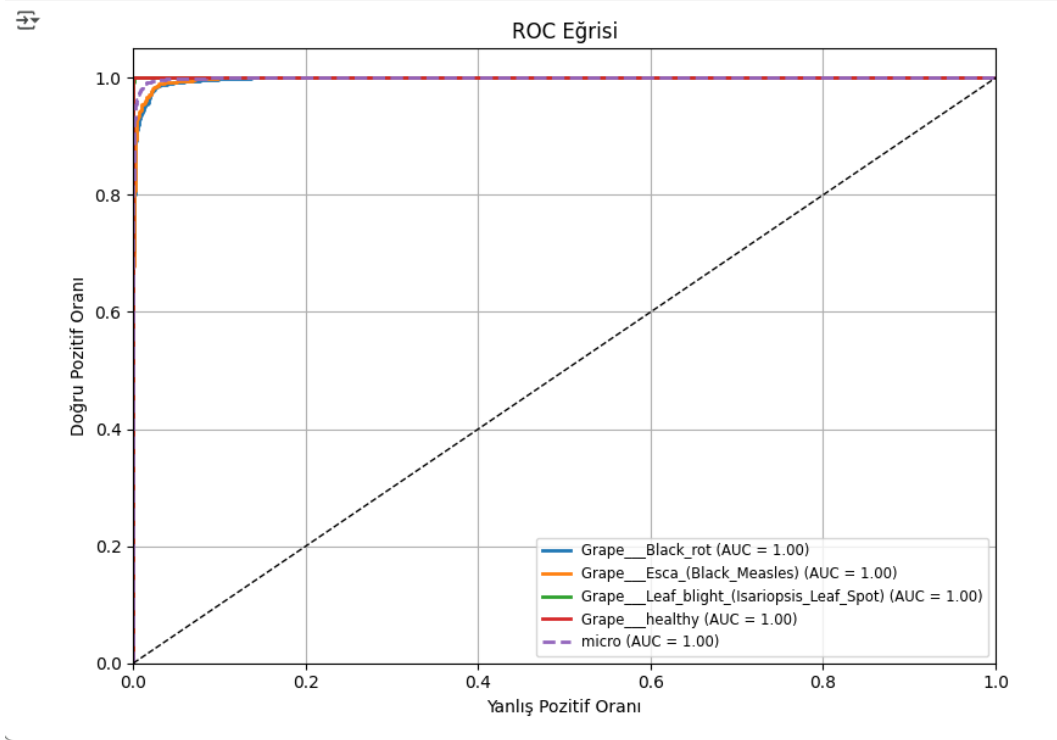
**Karmaşıklık Matrisi**

Gerçek Sınıf	Üzüm Çürük Yaprak	449	23	0	0
	Üzüm Siyah Kızamık Hastalığı	14	466	0	0
	Üzüm Isariopsis Yaprak Lekesi	3	1	426	0
	Sağlıklı	0	0	0	423
		Üzüm Çürük Yaprak	Üzüm Siyah Kızamık Hastalığı	Üzüm Isariopsis Yaprak Lekesi	Sağlıklı
		Tahmin Edilen Sınıf			

Şekil 25. MobileNetV2 modelinin 20 epoch eğitimi sonucunda elde edilen karmaşıklık matrisi

Şekil 25’te verilen karmaşıklık matrisi incelendiğinde, MobileNetV2 modelin tüm sınıflarda oldukça yüksek doğrulukla sınıflandırma gerçekleştirdiği görülmektedir. Diyagonal üzerinde yer alan yüksek değerler, modelin gerçek sınıfları büyük oranda doğru tahmin ettiğini göstermektedir. Özellikle *üzüm Isariopsis yaprak lekesi* ve *sağlıklı üzüm yaprağı* sınıflarında neredeyse tüm örneklerin doğru sınıflandırılması, modelin bu sınıflara ait ayırt edici özellikleri başarılı bir şekilde öğrendiğini ortaya koymaktadır. *üzüm çürük yaprak* ve *üzüm siyah kızamık hastalığı* sınıfları arasında sınırlı sayıda yanlış sınıflandırma bulunmakla birlikte, bu durum hastalık belirtilerinin görsel olarak benzer özellikler taşımasından kaynaklanan doğal bir karışma olarak değerlendirilebilir. Diyagonal dışındaki değerlerin oldukça düşük olması, modelin güçlü bir genelleme yeteneğine sahip olduğunu ve erken epoch aşamasında dahi stabil bir öğrenme performansı sergilediğini göstermektedir.

Bununla birlikte, MobileNetV2 modelinin 20 epoch eğitimi sonucunda elde edilen ROC eğrisi incelenmiştir. Şekil 26’da modelin sınıflar arasındaki ayırt edicilik performansını gösteren ROC eğrileri sunulmuştur.




Şekil 26. MobileNetV2 modelinin 20 epoch eğitimi sonucunda elde edilen ROC eğrisi

Şekil 26’da verilen MobileNetV2 modeline ait ROC eğrisi incelendiğinde, tüm sınıflara ait eğrilerin grafiğin sol üst köşesine oldukça yakın bir şekilde ilerlediği görülmektedir. ROC eğrisi altında kalan alan (AUC) değerlerinin tüm sınıflar için 1.00 seviyesinde olması, modelin pozitif ve negatif sınıfları ayırt etme konusunda çok yüksek bir başarıya ulaştığını göstermektedir. Bu durum, modelin yanlış pozitif ve yanlış negatif oranlarını minimum seviyeye indirerek güçlü bir sınıflandırma performansı sergilediğini ortaya koymaktadır. ROC eğrilerinin ideal sınıflandırma davranışını temsil eden üst sınıra yakın seyretmesi, modelin erken epoch aşamasında dahi ayırt edici özellikleri başarılı şekilde öğrenebildiğini ve yüksek genelleme performansı sağladığını göstermektedir.

Genel olarak değerlendirildiğinde, MobileNetV2 modelinin 20 epoch eğitimi sonucunda elde edilen sınıflandırma performans metrikleri, karmaşıklık matrisi ve ROC eğrisi sonuçlarının birbiri ile uyumlu olarak yüksek ayırt edicilik performansı sergilediği ve düşük hesaplama maliyetine rağmen güçlü bir sınıflandırma başarısı elde ettiği görülmektedir. Bu durum MobileNetV2 mimarisinin gerçek zamanlı ve kaynak kısıtlı uygulamalarda kullanılabilirliğini desteklemektedir.

#### 4.1.5. ResNet50 modelinin 20 epoch eğitim sonuçları

Üzüm yaprağı hastalığı tespiti için ResNet50 modeli ile 20 epoch eğitimler yapılmıştır. Eğitim sonuçlarına ait doğruluk ve kayıp grafikleri Şekil 27’de verilmiştir.



Şekil 27. ResNet50 modelinin 20 epoch eğitimi sonucunda elde edilen kayıp ve doğruluk grafikleri

Şekil 27 incelendiğinde, eğitim doğruluğu epoch ilerledikçe düzenli bir artış göstermekte ve modelin veri setindeki özellikleri kademeli olarak öğrendiğini ortaya koymaktadır. Doğrulama doğruluğu ise eğitim doğruluğundan daha yüksek seviyelerde seyretmekte ancak belirli epoch aralıklarında dalgalanmalar göstermektedir. Bu durum modelin genel özellikleri öğrenmeye başladığını ancak öğrenme sürecinin henüz tamamen stabilize olmadığını göstermektedir. ResNet50'nin derin mimari yapısı nedeniyle daha fazla epoch sayısına ihtiyaç duyduğu söylenebilir. Eğitim kaybı ve doğrulama kaybı değerleri epoch ilerledikçe düzenli biçimde azalmaktadır. Bu durum modelin öğrenme sürecinin doğru yönde ilerlediğini göstermektedir. Doğrulama kaybının eğitim kaybından daha düşük seviyelerde seyretmesi, modelin aşırı öğrenme (overfitting) eğilimi göstermediğini ve genelleme performansının kabul edilebilir düzeyde olduğunu göstermektedir. Ancak kayıp değerlerinin hâlâ düşmeye devam etmesi, modelin eğitim sürecinin henüz tamamlanmadığını işaret etmektedir.

Ayrıca, ResNet50 modelinin 20 epoch eğitimi sonucunda elde ettiği sınıflandırma performansı, accuracy, precision, recall ve F1-score metrikleri temelinde değerlendirilmiş olup, elde edilen sonuçlar Tablo 8’de sınıf bazlı olarak sunulmuştur.

Tablo 8. ResNet50 modelinin 20 epoch eğitimi sonucunda elde edilen sınıflandırma performansı

Sınıf	Precision	Recall	F1-Score	Support
Üzüm çürük yaprak	0.0000	0.0000	0.0000	472
Üzüm siyah kızamık hastalığı	0.4605	0.9583	0.6220	480
Üzüm Isariopsis yaprak lekesi	0.4209	0.2721	0.3305	430
Sağlıklı üzüm yaprağı	0.6837	0.8534	0.7592	423
<b>Accuracy</b>			0.5197	1805
<b>Macro Avg</b>	0.3913	0.5210	0.4279	1805
<b>Weighted Avg</b>	0.3829	0.5197	0.4221	1805

Tablo 8 incelendiğinde, ResNet50 modelinin 20 epoch eğitimi sonucunda %52 doğruluk oranına ulaşıldığı görülmektedir. Elde edilen F1-skorları modelin sınıflar arasında dengeli bir performans sergileyemediği görülmektedir. Özellikle *üzüm çürük yaprak* sınıfında modelin doğru sınıflandırma yapamaması nedeniyle F1-skorunun 0.00 seviyesinde kaldığı dikkat çekmektedir. Buna karşılık *üzüm siyah kızamık hastalığı* ve *sağlıklı üzüm yaprağı* sınıflarında daha yüksek recall değerleri elde edilmiştir. Macro F1-skorunun 0.4279 ve weighted F1-skorunun 0.4221 seviyesinde kalması, modelin erken epoch aşamasında veri setinin tüm ayırt edici özelliklerini öğrenemediğini göstermektedir.

ResNet50 modelinin 20 epoch eğitimi sonucunda elde ettiği sınıflandırma performansını daha ayrıntılı değerlendirebilmek amacıyla oluşturulan karmaşıklık matrisi sonuçları Şekil 28’de sunulmuştur.

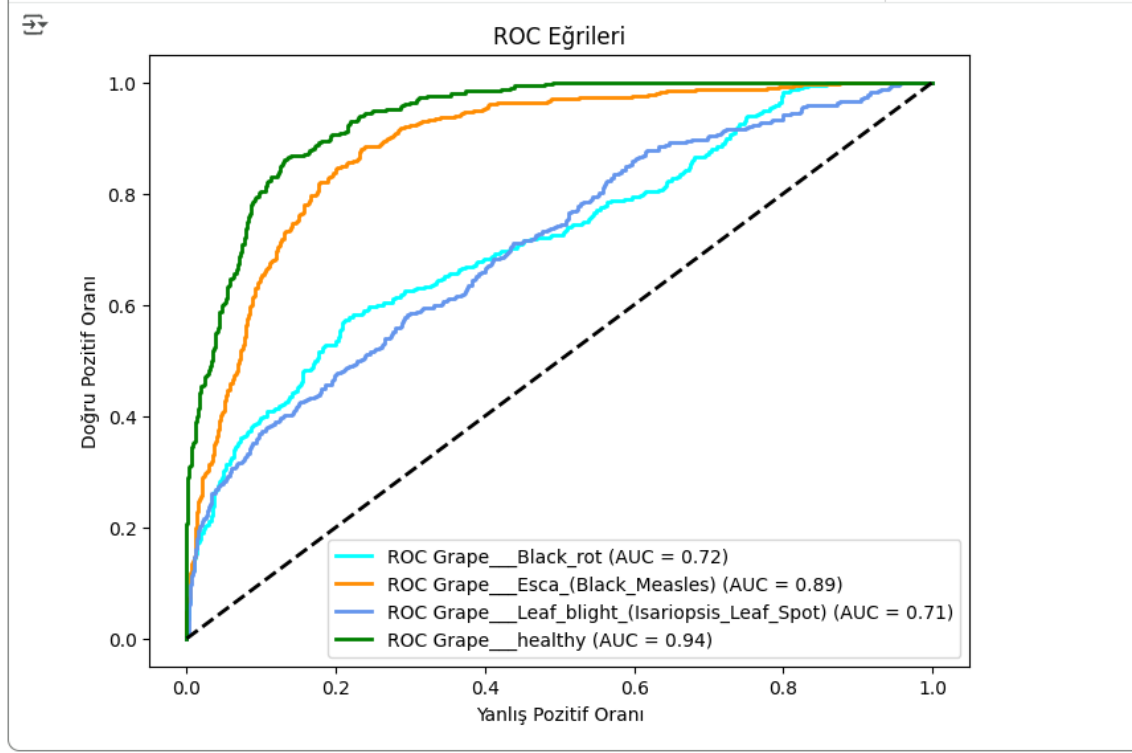
**Karmaşıklık Matrisi**

Gerçek Sınıf	Üzüm Çürük Yaprak -	0	305	106	61
	Üzüm Siyah Kızamık Hastalığı -	0	460	13	7
	Üzüm Isariopsis Yaprak Lekesi -	0	214	117	99
	Sağlıklı -	0	20	42	361
		Üzüm Çürük Yaprak	Üzüm Siyah Kızamık Hastalığı	Üzüm Isariopsis Yaprak Lekesi	Sağlıklı
		Tahmin Edilen Sınıf			

Şekil 28. ResNet50 modelinin 20 epoch eğitimi sonucunda elde edilen karmaşıklık matrisi

Şekil 28’de verilen karmaşıklık matrisi incelendiğinde, ResNet50 modelin bazı sınıfları doğru şekilde öğrenmesine rağmen sınıflar arasında belirgin karışmaların bulunduğu görülmektedir. Özellikle *üzüm siyah kızamık hastalığı* sınıfında doğru tahmin sayısının yüksek olması, modelin bu sınıfa ait özellikleri diğer sınıflara göre daha iyi öğrendiğini göstermektedir. Ancak *üzüm çürük yaprak* sınıfına ait örneklerin büyük bir kısmının *üzüm siyah kızamık hastalığı* ve diğer sınıflar olarak tahmin edilmesi, modelin bu hastalığa ait ayırt edici özellikleri yeterince öğrenemediğini ortaya koymaktadır. Benzer şekilde *üzüm Isariopsis yaprak lekisi* sınıfına ait örneklerin önemli bir bölümünün diğer hastalık sınıfları ile karışması, modelin erken epoch aşamasında sınıflar arası ayrımı tam olarak gerçekleştirmediğini göstermektedir. Sağlıklı yaprak sınıfında ise doğru tahmin oranının yüksek olmasına rağmen bazı örneklerin hastalıklı sınıflar ile karışması dikkat çekmektedir. Diyagonal dışındaki yüksek değerler, modelin genelleme performansının henüz istenilen seviyeye ulaşmadığını ve öğrenme sürecinin devam ettiğini göstermektedir.

Bununla birlikte, ResNet50 modelinin 20 epoch eğitimi sonucunda elde edilen ROC eğrisi incelenmiştir. Şekil 29’da modelin sınıflar arasındaki ayırt edicilik performansını gösteren ROC eğrileri sunulmuştur.



Şekil 29. ResNet50 modelinin 20 epoch eğitimi sonucunda elde edilen ROC eğrisi

Şekil 29’da verilen ResNet50 modeline ait ROC eğrisi incelendiğinde, sınıflar arasında ayırt edicilik performansının farklı seviyelerde olduğu görülmektedir. ROC eğrisi altında kalan alan (AUC) değerleri değerlendirildiğinde, *healthy* (sağlıklı üzüm yaprağı) sınıfı için AUC değerinin 0.94 olması modelin sağlıklı yaprakları diğer sınıflardan yüksek doğrulukla ayırt edebildiğini göstermektedir. Benzer şekilde *black\_measles* (üzüm siyah kızamık hastalığı) sınıfında AUC değerinin 0.89 seviyesinde olması, bu sınıf için kabul edilebilir bir ayırt edicilik performansına işaret etmektedir. Buna karşılık *black\_rot* (üzüm çürük yaprak) ve *Isariopsis\_leaf\_spot* (üzüm *Isariopsis* yaprak lekesi) sınıflarında AUC değerlerinin sırasıyla 0.72 ve 0.71 seviyelerinde kalması, modelin bu hastalık türlerini diğer sınıflardan ayırt etmekte zorlandığını göstermektedir. ROC eğrilerinin ideal sınıflandırmayı temsil eden sol üst köşeye yeterince yaklaşmaması ve bazı eğrilerin diyagonal referans çizgisine yakın seyretmesi, modelin erken epoch aşamasında yanlış pozitif ve yanlış negatif oranlarının yüksek olduğunu ortaya koymaktadır.

Genel olarak değerlendirildiğinde, ResNet50 modelinin 20 epoch eğitimi sürecinde öğrenme aşamasında olduğu, sınıflandırma performans metrikleri, karmaşıklık matrisi ve ROC eğrisi

sonuçlarının birbiri ile uyumlu olarak modelin daha yüksek epoch değerlerinde performansını artırabileceğini gösterdiği sonucuna ulaşılmıştır.

#### 4.1.6. CNN modellerinin 20 epoch eğitim sonuçlarının karşılaştırması

Kullanılan CNN modellerinin 20 epoch eğitim süresince elde ettiği doğruluk ve kayıp grafiklerine ait eğitim ve doğrulama değerleri karşılaştırmalı olarak incelenmiştir. Elde edilen bulgular Tablo 9’da verilmiştir.

Tablo 9. CNN modellerinin 20 epoch eğitimine ait doğruluk ve kayıp grafiklerinin karşılaştırması

Model	Doğruluk Davranışı	Kayıp Davranışı	Öğrenme Stabilitesi	Genel Yorum
<b>AlexNet</b>	Eğitim doğruluğu artarken doğrulama doğruluğu düşük ve dalgalıdır.	Eğitim kaybı azalırken doğrulama kaybı yüksek ve kararsızdır.	Düşük	Model temel özellikleri öğrenmiş ancak genelleme zayıf, yetersiz uyum (underfitting) görülmektedir.
<b>DenseNet121</b>	Eğitim ve doğrulama doğruluğu hızlı artış gösterir ve birbirine yakın ilerler.	Eğitim ve doğrulama kaybı düzenli ve paralel şekilde azalır.	Çok yüksek	Hızlı ve dengeli öğrenme, güçlü genelleme performansı görülmüştür.
<b>EfficientNetB3</b>	Doğruluk artışı mevcut ancak dalgalı yapı görülür.	Kayıp değerleri düzenli azalır fakat düşüş hızı sınırlıdır.	Orta	Öğrenme devam etmektedir, daha fazla epoch ile performans artışı beklenmektedir.
<b>MobileNetV2</b>	Eğitim ve doğrulama doğruluğu hızlı yükselir ve stabil hale gelir.	Kayıp hızlı düşer ve düşük seviyede sabitlenir.	Yüksek	Erken epochlarda hızlı yakınsama ve dengeli öğrenme gerçekleşmiştir.
<b>ResNet50</b>	Doğruluk artışı düzenli ancak düşük seviyededir.	Kayıp sürekli azalmaktadır.	Orta	Öğrenme sürmektedir, derin yapı nedeniyle daha uzun eğitim gereklidir.

20 epoch eğitimler sonucunda elde edilen doğruluk ve kayıp grafiklerinin birlikte değerlendirildiği Tablo 9 incelendiğinde, DenseNet121 ve MobileNetV2 modellerinin erken epochlarda daha hızlı yakınsama ve daha stabil öğrenme davranışı sergilediği görülmektedir. EfficientNetB3 ve ResNet50 modellerinde öğrenme sürecinin devam ettiği ve kayıp değerlerinin hâlen düşme eğiliminde olduğu gözlemlenmiştir. AlexNet modelinde ise doğrulama performansındaki dalgalanmalar nedeniyle genelleme başarısının sınırlı kaldığı belirlenmiştir. Bu sonuçlar, model mimarisinin öğrenme hızını ve erken epoch performansını doğrudan etkilediğini göstermektedir.

CNN modellerinin 20 epoch eğitim süresince elde ettiği sınıflandırma performansları, accuracy, macro ve weighted F1-score metrikleri temelinde de karşılaştırılmış olup, elde edilen sonuçlar Tablo 10'de sunulmuştur.

Tablo 10. CNN modellerinin 20 epoch eğitimine ait sınıflandırma performansı F1-score metriklerinin karşılaştırması

Model	Accuracy	Macro Avg	Weighted Avg	Genel Değerlendirme
AlexNet	0.56	0.51	0.50	Sınıflar arası dengesiz öğrenme
DenseNet121	0.98	0.98	0.98	En başarılı erken öğrenme
EfficientNetB3	0.43	0.31	0.33	Daha fazla epoch gerekli
MobileNetV2	0.97	0.97	0.97	Yüksek performans
ResNet50	0.51	0.42	0.42	Derin yapıdan dolayı epoch yetersiz

20 epoch eğitimler sonucunda elde edilen F1-skor metriklerinin birlikte değerlendirildiği Tablo 10 incelendiğinde, CNN mimarilerinin öğrenme hızlarının ve genelleme performanslarının mimari yapılarına bağlı olarak önemli farklılıklar gösterdiği görülmektedir. DenseNet121 modeli accuracy, macro ve weighted F1-skorlarında 0.98 seviyesine ulaşarak erken epoch aşamasında dahi yüksek doğruluk ve dengeli sınıf performansı sağlamış, bu durum modelin yoğun bağlantı yapısı sayesinde özellik tekrar kullanımını etkin biçimde gerçekleştirdiğini göstermiştir. Benzer şekilde MobileNetV2 modeli de hafif mimari yapısının avantajı ile erken epochlarda yüksek ve stabil bir performans sergilemiştir. Buna karşılık AlexNet modelinde düşük F1-skorları, modelin veri setindeki karmaşık özellikleri yeterince öğrenemediğini ve sınıflar arasında dengesiz tahminler yaptığını göstermektedir. EfficientNetB3 ve ResNet50 modellerinde ise bazı sınıflarda düşük F1-skorlarının görülmesi, bu modellerin daha derin ve karmaşık yapıları nedeniyle daha uzun eğitim süresine ihtiyaç duyduğunu ortaya koymaktadır. Özellikle ResNet50 modelinde bazı sınıfların hiç öğrenilememesi, 20 epoch değerinin model için yeterli olmadığını göstermektedir.

CNN modellerinin sınıflandırma performansları karmaşıklık matrisleri ve ROC eğrileri temelinde de karşılaştırılmıştır. 20 epoch eğitimler sonucunda elde edilen karmaşıklık matrisleri incelendiğinde, DenseNet121 ve MobileNetV2 modellerinde doğru sınıflandırma yoğunluğundaki (diyagonal) yüksek değerler, modelin gerçek sınıfları büyük oranda doğru tahmin ettiğini ve sınıflar arasında minimum karışma oluştuğunu göstermektedir. Buna karşılık AlexNet modelinde hastalık sınıfları arasında belirgin karışmalar görülmüş, özellikle görsel olarak benzer hastalık türlerinin birbirine yanlış atanması modelin ayırt edici özellikleri

yeterince öğrenemediğini göstermiştir. EfficientNetB3 modelinde ise bazı sınıfların doğru şekilde tahmin edilememesi, modelin 20 epoch eğitim süresinde henüz öğrenme aşamasında olduğunu ve daha uzun eğitim süresine ihtiyaç duyduğunu göstermektedir. ResNet50 modelinde belirli sınıflarda doğru tahmin oranı yüksek olmakla birlikte diyagonal dışındaki değerlerin hâlen yüksek olması, modelin öğrenme sürecinin devam ettiğini ve derin mimari yapısı nedeniyle daha fazla epoch ile performansını artırdığını göstermektedir. 20 epoch seviyesinde DenseNet121 ve MobileNetV2 modelleri en başarılı sınıf ayrımını gerçekleştirmiş, diğer modellerin ise optimal performansa ulaşabilmek için daha uzun eğitim süresine ihtiyaç duyduğu sonucuna ulaşılmıştır. Bu bulgular, erken epoch performansının yalnızca doğruluk değerleri ile değil, karmaşıklık matrisi üzerinden sınıf bazlı analizle değerlendirilmesinin gerekliliğini açıkça ortaya koymaktadır.

20 epoch eğitim süreci sonunda elde edilen ROC eğrileri incelendiğinde, DenseNet121 ve MobileNetV2 modellerinde tüm sınıflar için AUC değerlerinin 1.00 seviyesine ulaşması, bu modellerin yanlış pozitif ve yanlış negatif oranlarını minimum seviyeye indirerek erken epoch aşamasında dahi güçlü bir sınıf ayrımı gerçekleştirdiğini göstermektedir. AlexNet modelinde sağlıklı yaprak sınıfında yüksek AUC değeri elde edilmesine rağmen hastalık sınıflarında daha düşük AUC değerlerinin görülmesi, modelin bazı sınıfları ayırt etmekte zorlandığını göstermektedir. EfficientNetB3 modelinde AUC değerlerinin genel olarak orta seviyede kalması, modelin 20 epoch eğitim süresinde henüz yeterli öğrenme seviyesine ulaşmadığını ortaya koymaktadır. Benzer şekilde ResNet50 modelinde bazı sınıflarda kabul edilebilir AUC değerleri elde edilmesine rağmen tüm sınıflarda dengeli bir ayırt edicilik sağlanamamış, bu durum derin mimari yapının daha uzun eğitim süresine ihtiyaç duyduğunu göstermiştir.


