



T.C.

AMASYA ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

**DERİN ÖĞRENME YÖNTEMLERİ İLE ASMA YAPRAK
HASTALIKLARININ SINIFLANDIRILMASI**

YÜKSEK LİSANS TEZİ

YASİN ÜNAL

OCAK

**DERİN ÖĞRENME YÖNTEMLERİ İLE ASMA YAPRAK
HASTALIKLARININ SINIFLANDIRILMASI**

Yasin ÜNAL

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

Danışman

Prof. Dr. Mehmet KARA

**AMASYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

OCAK 2024

Yüksek Lisans Tezi Kabul ve Onay Sayfası

Yasin ÜNAL tarafından hazırlanan “Derin Öğrenme Yöntemleri ile Asma Yaprak Hastalıklarının Sınıflandırılması” adlı tez çalışması aşağıdaki jüri tarafından OY BİRLİĞİ/OY ÇOKLUĞU ile Amasya Üniversitesi Fen Bilimleri Enstitüsü Teknoloji ve İnovasyon Yönetimi Ana Bilim Dalında YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Danışman: Prof. Dr. Mehmet KARA

Termodinamik Anabilim Dalı, Amasya Üniversitesi

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

Başkan: Doç. Dr. Turgut ÖZSEVEN

Bilgisayar Bilimleri Anabilim Dalı, Tokat Gaziosmanpaşa Üniversitesi

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

Üye: Dr. Öğr. Üyesi Erhan BERGİL

Biyomedikal Anabilim Dalı, Amasya Üniversitesi

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

Tez Savunma Tarihi: 26/01/2024

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

.....

Doç. Dr. Ümit YILDIRIM

Fen Bilimleri Enstitüsü Müdürü

ETİK BEYAN

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

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

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

Yasin ÜNAL

26.01.2024

DERİN ÖĞRENME YÖNTEMLERİ İLE ASMA YAPRAK HASTALIKLARININ SINIFLANDIRILMASI

(Yüksek Lisans Tezi)

Yasin ÜNAL

AMASYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Ocak 2024

ÖZET

Asma yaprağı, insanlık için önemli bir besin kaynağıdır. Taze tüketiminin yanı sıra, bu bitki geniş bir ürün çeşitliliği sağlar. Dünya genelinde yaygın olarak yetiştirilen bu bitki ekonomik değere sahiptir. Asma yapraklarını etkileyen hastalıklar, hem meyveye hem de yapraklara zarar vererek önemli maddi kayıplara neden olabilir. Salamura asma yaprağına olan artan talep, bağcılıkta yeni bir üretim modeline yol açmaktadır. Bol ve yüksek kaliteli ürün elde etmek için bağlarda farklı kültürel yöntemlerin uygulanması aynı zamanda hastalıkların erken teşhis edilmesi ve gerekli önlemlerin alınması çok önemlidir. Gelişen teknolojiyle ortaya çıkan görüntü işleme yöntemi, tarımsal faaliyetlerde bitki hastalıklarının doğru ve hızlı bir şekilde tanımlanmasını sağlar. Bugün, yapay zeka ve görüntü işleme uygulamalarının tarımda kullanımının artması, bu alandaki sorunlara çözümler sunmakta ve bugüne kadar kullanılan yöntemlere alternatifler yaratmaktadır. Son yıllarda, bitki teşhis sistemleri, tür tanımlama, verim ve hastalık gibi sorunların çözümünde başarıyla kullanılmaktadır. Bu çalışmanın amacı, konvolüsyonel sinir ağları kullanarak asma yapraklarını hastalıklı ve sağlıklı yapraklar olarak sınıflandırmak ve tanımlamaktır. Colomerus vitis (bağ uyuzu) ve Plasmopara viticola (mildiyö) enfekte yapraklar ile sağlıklı asma yaprakları, önceden eğitilmiş derin öğrenme modelleri VGG16, VGG19, InceptionV3, Xception, MobilNet ve DenseNet201 kullanılarak sınıflandırıldı. Analiz, VGG16 modeliyle %95,33; VGG19 modeliyle %98,00; InceptionV3 modeliyle %96,67; Xception modeliyle %94,67; MobileNet modeliyle %96,00 ve DenseNet201 modeliyle ise %96,67 sınıflandırma doğruluğu gösterdi. En yüksek sınıflandırma başarısı VGG19 modeli ile elde edilmiştir. Modellerin performansı doğruluk, duyarlılık, kesinlik ve F-1 skor metrikleri aracılığıyla değerlendirildi. Elde edilen sonuçlar, bu yöntemlerin asma yaprak hastalık türlerinin belirlenmesinde başarıyla kullanılabileceğini ortaya koymaktadır. Ayrıca bu çalışmanın literatüre temel katkısı, bağ uyuzu ve mildiyö hastalıkları ile sağlıklı olmak üzere üç farklı sınıf için narince üzüm çeşidine ait asma yapraklarından oluşan yeni bir veri seti oluşturulmasıdır.