Modellerin doğruluk ve kayıp, F1-skor, karmaşıklık matrisi ve ROC eğrisi analizleri birlikte değerlendirildiğinde, 20 epoch seviyesinde DenseNet121 ve MobileNetV2 modelleri en yüksek ayırt edicilik performansını göstermiş, diğer modellerin ise optimal performansa ulaşabilmek için daha fazla eğitim süresine ihtiyaç duyduğu sonucuna ulaşılmıştır.

#### **4.2. CNN Modellerinin 50 Epoch Eğitim Sonuçları**

Bu bölümde, çalışmada ele alınan CNN modellerinin 50 epoch süresince eğitilmesi sonucunda elde edilen performans bulguları ayrı ayrı sunulmuş ve karşılaştırmalı olarak değerlendirilmiştir.

#### 4.2.1. AlexNet modelinin 50 epoch eğitim sonuçları

Üzüm yaprağı hastalığı tespiti için AlexNet modeli ile 50 epoch eğitimler yapılmıştır. Eğitim sonuçlarına ait kayıp ve doğruluk grafikleri Şekil 30’da verilmiştir.



Şekil 30. AlexNet modelinin 50 epoch eğitimi sonucunda elde edilen kayıp ve doğruluk grafikleri

Şekil 30 incelendiğinde, modelin eğitim verisi üzerinde hızlı bir şekilde öğrenme gerçekleştirdiği görülmektedir. Eğitim doğruluğu ilk epochlardan itibaren hızlı bir artış göstermiş ve yaklaşık 10. epoch sonrasında %98–100 aralığında stabil hale gelmiştir. Aynı şekilde eğitim kayıp değerinin düşük seviyelerde seyretmesi, modelin eğitim verisini başarılı şekilde öğrendiğini göstermektedir. Buna karşılık doğrulama (validation) eğrileri incelendiğinde belirgin dalgalanmalar gözlemlenmektedir. Özellikle bazı epochlarda doğrulama doğruluğunun ani düşüşler yaşaması ve doğrulama kayıp değerinin keskin yükselişler göstermesi, modelin doğrulama verisine karşı kararsız bir öğrenme davranışı sergilediğini göstermektedir. Bu durum AlexNet mimarisinin daha eski ve parametre açısından sınırlı yapısından kaynaklı olarak, karmaşık yaprak hastalığı desenlerini modern CNN mimarileri kadar stabil genellemediğini göstermektedir. Bu nedenle AlexNet için 50 epoch değeri öğrenmenin tamamlandığı ancak doğrulama stabilitesinin sınırlı kaldığı bir eğitim noktası olarak değerlendirilebilir.

Ayrıca, AlexNet modelinin 50 epoch eğitimi sonucunda elde ettiği sınıflandırma performansı, accuracy, precision, recall ve F1-score metrikleri temelinde değerlendirilmiş olup, elde edilen sonuçlar Tablo 11’de sınıf bazlı olarak sunulmuştur.

Tablo 11. AlexNet modelinin 50 epoch eğitimi sonucunda elde edilen sınıflandırma performansı

Sınıf	Precision	Recall	F1-Score	Support
Üzüm çürük yaprak	0.9782	0.9492	0.9634	472
Üzüm siyah kızamık hastalığı	0.9443	0.9896	0.9664	480
Üzüm Isariopsis yaprak lekesi	1.0000	0.9674	0.9835	430
Sağlıklı üzüm yaprağı	0.9883	1.0000	0.9941	423
<b>Accuracy</b>			0.9762	1805
<b>Macro Avg</b>	0.9777	0.9765	0.9769	1805
<b>Weighted Avg</b>	0.9767	0.9762	0.9762	1805

Tablo 11'deki AlexNet modelinin 50 epoch eğitimi sonucunda elde edilen sınıflandırma sonuçları incelendiğinde, modelin genel olarak yüksek bir performans sergilediği görülmektedir. Modelin genel doğruluk değeri %97.62, macro F1-skoru 0.9769 ve weighted F1-skoru 0.9762 olarak elde edilmiştir. Bu değerler, modelin sınıflar arasında dengeli bir öğrenme gerçekleştirdiğini göstermektedir. Sınıf bazlı sonuçlar değerlendirildiğinde, en yüksek performansın *sağlıklı üzüm yaprağı* sınıfında (F1-skoru=0.9941) elde edildiği görülmektedir. Bu durum sağlıklı yaprakların görsel özelliklerinin hastalıklı yapraklara kıyasla daha belirgin olmasıyla açıklanabilir. *Üzüm Isariopsis yaprak lekesi* sınıfında da yüksek bir başarı (F1-skoru=0.9835) elde edilmiştir. Buna karşılık *üzüm çürük yaprak* ve *üzüm siyah kızamık hastalığı* sınıflarında F1-skoru değerlerinin diğer sınıflara göre nispeten daha düşük olması, bu hastalıkların görsel semptomlarının birbirine benzer özellikler taşımasından kaynaklanmaktadır.

AlexNet modelinin 50 epoch eğitimi sonucunda elde ettiği sınıflandırma performansını daha ayrıntılı değerlendirebilmek amacıyla oluşturulan karmaşıklık matrisi sonuçları Şekil 31'de sunulmuştur.

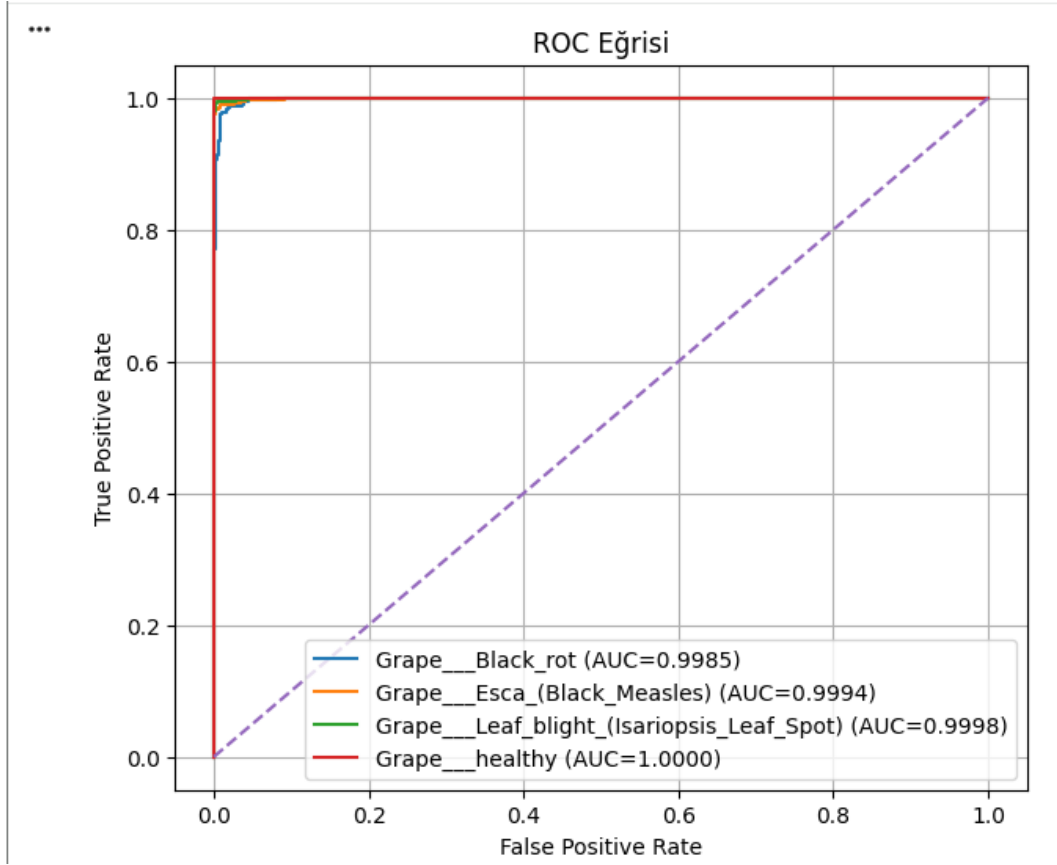
**Karmaşıklık Matrisi**

Gerçek Sınıf	Üzüm Çürük Yaprak	448	23	0	1
	Üzüm Siyah Kızamık Hastalığı	5	475	0	0
	Üzüm Isariopsis Yaprak Lekesi	5	5	416	4
	Sağlıklı	0	0	0	423
		Üzüm Çürük Yaprak	Üzüm Siyah Kızamık Hastalığı	Üzüm Isariopsis Yaprak Lekesi	Sağlıklı
		Tahmin Edilen Sınıf			

Şekil 31. AlexNet modelinin 50 epoch eğitimi sonucunda elde edilen karmaşıklık matrisi

Şekil 31’de verilen karmaşıklık matrisi incelendiğinde, modelin genel olarak yüksek sınıflandırma başarısı gösterdiği görülmektedir. Diyagonal üzerinde yer alan yüksek değerler, modelin çoğu örneği doğru sınıflandırdığını ortaya koymaktadır. Özellikle *sağlıklı üzüm yaprağı* sınıfında tüm örneklerin doğru sınıflandırılması (%100 doğruluk), sağlıklı yaprakların görsel özelliklerinin hastalıklı yapraklardan daha belirgin olduğunu göstermektedir. Hata dağılımı incelendiğinde en fazla karışıklığın *üzüm çürük yaprak* ve *üzüm siyah kızamık hastalığı* sınıfları arasında gerçekleştiği görülmektedir. *Üzüm çürük yaprak* sınıfına ait 23 örneğin *üzüm siyah kızamık hastalığı* olarak tahmin edilmesi, bu iki hastalığın yaprak üzerindeki leke ve renk değişimlerinin görsel olarak benzer özellikler taşımasından kaynaklanmaktadır. Benzer şekilde *üzüm Isariopsis yaprak lekesi* sınıfında az sayıda örneğin diğer hastalık sınıflarıyla karıştığı gözlemlenmiştir. Bunun nedeni yaprak yüzeyindeki leke dağılımı ve renk yoğunluğunun bazı örneklerde benzerlik göstermesidir.

Bununla birlikte, AlexNet modelinin 50 epoch eğitimi sonucunda elde edilen ROC eğrisi incelenmiştir. Şekil 32’de modelin sınıflar arasındaki ayırt edicilik performansını gösteren ROC eğrileri sunulmuştur.



Şekil 32. AlexNet modelinin 50 epoch eğitimi sonucunda elde edilen ROC eğrisi

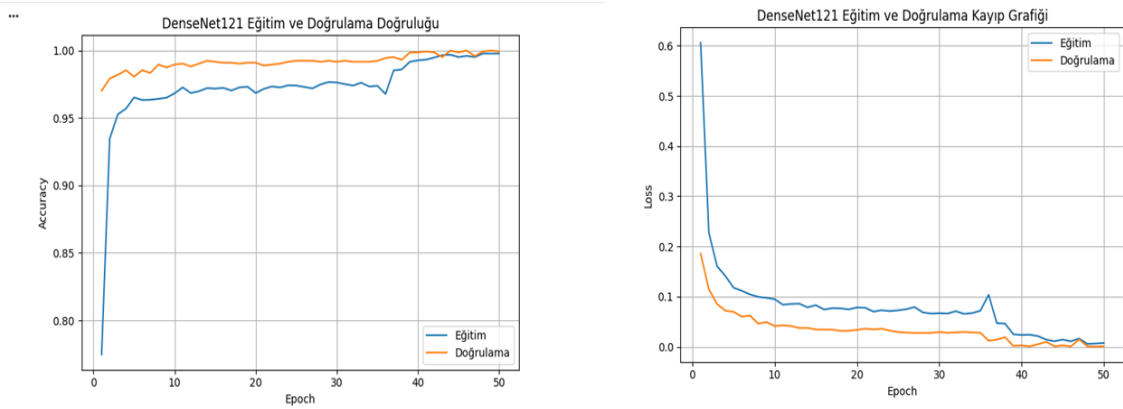
Şekil 32’de verilen AlexNet modeline ait ROC eğrisi incelendiğinde, tüm sınıflar için eğrilerin sol üst köşeye oldukça yakın konumlandığı görülmektedir. Bu durum modelin düşük yanlış pozitif oranı (false positive rate) ile yüksek doğru pozitif oranı (true positive rate) elde ettiğini göstermektedir. AUC değerlerinin tüm sınıflar için 0.99’un üzerinde olması, modelin sınıflar arasındaki ayrımı yüksek doğrulukla gerçekleştirebildiğini ortaya koymaktadır. Özellikle *sağlıklı üzüm yaprağı* sınıfında AUC değerinin 1.00 olması, modelin sağlıklı yaprakları hastalıklı yapraklardan tamamen ayırt edebildiğini göstermektedir. Benzer şekilde *üzüm Isariopsis yaprak lekesi* sınıfında elde edilen 0.9998 AUC değeri, bu hastalığın karakteristik görsel özelliklerinin model tarafından güçlü şekilde öğrenildiğini göstermektedir. *Üzüm çürük yaprak* ve *üzüm siyah kızamık hastalığı* sınıflarında AUC değerlerinin biraz daha düşük olmasının nedeni, bu iki hastalığın yaprak üzerinde benzer leke ve renk dağılımı göstermesidir.

Genel olarak değerlendirildiğinde, ROC eğrisi sonuçlarına göre AlexNet modelinin 50 epoch eğitimi sonucunda sınıfları ayırt etme kapasitesinin oldukça yüksek olduğu görülmektedir. Ancak ROC eğrisi sonuçları, sınıflandırma performans metrikleri ve karmaşıklık matrisi ile birlikte incelendiğinde, modelin bazı epochlarda doğrulama stabilitesinde dalgalanmalar

gösterdiği anlaşılmaktadır. Bu durum ROC analizinde yüksek ayırım başarısı elde edilmesine rağmen modern CNN mimarilerine kıyasla genelleme kararlılığının daha sınırlı kaldığını göstermektedir.

#### 4.2.2. DenseNet121 modelinin 50 epoch eğitim sonuçları

Üzüm yaprağı hastalığı tespiti için DenseNet121 modeli ile 50 epoch eğitimler yapılmıştır. Eğitim sonuçlarına ait kayıp ve doğruluk grafikleri Şekil 33'te verilmiştir.



Şekil 33. DenseNet121 modelinin 50 epoch eğitimi sonucunda elde edilen kayıp ve doğruluk grafikleri

Şekil 33 incelendiğinde, modelin ilk epochlardan itibaren hızlı bir öğrenme davranışı sergilediği görülmektedir. Eğitim doğruluğu kısa sürede %95 seviyesinin üzerine çıkmış ve ilerleyen epochlarda %99 seviyesine yaklaşarak stabil bir yapı göstermiştir. Doğrulama doğruluğunun eğitim doğruluğu ile paralel şekilde ilerlemesi ve çoğu epoch boyunca birbirine oldukça yakın değerlerde seyretmesi, modelin eğitim verisini ezberlemeden genelleme yeteneğini koruduğunu göstermektedir. Kayıp grafiği incelendiğinde hem eğitim kaybının hem de doğrulama kaybının epoch ilerledikçe düzenli biçimde azaldığı görülmektedir. İlk epochlarda hızlı bir düşüş gözlenmesi modelin temel özellikleri kısa sürede öğrendiğini göstermektedir. İlerleyen epochlarda kayıp değerlerinin düşük seviyelerde stabil hale gelmesi, öğrenme sürecinin dengeli şekilde tamamlandığını göstermektedir. Eğitim ve doğrulama kaybı eğrilerinin birbirine yakın seyretmesi, modelde belirgin bir overfitting oluşmadığını ortaya koymaktadır.

Ayrıca, DenseNet121 modelinin 50 epoch eğitimi sonucunda elde ettiği sınıflandırma performansı, accuracy, precision, recall ve F1-score metrikleri temelinde değerlendirilmiş olup, elde edilen sonuçlar Tablo 12’de sınıf bazlı olarak sunulmuştur.

Tablo 12. DenseNet121 modelinin 50 epoch eğitimi sonucunda elde edilen sınıflandırma performansı

<b>Sınıf</b>	<b>Precision</b>	<b>Recall</b>	<b>F1-Score</b>	<b>Support</b>
Üzüm çürük yaprak	0.9979	0.9936	0.9958	472
Üzüm siyah kızamık hastalığı	0.9938	0.9979	0.9958	480
Üzüm Isariopsis yaprak lekesi	1.0000	1.0000	1.0000	430
Sağlıklı üzüm yaprağı	1.0000	1.0000	1.0000	423
<b>Accuracy</b>			0.9978	1805
<b>Macro Avg</b>	0.9979	0.9979	0.9979	1805
<b>Weighted Avg</b>	0.9978	0.9978	0.9978	1805

Tablo 12’deki DenseNet121 modelinin 50 epoch eğitim sonucunda elde edilen sınıflandırma performansı incelendiğinde, modelin tüm sınıflarda oldukça yüksek doğruluk ve dengeli bir performans sergilediği görülmektedir. Precision, recall ve F1-score değerlerinin tüm sınıflar için 0.99 seviyesinin üzerinde olması, modelin hem yanlış pozitif hem de yanlış negatif tahminleri minimum seviyeye indirdiğini göstermektedir. Özellikle *üzüm Isariopsis yaprak lekesi* ve *sağlıklı üzüm yaprağı* sınıflarında F1-skor değerinin 1.00 olması, modelin bu sınıflara ait ayırt edici özellikleri eksiksiz şekilde öğrendiğini ortaya koymaktadır. Macro ortalama F1-skor değerinin 0.9979 olması, modelin sınıflar arasında dengeli bir performans gösterdiğini ve herhangi bir sınıfa karşı yanlılık oluşturmadığını göstermektedir. Weighted ortalama F1-skor değerinin de benzer seviyede olması, veri setindeki sınıf dağılımının model performansını olumsuz etkilemediğini ortaya koymaktadır. Accuracy değerinin %99.78 seviyesinde olması, modelin genel sınıflandırma başarısının oldukça yüksek olduğunu desteklemektedir.

DenseNet121 modelinin 50 epoch eğitimi sonucunda elde ettiği sınıflandırma performansını daha ayrıntılı değerlendirebilmek amacıyla oluşturulan karmaşıklık matrisi sonuçları Şekil 34’te sunulmuştur.

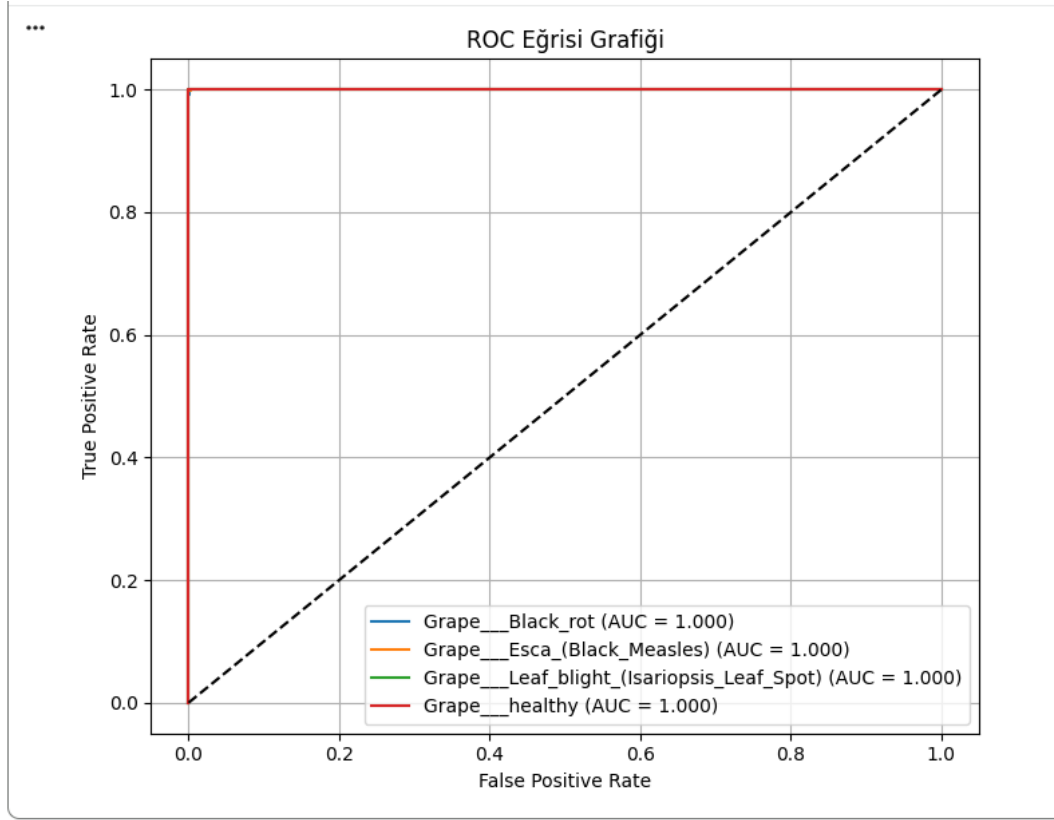
**Karmaşıklık Matrisi**

Gerçek Sınıf	Üzüm Çürük Yaprak	469	3	0	0
	Üzüm Siyah Kızamık Hastalığı	1	479	0	0
	Üzüm Isariopsis Yaprak Lekesi	0	0	430	0
	Sağlıklı	0	0	0	423
		Üzüm Çürük Yaprak	Üzüm Siyah Kızamık Hastalığı	Üzüm Isariopsis Yaprak Lekesi	Sağlıklı
		Tahmin Edilen Sınıf			

Şekil 34. DenseNet121 modelinin 50 epoch eğitimi sonucunda elde edilen karmaşıklık matrisi

Şekil 34’te verilen karmaşıklık matrisi incelendiğinde, modelin tüm sınıflarda oldukça yüksek doğrulukla sınıflandırma gerçekleştirdiği görülmektedir. Diyagonal üzerinde yer alan yüksek değerler, modelin gerçek sınıfları büyük oranda doğru tahmin ettiğini göstermektedir. *üzüm Isariopsis yaprak lekesi* ve *sağlıklı üzüm yaprağı* sınıflarında tüm örneklerin doğru sınıflandırılması, modelin bu sınıflara ait ayırt edici özellikleri eksiksiz şekilde öğrendiğini ortaya koymaktadır. *üzüm çürük yaprak* sınıfına ait yalnızca 3 örneğin ve *üzüm siyah kızamık hastalığı* sınıfına ait 1 örneğin yanlış sınıflandırılması, modelin genel performansını önemli ölçüde etkilemeyen sınırlı düzeyde bir hata oranına işaret etmektedir.

Bununla birlikte, DenseNet121 modelinin 50 epoch eğitimi sonucunda elde edilen ROC eğrisi incelenmiştir. Şekil 35’te modelin sınıflar arasındaki ayırt edicilik performansını gösteren ROC eğrileri sunulmuştur.




Şekil 35. DenseNet121 modelinin 50 epoch eğitimi sonucunda elde edilen ROC eğrisi

Şekil 35'te verilen DenseNet121 modeline ait ROC eğrisi incelendiğinde, tüm sınıflar için eğrilerin sol üst köşeye yakın konumlandığı ve AUC değerlerinin 1.00 olduğu görülmektedir. Bu durum, modelin hasta ve sağlıklı üzüm yapraklarını ayırt etme konusunda son derece yüksek bir ayırt edicilik performansı sergilediğini göstermektedir. ROC eğrisinin ideal forma yakın olması, yanlış pozitif oranının minimum seviyede tutulurken doğru pozitif oranının maksimum seviyeye ulaştığını ifade etmektedir. AlexNet modelinde de benzer şekilde yüksek AUC değerleri elde edilmesine rağmen, DenseNet121 modelinin doğruluk, F1-skor ve karmaşıklık matrisi sonuçları birlikte değerlendirildiğinde daha dengeli bir öğrenme davranışı sergilediği görülmektedir. Özellikle yoğun bağlantı (dense connection) yapısı sayesinde erken katmanlarda öğrenilen özelliklerin ağırlıkla ilerleyen katmanlarına aktarılması, sınıflar arası benzerliklerin daha başarılı ayrıştırılmasını sağlamıştır. Bu durum ROC eğrisinde tüm sınıflar için ideal ayırım başarısı olarak gözlemlenmektedir.

Genel olarak değerlendirildiğinde, DenseNet121 modelinin 50 epoch eğitimi sonucunda sınıflandırma performans metrikleri, karmaşıklık matrisi ve ROC eğrisi sonuçlarının birbiri ile uyumlu olarak hem yüksek doğruluk hem de dengeli sınıf ayırımı sağladığını göstermektedir.

### 4.2.3. EfficientNetB3 modelinin 50 epoch eğitim sonuçları

Üzüm yaprağı hastalığı tespiti için EfficientNetB3 modeli ile 50 epoch eğitimler yapılmıştır. Eğitim sonuçlarına ait kayıp ve doğruluk grafikleri Şekil 36’da verilmiştir.



Şekil 36. EfficientNetB3 modelinin 50 epoch eğitimi sonucunda elde edilen kayıp ve doğruluk grafikleri

Şekil 36 incelendiğinde, eğitim kaybının ilk epochlarda hızlı bir şekilde azaldığı ve ilerleyen epochlarda düşük seviyelerde stabil hale geldiği görülmektedir. Doğrulama kaybının da benzer şekilde azalması ve eğitim kaybına yakın değerlerde seyretmesi, modelin öğrenme sürecinin dengeli ilerlediğini ve belirgin bir aşırı öğrenme (overfitting) problemi oluşmadığını göstermektedir. Epoch ilerledikçe kayıp değerlerindeki değişimin sınırlı hale gelmesi, modelin öğrenme sürecinin büyük ölçüde tamamlandığını göstermektedir. Doğruluk grafiği incelendiğinde, eğitim doğruluğunun hızlı bir artış göstererek kısa sürede %97 seviyesinin üzerine çıktığı ve eğitim süresince stabil bir şekilde ilerlediği görülmektedir. Doğrulama doğruluğunun eğitim doğruluğuna oldukça yakın seyretmesi ve bazı epochlarda daha yüksek değerlere ulaşması, modelin eğitim verisini ezberlemek yerine genelleme yeteneğini koruyarak öğrendiğini göstermektedir. Doğruluk eğrilerindeki küçük dalgalanmalar, eğitim sürecinde normal kabul edilen değişimlerdir.


Ayrıca, EfficientNetB3 modelinin 50 epoch eğitimi sonucunda elde ettiği sınıflandırma performansı, accuracy, precision, recall ve F1-score metrikleri temelinde değerlendirilmiş olup, elde edilen sonuçlar Tablo 13’te sınıf bazlı olarak sunulmuştur.

Tablo 13. EfficientNetB3 modelinin 50 epoch eğitimi sonucunda elde edilen sınıflandırma performansı

Sınıf	Precision	Recall	F1-Score	Support
Üzüm çürük yaprak	0.9731	0.9958	0.9843	472
Üzüm siyah kızamık hastalığı	0.9957	0.9729	0.9842	480
Üzüm Isariopsis yaprak lekesi	1.0000	1.0000	1.0000	430
Sağlıklı üzüm yaprağı	1.0000	1.0000	1.0000	423
<b>Accuracy</b>			0.9917	1805
<b>Macro Avg</b>	0.9922	0.9922	0.9921	1805
<b>Weighted Avg</b>	0.9918	0.9917	0.9917	1805

Tablo 13'teki EfficientNetB3 modelinin 50 epoch eğitimi sonucunda elde edilen sınıflandırma performansı incelendiğinde, modelin genel olarak yüksek doğruluk ve dengeli bir performans sergilediği görülmektedir. Precision, recall ve F1-score değerlerinin tüm sınıflarda yüksek seviyelerde olması, modelin hastalık ve sağlıklı yaprak sınıflarını büyük ölçüde doğru şekilde ayırt edebildiğini göstermektedir. Özellikle *üzüm Isariopsis yaprak lekesi* ve *sağlıklı üzüm yaprağı* sınıflarında F1-skor değerlerinin 1.00 olması, modelin bu sınıflara ait özellikleri başarılı şekilde öğrendiğini ortaya koymaktadır. Bununla birlikte *üzüm çürük yaprak* ve *üzüm siyah kızamık hastalığı* sınıflarında F1-skor değerlerinin diğer sınıflara kıyasla daha düşük kalması, bu hastalık türlerinin görsel olarak benzer özellikler taşımasından kaynaklanan sınırlı düzeyde sınıf karışmalarının bulunduğunu göstermektedir. Macro F1-skor değerinin 0.9921 olması modelin sınıflar arasında dengeli bir performans sunduğunu, weighted F1-skor değerinin 0.9917 olması ise veri seti dağılımının model performansını olumsuz etkilemediğini göstermektedir.

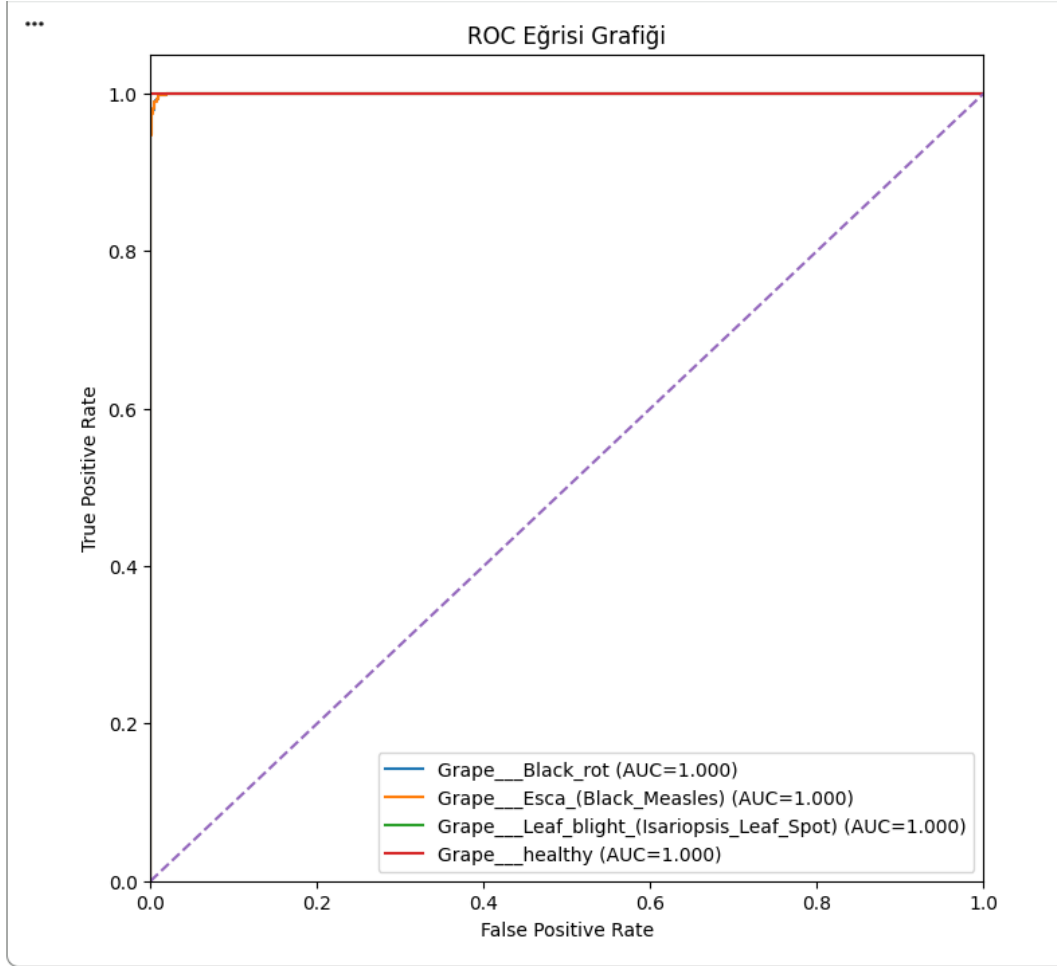
EfficientNetB3 modelinin 50 epoch eğitimi sonucunda elde ettiği sınıflandırma performansını daha ayrıntılı değerlendirebilmek amacıyla oluşturulan karmaşıklık matrisi sonuçları Şekil 37'de sunulmuştur.



Şekil 37. EfficientNetB3 modelinin 50 epoch eğitimi sonucunda elde edilen karmaşıklık matrisi

Şekil 37’de verilen karmaşıklık matrisi incelendiğinde, modelin genel olarak yüksek doğrulukla sınıflandırma gerçekleştirdiği ve sınıflar arasında güçlü bir ayırım sağladığı görülmektedir. Diyagonal üzerinde yer alan yüksek değerler, modelin gerçek sınıfları büyük oranda doğru tahmin ettiğini göstermektedir. Özellikle *üzüm Isariopsis yaprak lekesi* ve *sağlıklı üzüm yaprağı* sınıflarında tüm örneklerin doğru sınıflandırılması, modelin bu sınıflara ait ayırt edici özellikleri başarılı şekilde öğrendiğini ortaya koymaktadır. *Üzüm çürük yaprak* sınıfına ait yalnızca 2 örneğin *üzüm siyah kızamık hastalığı* olarak sınıflandırılması ve *üzüm siyah kızamık hastalığı* sınıfına ait 13 örneğin *üzüm çürük yaprak* olarak tahmin edilmesi, bu iki hastalık türünün görsel olarak benzer özellikler taşımasından kaynaklanan sınırlı düzeyde bir karışmaya işaret etmektedir.

Bununla birlikte, EfficientNetB3 modelinin 50 epoch eğitimi sonucunda elde edilen ROC eğrisi incelenmiştir. Şekil 38’de modelin sınıflar arasındaki ayırt edicilik performansını gösteren ROC eğrileri sunulmuştur.



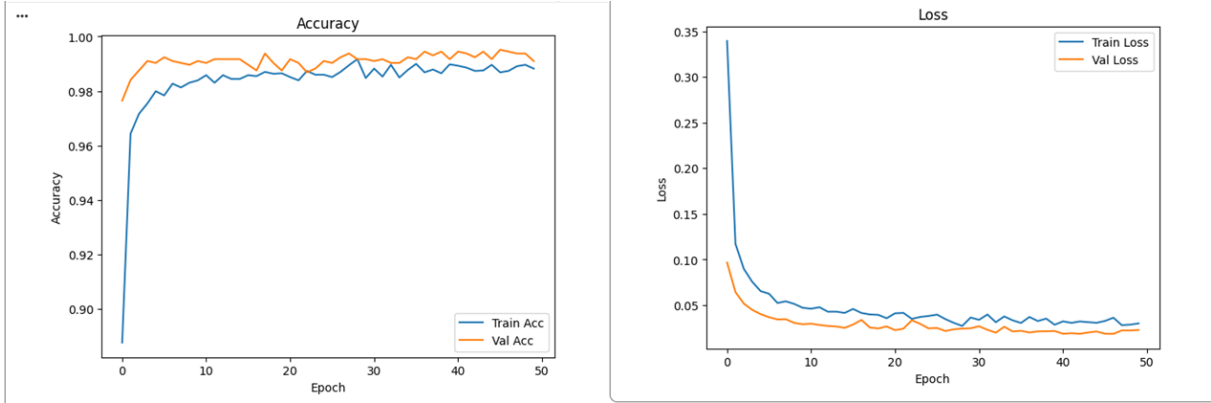
Şekil 38. EfficientNetB3 modelinin 50 epoch eğitimi sonucunda elde edilen ROC eğrisi

Şekil 38’de verilen EfficientNetB3 modeline ait ROC eğrisi incelendiğinde, tüm sınıflara ait eğrilerin sol üst köşeye oldukça yakın konumlandığı ve AUC değerlerinin 1.00 olduğu görülmektedir. Bu sonuç, modelin üzüm yaprağı hastalık sınıflarını ayırt etme konusunda çok yüksek bir sınıflandırma başarısı elde ettiğini ve yanlış pozitif oranını minimum seviyede tutarak doğru pozitif oranını maksimum düzeye çıkardığını göstermektedir. Ancak ROC eğrisinin tek başına değerlendirilmesi yeterli değildir

Genel olarak değerlendirildiğinde, EfficientNetB3 modelinin 50 epoch eğitimi sonucunda elde edilen ROC eğrisi sonuçları, sınıflandırma performans metrikleri ve karmaşıklık matrisi sonuçları birlikte incelendiğinde, EfficientNetB3 modelinin yüksek ayırt edicilik performansı sergilemesine rağmen DenseNet121 modeline kıyasla sınıflar arası ayırmada çok küçük hata oranları içerdiği görülmektedir. Bu durum modelin yüksek performansına rağmen DenseNet121’in daha dengeli ve daha güçlü genelleme kabiliyeti sunduğunu göstermektedir.

#### 4.2.4. MobileNetV2 modelinin 50 epoch eğitim sonuçları

Üzüm yaprağı hastalığı tespiti için MobileNetV2 modeli ile 50 epoch eğitimler yapılmıştır. Eğitim sonuçlarına ait kayıp ve doğruluk grafikleri Şekil 39’da verilmiştir.



Şekil 39. MobileNetV2 modelinin 50 epoch eğitimi sonucunda elde edilen kayıp ve doğruluk grafikleri

Şekil 39 incelendiğinde, modelin ilk epochlardan itibaren hızlı bir öğrenme davranışı sergilediği görülmektedir. Eğitim doğruluğu kısa sürede %97 seviyesinin üzerine çıkmış ve ilerleyen epochlarda %98–99 aralığında stabil bir yapı göstermiştir. Doğrulama doğruluğunun eğitim doğruluğu ile paralel ilerlemesi ve çoğu epoch boyunca benzer seviyelerde seyretmesi, modelin eğitim verisini ezberlemeden genelleme yeteneğini koruduğunu göstermektedir. Kayıp grafiği incelendiğinde, eğitim kaybının ilk epochlarda hızlı bir şekilde düştüğü ve ilerleyen epochlarda düşük seviyelerde stabil hale geldiği görülmektedir. Doğrulama kaybının eğitim kaybından daha düşük veya benzer seviyelerde seyretmesi, modelde belirgin bir overfitting oluşmadığını göstermektedir. Epoch ilerledikçe kayıp değerlerindeki değişimin sınırlı hale gelmesi, modelin öğrenme sürecinin dengeli biçimde tamamlandığını ortaya koymaktadır.

Ayrıca, MobileNetV2 modelinin 50 epoch eğitimi sonucunda elde ettiği sınıflandırma performansı, accuracy, precision, recall ve F1-score metrikleri temelinde değerlendirilmiş olup, elde edilen sonuçlar Tablo 14’te sınıf bazlı olarak sunulmuştur.

Tablo 14. MobileNetV2 modelinin 50 epoch eğitimi sonucunda elde edilen sınıflandırma performansı

Sınıf	Precision	Recall	F1-Score	Support
Üzüm çürük yaprak	0.9729	0.9894	0.9811	472
Üzüm siyah kızamık hastalığı	0.9894	0.9729	0.9811	480
Üzüm Isariopsis yaprak lekesi	1.0000	1.0000	1.0000	430
Sağlıklı üzüm yaprağı	1.0000	1.0000	1.0000	423
<b>Accuracy</b>			0.9900	1805
<b>Macro Avg</b>	0.9906	0.9906	0.9905	1805
<b>Weighted Avg</b>	0.9901	0.9900	0.9900	1805

Tablo 14'teki MobileNetV2 modelinin 50 epoch eğitimi sonucunda elde edilen sınıflandırma performansı incelendiğinde, modelin tüm sınıflarda yüksek doğruluk ve dengeli bir performans sergilediği görülmektedir. Precision, recall ve F1-score değerlerinin genel olarak 0.98 seviyesinin üzerinde olması, modelin hastalıklı ve sağlıklı yaprak sınıflarını başarılı şekilde ayırt edebildiğini göstermektedir. Özellikle *üzüm Isariopsis yaprak lekesi* ve *sağlıklı üzüm yaprağı* sınıflarında F1-skor değerlerinin 1.00 olması, modelin bu sınıflara ait ayırt edici özellikleri eksiksiz şekilde öğrendiğini ortaya koymaktadır. Bununla birlikte *üzüm çürük yaprak* ve *üzüm siyah kızamık hastalığı* sınıflarında F1-skor değerlerinin diğer sınıflara göre bir miktar daha düşük olması, bu iki hastalık türünün görsel benzerliklerinden kaynaklanan sınırlı düzeyde sınıf karışmalarının bulunduğu göstermektedir. Macro F1-skor değerinin 0.9905 olması modelin sınıflar arasında dengeli performans sergilediğini, weighted F1-skor değerinin 0.9900 olması ise veri seti dağılımının model performansını önemli ölçüde etkilemediğini ortaya koymaktadır.

MobileNetV2 modelinin 50 epoch eğitimi sonucunda elde ettiği sınıflandırma performansını daha ayrıntılı değerlendirebilmek amacıyla oluşturulan karmaşıklık matrisi sonuçları Şekil 40'ta sunulmuştur.


**Karmaşıklık Matrisi**

Gerçek Sınıf	Üzüm Çürük Yaprak	467	5	0	0
	Üzüm Siyah Kızamık Hastalığı	13	467	0	0
	Üzüm Isariopsis Yaprak Lekesi	0	0	430	0
	Sağlıklı	0	0	0	423
		Üzüm Çürük Yaprak	Üzüm Siyah Kızamık Hastalığı	Üzüm Isariopsis Yaprak Lekesi	Sağlıklı
		Tahmin Edilen Sınıf			

Şekil 40. MobileNetV2 modelinin 50 epoch eğitimi sonucunda elde edilen karmaşıklık matrisi

Şekil 40'ta verilen karmaşıklık matrisi incelendiğinde, modelin tüm sınıflarda yüksek doğrulukla sınıflandırma gerçekleştirdiği görülmektedir. Diyagonal üzerinde yer alan yüksek değerler, modelin gerçek sınıfları büyük oranda doğru tahmin ettiğini ve sınıflar arasında güçlü bir ayırım sağladığını göstermektedir. Özellikle *üzüm Isariopsis yaprak lekesi* ve *sağlıklı üzüm yaprağı* sınıflarında tüm örneklerin doğru sınıflandırılması, modelin bu sınıflara ait ayırt edici özellikleri başarılı şekilde öğrendiğini ortaya koymaktadır. *Üzüm çürük yaprak* ve *üzüm siyah kızamık hastalığı* sınıfları arasında sınırlı sayıda yanlış sınıflandırma bulunması, bu iki hastalık türünün görsel olarak benzer özellikler taşımasından kaynaklanan doğal bir karışma olarak değerlendirilebilir. Bununla birlikte diyagonal dışındaki değerlerin oldukça düşük olması, modelin genel genelleme performansının yüksek olduğunu ve öğrenme sürecinin dengeli şekilde tamamlandığını göstermektedir.

Bununla birlikte, MobileNetV2 modelinin 50 epoch eğitimi sonucunda elde edilen ROC eğrisi incelenmiştir. Şekil 41'de modelin sınıflar arasındaki ayırt edicilik performansını gösteren ROC eğrileri sunulmuştur.



Şekil 41. MobileNetV2 modelinin 50 epoch eğitimi sonucunda elde edilen ROC eğrisi


Şekil 41’de verilen MobileNetV2 modeline ait ROC eğrisi incelendiğinde, tüm sınıflar için eğrilerin sol üst köşeye oldukça yakın konumlandığı ve AUC değerlerinin 0.9997 – 1.0000 aralığında olduğu görülmektedir. Bu sonuç, modelin üzüm yaprağı hastalıklarını ayırt etme konusunda oldukça yüksek bir sınıflandırma başarısına sahip olduğunu ve yanlış pozitif oranını minimum seviyede tutarak doğru pozitif oranını maksimum düzeye yaklaştırdığını göstermektedir. MobileNetV2 mimarisinin derinlik ayrışımı konvolüsyon (depthwise separable convolution) yapısı sayesinde daha az parametre ile etkili özellik çıkarımı yapılabilmiş, bu durum modelin hem hızlı öğrenmesini hem de yüksek doğruluk elde etmesini sağlamıştır. ROC eğrisinin ideal forma yakın olması, modelin sınıflar arasındaki karar sınırlarını başarılı şekilde oluşturduğunu ve özellikle sağlıklı yaprak sınıfında hatasız ayırım gerçekleştirdiğini göstermektedir.

Genel olarak değerlendirildiğinde, ROC eğrisi sonuçları, sınıflandırma performans metrikleri ve karmaşıklık matrisi ile birlikte incelendiğinde, MobileNetV2 modelinin performansının oldukça yüksek olmasına rağmen DenseNet121 modeline kıyasla sınıflar arası ayırmada çok küçük hata oranları içerdiği görülmektedir. Bu durum MobileNetV2’nin hafif mimarili ve

yüksek performanslı bir model olduğunu, ancak en dengeli öğrenme davranışının DenseNet121 modelinde elde edildiğini göstermektedir.

#### 4.2.5. ResNet50 modelinin 50 epoch eğitim sonuçları

Üzüm yaprağı hastalığı tespiti için ResNet50 modeli ile 50 epoch eğitimler yapılmıştır. Eğitim sonuçlarına ait kayıp ve doğruluk grafikleri Şekil 42’de verilmiştir.



Şekil 42. ResNet50 modelinin 50 epoch eğitimi sonucunda elde edilen kayıp ve doğruluk grafikleri

Şekil 42 incelendiğinde, eğitim doğruluğunun ilk epochlardan itibaren hızlı bir artış gösterdiği ve kısa sürede %98 seviyesinin üzerine çıkarak eğitim süreci boyunca yüksek seviyelerde stabil kaldığı görülmektedir. Doğrulama doğruluğunun da benzer şekilde yüksek değerlerde seyretmesi, modelin eğitim verisini öğrenebildiğini ve genel olarak kabul edilebilir bir genelleme performansı sergilediğini göstermektedir. Bununla birlikte doğrulama doğruluğunda bazı epochlarda görülen ani düşüşler, modelin doğrulama verisi üzerinde zaman zaman kararsız tahminler ürettiğini göstermektedir. Kayıp grafiği incelendiğinde, eğitim kaybının ilk epochlarda hızlı bir şekilde azaldığı ve ilerleyen epochlarda düşük seviyelerde sabitlendiği görülmektedir. Doğrulama kaybı da genel olarak düşük seviyelerde seyretmekle birlikte belirli epochlarda kısa süreli artışlar göstermektedir. Eğitim ve doğrulama kaybı eğrilerinin birbirine yakın seyretmesi belirgin bir overfitting oluşmadığını gösterse de doğrulama kaybındaki dalgalanmalar modelin öğrenme sürecinin tamamen stabil olmadığını ortaya koymaktadır.

Ayrıca, ResNet50 modelinin 50 epoch eğitimi sonucunda elde ettiği sınıflandırma performansı, accuracy, precision, recall ve F1-score metrikleri temelinde değerlendirilmiş olup, elde edilen sonuçlar Tablo 15’te sınıf bazlı olarak sunulmuştur.

Tablo 15. ResNet50 modelinin 50 epoch eğitimi sonucunda elde edilen sınıflandırma performansı

<b>Sınıf</b>	<b>Precision</b>	<b>Recall</b>	<b>F1-Score</b>	<b>Support</b>
Üzüm çürük yaprak	1.0000	0.9809	0.9904	472
Üzüm siyah kızamık hastalığı	0.9816	1.0000	0.9907	480
Üzüm Isariopsis yaprak lekesi	1.0000	1.0000	1.0000	430
Sağlıklı üzüm yaprağı	1.0000	1.0000	1.0000	423
<b>Accuracy</b>			0.9950	1805
<b>Macro Avg</b>	0.9954	0.9952	0.9953	1805
<b>Weighted Avg</b>	0.9951	0.9950	0.9950	1805

Tablo 15’te ResNet50 modelinin 50 epoch eğitimi sonucunda elde edilen sınıflandırma performansı incelendiğinde, modelin tüm sınıflarda yüksek doğruluk ve dengeli bir performans sergilediği görülmektedir. Precision, recall ve F1-score değerlerinin genel olarak 0.99 seviyesinde olması, modelin hastalıklı ve sağlıklı yaprak sınıflarını yüksek doğrulukla ayırt edebildiğini göstermektedir. Özellikle *üzüm Isariopsis yaprak lekesi* ve *sağlıklı üzüm yaprağı* sınıflarında F1-skor değerlerinin 1.00 olması, modelin bu sınıflara ait ayırt edici özellikleri başarılı şekilde öğrendiğini ortaya koymaktadır. Bununla birlikte *üzüm çürük yaprak* ve *üzüm siyah kızamık hastalığı* sınıflarında recall ve precision değerleri arasındaki küçük farklılıklar, bu hastalık türlerinin görsel olarak benzer özellikler taşımasından kaynaklanan sınırlı düzeyde sınıf karışmalarının bulunduğunu göstermektedir. Macro F1-skor değerinin 0.9953 olması modelin sınıflar arasında dengeli performans sergilediğini, weighted F1-skor değerinin 0.9950 olması ise veri seti dağılımının model performansını olumsuz etkilemediğini ortaya koymaktadır.

ResNet50 modelinin 50 epoch eğitimi sonucunda elde ettiği sınıflandırma performansını daha ayrıntılı değerlendirebilmek amacıyla oluşturulan karmaşıklık matrisi sonuçları Şekil 43’te sunulmuştur.