Sayfa Adedi : 70
Anahtar Kelimeler : Asma yaprağı, Bağ hastalıkları, Derin öğrenme.
Danışman : Prof. Dr. Mehmet KARA

CLASSIFICATION OF VINE LEAF DISEASES USING DEEP LEARNING METHODS

(M.Sc. Thesis)

Yasin ÜNAL

AMASYA UNIVERSITY

GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

January 2024

ABSTRACT

Vine leaves are an important food source for humanity. Besides its fresh consumption, this plant provides a wide variety of products. This plant, which is widely grown throughout the world, has economic value. Diseases affecting vine leaves can cause significant financial losses by damaging both the fruit and the leaves. The increasing demand for pickled vine leaves leads to a new production model in viticulture. In order to obtain abundant and high-quality products, it is very important to apply different cultural methods in the vineyards, as well as to diagnose diseases early and take the necessary precautions. The image processing method that emerged with developing technology enables accurate and rapid identification of plant diseases in agricultural activities. Today, the increasing use of artificial intelligence and image processing applications in agriculture offers solutions to problems in this field and creates alternatives to the methods used to date. In recent years, plant identification systems have been successfully used to solve problems such as species identification, yield and disease. The aim of this study is to classify and identify grape leaves as diseased and healthy leaves using convolutional neural networks. Colomerus vitis (vine scab) and Plasmopara viticola (downy mildew) infected leaves and healthy grapevine leaves were classified using pre-trained deep learning models VGG16, VGG19, InceptionV3, Xception, MobilNet and DenseNet201. Analysis, 95.33% with VGG16 model; 98.00% with VGG19 model; 96.67% with InceptionV3 model; 94.67% with Xception model; It showed 96.00% classification accuracy with the MobileNet model and 96.67% with the DenseNet201 model. The highest classification success was achieved with the VGG19 model. The performance of the models was evaluated through accuracy, sensitivity, precision, and F-1 score metrics. The results obtained reveal that these methods can be used successfully in determining grapevine leaf disease types. In addition, the main contribution of this study to the literature is the creation of a new data set consisting of grape leaves of Narince grape variety for three different classes: vineyard scab and downy mildew diseases and healthy ones.

Page Number : 70

Key-Words : Vine leaf, Vineyard diseases, Deep learning.

Supervisor : Prof. Dr. Mehmet KARA

ÖN SÖZ VE TEŞEKKÜR

Yüksek Lisans Tezi olarak sunduğum “Derin Öğrenme Yöntemleri ile Asma Yaprak Hastalıklarının Sınıflandırılması” başlıklı bu çalışmanın, bilimsel ahlak ve geleneklere aykırı düşecek bir yardıma başvurmaksızın tarafımdan yazıldığını ve yararlandığım bütün kaynakların hem metin içinde hem de kaynakçada yöntemine uygun biçimde gösterilenlerden oluştuğunu belirtir, bunu onurumla doğrularım.

Yüksek lisans öğrenimimde bana yol gösteren, destek veren ve katkılarını esirgemeyen tez danışmanım Prof. Dr. Mehmet KARA’ya teşekkür ederim.

Çalışmam boyunca bana maddi manevi desteğini esirgemeyen ve sabır gösteren aileme, teşekkür ederim.

İÇİNDEKİLER

	Sayfa
ÖZET	vi
ABSTRACT.....	vii
ÖN SÖZ VE TEŞEKKÜR.....	viii
İÇİNDEKİLER	ix
ÇİZELGELER DİZİNİ	xii
ŞEKİLLER DİZİNİ	xiii
RESİMLER DİZİNİ.....	xv
KISALTMALAR DİZİNİ.....	xvi
1. GİRİŞ.....	1
1.1. Bağ Yaprak Hastalıkları	4
1.1.1. Bağ yaprak uyuzu	5
1.1.2. Bağ mildiyözü	6
1.1.3. Bağ antraknozu hastalığı.....	7
1.1.4. Külleme hastalığı.....	8
2. İLİŞKİLİ ÇALIŞMALAR.....	10
3. PROBLEM TANIMI VE ÖN-BİLGİ.....	18
3.1. Problemin Durumu	18
3.2. Araştırmanın Amacı	18
4. MATERYAL VE YÖNTEM.....	19
4.1. Veri Seti	19
4.2. Derin Öğrenme	22
4.3. CNN (Convolutional Neural Network-Evrişimli Sinir Ağları)	24
4.3.1. Giriş katmanı	25

Sayfa

4.3.2. Konvolüsyon katmanı.....	26
4.3.3. Aktivasyon katmanı (Activation layer)	26
4.3.4. Havuzlama katmanı (Pooling layer).....	27
4.3.5. Tam bağlı katman (Fully connected layer).....	27
4.3.6. Sadeleştirme katmanı (Dropout) katmanı.....	27
4.4. VGG16 Modeli	28
4.5. VGG19 Modeli	29
4.6. Inception V3 Modeli.....	30
4.7. Xception Modeli	31
4.8. MobileNet Modeli	32
4.10. Performans Metrikleri.....	34
4.10.1. Karışıklık matrisi	34
5. DENEYLER VE GÖZLEMLER.....	38
5.1. Deney Konfigürasyonu.....	38
5.2. Deney Sonuçları	39
5.3. VGG16 Analiz Sonuçları.....	40
5.4. VGG19 Analiz Sonuçları.....	43
5.5. InceptionV3 Analiz Sonuçları	46
5.6. Xception Analiz Sonuçları.....	49
5.7. MobileNet Analiz Sonuçları	51
5.8. DenseNet201 Analiz Sonuçları	54
5.9. Bağ Uyuzu Görüntülerinin Analiz Sonuçları	57
5.10. Mildiyö Görüntülerinin Analiz Sonuçları.....	57
5.11. Sağlıklı Görüntülerinin Analiz Sonuçları	58