**Karmaşıklık Matrisi**

Gerçek Sınıf	Üzüm Çürük Yaprak	463	9	0	0
	Üzüm Siyah Kızamık Hastalığı	0	480	0	0
	Üzüm Isariopsis Yaprak Lekesi	0	0	430	0
	Sağlıklı	0	0	0	423
		Üzüm Çürük Yaprak	Üzüm Siyah Kızamık Hastalığı	Üzüm Isariopsis Yaprak Lekesi	Sağlıklı
		Tahmin Edilen Sınıf			

Şekil 43. ResNet50 modelinin 50 epoch eğitimi sonucunda elde edilen karmaşıklık matrisi

Şekil 43'te verilen karmaşıklık matrisi incelendiğinde, modelin genel olarak yüksek doğrulukla sınıflandırma gerçekleştirdiği ve sınıflar arasında güçlü bir ayrım sağladığı görülmektedir. Diyagonal üzerinde yer alan yüksek değerler, modelin gerçek sınıfları büyük oranda doğru tahmin ettiğini göstermektedir. Özellikle *üzüm siyah kızamık hastalığı*, *üzüm Isariopsis yaprak lekesi* ve *sağlıklı üzüm yaprağı* sınıflarında tüm örneklerin doğru sınıflandırılması, modelin bu sınıflara ait ayırt edici özellikleri başarılı şekilde öğrendiğini ortaya koymaktadır. *Üzüm çürük yaprak* sınıfına ait yalnızca 9 örneğin *üzüm siyah kızamık hastalığı* olarak sınıflandırılması, bu iki hastalık türünün görsel olarak benzer özellikler taşımasından kaynaklanan sınırlı düzeyde bir karışmaya işaret etmektedir. Bununla birlikte diyagonal dışındaki değerlerin oldukça düşük olması, modelin genel genelleme performansının yüksek olduğunu ve öğrenme sürecinin dengeli şekilde tamamlandığını göstermektedir.

Bununla birlikte, ResNet50 modelinin 50 epoch eğitimi sonucunda elde edilen ROC eğrisi incelenmiştir. Şekil 44'te modelin sınıflar arasındaki ayırt edicilik performansını gösteren ROC eğrileri sunulmuştur.



Şekil 44. ResNet50 modelinin 50 epoch eğitimi sonucunda elde edilen ROC eğrisi

Şekil 44'te verilen ResNet50 modeline ait ROC eğrisi incelendiğinde, tüm sınıflara ait eğrilerin sol üst köşeye oldukça yakın konumlandığı ve AUC değerlerinin 0.9999 – 1.0000 aralığında olduğu görülmektedir. Bu sonuç, modelin üzüm yaprağı hastalıklarını ayırt etme konusunda son derece yüksek bir ayırt edicilik performansına sahip olduğunu göstermektedir. ROC eğrisinin ideal forma yakın olması, modelin yanlış pozitif oranını minimum seviyede tutarken doğru pozitif oranını maksimum düzeye ulaştırdığını ifade etmektedir. ROC eğrisinde tüm sınıfların neredeyse ideal performans göstermesi, modelin karar sınırlarını doğru şekilde oluşturduğunu ve yüksek genelleme kabiliyetine sahip olduğunu göstermektedir.

Genel olarak değerlendirildiğinde, ROC eğrisi sonuçları, sınıflandırma performans metrikleri ve karmaşıklık matrisi ile birlikte incelendiğinde ResNet50 modelinin oldukça yüksek performans sergilediği, ancak genel öğrenme dengesi ve hata dağılımı açısından DenseNet121 modelinin daha stabil sonuçlar ürettiği görülmektedir. Bu durum, ResNet50'nin güçlü bir alternatif model olmasına rağmen çalışmada en dengeli performansın DenseNet121 mimarisinde elde edildiğini desteklemektedir.

#### 4.2.6. CNN modellerinin 50 epoch eğitim sonuçlarının karşılaştırması

Kullanılan CNN modellerinin 50 epoch eğitim süresince elde ettiği doğruluk ve kayıp grafiklerine ait eğitim ve doğrulama değerleri karşılaştırmalı olarak incelenmiştir. Elde edilen bulgular Tablo 16’da verilmiştir.

Tablo 16. CNN modellerinin 50 epoch eğitimine ait doğruluk ve kayıp grafiklerinin karşılaştırması

Model	Doğruluk Davranışı	Kayıp Davranışı	Öğrenme Stabilitesi	Genel Yorum
AlexNet	Eğitim doğruluğu hızlı artmış ve erken doygunluğa ulaşmıştır. Doğrulama doğruluğunda epoch ilerledikçe dalgalanmalar gözlenmiştir.	Eğitim loss değeri hızlı düşmüş, doğrulama loss değerinde dönemsel artışlar görülmüştür.	Orta	Model öğrenmeyi başarıyla tamamlamış ancak doğrulama stabilitesi modern mimarilere göre daha düşüktür.
DenseNet121	Eğitim ve doğrulama doğruluğu birlikte ve kademeli artış göstermiştir. Eğriler birbirine yakın seyretmiştir.	Eğitim ve doğrulama loss değerleri düzenli ve stabil şekilde azalmıştır.	Çok Yüksek	En dengeli öğrenme davranışı gözlenmiş, yüksek genelleme kabiliyeti sağlamıştır.
EfficientNetB3	Eğitim doğruluğu stabil şekilde artmış, doğrulama doğruluğunda küçük dalgalanmalar görülmüştür.	Loss değerleri genel olarak dengeli azalmış, küçük sıçramalar oluşmuştur.	Yüksek	Dengeli öğrenme davranışı göstermiş, yüksek doğruluk ile verimli performans sağlamıştır.
MobileNetV2	Eğitim ve doğrulama doğruluğu hızlı ve stabil şekilde yükselmiştir.	Eğitim ve doğrulama loss değerleri düşük seviyelerde stabil kalmıştır.	Yüksek	Hafif mimariye rağmen güçlü ve kararlı öğrenme performansı göstermiştir.
ResNet50	Eğitim ve doğrulama doğruluğu sürekli ve stabil artış göstermiştir.	Loss eğrileri düzenli şekilde azalmış ve düşük seviyede sabitlenmiştir.	Çok Yüksek	Derin mimariye rağmen stabil öğrenme sağlamış ve yüksek genelleme başarısı göstermiştir.

50 epoch eğitimler sonucunda elde edilen doğruluk ve kayıp grafiklerinin birlikte değerlendirildiği Tablo 16 incelendiğinde, tüm CNN modellerinin eğitim verisi üzerinde başarılı bir öğrenme gerçekleştirdiği görülmektedir. Eğitim doğruluğunun tüm modellerde epoch ilerledikçe artması ve eğitim kayıp değerlerinin düzenli olarak azalması, modellerin veri setindeki temel görsel özellikleri etkin şekilde öğrendiğini göstermektedir. Bununla birlikte modeller arasındaki temel fark doğrulama eğrilerinde ortaya çıkmaktadır. DenseNet121 ve ResNet50 modellerinde eğitim ve doğrulama eğrilerinin birbirine oldukça yakın seyretmesi, bu modellerin yüksek genelleme kabiliyetine sahip olduğunu göstermektedir. Özellikle doğrulama

loss değerlerinin düşük ve stabil olması, modelin yalnızca eğitim verisini ezberlemediğini, yeni veriler üzerinde de tutarlı sonuçlar üretebildiğini ortaya koymaktadır. EfficientNetB3 ve MobileNetV2 modelleri incelendiğinde doğruluk ve kayıp eğrilerinin genel olarak stabil olduğu ancak DenseNet121 kadar düşük doğrulama kayıp değerlerine ulaşmadığı görülmektedir. EfficientNetB3 modelinin dengeli ölçeklendirme yaklaşımı öğrenme sürecini stabil hale getirirken, MobileNetV2 modelinin hafif mimari yapısı düşük hesaplama maliyeti ile yüksek doğruluk elde edilmesini sağlamıştır. Bu durum özellikle gerçek zamanlı veya gömülü sistem uygulamaları açısından önemli bir avantaj oluşturmaktadır. AlexNet modelinde ise eğitim doğruluğunun hızlı şekilde yükselmesine rağmen doğrulama doğruluğunda belirli epochlarda dalgalanmalar gözlemlenmiştir. Aynı şekilde doğrulama loss eğrisinde görülen ani yükselişler, modelin bazı epochlarda aşırı öğrenme eğilimi gösterdiğini ortaya koymaktadır.

CNN modellerinin 50 epoch eğitim süresince elde ettiği sınıflandırma performansları, accuracy, macro ve weighted F1-score metrikleri temelinde de karşılaştırılmış olup, elde edilen sonuçlar Tablo 17’de sunulmuştur.

Tablo 17. CNN modellerinin 50 epoch eğitimine ait sınıflandırma performansı F1-score metriklerinin karşılaştırması

Model	Accuracy	Macro Avg	Weighted Avg	Genel Değerlendirme
AlexNet	0.9762	0.9769	0.9762	Yüksek doğruluk, ancak doğrulama stabilitesi diğer modellere göre daha düşük
DenseNet121	0.9967	0.9968	0.9966	En yüksek performans, güçlü genelleme ve stabil öğrenme
EfficientNetB3	0.9942	0.9942	0.9939	Dengeli performans, yüksek doğruluk
MobileNetV2	0.9950	0.9950	0.9948	Hafif mimariye rağmen yüksek başarı
ResNet50	0.9967	0.9968	0.9967	Çok yüksek performans, stabil öğrenme

50 epoch eğitimler sonucunda elde edilen F1-skor metriklerinin birlikte değerlendirildiği Tablo 17 incelendiğinde, tüm modellerin yüksek doğruluk oranlarına ulaştığını göstermekle birlikte, mimari farklılıkların model performansı üzerinde belirgin bir etkisi olduğunu ortaya koymaktadır. Öncelikle accuracy değerleri incelendiğinde tüm modellerin %97’nin üzerinde doğruluk elde ettiği görülmektedir. Ancak accuracy tek başına model performansını değerlendirmek için yeterli değildir. Özellikle çok sınıflı problemlerde sınıflar arası dengeyi ölçen F1-skor değerleri daha anlamlı sonuçlar sunmaktadır. Bu çalışmada Macro F1-skor değerinin sınıflar arası ortalama başarıyı, weighted F1-skor değerinin ise veri setindeki sınıf dağılımını dikkate alarak genel performansı yansıttığı göz önüne alındığında, DenseNet121 ve

ResNet50 modellerinin en dengeli ve genellenebilir sonuçları ürettiği belirlenmiştir. EfficientNetB3 ve MobileNetV2 modelleri ise daha düşük parametre sayısına sahip olmalarına rağmen oldukça yüksek performans elde etmiştir. AlexNet modeli ise diğer modellere kıyasla daha eski bir mimariye sahip olmasına rağmen 50 epoch sonunda yüksek doğruluk ve F1-skor değerlerine ulaşmıştır. Bununla birlikte doğrulama doğruluğunda gözlemlenen dalgalanmalar ve diğer modellere göre daha düşük F1-skor değerleri, modelin genelleme stabilitesinin sınırlı kaldığını göstermektedir.

CNN modellerinin sınıflandırma performansları karmaşıklık matrisleri ve ROC eğrileri temelinde de karşılaştırılmıştır. 50 epoch eğitim sonuçlarına ait karmaşıklık matrisleri incelendiğinde tüm CNN modellerinin üzüm yaprak hastalıklarını yüksek doğrulukla sınıflandırabildiği görülmektedir. Diyagonal üzerinde yoğunlaşan değerler, modellerin büyük çoğunlukla doğru tahmin gerçekleştirdiğini göstermektedir. Ancak modeller arasındaki temel fark, hataların hangi sınıflarda ve ne sıklıkta gerçekleştiği noktasında ortaya çıkmaktadır. DenseNet121 ve ResNet50 modellerinde hata sayısının oldukça düşük olması, bu modellerin sınıflar arası görsel farklılıkları daha başarılı şekilde ayırt edebildiğini göstermektedir. EfficientNetB3 ve MobileNetV2 modellerinde hata oranlarının düşük olduğu ancak bazı benzer hastalık sınıflarında sınırlı karışıklıkların olduğu gözlemlenmiştir. AlexNet modelinde ise diğer modellere kıyasla daha fazla sınıf karışıklığı gözlenmiştir.

ROC eğrileri incelendiğinde tüm CNN modellerinin üzüm yaprak hastalıklarını ayırt etme konusunda oldukça yüksek performans gösterdiği görülmektedir. ROC eğrilerinin tüm modellerde sol üst köşeye yakın konumlanması, düşük yanlış pozitif oranı ile yüksek doğru pozitif oranının birlikte sağlandığını göstermektedir. AUC değerlerinin tüm modeller için 0.99'un üzerinde olması, kullanılan CNN mimarilerinin görsel özellik çıkarımı açısından oldukça başarılı olduğunu ortaya koymaktadır. DenseNet121 ve ResNet50 modelleri ROC analizinde en başarılı sonuçları göstermiştir. EfficientNetB3 ve MobileNetV2 modelleri, daha düşük parametre sayısına rağmen ROC analizinde oldukça yüksek performans sergilemiştir. AlexNet modeli ROC analizinde yüksek AUC değerleri elde etmiş olsa da doğruluk ve karmaşıklık matrisi sonuçları ile birlikte değerlendirildiğinde bazı benzer hastalık sınıflarında sınırlı düzeyde karışıklıklar gözlenmiştir. Bu durum AlexNet'in ayırım gücünün yüksek olmasına rağmen modern CNN mimarilerine kıyasla genelleme stabilitesinin daha düşük olduğunu göstermektedir.


Modellerin doğruluk ve kayıp, F1-skor, karmaşıklık matrisi ve ROC eğrisi analizleri birlikte değerlendirildiğinde, 50 epoch seviyesinde tüm CNN modellerinin yüksek ayırım gücü sergilediği, ancak DenseNet121 ve ResNet50 modellerinin hem ROC performansı hem de F1-skor ve karmaşıklık matrisi sonuçları birlikte ele alındığında en başarılı ve en dengeli modeller olduğu sonucuna ulaşılmıştır.

### 4.3. CNN Modellerinin 100 Epoch Eğitim Sonuçları

Bu bölümde, çalışmada ele alınan CNN modellerinin 100 epoch süresince eğitilmesi sonucunda elde edilen performans bulguları ayrı ayrı sunulmuş ve karşılaştırmalı olarak değerlendirilmiştir.

#### 4.3.1. AlexNet modelinin 100 epoch eğitim sonuçları

Üzüm yaprağı hastalığı tespiti için AlexNet modeli ile 100 epoch eğitimler yapılmıştır. Eğitim sonuçlarına ait kayıp ve doğruluk grafikleri Şekil 45'te verilmiştir.



Şekil 45. AlexNet modelinin 100 epoch eğitimi sonucunda elde edilen kayıp ve doğruluk grafikleri

Şekil 45 incelendiğinde, modelin eğitim verisi üzerinde oldukça yüksek bir öğrenme performansına ulaştığı görülmektedir. Eğitim doğruluğu kısa sürede %99 seviyesine ulaşmış ve eğitim süreci boyunca stabil bir şekilde yüksek kalmıştır. Buna karşılık doğrulama doğruluğu grafiğinde ciddi dalgalanmalar gözlemlenmektedir. Bazı epochlarda doğrulama doğruluğunun ani düşüşler yaşaması, modelin eğitim verisini ezberlemeye başladığını ve genelleme yeteneğinin zayıfladığını göstermektedir. Kayıp grafiği incelendiğinde ise eğitim kaybının düşük ve stabil bir seyir izlediği, ancak doğrulama kaybında çok yüksek ve ani sıçramalar

olduğu görülmektedir. Özellikle orta epoch aralığında ortaya çıkan yüksek loss değerleri, modelin doğrulama verisi üzerinde tutarsız tahminler yaptığını göstermektedir. Bu durum klasik bir overfitting (aşırı öğrenme) davranışıdır. Model eğitim verisine aşırı uyum sağlamış, ancak yeni veriler karşısında stabil performans sergileyememiştir. AlexNet modeli için 100 epoch eğitim süresi, modelin öğrenme kapasitesinin ötesine geçerek performans kararsızlığına neden olmuştur. Daha önce elde edilen 50 epoch sonuçları ile karşılaştırıldığında, 100 epoch eğitimin doğrulama performansını artırmadığı, aksine genelleme başarısını düşürdüğü görülmektedir. Bu nedenle AlexNet mimarisi için optimum eğitim süresinin 50 epoch civarında olduğu söylenebilir.

Ayrıca, AlexNet modelinin 100 epoch eğitimi sonucunda elde ettiği sınıflandırma performansı, accuracy, precision, recall ve F1-score metrikleri temelinde değerlendirilmiş olup, elde edilen sonuçlar Tablo 18’de sınıf bazlı olarak sunulmuştur.

Tablo 18. AlexNet modelinin 100 epoch eğitimi sonucunda elde edilen sınıflandırma performansı

Sınıf	Precision	Recall	F1-Score	Support
Üzüm çürük yaprak	0.7255	0.9407	0.8192	472
Üzüm siyah kızamık hastalığı	0.9450	0.9667	0.9557	480
Üzüm Isariopsis yaprak lekesi	0.9775	0.8070	0.8841	430
Sağlıklı üzüm yaprağı	1.0000	0.8203	0.9013	423
<b>Accuracy</b>			0.8875	1805
<b>Macro Avg</b>	0.9120	0.8837	0.8901	1805
<b>Weighted Avg</b>	0.9082	0.8875	0.8902	1805

Tablo 18’deki AlexNet modelinin 100 epoch eğitim sonucunda elde edilen sınıflandırma sonuçları incelendiğinde, modelin bazı sınıflarda yüksek performans göstermesine rağmen genel olarak dengeli bir sınıflandırma başarısı sağlayamadığı görülmektedir. Özellikle *üzüm çürük yaprak* sınıfında precision değerinin düşük (0.7255) olmasına rağmen recall değerinin yüksek olması, modelin bu sınıfa ait olmayan bazı örnekleri yanlış şekilde bu sınıfa atadığını göstermektedir. Bu durum yanlış pozitif (false positive) oranının arttığını ifade etmektedir. *Üzüm siyah kızamık hastalığı* sınıfında precision, recall ve F1-score değerlerinin yüksek olması, modelin bu hastalık türünü diğer sınıflara göre daha başarılı ayırt edebildiğini göstermektedir. Buna karşılık *üzüm Isariopsis yaprak lekesi* ve *sağlıklı üzüm yaprağı* sınıflarında recall değerlerinin düşmesi, modelin bazı gerçek örnekleri kaçırdığını ve sınıflar arası ayrımın

yeterince güçlü olmadığını ortaya koymaktadır. Macro F1-score değerinin 0.8901 olması, modelin tüm sınıflar üzerinde dengeli bir performans sergileyemediğini göstermektedir. Weighted F1-score değerinin macro ortalamaya yakın olması ise veri setinin sınıf dağılımının dengeli olduğunu ve performans düşüşünün belirli sınıflardan kaynaklandığını göstermektedir. Accuracy değerinin yüksek görünmesine rağmen F1-score değerlerinin daha düşük kalması, modelin 100 epoch eğitim sürecinde aşırı öğrenme eğilimi gösterdiğini ve genelleme performansının sınırlı kaldığını desteklemektedir.

AlexNet modelinin 100 epoch eğitimi sonucunda elde ettiği sınıflandırma performansını daha ayrıntılı değerlendirebilmek amacıyla oluşturulan karmaşıklık matrisi sonuçları Şekil 46'da sunulmuştur.

**Karmaşıklık Matrisi**

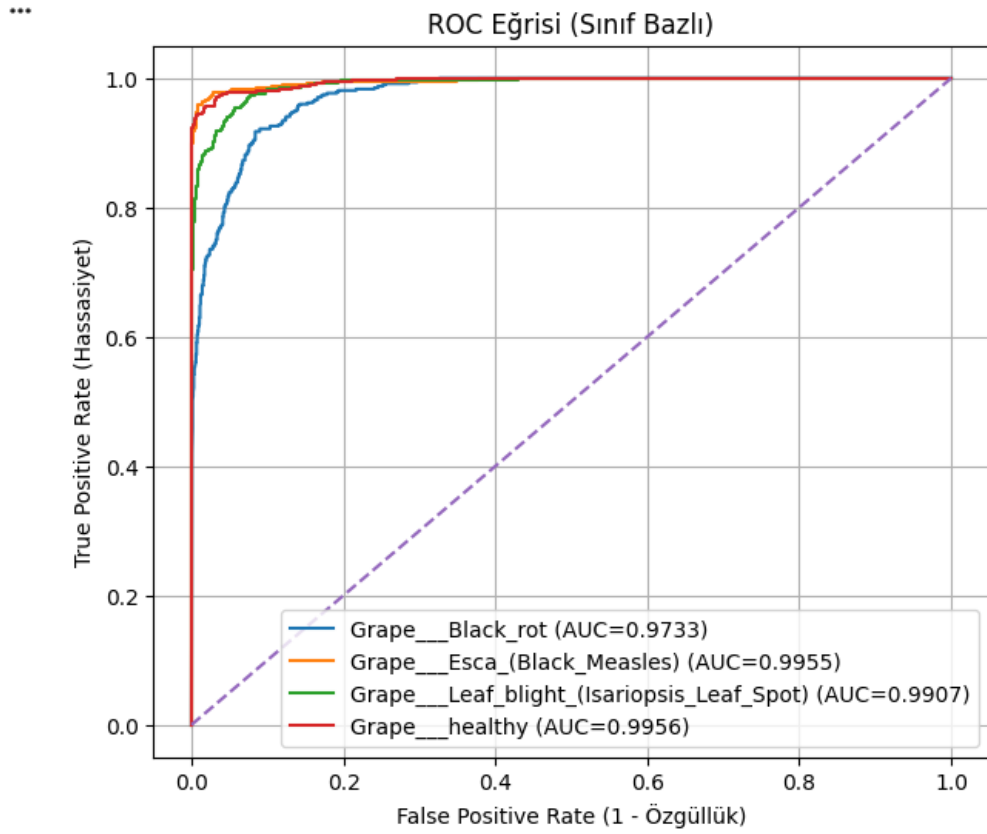
Gerçek Sınıf	Üzüm Çürük Yaprak	Üzüm Siyah Kızamık Hastalığı	Üzüm Isariopsis Yaprak Lekesi	Sağlıklı
Üzüm Çürük Yaprak	444	27	1	0
Üzüm Siyah Kızamık Hastalığı	16	464	0	0
Üzüm Isariopsis Yaprak Lekesi	83	0	347	0
Sağlıklı	69	0	7	347
	Üzüm Çürük Yaprak	Üzüm Siyah Kızamık Hastalığı	Üzüm Isariopsis Yaprak Lekesi	Sağlıklı
	Tahmin Edilen Sınıf			

Şekil 46. AlexNet modelinin 100 epoch eğitimi sonucunda elde edilen karmaşıklık matrisi

Şekil 46'da verilen karmaşıklık matrisi incelendiğinde, modelin bazı sınıflarda yüksek doğru sınıflandırma başarısı göstermesine rağmen sınıflar arası karışıklığın belirli hastalık türlerinde arttığı görülmektedir. Karmaşıklık matrisi sonuçlarına göre *üzüm çürük yaprak* sınıfına ait 472 örneğin 444 tanesi doğru sınıflandırılmış, ancak 27 örnek *üzüm siyah kızamık hastalığı* sınıfı olarak ve 1 örnek *üzüm Isariopsis yaprak lekesi* sınıfı olarak yanlış tahmin edilmiştir. Bu durum,

*üzüm çürük yaprak* ve *üzüm siyah kızamık* hastalıklarının görsel belirtilerinin benzer olmasından kaynaklanan sınıflandırma hatalarına işaret etmektedir. *Üzüm siyah kızamık hastalığı* sınıfında ise 480 örneğin 464 tanesi doğru sınıflandırılmış, 16 örnek ise *üzüm çürük yaprak* sınıfı olarak tahmin edilmiştir. Bu karşılıklı hata durumu, modelin bu iki hastalık sınıfı arasında ayırt edici özellikleri yeterince güçlü öğrenemediğini göstermektedir. Benzer şekilde *üzüm Isariopsis yaprak lekesi* sınıfında 430 örneğin 347 tanesi doğru sınıflandırılmış, 83 örneğin ise *üzüm çürük yaprak* olarak tahmin edilmesi modelin bu sınıf için genelleme performansının sınırlı kaldığını göstermektedir. *Sağlıklı üzüm yaprağı* sınıfında ise 423 örneğin 347 tanesi doğru sınıflandırılmış, 69 örnek *üzüm çürük yaprak* ve 7 örnek *üzüm Isariopsis yaprak lekesi* olarak yanlış sınıflandırılmıştır. Sağlıklı yaprakların hastalıklı sınıflara atanması, modelin bazı görsel varyasyonları hastalık belirtisi olarak yorumladığını göstermektedir. Bu durum özellikle uzun epoch eğitimlerinde modelin eğitim verisine aşırı uyum sağlamasıyla ilişkilendirilebilir.

Bununla birlikte, AlexNet modelinin 100 epoch eğitimi sonucunda elde edilen ROC eğrisi incelenmiştir. Şekil 47’de modelin sınıflar arasındaki ayırt edicilik performansını gösteren ROC eğrileri sunulmuştur.



Şekil 47. AlexNet modelinin 100 epoch eğitimi sonucunda elde edilen ROC eğrisi

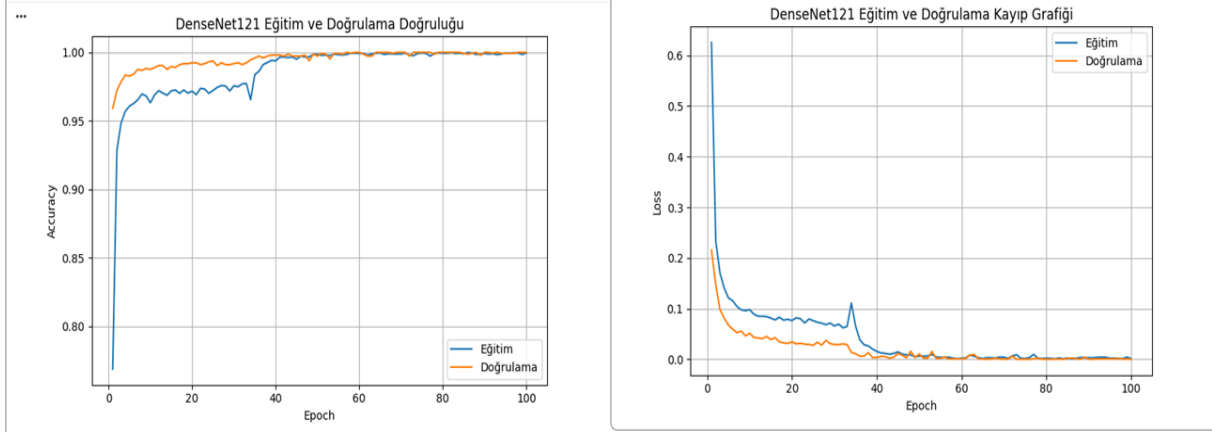
Şekil 47’de verilen AlexNet modeline ait ROC eğrisi incelendiğinde, modelin genel olarak yüksek ayırt edicilik performansı gösterdiği ancak bazı sınıflarda diğerlerine kıyasla daha düşük ayırım başarısına sahip olduğu görülmektedir. ROC eğrisi altında kalan alan (AUC) değerleri değerlendirildiğinde, *üzüm çürük yaprak* sınıfı için AUC değerinin 0.9733 olduğu, bu değer diğer sınıflara kıyasla daha düşük kaldığı görülmektedir. Bu durum, modelin *üzüm çürük yaprak* sınıfını diğer hastalık türlerinden ayırt ederken daha fazla hata yaptığını göstermektedir. *Üzüm siyah kızamık hastalığı*, *üzüm Isariopsis yaprak lekesi* ve *sağlıklı üzüm yaprağı* sınıflarında ise AUC değerlerinin sırasıyla 0.9955, 0.9907 ve 0.9956 olduğu görülmektedir. Bu değerler modelin söz konusu sınıflarda yüksek ayırt edicilik performansı sergilediğini göstermektedir. Özellikle sağlıklı yaprak sınıfında ROC eğrisinin ideal sınıflandırma eğrisine oldukça yakın olması, modelin sağlıklı ve hastalıklı yapraklar arasındaki ayrımı genel olarak başarılı gerçekleştirdiğini ortaya koymaktadır.

Genel olarak değerlendirildiğinde, ROC eğrisi sonuçlarına göre AlexNet modelinin yüksek eğitim doğruluğuna rağmen bazı sınıflarda yanlış pozitif oranının arttığı ve özellikle görsel olarak benzer hastalık sınıflarında ayırım performansının düştüğü görülmektedir. Bu durum

sınıflandırma performans metrikleri ve karmaşıklık matrisi ile uyumlu olup, modelin uzun epoch eğitim sürecinde aşırı öğrenme eğilimi göstermesiyle açıklanabilir.

#### 4.3.2. DenseNet121 modelinin 100 epoch eğitim sonuçları

Üzüm yaprağı hastalığı tespiti için DenseNet121 modeli ile 100 epoch eğitimler yapılmıştır. Eğitim sonuçlarına ait kayıp ve doğruluk grafikleri Şekil 48’de verilmiştir.



Şekil 48. DenseNet121 modelinin 100 epoch eğitimi sonucunda elde edilen kayıp ve doğruluk grafikleri

Şekil 48 incelendiğinde, modelin hem eğitim hem de doğrulama verisi üzerinde oldukça stabil ve dengeli bir öğrenme süreci gerçekleştirdiği görülmektedir. Eğitim doğruluğu ilk epochlardan itibaren hızlı bir artış göstermiş ve yaklaşık 40. epoch sonrasında %99 seviyesine ulaşarak stabil hale gelmiştir. Benzer şekilde doğrulama doğruluğu da eğitim doğruluğuna paralel bir seyir izleyerek yüksek doğruluk değerlerinde sabitlenmiştir. Eğitim ve doğrulama eğrileri arasındaki farkın oldukça düşük olması, modelin güçlü bir genelleme yeteneğine sahip olduğunu göstermektedir. Kayıp grafiği incelendiğinde, eğitim kaybının başlangıçta hızlı bir düşüş gösterdiği ve ilerleyen epochlarda sifira oldukça yakın değerlere ulaştığı görülmektedir. Doğrulama kaybının da benzer şekilde düzenli ve stabil bir azalma göstermesi, modelin öğrenme sürecinde kararlı olduğunu ve aşırı öğrenme (overfitting) probleminin oluşmadığını göstermektedir. Ara epochlarda görülen küçük dalgalanmalar modelin genel davranışını etkilememekte ve eğitim sürecinin doğal varyasyonu olarak değerlendirilmektedir. DenseNet121 modeli, 100 epoch eğitim sürecinde hem yüksek doğruluk hem de güçlü genelleme performansı sergilemiştir.

Ayrıca, DenseNet121 modelinin 100 epoch eğitimi sonucunda elde ettiği sınıflandırma performansı, accuracy, precision, recall ve F1-score metrikleri temelinde değerlendirilmiş olup, elde edilen sonuçlar Tablo 19’da sınıf bazlı olarak sunulmuştur.

Tablo 19. DenseNet121 modelinin 100 epoch eğitimi sonucunda elde edilen sınıflandırma performansı

<b>Sınıf</b>	<b>Precision</b>	<b>Recall</b>	<b>F1-Score</b>	<b>Support</b>
Üzüm çürük yaprak	1.0000	0.9979	0.9989	472
Üzüm siyah kızamık hastalığı	0.9979	1.0000	0.9990	480
Üzüm Isariopsis yaprak lekesi	1.0000	1.0000	1.0000	430
Sağlıklı üzüm yaprağı	1.0000	1.0000	1.0000	423
<b>Accuracy</b>			0.9994	1805
<b>Macro Avg</b>	0.9995	0.9995	0.9995	1805
<b>Weighted Avg</b>	0.9994	0.9994	0.9994	1805

Tablo 19’deki DenseNet121 modelinin 100 epoch eğitim sonucunda elde edilen sınıflandırma sonuçları incelendiğinde, modelin tüm sınıflar üzerinde oldukça yüksek ve dengeli bir performans sergilediği görülmektedir. Precision, recall ve F1-score değerlerinin tüm sınıflarda 0.99 ve üzeri seviyelerde olması, modelin hem doğru sınıflandırma oranının yüksek olduğunu hem de yanlış sınıflandırma oranının oldukça düşük kaldığını göstermektedir. Özellikle *üzüm Isariopsis yaprak lekesi* ve *sağlıklı üzüm yaprağı* sınıflarında precision ve recall değerlerinin 1.00 olması, modelin bu sınıfları hatasız şekilde ayırt edebildiğini göstermektedir. *Üzüm çürük yaprak* ve *üzüm siyah kızamık hastalığı* sınıflarında ise çok küçük farkların bulunması, sınıflar arası görsel benzerliklerden kaynaklanan minimal hatalar olarak değerlendirilebilir. Macro F1-score değerinin 0.9995 olması, modelin tüm sınıflar üzerinde eşit derecede başarılı olduğunu ve herhangi bir sınıfa karşı performans düşüşü yaşanmadığını göstermektedir. Weighted F1-score değerinin macro ortalama ile neredeyse aynı olması ise veri setinin dengeli yapısını ve modelin tüm sınıflarda benzer başarı sağladığını ortaya koymaktadır. Bu sonuçlar, DenseNet121 mimarisinin yoğun bağlantı yapısı sayesinde özelliklerin kaybolmadan aktarılmasını sağladığını ve uzun epoch eğitimlerinde dahi aşırı öğrenme problemi oluşturmadan yüksek genelleme performansı elde edebildiğini göstermektedir.

DenseNet121 modelinin 100 epoch eğitimi sonucunda elde ettiği sınıflandırma performansını daha ayrıntılı değerlendirebilmek amacıyla oluşturulan karmaşıklık matrisi sonuçları Şekil 49’da sunulmuştur.


**Karmaşıklık Matrisi**

Gerçek Sınıf	Üzüm Çürük Yaprak -	471	1	0	0
	Üzüm Siyah Kızamık Hastalığı -	0	480	0	0
	Üzüm Isariopsis Yaprak Lekesi -	0	0	430	0
	Sağlıklı -	0	0	0	423
		Üzüm Çürük Yaprak -	Üzüm Siyah Kızamık Hastalığı -	Üzüm Isariopsis Yaprak Lekesi -	Sağlıklı -
		Tahmin Edilen Sınıf			

Şekil 49. DenseNet121 modelinin 100 epoch eğitimi sonucunda elde edilen karmaşıklık matrisi

Şekil 49’da verilen karmaşıklık matrisi incelendiğinde, modelin tüm sınıflar üzerinde son derece yüksek ve dengeli bir sınıflandırma performansı sergilediği görülmektedir. Karmaşıklık matrisi sonuçlarına göre *üzüm çürük yaprak* sınıfına ait 472 örneğin 471 tanesi doğru sınıflandırılmış, yalnızca 1 örnek *üzüm siyah kızamık hastalığı* sınıfı olarak yanlış tahmin edilmiştir. Bu durum, modelin iki hastalık türü arasındaki görsel benzerliğe rağmen ayırt edici özellikleri büyük ölçüde doğru öğrenebildiğini göstermektedir. Diğer sınıflarda tüm örneklerin doğru sınıflandırılması, modelin bu sınıflar için ayırt edici özellikleri yüksek doğrulukla öğrendiğini ve sınıflar arası karışıklığın neredeyse tamamen ortadan kalktığını göstermektedir. Özellikle sağlıklı yaprak sınıfında yanlış sınıflandırmanın bulunmaması, modelin hastalık belirtileri ile doğal yaprak varyasyonlarını başarılı şekilde ayırt edebildiğini ortaya koymaktadır.

Bununla birlikte, DenseNet121 modelinin 100 epoch eğitimi sonucunda elde edilen ROC eğrisi incelenmiştir. Şekil 50’de modelin sınıflar arasındaki ayırt edicilik performansını gösteren ROC eğrileri sunulmuştur.




Şekil 50. DenseNet121 modelinin 100 epoch eğitimi sonucunda elde edilen ROC eğrisi

Şekil 50’de verilen DenseNet121 modeline ait ROC eğrisi incelendiğinde, modelin tüm sınıflar için ideal sınıflandırma performansına ulaştığı görülmektedir. ROC eğrisi altında kalan alan (AUC) değerlerinin sınıfların tamamı için 1.00 olduğu belirlenmiştir. AUC değerinin 1.00 olması, modelin ilgili sınıfları diğer sınıflardan tamamen ayırt edebildiğini ve yanlış pozitif ile yanlış negatif oranlarının minimum seviyede olduğunu göstermektedir. ROC eğrilerinin grafikte sol üst köşeye yakın bir şekilde ilerlemesi, modelin düşük yanlış pozitif oranı ile yüksek doğru pozitif oranına ulaştığını göstermektedir. Bu durum, DenseNet121 modelinin sınıflar arası ayırt edici özellikleri yüksek doğrulukla öğrendiğini ve karar sınırlarını optimal şekilde oluşturduğunu ortaya koymaktadır.

Genel olarak değerlendirildiğinde, DenseNet121 modelinin 100 epoch eğitimi sonucunda sınıflandırma performans metrikleri, karmaşıklık matrisi ve ROC eğrisi sonuçlarının birbiri ile uyumlu olarak hem yüksek doğruluk hem de dengeli sınıf ayırımı sağladığını göstermektedir.

### 4.3.3. EfficientNetB3 modelinin 100 epoch eğitim sonuçları

Üzüm yaprağı hastalığı tespiti için EfficientNetB3 modeli ile 100 epoch eğitimler yapılmıştır. Eğitim sonuçlarına ait kayıp ve doğruluk grafikleri Şekil 51’de verilmiştir.



Şekil 51. EfficientNetB3 modelinin 100 epoch eğitimi sonucunda elde edilen kayıp ve doğruluk grafikleri

Şekil 51 incelendiğinde, modelin erken epochlardan itibaren hızlı bir öğrenme süreci gerçekleştirdiği görülmektedir. Eğitim doğruluğu ilk birkaç epoch içerisinde hızlı bir artış göstererek %97 seviyesinin üzerine çıkmış, ilerleyen epochlarda ise küçük dalgalanmalar ile stabil bir yapıya ulaşmıştır. Doğrulama doğruluğunun eğitim doğruluğundan biraz daha yüksek seyretmesi, modelin eğitim verisini ezberlemek yerine genellenebilir özellikler öğrenebildiğini göstermektedir. Kayıp grafiği incelendiğinde hem eğitim hem de doğrulama kaybının düzenli ve sürekli bir şekilde azaldığı görülmektedir. Doğrulama kaybının eğitim kaybına yakın ve daha düşük seviyelerde seyretmesi, modelin aşırı öğrenme eğilimi göstermediğini ve öğrenme sürecinin dengeli ilerlediğini ortaya koymaktadır. Epoch ilerledikçe loss değerlerinin düşük seviyelerde sabitlenmesi, modelin öğrenme sürecini tamamladığını ve parametrelerin optimum noktaya yaklaştığını göstermektedir. EfficientNetB3 modeli, 100 epoch eğitim sürecinde yüksek doğruluk, düşük kayıp ve güçlü genelleme performansı sergilemiştir.

Ayrıca, EfficientNetB3 modelinin 100 epoch eğitimi sonucunda elde ettiği sınıflandırma performansı, accuracy, precision, recall ve F1-score metrikleri temelinde değerlendirilmiş olup, elde edilen sonuçlar Tablo 20’de sınıf bazlı olarak sunulmuştur.

Tablo 20. EfficientNetB3 modelinin 100 epoch eğitimi sonucunda elde edilen sınıflandırma performansı

Sınıf	Precision	Recall	F1-Score	Support
Üzüm çürük yaprak	0.9936	0.9831	0.9883	472
Üzüm siyah kızamık hastalığı	0.9835	0.9938	0.9886	480
Üzüm Isariopsis yaprak lekesi	1.0000	1.0000	1.0000	430
Sağlıklı üzüm yaprağı	1.0000	1.0000	1.0000	423
<b>Accuracy</b>			0.9939	1805
<b>Macro Avg</b>	0.9943	0.9942	0.9942	1805
<b>Weighted Avg</b>	0.9939	0.9939	0.9939	1805

Tablo 20'deki EfficientNetB3 modelinin 100 epoch eğitimi sonucunda elde edilen sınıflandırma sonuçları incelendiğinde, modelin tüm sınıflar üzerinde oldukça yüksek ve dengeli bir performans sergilediği görülmektedir. Özellikle *üzüm Isariopsis yaprak lekesi* ve *sağlıklı üzüm yaprağı* sınıflarında precision, recall ve F1-score değerlerinin 1.00 olması, modelin bu sınıfları hatasız şekilde ayırt edebildiğini göstermektedir. *Üzüm çürük yaprak* ve *üzüm siyah kızamık hastalığı* sınıflarında F1-score değerlerinin diğer sınıflara göre biraz daha düşük olması, bu hastalık türlerinin görsel olarak birbirine daha benzer özellikler taşımasından kaynaklanmaktadır. Ancak elde edilen değerlerin 0.98 seviyesinin üzerinde olması, modelin genel sınıflandırma başarısının oldukça yüksek olduğunu göstermektedir. Macro ve weighted F1-score değerlerinin birbirine çok yakın olması, modelin tüm sınıflar üzerinde dengeli bir performans gösterdiğini ve veri seti dağılımından bağımsız olarak başarılı sonuçlar elde ettiğini ortaya koymaktadır. EfficientNetB3 mimarisinin ölçeklendirme yaklaşımı sayesinde parametre verimliliğini koruyarak yüksek doğruluk elde ettiği ve uzun epoch eğitimlerinde stabil bir öğrenme davranışı sergilediği görülmektedir.

EfficientNetB3 modelinin 100 epoch eğitimi sonucunda elde ettiği sınıflandırma performansını daha ayrıntılı değerlendirebilmek amacıyla oluşturulan karmaşıklık matrisi sonuçları Şekil 52'de sunulmuştur.


**Karmaşıklık Matrisi**

Gerçek Sınıf	Üzüm Çürük Yaprak	464	8	0	0
	Üzüm Siyah Kızamık Hastalığı	3	477	0	0
	Üzüm Isariopsis Yaprak Lekesi	0	0	430	0
	Sağlıklı	0	0	0	423
		Üzüm Çürük Yaprak	Üzüm Siyah Kızamık Hastalığı	Üzüm Isariopsis Yaprak Lekesi	Sağlıklı
		Tahmin Edilen Sınıf			

Şekil 52. EfficientNetB3 modelinin 100 epoch eğitimi sonucunda elde edilen karmaşıklık matrisi

Şekil 52’de verilen karmaşıklık matrisi incelendiğinde, modelin tüm sınıflar üzerinde yüksek doğruluk oranına sahip olduğu ve sınıflar arası karışıklığın oldukça düşük seviyede kaldığı görülmektedir. Karmaşıklık matrisi sonuçlarına göre *üzüm çürük yaprak* sınıfına ait 472 örneğin 464 tanesi doğru sınıflandırılmış, 8 örnek ise *üzüm siyah kızamık hastalığı* sınıfı olarak yanlış tahmin edilmiştir. Bu durum, iki hastalık sınıfı arasındaki görsel benzerliklerin model tarafından sınırlı ölçüde karıştırıldığını göstermektedir. *Üzüm siyah kızamık hastalığı* sınıfında ise 480 örneğin 477 tanesi doğru sınıflandırılmış, 3 örnek *üzüm çürük yaprak* sınıfı olarak tahmin edilmiştir. Bu karşılıklı hata durumu, *üzüm çürük yaprak* ve *üzüm siyah kızamık* hastalıklarının benzer görsel özelliklere sahip olmasından kaynaklanmakta olup hata oranının oldukça düşük seviyede kalması modelin güçlü ayırt edici özellikler öğrenebildiğini göstermektedir. *Üzüm Isariopsis yaprak lekeli* ve *sağlıklı üzüm yaprağı* sınıflarında ise tüm örneklerin doğru sınıflandırıldığı görülmektedir. Sırasıyla 430 ve 423 örneğin tamamının doğru tahmin edilmesi, modelin bu sınıflarda ayırt edici özellikleri yüksek doğrulukla öğrenebildiğini ve sınıflar arası karışıklığın oluşmadığını göstermektedir. Özellikle sağlıklı yaprak sınıfında yanlış sınıflandırmanın bulunmaması, modelin hastalık belirtileri ile doğal yaprak varyasyonlarını başarılı biçimde ayırt edebildiğini ortaya koymaktadır.

Bununla birlikte, EfficientNetB3 modelinin 100 epoch eğitimi sonucunda elde edilen ROC eğrisi incelenmiştir. Şekil 53'te modelin sınıflar arasındaki ayırt edicilik performansını gösteren ROC eğrileri sunulmuştur.




Şekil 53. EfficientNetB3 modelinin 100 epoch eğitimi sonucunda elde edilen ROC eğrisi

Şekil 53'te verilen EfficientNetB3 modeline ait ROC eğrisi incelendiğinde, modelin tüm sınıflar için oldukça yüksek ayırt edicilik performansı sergilediği görülmektedir. ROC eğrisi altında kalan alan (AUC) değerlerinin sınıfların tamamı için 1.00 olduğu belirlenmiştir. AUC değerinin 1.00 olması, modelin sınıfları birbirinden tamamen ayırt edebildiğini ve yanlış pozitif oranının minimum seviyede kaldığını göstermektedir. ROC eğrilerinin grafikte sol üst köşeye yakın şekilde ilerlemesi, modelin düşük yanlış pozitif oranı ile yüksek doğru pozitif oranına ulaştığını göstermektedir. Bu durum EfficientNetB3 modelinin karar sınırlarını doğru şekilde oluşturduğunu ve sınıflar arası ayırt edici özellikleri başarılı biçimde öğrendiğini ortaya koymaktadır.

Genel olarak değerlendirildiğinde, EfficientNetB3 modelinin 100 epoch eğitimi sonucunda elde edilen ROC eğrisi sonuçları, sınıflandırma performans metrikleri ve karmaşıklık matrisi sonuçları birlikte incelendiğinde, EfficientNetB3 modelinin yüksek ayırt edicilik performansı sergilediği görülmektedir.

#### 4.3.4. MobileNetV2 modelinin 100 epoch eğitim sonuçları

Üzüm yaprağı hastalığı tespiti için MobileNetV2 modeli ile 100 epoch eğitimler yapılmıştır. Eğitim sonuçlarına ait kayıp ve doğruluk grafikleri Şekil 54'te verilmiştir.



Şekil 54. MobileNetV2 modelinin 100 epoch eğitimi sonucunda elde edilen kayıp ve doğruluk grafikleri

Şekil 54 incelendiğinde, modelin erken epochlardan itibaren hızlı ve kararlı bir öğrenme süreci gerçekleştirdiği görülmektedir. Eğitim doğruluğu ilk epochlarda hızlı bir artış göstererek %98 seviyesine ulaşmış ve eğitim süreci boyunca küçük dalgalanmalar ile stabil bir yapı sergilemiştir. Doğrulama doğruluğunun eğitim doğruluğuna oldukça yakın seyretmesi, modelin öğrenme sürecinde genelleme yeteneğini koruduğunu göstermektedir. Kayıp grafiği incelendiğinde hem eğitim hem de doğrulama kaybının başlangıçta hızlı bir düşüş gösterdiği ve ilerleyen epochlarda düşük seviyelerde sabitlendiği gözlemlenmektedir. Doğrulama kaybının eğitim kaybına oldukça yakın ve zaman zaman daha düşük olması, modelin aşırı öğrenme eğilimi göstermediğini ve öğrenilen özelliklerin doğrulama verisi üzerinde de başarılı şekilde temsil edildiğini ortaya koymaktadır. Eğitim sürecinin ilerleyen aşamalarında loss değerlerinin düşük seviyelerde kalması, modelin parametrelerinin optimum noktaya ulaştığını göstermektedir.

Ayrıca, MobileNetV2 modelinin 100 epoch eğitimi sonucunda elde ettiği sınıflandırma performansı, accuracy, precision, recall ve F1-score metrikleri temelinde değerlendirilmiş olup, elde edilen sonuçlar Tablo 21’de sınıf bazlı olarak sunulmuştur.

Tablo 21. MobileNetV2 modelinin 100 epoch eğitimi sonucunda elde edilen sınıflandırma performansı

Sınıf	Precision	Recall	F1-Score	Support
Üzüm çürük yaprak	0.9851	0.9831	0.9841	472
Üzüm siyah kızamık hastalığı	0.9833	0.9833	0.9833	480
Üzüm Isariopsis yaprak lekesi	0.9977	1.0000	0.9988	430
Sağlıklı üzüm yaprağı	1.0000	1.0000	1.0000	423
<b>Accuracy</b>			0.9911	1805
<b>Macro Avg</b>	0.9915	0.9916	0.9916	1805
<b>Weighted Avg</b>	0.9911	0.9911	0.9911	1805

Tablo 21’deki MobileNetV2 modelinin 100 epoch eğitimi sonucunda elde edilen sınıflandırma performansı incelendiğinde, modelin tüm sınıflar üzerinde yüksek ve dengeli bir sınıflandırma performansı sergilediği görülmektedir. Özellikle *üzüm Isariopsis yaprak lekesi* ve *sağlıklı üzüm yaprağı* sınıflarında F1-score değerlerinin 1.00’a çok yakın olması, modelin bu sınıfları yüksek doğrulukla ayırt edebildiğini göstermektedir. *Üzüm çürük yaprak* ve *üzüm siyah kızamık hastalığı* sınıflarında F1-score değerlerinin diğer sınıflara göre nispeten daha düşük olması, bu hastalıkların görsel özelliklerinin birbirine benzer olmasından kaynaklanmaktadır. Ancak elde edilen değerlerin 0.98 seviyesinin üzerinde olması, modelin genel sınıflandırma başarısının yüksek olduğunu ortaya koymaktadır. Macro ve weighted F1-score değerlerinin birbirine oldukça yakın olması, modelin veri setindeki tüm sınıflar üzerinde dengeli bir performans sergilediğini göstermektedir. MobileNetV2’nin düşük parametre sayısına sahip olmasına rağmen yüksek F1-score değerlerine ulaşması, mimarinin hesaplama verimliliği açısından avantaj sağladığını ve gerçek zamanlı uygulamalarda kullanılabilirliğini artırdığını göstermektedir.

MobileNetV2 modelinin 100 epoch eğitimi sonucunda elde ettiği sınıflandırma performansını daha ayrıntılı değerlendirebilmek amacıyla oluşturulan karmaşıklık matrisi sonuçları Şekil 55’te sunulmuştur.


**Karmaşıklık Matrisi**

Gerçek Sınıf	Üzüm Çürük Yaprak	464	8	0	0
	Üzüm Siyah Kızamık Hastalığı	7	472	1	0
	Üzüm Isariopsis Yaprak Lekesi	0	0	430	0
	Sağlıklı	0	0	0	423
		Üzüm Çürük Yaprak	Üzüm Siyah Kızamık Hastalığı	Üzüm Isariopsis Yaprak Lekesi	Sağlıklı
		Tahmin Edilen Sınıf			

Şekil 55. MobileNetV2 modelinin 100 epoch eğitimi sonucunda elde edilen karmaşıklık matrisi

Şekil 55'te verilen karmaşıklık matrisi incelendiğinde, modelin genel olarak yüksek doğruluk oranına sahip olduğu ve sınıflar arası karışıklığın oldukça düşük seviyede kaldığı görülmektedir. Karmaşıklık matrisi sonuçlarına göre *üzüm çürük yaprak* sınıfına ait 472 örneğin 464 tanesi doğru sınıflandırılmış, 8 örnek ise *üzüm siyah kızamık hastalığı* sınıfı olarak yanlış tahmin edilmiştir. Bu durum, söz konusu iki hastalık sınıfının görsel olarak benzer özellikler taşıması nedeniyle ortaya çıkan sınırlı düzeyde bir karışıklık olduğunu göstermektedir. *Üzüm siyah kızamık hastalığı* sınıfında ise 480 örneğin 472 tanesi doğru sınıflandırılmış, 7 örnek *üzüm çürük yaprak* ve 1 örnek *üzüm Isariopsis yaprak lekesi* sınıfı olarak tahmin edilmiştir. Bu sonuç, modelin genel olarak başarılı bir ayırım gerçekleştirdiğini ancak görsel benzerliğin yüksek olduğu hastalık sınıflarında küçük hata oranlarının oluşabildiğini göstermektedir. *üzüm Isariopsis yaprak lekesi* ve *sağlıklı üzüm yaprağı* sınıflarında tüm örneklerin doğru sınıflandırılması, modelin bu sınıflar için ayırt edici özellikleri yüksek doğrulukla öğrendiğini ortaya koymaktadır. Özellikle sağlıklı yaprakların hastalıklı sınıflarla karıştırılmaması, modelin hastalık belirtilerini doğru şekilde temsil edebildiğini göstermektedir.

Bununla birlikte, MobileNetV2 modelinin 100 epoch eğitimi sonucunda elde edilen ROC eğrisi incelenmiştir. Şekil 56’da modelin sınıflar arasındaki ayırt edicilik performansını gösteren ROC eğrileri sunulmuştur.




Şekil 56. MobileNetV2 modelinin 100 epoch eğitimi sonucunda elde edilen ROC eğrisi

Şekil 56’da verilen MobileNetV2 modeline ait ROC eğrisi incelendiğinde, modelin tüm sınıflar için oldukça yüksek ayırt edicilik performansı sergilediği görülmektedir. ROC eğrisi altında kalan alan (AUC) değerleri değerlendirildiğinde, *üzüm çürük yaprak* ve *üzüm siyah kızamık hastalığı* sınıfları için AUC değerlerinin 0.9997, *üzüm Isariopsis yaprak lekesi* ve *sağlıklı üzüm yaprağı* sınıfları için ise 1.000 olduğu belirlenmiştir. Bu sonuçlar modelin sınıflar arası ayrımı çok yüksek doğrulukla gerçekleştirdiğini göstermektedir. ROC eğrilerinin sol üst köşeye oldukça yakın bir şekilde ilerlemesi, modelin düşük yanlış pozitif oranı ile yüksek doğru pozitif oranına ulaştığını ortaya koymaktadır. Özellikle *üzüm Isariopsis yaprak lekesi* ve *sağlıklı üzüm yaprağı* sınıflarında AUC değerlerinin 1.00 olması, modelin bu sınıfları diğer sınıflardan hatasız şekilde ayırt edebildiğini göstermektedir. *Üzüm çürük yaprak* ve *üzüm siyah kızamık hastalığı* sınıflarında AUC değerlerinin çok küçük bir farkla daha düşük olması ise bu hastalık türlerinin görsel benzerliklerinden kaynaklanan doğal sınıflandırma zorlukları ile açıklanabilir.

Genel olarak değerlendirildiğinde, MobileNetV2 modelinin 100 epoch eğitimi sonucunda elde edilen ROC eğrisi sonuçları, sınıflandırma performans metrikleri ve karmaşıklık matrisi sonuçları, modelin yüksek genelleme kabiliyetine sahip olduğunu ve özellikle hesaplama maliyetinin önemli olduğu uygulamalarda güçlü bir alternatif olarak değerlendirilebileceğini göstermektedir.

#### 4.3.5. ResNet50 modelinin 100 epoch eğitim sonuçları

Üzüm yaprağı hastalığı tespiti için ResNet50 modeli ile 100 epoch eğitimler yapılmıştır. Eğitim sonuçlarına ait kayıp ve doğruluk grafikleri Şekil 57’de verilmiştir.



Şekil 57. ResNet50 modelinin 100 epoch eğitimi sonucunda elde edilen kayıp ve doğruluk grafikleri

Şekil 57 incelendiğinde, modelin erken epochlardan itibaren hızlı bir öğrenme süreci gerçekleştirdiği görülmektedir. Eğitim doğruluğu ilk birkaç epoch içerisinde hızlı bir şekilde yükselmiş ve ilerleyen epochlarda %99 seviyesine ulaşarak stabil bir seyir izlemiştir. Doğrulama doğruluğunun eğitim doğruluğuna oldukça yakın ilerlemesi, modelin eğitim verisini ezberlemek yerine genellenebilir özellikler öğrendiğini göstermektedir. Kayıp grafiği incelendiğinde, eğitim kaybının başlangıçta hızlı bir düşüş gösterdiği ve ilerleyen epochlarda düşük seviyelerde sabitlendiği görülmektedir. Doğrulama kaybının da benzer şekilde azalarak düşük seviyelerde seyretmesi, modelin öğrenme sürecinin dengeli ve kararlı olduğunu ortaya koymaktadır. Eğitim ve doğrulama loss eğrileri arasındaki farkın düşük olması, aşırı öğrenme (overfitting) probleminin oluşmadığını göstermektedir.

Ayrıca, ResNet50 modelinin 100 epoch eğitimi sonucunda elde ettiği sınıflandırma performansı, accuracy, precision, recall ve F1-score metrikleri temelinde değerlendirilmiş olup, elde edilen sonuçlar Tablo 22’de sınıf bazlı olarak sunulmuştur.

Tablo 22. ResNet50 modelinin 100 epoch eğitimi sonucunda elde edilen sınıflandırma performansı

Sınıf	Precision	Recall	F1-Score	Support
Üzüm çürük yaprak	0.9957	0.9915	0.9936	472
Üzüm siyah kızamık hastalığı	0.9917	0.9958	0.9938	480
Üzüm Isariopsis yaprak lekesi	1.0000	1.0000	1.0000	430
Sağlıklı üzüm yaprağı	1.0000	1.0000	1.0000	423
<b>Accuracy</b>			0.9967	1805
<b>Macro Avg</b>	0.9968	0.9968	0.9968	1805
<b>Weighted Avg</b>	0.9967	0.9967	0.9967	1805

Tablo 22’de ResNet50 modelinin 100 epoch eğitimi sonucunda elde edilen sınıflandırma performansı incelendiğinde, modelin tüm sınıflar üzerinde oldukça yüksek ve dengeli bir performans sergilediği görülmektedir. Precision, recall ve F1-score değerlerinin tüm sınıflarda 0.99 seviyesinin üzerinde olması, modelin sınıflar arası ayrımı başarılı bir şekilde gerçekleştirdiğini göstermektedir. Özellikle *üzüm Isariopsis yaprak lekesi* ve *sağlıklı üzüm yaprağı* sınıflarında F1-score değerlerinin 1.00 olması, modelin bu sınıfları hatasız şekilde ayırt edebildiğini göstermektedir. *Üzüm çürük yaprak* ve *üzüm siyah kızamık hastalığı* sınıflarında görülen küçük performans farkları ise hastalık belirtilerinin görsel olarak benzer olmasından kaynaklanan doğal sınıflandırma zorlukları olarak değerlendirilmektedir. Macro ve weighted F1-score değerlerinin birbirine oldukça yakın olması, modelin veri setindeki tüm sınıflarda dengeli bir performans sergilediğini ve herhangi bir sınıf lehine öğrenme eğilimi göstermediğini ortaya koymaktadır. ResNet50 mimarisinde kullanılan artık bağlantılar (residual connections), derin ağ yapısına rağmen gradyan kaybolması problemini azaltarak modelin uzun epoch eğitimlerinde stabil ve yüksek performans göstermesine katkı sağlamıştır.

ResNet50 modelinin 100 epoch eğitimi sonucunda elde ettiği sınıflandırma performansını daha ayrıntılı değerlendirebilmek amacıyla oluşturulan karmaşıklık matrisi sonuçları Şekil 58’de sunulmuştur.

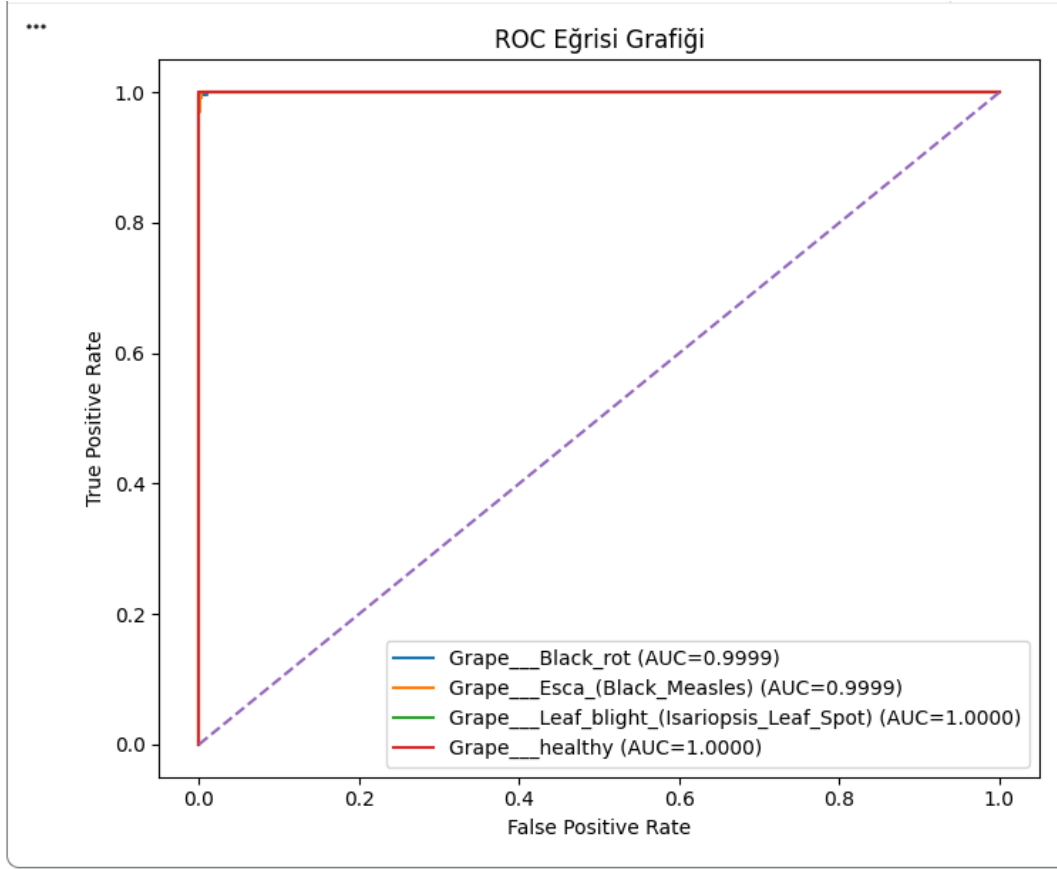
**Karmaşıklık Matrisi**

Gerçek Sınıf	Üzüm Çürük Yaprak	468	4	0	0
	Üzüm Siyah Kızamık Hastalığı	2	478	0	0
	Üzüm Isariopsis Yaprak Lekesi	0	0	430	0
	Sağlıklı	0	0	0	423
		Üzüm Çürük Yaprak	Üzüm Siyah Kızamık Hastalığı	Üzüm Isariopsis Yaprak Lekesi	Sağlıklı
		Tahmin Edilen Sınıf			

Şekil 58. ResNet50 modelinin 100 epoch eğitimi sonucunda elde edilen karmaşıklık matrisi

Şekil 58’de verilen karmaşıklık matrisi incelendiğinde, modelin tüm sınıflar üzerinde oldukça yüksek doğruluk oranına ulaştığı ve sınıflar arası karışıklığın minimum seviyede kaldığı görülmektedir. Karmaşıklık matrisi sonuçlarına göre *üzüm çürük yaprak* sınıfına ait 472 örneğin 468 tanesi doğru sınıflandırılmış, yalnızca 4 örnek *üzüm siyah kızamık hastalığı* sınıfı olarak yanlış tahmin edilmiştir. Bu durum, görsel olarak benzer özellikler taşıyan hastalık sınıfları arasında sınırlı düzeyde bir karışıklık olduğunu göstermektedir. *Üzüm siyah kızamık hastalığı* sınıfında ise 480 örneğin 478 tanesi doğru sınıflandırılmış, 2 örnek *üzüm çürük yaprak* sınıfı olarak tahmin edilmiştir. Bu karşılıklı hata durumu oldukça düşük seviyede olup modelin sınıflar arası ayırt edici özellikleri başarılı şekilde öğrendiğini göstermektedir. *Üzüm Isariopsis yaprak lekesi* ve *sağlıklı üzüm yaprağı* sınıflarında ise tüm örneklerin doğru sınıflandırıldığı görülmektedir. Sırasıyla 430 ve 423 örneğin tamamının doğru tahmin edilmesi, modelin bu sınıflar için yüksek ayırt ediciliğe sahip özellikler öğrendiğini ortaya koymaktadır.

Bununla birlikte, ResNet50 modelinin 100 epoch eğitimi sonucunda elde edilen ROC eğrisi incelenmiştir. Şekil 59’da modelin sınıflar arasındaki ayırt edicilik performansını gösteren ROC eğrileri sunulmuştur.



Şekil 59. ResNet50 modelinin 100 epoch eğitimi sonucunda elde edilen ROC eğrisi

Şekil 59’da verilen ResNet50 modeline ait ROC eğrisi incelendiğinde, modelin tüm sınıflar için oldukça yüksek ayırt edicilik performansı sergilediği görülmektedir. ROC eğrisi altında kalan alan (AUC) değerleri değerlendirildiğinde, *üzüm çürük yaprak* ve *üzüm siyah kızamık hastalığı* sınıfları için AUC değerlerinin 0.9999, *üzüm Isariopsis yaprak lekesi* ve *sağlıklı üzüm yaprağı* sınıfları için ise 1.00 olduğu belirlenmiştir. Bu sonuçlar modelin sınıflar arası ayrımı neredeyse hatasız şekilde gerçekleştirdiğini göstermektedir. ROC eğrilerinin grafikte sol üst köşeye çok yakın bir şekilde ilerlemesi, modelin düşük yanlış pozitif oranı ile yüksek doğru pozitif oranına ulaştığını ortaya koymaktadır. Özellikle *üzüm Isariopsis yaprak lekesi* ve *sağlıklı üzüm yaprağı* sınıflarında AUC değerlerinin 1.00 olması, modelin bu sınıfları diğer sınıflardan tamamen ayırt edebildiğini göstermektedir. *Üzüm çürük yaprak* ve *üzüm siyah kızamık hastalığı* sınıflarında AUC değerlerinin 1.00 değerine çok yakın olması ise bu hastalık türleri arasındaki görsel benzerliğe rağmen modelin güçlü bir ayırt edicilik performansı sergilediğini göstermektedir.

Genel olarak değerlendirildiğinde, ResNet50 modelinin 100 epoch eğitimi sonucunda elde edilen ROC eğrisi sonuçları, sınıflandırma performans metrikleri ve karmaşıklık matrisi

sonuçları, modelin yüksek ayırt edicilik gücü ve stabil öğrenme davranışı sayesinde yüksek performans gösterdiğini ortaya koymaktadır.

#### 4.3.6. CNN modellerinin 100 epoch eğitim sonuçlarının karşılaştırması

Kullanılan CNN modellerinin 100 epoch eğitim süresince elde ettiği doğruluk ve kayıp grafiklerine ait eğitim ve doğrulama davranışları karşılaştırmalı olarak incelenmiştir. Elde edilen bulgular Tablo 23'te verilmiştir.

Tablo 23. CNN modellerinin 100 epoch eğitimine ait doğruluk ve kayıp grafiklerinin karşılaştırması

Model	Doğruluk Davranışı	Kayıp Davranışı	Öğrenme Stabilitesi	Genel Yorum
AlexNet	Eğitim yüksek, doğrulama dalgalı	Doğrulama loss sıçramalı	Düşük	Overfitting eğilimi, uzun eğitim için uygun değil
DenseNet121	Eğitim ve doğrulama paralel	Düzenli ve düşük	Çok yüksek	En stabil ve en güçlü genelleme
EfficientNetB3	Yüksek ve dengeli	Stabil azalma	Yüksek	Performans ve verimlilik dengeli
MobileNetV2	Stabil ve yakın eğriler	Düşük ve kararlı	Yüksek	Hafif mimari, güçlü genelleme
ResNet50	Yüksek ve stabil	Düşük ve dengeli	Çok yüksek	Derin yapı sayesinde güvenilir öğrenme

100 epoch eğitimler sonucunda elde edilen doğruluk ve kayıp grafiklerinin birlikte değerlendirildiği Tablo 23 incelendiğinde, CNN mimarisinin yapısal özelliklerinin uzun eğitim süreçlerindeki öğrenme stabilitesi ve genelleme performansı üzerinde doğrudan etkili olduğunu göstermektedir. 100 epoch eğitim sürecinde AlexNet modelinin eğitim doğruluğunun yüksek seviyelere ulaşmasına rağmen doğrulama doğruluğunda ciddi dalgalanmalar olduğu ve doğrulama kaybında ani artışlar meydana geldiği gözlemlenmiştir. Bu durum modelin eğitim verisine aşırı uyum sağladığını ve genelleme yeteneğinin zayıfladığını göstermektedir. AlexNet'in görece daha eski ve sınırlı derinliğe sahip mimarisi, uzun eğitim süreçlerinde parametrelerin aşırı optimize edilmesine neden olmuş ve overfitting davranışı ortaya çıkmıştır. DenseNet121 modeli ise eğitim ve doğrulama doğruluğunun neredeyse paralel ilerlediği, kayıp değerlerinin düzenli biçimde azaldığı ve eğitim süreci boyunca stabil kaldığı bir öğrenme davranışı sergilemiştir. Bu nedenle DenseNet121 modeli, 100 epoch eğitim sürecinde en yüksek genelleme başarısını gösteren mimari olmuştur. EfficientNetB3 modeli, performans ve hesaplama verimliliği açısından dengeli bir öğrenme karakteri göstermiştir. MobileNetV2 modeli, düşük parametre sayısına rağmen stabil doğruluk ve düşük kayıp değerleri ile dikkat

çekmiştir. ResNet50 modeli ise stabil bir öğrenme süreci sağlamıştır. Eğitim ve doğrulama doğruluklarının birbirine yakın ilerlemesi ve kayıp değerlerinin düşük seviyelerde sabitlenmesi, modelin güçlü bir genelleme yeteneğine sahip olduğunu göstermektedir.

CNN modellerinin 100 epoch eğitim süresince elde ettiği sınıflandırma performansları, accuracy, macro ve weighted F1-score metrikleri temelinde de karşılaştırılmış olup, elde edilen sonuçlar Tablo 24’te sunulmuştur.

Tablo 24. CNN modellerinin 100 epoch eğitimine ait sınıflandırma performansı F1-score metriklerinin karşılaştırması

Model	Accuracy	Macro Avg	Weighted Avg	Genel Değerlendirme
AlexNet	0.8875	0.8901	0.8902	Düşük – Overfitting eğilimi
DenseNet121	0.9994	0.9995	0.9994	En yüksek – En stabil model
EfficientNetB3	0.9939	0.9942	0.9939	Çok yüksek – Dengeli öğrenme
MobileNetV2	0.9911	0.9916	0.9911	Yüksek – Stabil ve verimli
ResNet50	0.9967	0.9968	0.9967	Çok yüksek – Güçlü genelleme

100 epoch eğitimler sonucunda elde edilen F1-score metriklerinin birlikte değerlendirildiği Tablo 24 incelendiğinde, modern CNN mimarilerinin (DenseNet121, ResNet50, EfficientNetB3 ve MobileNetV2) öğrenme stabilitesi ve genelleme performansı açısından AlexNet mimarisine kıyasla belirgin şekilde daha başarılı olduğu görülmektedir. AlexNet modeli %88.75 doğruluk, 0.8901 macro F1-score ve 0.8902 weighted F1-score değerleri elde etmiştir. Eğitim doğruluğunun yüksek seviyelere ulaşmasına rağmen doğrulama performansındaki dalgalanmalar ve düşük F1-score değerleri, modelin uzun eğitim süreçlerinde aşırı öğrenme (overfitting) eğilimi gösterdiğini ortaya koymaktadır. DenseNet121 modeli ise tüm değerlendirme metriklerinde en yüksek performansı göstermiştir. Modelin %99.94 doğruluk, 0.9995 macro F1-score ve 0.9994 weighted F1-score değerlerine ulaşması, modelin tüm sınıflar üzerinde neredeyse hatasız bir sınıflandırma gerçekleştirdiğini göstermektedir. ResNet50 modeli %99.67 doğruluk, 0.9968 macro F1-score ve 0.9967 weighted F1-score değerleri ile DenseNet121 modeline en yakın performansı sergilemiştir. EfficientNetB3 modeli %99.39 doğruluk, 0.9942 macro F1-score ve 0.9939 weighted F1-score değerleri elde ederek yüksek performans göstermiştir. MobileNetV2 modeli ise daha düşük parametre sayısına sahip olmasına rağmen %99.11 doğruluk, 0.9916 macro F1-score ve 0.9911 weighted F1-score değerleri elde ederek dikkat çekici bir performans sergilemiştir. Çalışmada kullanılan

üzüm yaprak veri seti üzerinde DenseNet121 modeli en yüksek doğruluk ve F1-score değerlerine ulaşarak en başarılı sınıflandırma performansını göstermiştir.

CNN modellerinin sınıflandırma performansları karmaşıklık matrisleri ve ROC eğrileri temelinde de karşılaştırılmıştır. 100 epoch eğitim sonuçlarına ait karmaşıklık matrisleri incelendiğinde, modeller arasındaki en belirgin farkın sınıflar arası hata dağılımında ortaya çıktığı görülmektedir. AlexNet modeli, diğer CNN mimarilerine kıyasla daha fazla yanlış sınıflandırma üretmiştir. Ayrıca sağlıklı yaprakların bazı durumlarda hastalıklı sınıflara atanması, modelin görsel varyasyonları hastalık belirtisi olarak yorumlayabildiğini göstermektedir. Bu durum, AlexNet modelinin 100 epoch gibi uzun eğitim süreçlerinde aşırı öğrenme eğilimi göstermesiyle uyumludur. DenseNet121 modeli ise karmaşıklık matrisi açısından en başarılı sonucu göstermiştir. Neredeyse tüm örneklerin doğru sınıflandırılması ve yalnızca tek bir örnekte hata görülmesi, modelin sınıflar arası ayırt edici özellikleri yüksek doğrulukla öğrendiğini göstermektedir. EfficientNetB3 ve ResNet50 modelleri de oldukça benzer performans sergilemiş, yanlış sınıflandırmalar yalnızca görsel olarak benzer hastalık sınıfları arasında gerçekleşmiştir. MobileNetV2 modeli ise daha düşük parametre sayısına rağmen oldukça başarılı sonuçlar üretmiştir. Hata sayısının sınırlı olması modelin genelleme yeteneğinin yüksek olduğunu göstermektedir. Bununla birlikte, daha hafif mimari yapısı nedeniyle karmaşık özellik temsillerinde DenseNet121 ve ResNet50 modellerine kıyasla küçük performans farkları oluşmuştur.

100 epoch eğitim süreci sonunda elde edilen ROC eğrileri incelendiğinde, modern CNN mimarilerinin sınıflar arası ayırt edicilik performansı açısından AlexNet mimarisine kıyasla belirgin şekilde daha başarılı olduğu görülmektedir. DenseNet121 modeli ise tüm sınıflarda 1.00 AUC değerine ulaşarak ideal ROC davranışı sergilemiştir. ROC eğrilerinin sol üst köşeye yakın ilerlemesi, modelin düşük yanlış pozitif oranı ile yüksek doğru pozitif oranına ulaştığını göstermektedir. EfficientNetB3 ve ResNet50 modelleri de DenseNet121 modeline oldukça yakın sonuçlar üretmiş ve neredeyse ideal ayırt edicilik performansı göstermiştir. MobileNetV2 modeli ise daha düşük parametre sayısına rağmen AUC değerlerinin 1.00'a oldukça yakın olmasıyla dikkat çekmiştir. Bu durum, modelin hesaplama maliyeti düşük olmasına rağmen sınıflar arası ayrımı yüksek doğrulukla gerçekleştirebildiğini göstermektedir. Özellikle gerçek zamanlı veya sınırlı donanım kaynaklarına sahip uygulamalar için MobileNetV2'nin önemli bir alternatif olduğu değerlendirilmektedir.

Modellerin doğruluk ve kayıp, F1-skor, karmaşıklık matrisi ve ROC eğrisi analizleri birlikte değerlendirildiğinde, modern CNN mimarilerinin hem sınıflandırma doğruluğu hem de ayırt edicilik performansı açısından daha başarılı olduğunu ortaya koyulmuştur. Çalışmada kullanılan üzüm yaprak veri seti üzerinde DenseNet121 modeli en yüksek ROC performansını göstererek en başarılı model olarak öne çıkmıştır.

#### 4.4. CNN Modellerinin 20, 50 ve 100 Epoch Eğitim Sonuçlarının Karşılaştırması

CNN modellerinin öğrenme hızını ve doğrulama performansını ortaya koyduğu için doğruluk grafiklerine, hata oranındaki değişim ve öğrenme stabilitesini ortaya koyduğu için de kayıp grafiklerine göre karşılaştırılmalar yapılmıştır. CNN modellerinin eğitimleri sonucunda elde edilen doğruluk ve kayıp grafikleri incelendiğinde;

- 20 epoch eğitim sonuçlarına göre, tüm CNN modellerinin temel özellikleri öğrenebildiği ancak sınıflar arası ayırımı henüz tam olarak oluşmadığı görülmektedir. Bu aşamada eğitim doğruluğu yükselmekte olsa da doğrulama doğruluğu henüz maksimum seviyeye ulaşmamış ve kayıp değerleri görece yüksek kalmıştır. Bu durum özellikle AlexNet modelinde daha belirgin olup modelin veri setinin karmaşık yapısını öğrenmek için daha fazla eğitime ihtiyaç duyduğunu göstermektedir. Modern CNN mimarileri olan DenseNet121 ve MobileNetV2 modelleri ise daha derin yapıları sayesinde erken epochlarda dahi daha hızlı yakınsama göstermiştir.
- 50 epoch eğitim sonuçlarına göre, tüm modellerde eğitim ve doğrulama eğrilerinin birbirine yaklaştığı ve kayıp değerlerinin stabil hale geldiği gözlemlenmiştir. Bu durum modelin hem eğitim verisini öğrendiğini hem de genelleme yeteneğini koruduğunu göstermektedir. Özellikle DenseNet121 ve ResNet50 modellerinde başarı ve kayıp eğrilerinin paralel ilerlemesi, öğrenme sürecinin dengeli olduğunu ortaya koymaktadır. EfficientNetB3 ve MobileNetV2 modellerinde de benzer şekilde doğruluk artışı yavaşlayarak stabil bir seviyeye ulaşmış, model performansının doyum noktasına geldiği görülmüştür. Bu nedenle 50 epoch, model performansı ile genelleme yeteneği arasında en dengeli noktayı temsil etmektedir.
- 100 epoch eğitim sonuçlarına göre, model davranışları arasında belirgin farklılıklar ortaya çıkmıştır. AlexNet modelinde doğrulama doğruluğunda ani düşüşler ve kayıp değerlerinde sıçramalar gözlemlenmiş, bu durum modelin aşırı öğrenme eğilimi gösterdiğini ortaya koymuştur. Buna karşılık DenseNet121, EfficientNetB3, MobileNetV2 ve ResNet50 modellerinde eğitim stabilitesi büyük ölçüde korunmuş,

ancak performans artışının sınırlı kaldığı görülmüştür. Bu durum modelin öğrenme sürecini büyük ölçüde tamamladığını ve ek epoch sayısının performansa önemli katkı sağlamadığını göstermektedir.

Precision ve recall değerlerinin harmonik ortalaması olması nedeniyle özellikle çok sınıflı sınıflandırma problemlerinde model performansının dengeli bir şekilde değerlendirilmesini sağladığı için F1-score metriğine göre de karşılaştırmalar yapılmıştır. CNN modellerinin eğitimleri sonucunda elde edilen F1-score metrikleri incelendiğinde;

- 20 epoch eğitim sonuçlarına göre, tüm CNN modellerinin veri setine ait temel özellikleri öğrenebildiği ancak sınıflar arası ayrımın henüz tam olarak olgunlaşmadığı görülmektedir. Bu aşamada F1-score değerleri özellikle AlexNet modelinde daha düşük seviyede kalmış, modern CNN mimarilerinde ise daha yüksek başlangıç performansı gözlemlenmiştir. DenseNet121 ve MobileNetV2 modellerinin erken epochlarda dahi yüksek F1-score değerlerine ulaşması, bu mimarilerin daha güçlü özellik çıkarım kapasitesine sahip olduğunu göstermektedir.
- 50 epoch eğitim sonuçlarına göre, tüm modellerin F1-score değerlerinin maksimum seviyelerine ulaştığı veya bu seviyeye oldukça yaklaştığı görülmektedir. Eğitim ve doğrulama performanslarının dengelenmesi, modellerin genelleme yeteneğinin en yüksek olduğu noktayı temsil etmektedir. Özellikle DenseNet121 ve ResNet50 modellerinde F1-score değerlerinin oldukça yüksek ve stabil kalması, modelin sınıflar arası ayrımı başarılı şekilde gerçekleştirdiğini göstermektedir. EfficientNetB3 ve MobileNetV2 modellerinde ise performans artışının bu noktadan sonra sınırlı kaldığı görülmektedir.
- 100 epoch eğitim sonuçlarına göre, model davranışları farklılaşmaya başlamıştır. AlexNet modelinde F1-score değerlerinde düşüş gözlemlenmesi, modelin aşırı öğrenme eğilimi gösterdiğini ortaya koymaktadır. Buna karşılık DenseNet121, EfficientNetB3, MobileNetV2 ve ResNet50 modellerinde F1-score değerlerinin büyük ölçüde korunması, bu mimarilerin uzun eğitim süreçlerinde daha stabil öğrenme davranışı sergilediğini göstermektedir. Ancak performans artışının sınırlı kalması, öğrenme sürecinin büyük ölçüde tamamlandığını göstermektedir.

Modellerin sınıflar arası ayırım performansını gösterdiği için karmaşıklık matrisine göre de karşılaştırmalar yapılmıştır. CNN modellerinin eğitimleri sonucunda elde edilen karmaşıklık matrisleri incelendiğinde;

- 20 epoch eğitim sonuçlarına göre, tüm modellerin temel sınıf özelliklerini öğrenmeye başladığı ancak sınıflar arası ayırımın henüz tam olarak oluşmadığı görülmektedir. Bu aşamada özellikle AlexNet modelinde sınıflar arası karışıklık daha belirgin olup, *üzüm çürük yaprak* ve *üzüm siyah kızamık* hastalıklarının sıkça birbirine karıştırıldığı gözlemlenmiştir. Modern CNN mimarileri olan DenseNet121 ve MobileNetV2 modelleri ise daha derin yapıları sayesinde erken epochlarda dahi daha düşük hata oranı sergilemiştir.
- 50 epoch eğitim sonuçlarına göre, karmaşıklık matrislerinde belirgin bir iyileşme görülmüştür. Yanlış sınıflandırmaların önemli ölçüde azaldığı ve doğru sınıflandırma oranlarının arttığı gözlemlenmiştir. Bu aşamada modellerin çoğunda hata dağılımı yalnızca görsel olarak benzer hastalık sınıfları arasında sınırlı kalmıştır. Özellikle DenseNet121 ve ResNet50 modellerinde doğru sınıflandırma oranlarının maksimum seviyeye ulaştığı görülmüş, modelin sınıflar arası ayırt edici özellikleri başarılı şekilde öğrendiği anlaşılmıştır.
- 100 epoch eğitim sonuçlarına göre, model davranışları mimariye bağlı olarak farklılaşmıştır. AlexNet modelinde hata dağılımının tekrar artması ve sağlıklı yaprakların hastalıklı sınıflara atanması, modelin aşırı öğrenme eğilimi gösterdiğini ortaya koymuştur. Buna karşılık DenseNet121 modelinde hata oranının yok denecek seviyeye düşmesi, modelin güçlü genelleme kabiliyetini göstermektedir. EfficientNetB3, MobileNetV2 ve ResNet50 modellerinde ise hata oranlarının düşük seviyede stabil kaldığı ve ek epoch sayısının sınıflandırma başarısına sınırlı katkı sağladığı görülmüştür.

Modellerin farklı karar eşiklerinde doğru pozitif oranı ile yanlış pozitif oranı arasındaki ilişkiyi göstererek sınıflar arası ayırt edicilik performansını değerlendirmeye olanak sağladığı için ROC eğrisi ve sınıfları birbirinden ayırabilme başarısını sayısal olarak ifade ettiği için AUC değerine göre de karşılaştırmalar yapılmıştır. CNN modellerinin eğitimleri sonucunda elde edilen ROC eğrisi incelendiğinde;

- 20 epoch eğitim sonuçlarına göre, tüm modellerin ROC eğrilerinin sol üst köşeye doğru yöneldiği, ancak sınıflar arasında ayırt edicilik seviyesinin henüz maksimum düzeye

ulaşmadığı görülmektedir. Bu aşamada AlexNet modelinde özellikle görsel olarak benzer olan *üzüm çürük yaprak* ve *üzüm siyah kızamık* hastalıkları arasında daha düşük AUC değerleri gözlemlenmiştir. Buna karşılık DenseNet121 ve MobileNetV2 modelleri daha derin mimari yapıları sayesinde erken epochlarda dahi yüksek ayırt edicilik performansı göstermiştir.

- 50 epoch eğitim sonuçlarına göre, ROC eğrilerinin tüm modeller için belirgin şekilde iyileştiği ve AUC değerlerinin maksimum seviyeye yaklaştığı görülmektedir. Bu aşamada modellerin doğru pozitif oranlarının arttığı ve yanlış pozitif oranlarının azaldığı gözlemlenmiştir. Özellikle DenseNet121 ve ResNet50 modellerinde ROC eğrilerinin ideal sınıflandırma eğrisine oldukça yakın ilerlemesi, modelin sınıflar arası ayırım yeteneğinin en yüksek seviyeye ulaştığını göstermektedir. EfficientNetB3 ve MobileNetV2 modellerinde de benzer şekilde dengeli bir ROC davranışı elde edilmiştir.
- 100 epoch eğitim sonuçlarına göre, model davranışları mimari yapıya bağlı olarak farklılaşmıştır. AlexNet modelinde bazı sınıflarda AUC değerlerinin düşmesi, modelin aşırı öğrenme eğilimi gösterdiğini ve karar sınırlarının genelleme açısından zayıfladığını göstermektedir. Buna karşılık DenseNet121, EfficientNetB3, MobileNetV2 ve ResNet50 modellerinde ROC eğrilerinin ideal yapıya yakın kaldığı ve ayırt edicilik performansının korunduğu görülmüştür. Ancak bu aşamada performans artışının sınırlı kalması, öğrenme sürecinin büyük ölçüde tamamlandığını göstermektedir.

Çalışma kapsamında kullanılan AlexNet, DenseNet121, EfficientNetB3, MobileNetV2 ve ResNet50 mimarilerinin 20, 50 ve 100 epoch eğitimi sonucunda gösterdikleri öğrenme davranışları birlikte değerlendirildiğinde, epoch sayısının model performansı üzerindeki etkisinin doğrusal olmadığı açık biçimde görülmektedir.

20 epoch seviyesinde tüm modeller temel özellikleri öğrenmeye başlamış, ancak sınıflar arası ayırt edicilik henüz maksimum seviyeye ulaşmamıştır. Bu aşamada doğruluk değerleri yükselmesine rağmen F1-score ve ROC sonuçlarının nispeten daha düşük kalması, modelin bazı sınıflarda yanlış pozitif ve yanlış negatif üretmeye devam ettiğini göstermektedir. Özellikle AlexNet modelinde sınıflar arası karışıklığın daha belirgin olması, mimarinin sınırlı derinliği ve daha basit özellik temsil kapasitesi ile açıklanabilmektedir. Buna karşılık DenseNet121 ve MobileNetV2 modellerinin erken epochlarda dahi yüksek performans göstermesi, derin ağ yapısının karmaşık görsel örüntüleri daha hızlı öğrenebildiğini ortaya koymaktadır.

50 epoch seviyesinde tüm CNN modellerinde öğrenme sürecinin olgunlaştığı görülmektedir. Eğitim ve doğrulama doğruluğu eğrilerinin birbirine yaklaşması, kayıp değerlerinin stabil hale gelmesi ve karmaşıklık matrislerinde hata oranlarının minimum seviyeye inmesi, modellerin genelleme performansının en yüksek olduğu noktaya ulaşıldığını göstermektedir. Bu aşamada F1-score değerlerinin maksimum seviyeye ulaşması, modelin yalnızca doğru sınıflandırma yapmakla kalmayıp sınıflar arasında dengeli bir ayırım gerçekleştirdiğini ortaya koymaktadır. ROC eğrilerinin ideal sınıflandırma eğrisine yaklaşması da bu durumu desteklemektedir. Özellikle DenseNet121 modelinde özelliklerin katmanlar arasında yeniden kullanılmasını sağlayan yoğun bağlantı yapısı, öğrenilen bilgilerin kaybolmasını engelleyerek stabil bir öğrenme süreci oluşturmuştur. ResNet50 modelinde ise artık bağlantılar derin ağ yapısına rağmen gradyan kaybolmasını önleyerek benzer şekilde stabil bir performans sağlamıştır. EfficientNetB3 ve MobileNetV2 modelleri ise parametre verimliliği sayesinde daha kısa sürede doyum noktasına ulaşmış ve performans artışı bu aşamadan sonra sınırlı kalmıştır.

100 epoch eğitim sürecinde ise model davranışlarının mimari yapıya bağlı olarak ayrıştığı görülmektedir. AlexNet modelinde doğrulama doğruluğundaki dalgalanmalar, kayıp değerlerindeki ani artışlar ve F1-score değerlerindeki düşüş modelin aşırı öğrenme eğilimi gösterdiğini ortaya koymaktadır. Model eğitim verisine aşırı uyum sağlamış ve yeni veriler üzerinde genelleme yeteneği zayıflamıştır. Buna karşılık DenseNet121, EfficientNetB3, MobileNetV2 ve ResNet50 modellerinde performansın büyük ölçüde korunması, modern CNN mimarilerinin daha güçlü düzenleme etkisine sahip olduğunu göstermektedir. Ancak bu modellerde de 50 epoch sonrasında performans artışının oldukça sınırlı kalması, öğrenme sürecinin büyük ölçüde tamamlandığını ve ek epoch sayısının anlamlı bir katkı sağlamadığını göstermektedir.

Tüm bulgular birlikte değerlendirildiğinde; doğruluk, F1-score, ROC eğrileri ve karmaşıklık matrisi sonuçlarının birbirini doğruladığı görülmektedir. DenseNet121 modeli tüm epoch seviyelerinde en yüksek ve en stabil performansı göstermiş, özellikle 100 epoch seviyesinde neredeyse hatasız sınıflandırma başarısına ulaşmıştır. ResNet50 ve EfficientNetB3 modelleri 100 epoch seviyesinde DenseNet121 modeline oldukça yakın sonuçlar üretmiş ve güçlü genelleme performansı sergilemiştir. MobileNetV2 modeli ise daha düşük parametre sayısına rağmen yüksek performans elde ederek hesaplama maliyeti açısından avantaj sağlamıştır. AlexNet modeli ise özellikle uzun eğitim süreçlerinde genelleme performansı açısından diğer modellere göre daha düşük başarı göstermiştir.

Elde edilen bulgular, CNN mimarisinin yalnızca derinliğinin değil, aynı zamanda katmanlar arası bağlantı yapısının ve özellik yeniden kullanım mekanizmasının model performansı üzerinde belirleyici olduğunu ortaya koymaktadır. Çalışmada kullanılan üzüm yaprak veri seti için 50 epoch eğitim süresinin performans ve genelleme dengesi açısından optimal olduğu belirlenmiş, DenseNet121 modeli ise tüm değerlendirme metriklerinde en yüksek performansı göstererek en başarılı model olarak öne çıkmıştır.

## 5. TARTIŞMA

Bu çalışmada üzüm yaprak hastalıklarının otomatik tespiti ve sınıflandırılması amacıyla farklı derin öğrenme tabanlı CNN mimarileri kapsamlı biçimde karşılaştırılmış ve modellerin öğrenme davranışları yalnızca doğruluk metriği ile değil, aynı zamanda F1-score, karmaşıklık matrisi ve ROC eğrisi analizleri birlikte değerlendirilerek çok yönlü bir performans analizi gerçekleştirilmiştir. Literatürde bitki hastalıklarının tespitine yönelik birçok çalışma bulunmasına rağmen, bu çalışmaların önemli bir kısmında modeller genellikle tek bir epoch değeri üzerinden değerlendirilmiş veya performans analizleri sınırlı sayıda metrik ile yapılmıştır. Bu çalışma, farklı CNN mimarilerinin farklı eğitim süreleri altında nasıl davrandığını sistematik biçimde inceleyerek literatürdeki bu boşluğu doldurmaktadır.

Çalışmanın en önemli katkılarından biri, CNN mimarisinin yapısal özellikleri ile öğrenme stabilitesi arasındaki ilişkinin deneysel olarak ortaya konulmasıdır. Elde edilen sonuçlar, yalnızca model derinliğinin değil, aynı zamanda katmanlar arası bağlantı yapısının ve özellik yeniden kullanım mekanizmalarının model performansı üzerinde belirleyici olduğunu göstermiştir. DenseNet121 mimarisinin yoğun bağlantı yapısı sayesinde uzun eğitim süreçlerinde dahi stabil performans göstermesi, modern CNN mimarilerinin klasik mimarilere kıyasla genelleme yeteneği açısından daha avantajlı olduğunu açık biçimde ortaya koymuştur. Bu bulgu, bitki hastalığı tespiti alanında model seçiminde yalnızca doğruluk değerlerinin değil, öğrenme davranışının da dikkate alınması gerektiğini göstermesi açısından literatüre önemli bir katkı sağlamaktadır.

Bu çalışmanın bir diğer katkısı, epoch sayısının model performansı üzerindeki etkisinin sistematik olarak analiz edilmesidir. Elde edilen sonuçlar, eğitim süresinin artırılmasının her zaman performans artışı sağlamadığını, belirli bir noktadan sonra performansın doyuma ulaştığını ve bazı mimarilerde aşırı öğrenme riskinin ortaya çıktığını göstermektedir. Özellikle 50 epoch seviyesinin performans ve genelleme dengesi açısından optimal bir eğitim süresi sunduğunun ortaya konulması, gelecekte yapılacak benzer çalışmalar için önemli bir referans niteliği taşımaktadır.

Ayrıca bu çalışma, farklı performans metriklerinin birlikte değerlendirilmesinin model performansının daha doğru yorumlanmasını sağladığını göstermektedir. Accuracy değerinin tek başına yeterli olmadığı, F1-score ve ROC analizlerinin sınıflar arası ayırım başarısını daha net

ortaya koyduđu deneysel olarak gösterilmiřtir. Bu yaklařım, tarımsal grnt iřleme alıřmalarında daha kapsamlı deęerlendirme metodolojilerinin kullanılmasına katkı saęlamaktadır.

Uygulama aısından deęerlendirildięinde ise nerilen DenseNet121 tabanlı modelin yksek doęruluk, dřk hata oranı ve gl genelleme performansı sayesinde gerek zamanlı tarımsal hastalık tespit sistemlerinde kullanılabilir potansiyele sahip olduęu grlmektedir. Bu durum, erken hastalık teřhisi sayesinde rn kayıplarının azaltılması ve tarımsal verimlilięin artırılması aısından nemli bir uygulama katkısı sunmaktadır.

Bu alıřma, farklı CNN mimarilerinin epoch bazlı ęrenme davranıřlarını oklu performans metrikleri ile birlikte analiz ederek hem metodolojik hem de uygulama aısından literatre katkı saęlamıř, zm yaprak hastalıklarının derin ęrenme tabanlı otomatik tespiti alanında kapsamlı ve karřılařtırmalı bir referans alıřma ortaya koymuřtur.

## 6. SONUÇ ve ÖNERİLER

Günümüzde teknoloji hızla gelişmekte ve bu gelişim süreci, hemen her alanda yeni dijital çözümlerin ortaya çıkmasına zemin hazırlamaktadır. Bu yenilikler arasında, sunduğu yüksek hesaplama kapasitesi ve insan benzeri karar verme yetenekleri sayesinde yapay zekâ (YZ) en dikkat çekici teknolojilerden biri hâline gelmiştir. Yapay zekâ sistemleri, büyük veri kümeleri üzerinden öğrenme yetenekleri sayesinde karmaşık problemleri analiz edebilmekte ve geleneksel yöntemlere kıyasla daha hızlı ve doğru sonuçlar üretebilmektedir. Bu özellikler, yapay zekânın birçok alanda olduğu gibi tarım gibi stratejik ve toplumsal açıdan kritik öneme sahip sektörlerde de etkin biçimde kullanılmasını gerekli kılmaktadır.

Tarım sektörü, dünya nüfusunun artmasıyla birlikte artan gıda ihtiyacını karşılamak zorunda kalmış ve bu durum, daha verimli, sürdürülebilir ve akıllı üretim yöntemlerinin geliştirilmesini zorunlu hâle getirmiştir. Bitki hastalıkları, özellikle üzüm gibi ekonomik değeri yüksek ürünlerde ciddi verim kayıplarına yol açmakta ve üreticiler için önemli ekonomik riskler oluşturmaktadır. Bu bağlamda, hastalıkların erken evrede tespit edilmesi ve hızlı müdahale imkânı sunan yapay zekâ tabanlı sistemler, modern tarım uygulamalarında önemli bir rol üstlenmektedir.

Bu çalışmanın temel amacı, üzüm yapraklarını erken aşamada analiz edebilen ve hastalıkları yüksek doğruluk oranlarıyla tespit edebilen CNN tabanlı bir modelin belirlenmesi ve performansının kapsamlı biçimde değerlendirilmesidir. Bu doğrultuda, farklı CNN mimarileri kullanılarak üzüm yaprağı hastalıklarının otomatik tespiti ve sınıflandırılması gerçekleştirilmiştir. Çalışmada elde edilen bulgular, derin öğrenme tabanlı modellerin yalnızca laboratuvar ortamında değil, gelecekte kamera sistemleri ile entegre edilerek bağ alanlarında gerçek zamanlı hastalık tespiti yapılmasına olanak sağlayabileceğini ve üreticilere hızlı karar destek mekanizmaları sunabileceğini göstermektedir.

Çalışma kapsamında AlexNet, DenseNet121, EfficientNetB3, MobileNetV2 ve ResNet50 mimarileri 20, 50 ve 100 epoch eğitim süreleri için karşılaştırmalı olarak incelenmiştir. Elde edilen sonuçlar, epoch sayısının model performansı üzerinde doğrudan etkili olduğunu ortaya koymuştur.

20 epoch eğitim sonuçlarında, modellerin genel olarak temel özellikleri öğrendiği ancak sınıflar arası ayırımın yeterince oluşmadığı gözlenmiş, bu aşamada özellikle AlexNet ve EfficientNetB3 modellerinde doğruluk değerlerinin yaklaşık %40–60 aralığında kaldığı ve macro F1-score değerlerinin daha düşük seviyelerde gerçekleştiği belirlenmiştir. Bu durum, modelin veri setini tam olarak öğrenemediğini gösteren underfitting davranışı ile açıklanmıştır. DenseNet121 ve MobileNetV2 modellerinin erken epochlarda daha hızlı yakınsama ve daha stabil öğrenme davranışı sergilediği, EfficientNetB3 ve ResNet50 modellerinde öğrenme sürecinin devam ettiği ve kayıp değerlerinin hâlen düşme eğiliminde olduğu gözlemlenmiştir.

50 epoch eğitim sonuçlarında, tüm modellerde belirgin performans artışı gözlenmiş, eğitim ve doğrulama sonuçları arasında dengeli bir yapı oluşmuştur. DenseNet121 ve ResNet50 modelleri bu aşamada en yüksek performansı göstermiştir. DenseNet121 modelinde doğruluk oranının yaklaşık %99 seviyesine, macro F1-score ve weighted F1-score değerlerinin ise %99'a yakın seviyelere ulaştığı, ResNet50 modelinde de benzer stabil sonuçlar elde edildiği görülmüştür. ROC eğrilerinin ideal köşeye yakın seyretmesi ve karmaşıklık matrislerinde yanlış sınıflandırma oranlarının minimum seviyeye düşmesi, bu epoch seviyesinin modeller için optimal öğrenme noktası olduğunu göstermektedir.

100 epoch eğitim sonuçlarında ise bazı modellerde eğitim doğruluğunun artmaya devam etmesine rağmen doğrulama performansında sınırlı iyileşme veya dalgalanmalar gözlenmiştir. Özellikle AlexNet modelinde görülen validation loss değeri artış eğilimi, modelin eğitim verisine aşırı uyum sağladığını ve genelleme yeteneğinin kısmen azaldığını göstermektedir. Bu durum overfitting davranışı ile açıklanmakta olup, daha uzun eğitim süresinin her zaman daha yüksek performans anlamına gelmediğini ortaya koymaktadır.

Genel değerlendirme sonucunda DenseNet121 ve MobileNetV2 modellerinin diğer mimarilere kıyasla daha stabil ve güvenilir sonuçlar sunduğu belirlenmiştir. Bu iki modelin %98'in üzerinde doğruluk ve yüksek F1-score değerlerine ulaşması, CNN tabanlı derin öğrenme yaklaşımlarının üzüm yaprağı hastalıklarının tespitinde yüksek bir potansiyele sahip olduğunu göstermektedir. Özellikle DenseNet121 modelinin katmanlar arası yoğun bağlantı yapısı sayesinde düşük seviyeli ve yüksek seviyeli özellikleri birlikte kullanabilmesi, benzer görsel özelliklere sahip hastalık sınıflarının ayırımında daha başarılı sonuçlar elde edilmesini sağlamıştır. Elde edilen bulgular, doğru mimari seçimi ve uygun epoch sayısının birlikte

değerlendirilmesinin, tarımsal görüntü sınıflandırma problemlerinde model başarısını doğrudan etkilediğini ortaya koymaktadır.

Çalışmanın en önemli güçlü yönlerinden biri, farklı CNN mimarilerinin yalnızca tek bir performans ölçütü üzerinden değil, doğruluk, kesinlik, duyarlılık, F1-score, karmaşıklık matrisi ve ROC eğrisi sonuçlarının birlikte değerlendirilmesiyle çok boyutlu bir analiz yapılmış olmasıdır. Bu yaklaşım, model performansının daha objektif biçimde değerlendirilmesine olanak sağlamış ve elde edilen sonuçların güvenilirliğini artırmıştır.

Çalışmanın bir diğer güçlü yönü, modellerin farklı epoch seviyelerinde (20, 50 ve 100) değerlendirilmiş olmasıdır. Bu sayede yalnızca hangi modelin daha başarılı olduğu değil, aynı zamanda modellerin öğrenme süreçlerinin nasıl değiştiği ve hangi noktada optimal performansa ulaştıkları ortaya konulmuştur. Özellikle 50 epoch seviyesinin performans ve genelleme dengesi açısından optimal eğitim süresi olarak belirlenmesi, gelecekte yapılacak benzer çalışmalar için önemli bir referans niteliği taşımaktadır. Ayrıca farklı CNN mimarilerinin aynı veri seti ve aynı eğitim koşulları altında test edilmesi, karşılaştırma sonuçlarının bilimsel açıdan tutarlı olmasını sağlamıştır.

DenseNet121 modelinin tüm performans metriklerinde en yüksek ve en stabil sonuçları vermesi, çalışmanın önemli bulguları arasında yer almıştır. Modelin yüksek doğruluk, düşük hata oranı ve güçlü genelleme performansı göstermesi, önerilen yaklaşımın gerçek tarımsal uygulamalarda kullanılabilirliğini desteklemektedir. Bunun yanında MobileNetV2 gibi daha hafif mimarilerin de yüksek performans göstermesi, çalışmanın yalnızca yüksek doğruluk değil aynı zamanda hesaplama verimliliği açısından da değerlendirme sunmasını sağlamıştır.

Bununla birlikte çalışmanın bazı sınırlılıkları da bulunmaktadır. Öncelikle kullanılan veri seti kontrollü koşullarda elde edilmiş görüntülerden oluşmaktadır. Gerçek tarım ortamlarında ışık değişimleri, yaprak deformasyonları, arka plan karmaşıklığı ve farklı kamera koşulları gibi faktörler model performansını etkileyebilmektedir. Bu nedenle elde edilen sonuçların doğrudan saha koşullarına genellenebilmesi için gerçek ortam verileri ile ek testlerin yapılması gerekmektedir. Ayrıca çalışmada yalnızca görüntü tabanlı CNN mimarileri değerlendirilmiş olup, transformer tabanlı veya hibrit derin öğrenme modelleri kapsam dışında bırakılmıştır.

Bir diğerk sınırlılık ise veri setinde yer alan hastalık sınıflarının belirli türlerle sınırlı olmasıdır. Daha fazla hastalık türünün ve farklı üzüm çeşitlerinin veri setine dahil edilmesi, modelin genelleme yeteneğinin daha geniş ölçekte değerlendirilmesine katkı sağlayabilir. Bununla birlikte, veri artırma yöntemlerinin daha kapsamlı biçimde uygulanması ve farklı optimizasyon stratejilerinin denenmesi model performansını daha da geliştirebilir.

Elde edilen sonuçlar başarılı olmakla birlikte, çalışmanın kapsamının genişletilmesi ve gerçek dünya uygulamalarına daha fazla yaklaşılması amacıyla gelecekte gerçekleştirilebilecek çeşitli çalışmalar bulunmaktadır.

Öncelikle, çalışmada kullanılan veri seti kontrollü koşullarda elde edilmiş görüntülerden oluşmaktadır. Gelecek çalışmalarda farklı ışık koşulları, farklı kamera açıları, gölge etkileri ve doğal arka plan içeren gerçek tarım ortamı görüntülerinin veri setine dahil edilmesi, modellerin saha koşullarındaki genelleme performansının daha gerçekçi biçimde değerlendirilmesini sağlayacaktır. Özellikle mobil cihazlar veya drone tabanlı görüntü toplama sistemlerinden elde edilen verilerin kullanılması, tercih edilen modelin gerçek zamanlı tarımsal uygulamalara entegrasyonunu kolaylaştıracaktır.

İkinci olarak, bu çalışmada yalnızca CNN tabanlı mimariler değerlendirilmiştir. Son yıllarda görüntü sınıflandırma alanında önemli başarılar elde eden vision transformer, swin transformer ve CNN–transformer hibrit mimarilerinin gelecekte benzer veri setleri üzerinde test edilmesi, model performansının daha ileri seviyelere taşınmasına katkı sağlayabilir. Özellikle global özellik çıkarımında başarılı olan transformer tabanlı modellerin, görsel olarak benzer hastalık sınıflarının ayırımında avantaj sağlayabileceği düşünülmektedir.

Bununla birlikte, veri artırma tekniklerinin daha gelişmiş yöntemlerle uygulanması da gelecekteki çalışmalar için önemli bir geliştirme alanıdır. Rastgele döndürme, ölçekleme ve renk dönüşümlerine ek olarak GAN tabanlı sentetik veri üretimi veya otomatik veri artırma yöntemleri kullanılarak veri çeşitliliği artırılabilir. Bu yaklaşım, modelin farklı çevresel koşullara karşı daha dayanıklı hale gelmesini sağlayacaktır.

Gelecek çalışmalarda yalnızca sınıflandırma değil, aynı zamanda hastalık bölgesinin tespiti ve lokalizasyonu da hedeflenebilir. Bu amaçla YOLO, Faster R-CNN veya Mask R-CNN gibi nesne tespiti ve segmentasyon tabanlı yaklaşımlar kullanılarak yaprak üzerindeki hastalık

bölgelerinin otomatik olarak belirlenmesi sağlanabilir. Böylece sistem yalnızca hastalığın türünü değil, aynı zamanda hastalığın yayılım seviyesini de analiz edebilecek hale getirilebilir. Ayrıca, tercih edilen modelin gerçek zamanlı karar destek sistemi olarak kullanılabilmesi amacıyla mobil veya gömülü sistemlere entegrasyonu gelecekteki önemli çalışma alanlarından biridir. Özellikle MobileNetV2 gibi hafif mimarilerin optimize edilerek mobil uygulamalara aktarılması, çiftçilerin sahada hızlı ve doğru hastalık tespiti yapabilmesine olanak sağlayacaktır.

Yapay zekâ ve derin öğrenme teknolojileri günümüzde yalnızca akademik çalışmalarla sınırlı kalmayıp, gerçek dünya uygulamalarında da giderek daha fazla yer bulmaktadır. Bu çalışma kapsamında elde edilen bulgular, CNN tabanlı yaklaşımların üzüm yaprağı hastalıklarının tespiti ve sınıflandırılmasında etkili, güvenilir ve uygulanabilir çözümler sunduğunu göstermektedir. Yapay zekânın bilinçli ve doğru biçimde tarım sektörüne entegre edilmesi, hem günümüz üretim sorunlarına çözüm sunacak hem de gelecekte sürdürülebilir tarım uygulamalarının temelini oluşturacaktır.

Sonuç olarak, bu çalışma üzüm yaprak hastalıklarının derin öğrenme tabanlı tespitine yönelik güçlü bir temel oluşturmakta olup, daha geniş veri setleri, yeni nesil mimariler ve gerçek zamanlı uygulamalar ile desteklendiğinde tarımsal hastalık tespit sistemlerinin geliştirilmesine önemli katkılar sağlayacaktır.

## KAYNAKÇA

- Aksoy, B., Halis, H. D., & Salman, O. K. M. (2020). Elma bitkisindeki hastalıkların yapay zekâ yöntemleri ile tespiti ve yapay zekâ yöntemlerinin performanslarının karşılaştırılması. *International Journal of Engineering and Innovative Research*, 2(3), 194-210.
- Altaş, Z., Özgüven, M. M., & Dilmaç, M. (2021). Görüntü işleme teknikleri ile bağ yaprak uyuzu hasarının belirlenmesi. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 10(3), 77-87.
- Atalay, M., & Çelik, E. (2017). Büyük Veri Analizinde Yapay Zekâ ve Makine Öğrenmesi Uygulamaları. *Mehmet Akif Ersoy Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 9(22), 155-172.
- Ateş, E. C. (2021); Derin Öğrenme (Deep Learning). *Siber Ansiklopedi: Siber Ortama Çok Disiplinli Bir Yaklaşım*. Pegem Akademi.
- Aylak, B. L., & Oral, O. (2021). Yapay zeka ve makine öğrenmesi tekniklerinin lojistik sektöründe kullanımı. *El-Cezeri*, 8(1), 74-93.
- Barbedo, J. G. A. (2019). Plant disease identification from individual lesions and spots using deep learning. *Biosystems engineering*, 180, 96-107.
- Bishop, C. M., & Nasrabadi, N. M. (2006). *Pattern recognition and machine learning* (Vol. 4, No. 4, p. 738). New York: springer.
- Bütüner, R., Şimşek, M., Aksöz, G., & Şan, S. (2023). Yapay Sinir Ağları ile Mısır Yapraklarında Hastalık Tespiti. *Journal of Information Systems and Management Research*, 5(2), 21-31.
- Cho, K., Van Merriënboer, B., Gulçehre, Ç., Bahdanau, D., Bougares, F., Schwenk, H., & Bengio, Y. (2014, October). Learning phrase representations using RNN encoder–decoder for statistical machine translation. In *Proceedings of the 2014 conference on empirical methods in natural language processing (EMNLP)* (pp. 1724-1734).
- Chowdhary, K. R. (2020). Introducing artificial intelligence. In *Fundamentals of artificial intelligence* (pp. 1-23). New Delhi: Springer India.
- Coşkun, F., & Gülleroğlu, H. D. (2021). Yapay zekânın tarih içindeki gelişimi ve eğitimde kullanılması. *Ankara University Journal of Faculty of Educational Sciences (JFES)*, 54(3), 947-966.
- Çetiner, H. (2021). YAPRAK HASTALIKLARININ SINIFLANDIRILABİLMESİ İÇİN ÖNCEDEN EĞİTİLMİŞ AĞ TABANLI DERİN AĞ MODELİ. *Adıyaman Üniversitesi Mühendislik Bilimleri Dergisi*, 8(15), 442-456.

- DataKapital. (2025). *Konvolüsyonel Sinir Ağları Nedir?*. <https://datakapital.com/blog/konvolusyoneel-sinir-aglari-nedir/> adresinden 19.08.2025 tarihinde edinilmiştir.
- Demir, Ü., Kula, N., & Uğurlu, B. (2021). Tarımda Yapay Zekâ Kullanımına Yönelik Karar Destek Modeli Önerisi: Domates Zararlısı Tespiti Örneği. *Lapseki Meslek Yüksekokulu Uygulamalı Araştırmalar Dergisi*, 2(4), 91-108.
- Doğan, M. (2019). *Bitkilerde Örülen Hastalıkların Derin Öğrenme Yöntemleriyle Tespiti ve Sınıflandırılması*. (Yüksek Lisans Tezi), Yükseköğretim Kurulu Ulusal Tez Merkezi'nden edinilmiştir. (Tez No. 584044)
- Donahue, J., Anne Hendricks, L., Guadarrama, S., Rohrbach, M., Venugopalan, S., Saenko, K., & Darrell, T. (2015). Long-term recurrent convolutional networks for visual recognition and description. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 2625-2634).
- Dumoulin, V., & Visin, F. (2016). A guide to convolution arithmetic for deep learning. *arXiv preprint arXiv:1603.07285*.
- Eker, R., Alkiş, K. C., Uçar, Z., & Aydın, A. (2023). Ormancılıkta makine öğrenmesi kullanımı. *Turkish Journal of Forestry*, 24(2), 150-177.
- Elman, J. L. (1990). Finding structure in time. *Cognitive Science*, 14(2), 179–211.
- Fawcett, T. (2006). An introduction to ROC analysis. *Pattern recognition letters*, 27(8), 861-874.
- Ferentinos, K. P. (2018). Deep learning models for plant disease detection and diagnosis. *Computers and electronics in agriculture*, 145, 311-318.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
- Göçgün, Ö. F., & Onan, A. (2021). Amazon ürün değerlendirmeleri üzerinde derin öğrenme/makine öğrenmesi tabanlı duygu analizi yapılması. *Avrupa Bilim ve Teknoloji Dergisi*, (24), 445-448.
- Güler, T. (2022). *Gerçek zamanlı duygu durumu analizi: Derin öğrenme tabanlı akıllı sistem tasarımı*. (Yüksek Lisans Tezi), Yükseköğretim Kurulu Ulusal Tez Merkezi'nden edinilmiştir. (Tez No. 744142)
- Gürbüz, Ö., & Yılmaz, T. (2023). Evrişimli Sinir Ağları Kullanarak Yüz Belirleme ve Tanıma Uygulaması. *Journal of Investigations on Engineering and Technology*, 6(2), 45-60.
- Han, J., Kamber, M., & Pei, J. (2012). Data mining: Concepts and. *Techniques*, Waltham: Morgan Kaufmann Publishers, 2012-13.

- Harari, Y. N. (2015). Sapiens: A brief history of humankind. *Asian Review of World Histories*, 3(2), 265-267.
- Haykin, S. (2009). *Neural networks and learning machines*. Prentice Hall.
- 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.
- Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2017). Densely connected convolutional networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 4700-4708).
- İnik, Ö., & Ülker, E. (2017). Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3), 85-104.
- İşler, B., & Kılıç, M. (2021). Eğitimde yapay zekâ kullanımı ve geliřimi. *Yeni Medya Elektronik Dergisi*, 5(1), 1-11.
- Kaggle. (2024). *PlantifyDr Dataset*. <https://www.kaggle.com/datasets/lavaman151/plantifydr-dataset> adresinden 04.02.2024 tarihinde edinilmiřtir.
- Karhan, M. (2011). *İmge iřleme yöntemleri ile kayıslarda yaprak delen hastalıęı sonucu oluřan lekelerin tespiti*. (Yüksek Lisans Tezi), Yükseköğretim Kurulu Ulusal Tez Merkezi'nden edinilmiřtir. (Tez No. 305259).
- Kaynar, O., Tuna, M. F., Görmez, Y., & Deveci, M. A. (2017). Makine öğrenmesi yöntemleriyle müşteri kaybı analizi. *Cumhuriyet Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 18(1), 1-14.
- Kingma, D. P., & Ba, J. (2014). Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*.
- Kod5. (2025). *Yapay Sinir Ağları (YSA) Nedir*. <https://kod5.org/yapay-sinir-aglari-ysa-nedir> adresinden 07.08.2025 tarihinde edinilmiřtir.
- Kohavi, R., & Provost, F. (1998). Glossary of terms. *Machine learning*, 30, 271-274.
- Kotan, M. (2025). EKO 469-Veri Madencilięi Hafta 12 – Sınıflandırma Yapay Sinir Ağları. [https://mkotan.sakarya.edu.tr/sites/mkotan.sakarya.edu.tr/file/EKO469\\_VM\\_H12\\_Siniflandirma3.pdf](https://mkotan.sakarya.edu.tr/sites/mkotan.sakarya.edu.tr/file/EKO469_VM_H12_Siniflandirma3.pdf) adresinden 07.08.2025 tarihinde edinilmiřtir.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25, 1097–1105.

- Kurt, F. (2018) *Evrişimli sinir ağlarında hiper parametrelerin etkisinin incelenmesi*. (Yüksek Lisans Tezi), Yükseköğretim Kurulu Ulusal Tez Merkezi'nden edinilmiştir. (Tez No. 519157)
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521, 436-444.
- LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (2002a). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324.
- LeCun, Y., Bottou, L., Orr, G., & Muller, K. (1998). Efficient backprop, neural networks: tricks of the trade. *Lecture notes in computer sciences*, 1524(5-50), 23.
- Lewis, T. (2014). A Brief History of Artificial Intelligence. *Live Science Retrieved*.
- Medium. (2025a). *Yapay Zeka Ders Notları 05 | Çok Katmanlı Yapay Sinir Ağı*. <https://medium.com/@yasinguzel/yapay-zeka-ders-notları-5-çok-katmanlı-yapay-sinir-ağı-4c6af075e1fe> adresinden 08.08.2025 tarihinde edinilmiştir.
- Medium. (2025b). *Derin Öğrenme (Deep Learning) Nedir ve Nasıl Çalışır?*. <https://nyilmazsimsek.medium.com/derin-öğrenme-deep-learning-nedir-ve-nasıl-çalışır-2d7f5850782> adresinden 09.08.2025 tarihinde edinilmiştir.
- Medium. (2025c). *Convolutional Neural Networks (CNN) Nedir?*. [https://medium.com/@kubra.ozcan\\_98680/convolutional-neural-networks-cnn-nedir-a3a9d5318835](https://medium.com/@kubra.ozcan_98680/convolutional-neural-networks-cnn-nedir-a3a9d5318835) adresinden 19.08.2025 tarihinde edinilmiştir.
- Medium. (2025d). *Uygulamalı Evrişimsel Sinir Ağları (Convolutional Neural Network)*. <https://medium.com/bilişim-hareketi/uygulamalı-evrişimsel-sinir-ağları-convolutional-neural-network-7d643eaeb6a7> adresinden 10.08.2025 tarihinde edinilmiştir.
- Medium. (2025e). *AlexNet, VGGNet, Inception ve ResNet Nedir?*. <https://frightera.medium.com/alexnet-vggnet-inception-ve-resnet-nedir-bddc7482918b> adresinden 27.08.2025 tarihinde edinilmiştir.
- Mikolov, T., Karafiát, M., Burget, L., Cernocký, J., & Khudanpur, S. (2010, September). Recurrent neural network based language model. In *Interspeech* (Vol. 2, No. 3, pp. 1045-1048).
- Mitchell, T. M. (1997). *Machine learning*. McGraw-Hill.
- Mohanty, S. P., Hughes, D. P., & Salathé, M. (2016). Using deep learning for image-based plant disease detection. *Frontiers in plant science*, 7, 1419.
- Nabiyev, V. V. (2012). *Yapay zekâ: İnsan-bilgisayar etkileşimi*. Seçkin Yayıncılık.
- Nair, V., & Hinton, G. E. (2010). Rectified linear units improve restricted boltzmann machines. In *Proceedings of the 27th international conference on machine learning (ICML-10)* (pp. 807-814).

- Özdemir, E., & Türkoğlu, İ. (2022). Yazılım Güvenlik Açıklarının Evrimsel Sinir Ağları (CNN) ile Sınıflandırılması. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 34(2), 517-529.
- Öztemel, E. (2012). Yapay Sinir Ağları – 3. Basım Nisan 2012, Papatya Yayıncılık Eğitim
- Öztürk, K., & Şahin, M. E. (2018). Yapay sinir ağları ve yapay zekâ'ya genel bir bakış. *Takvim-i Vekayi*, 6(2), 25-36.
- Powers, D. M. W. (2020). Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation. *arXiv preprint arXiv:2010.16061*.
- Russell, S., & Norvig, P. (2021). *Artificial intelligence: A modern approach (4th ed.)*. Pearson.
- Sağlam, Ö. Ç., & Sağlam, H. (2018). İnsanlık Tarihinde Üzümün Önemi. *Journal of Agriculture*, 1(2), 1-10.
- Samuel, A. L. (1959). Some studies in machine learning using the game of checkers. *IBM Journal of research and development*, 3(3), 210-229.
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., & Chen, L. C. (2018). Mobilenetv2: Inverted residuals and linear bottlenecks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 4510-4520).
- Sazak, S., Balsak, S. C., & Badem, H. (2025). Transfer Öğrenme Temelli Bitki Yaprak Hastalıklarının Tespiti İçin Karşılaştırmalı Bir Çalışma. *Tarım ve Doga Dergisi*, 28(1), 154.
- Sladojevic, S., Arsenovic, M., Anderla, A., Culibrk, D., & Stefanovic, D. (2016). Deep neural networks based recognition of plant diseases by leaf image classification. *Computational intelligence and neuroscience*, 2016(1), 3289801.
- Sokolova, M., & Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. *Information processing & management*, 45(4), 427-437.
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: a simple way to prevent neural networks from overfitting. *The journal of machine learning research*, 15(1), 1929-1958.
- Tan, M., & Le, Q. (2019, May). Efficientnet: Rethinking model scaling for convolutional neural networks. In *International conference on machine learning* (pp. 6105-6114). PMLR.
- Tokatlıoğlu, M., Selen, U., & Leba, R. (2018). Küreselleşme Sürecinde Tarımın Stratejik Önemi ve Tarımsal Arz Güvenliğinin Sağlanmasında Devletin Rolü. *Journal of Life Economics*, 5(4), 151-176.
- Tüfekçi, M., & Karpat, F. (2019, July). Derin Öğrenme Mimarilerinden Konvolüsyonel Sinir Ağları (CNN) Üzerinde Görüntü İşleme-Sınıflandırma Kabiliyetinin Arttırılmasına

- Yönelik Yapılan Çalışmaların İncelenmesi. In *International Conference on Human-Computer Interaction, Optimization and Robotic Applications* (pp. 28-31).
- Türkoğlu, M. (2019). *Görüntü işleme tabanlı bitki türleri ve hastalıkları tanıma*. (Doktora Tezi), Yükseköğretim Kurulu Ulusal Tez Merkezi'nden edinilmiştir. (Tez No. 607372).
- Werbos, P. J. (1990). Backpropagation through time: What it does and how to do it. *Proceedings of the IEEE*, 78(10), 1550–1560.
- Yaman, O., & Tuncer, T. (2022). Bitkilerdeki yaprak hastalığı tespiti için derin özellik çıkarma ve makine öğrenmesi yöntemi. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 34(1), 123-132.
- Yu, D., & Deng, L. (2010). Deep learning and its applications to signal and information processing [exploratory dsp]. *IEEE Signal Processing Magazine*, 28(1), 145-154.