	Sayfa
5.12. Modellerin Sınıflandırma Analiz Sonuçları	59
6. TARTIŞMA VE SONUÇ	60
KAYNAKLAR	64
ÖZGEÇMİŞ	70



ÇİZELGELER DİZİNİ

Çizelge	Sayfa
Çizelge 4. 1. İkili sınıflandırma için karışıklık matrisi	35
Çizelge 5. 1. Derin öğrenme modellerinde kullanılan parametre değerleri.	38
Çizelge 5. 2. Sınıflandırma performans metrikleri (VGG16)	41
Çizelge 5. 3. Sınıflandırma performans metrikleri (VGG19)	43
Çizelge 5. 4. Sınıflandırma performans metrikleri (InceptionV3).....	46
Çizelge 5. 5. Sınıflandırma performans metrikleri (Xception)	49
Çizelge 5. 6. Sınıflandırma performans metrikleri (MobileNet)	52
Çizelge 5. 7. Sınıflandırma performans metrikleri (DenseNet201)	54
Çizelge 5. 8. Bağ uyuzu görüntülerde modellerin sınıflandırma raporu.....	57
Çizelge 5. 9. Mildiyö görüntülerde modellerin sınıflandırma raporu	58
Çizelge 5. 10. Sağlıklı görüntülerde modellerin sınıflandırma raporu	58
Çizelge 5. 11. Modellerin sınıflandırma raporu	59
Çizelge 6. 1. Asma yaprağı hastalıkları üzerine literatürde yer alan çalışmalar	61

ŞEKİLLER DİZİNİ

Şekil	Sayfa
Şekil 4. 1. Evrişimsel Sinir Ağı Mimarisi (CNN).....	25
Şekil 4. 2. VGG16 Model Yapısı.....	29
Şekil 4. 3. VGG19 Model Yapısı.....	30
Şekil 4. 4. Inception V3 Model Yapısı	31
Şekil 4. 5. Xception Model Yapısı.....	32
Şekil 4. 6. MobileNet Model Yapısı	33
Şekil 4. 7. DenseNet201 Diagram şeması.....	34
Şekil 5. 1. VGG16 mimarisi için eğitim ve doğrulama grafiği.....	41
Şekil 5. 2. VGG16 mimarisi için eğitim ve doğrulama kaybı grafiği.....	42
Şekil 5. 3. VGG16 modeli karışıklık matrisi	43
Şekil 5. 4. VGG19 mimarisi için eğitim ve doğrulama grafiği.....	44
Şekil 5. 5. VGG19 mimarisi için eğitim ve doğrulama kaybı grafiği.....	45
Şekil 5. 6. VGG19 modeli karışıklık matrisi	46
Şekil 5. 7. InceptionV3 mimarisi için eğitim ve doğrulama grafiği	47
Şekil 5. 8. InceptionV3 mimarisi için eğitim ve doğrulama kaybı grafiği	48
Şekil 5. 9. Inception V3 modeli karışıklık matrisi	48
Şekil 5. 10. Xception mimarisi için eğitim ve doğrulama grafiği.....	50
Şekil 5. 11. Xception mimarisi için eğitim ve doğrulama kaybı grafiği.....	50
Şekil 5. 12. Xception modeli karışıklık matrisi	51
Şekil 5. 13. MobileNet mimarisi için eğitim ve doğrulama grafiği	52
Şekil 5. 14. MobileNet mimarisi için eğitim ve doğrulama kaybı grafiği	53
Şekil 5. 15. MobileNet modeli karışıklık matrisi.....	54
Şekil 5. 16. DenseNet201 mimarisi için eğitim ve doğrulama grafiği.....	55

Şekil**Sayfa**

Şekil 5. 17. DenseNet201 mimarisi için eğitim ve doğrulama kaybı grafiği.....56

Şekil 5. 18. DenseNet201 modeli karışıklık matrisi57



RESİMLER DİZİNİ

Resim	Sayfa
Resim 1. 1. Bağ uyuzu görülen bir asma yaprağı	6
Resim 1. 2. Bağ mildiyösü görülen bir asma yaprağı	7
Resim 1. 3. Antraknoz olan bir asma yaprağı	8
Resim 1. 4. Külleme hastalığı olan bir asma yaprağı	9
Resim 4. 1. Asma Bağına ait bir görüntü	20
Resim 4. 2. Bağ görüntüsü	20
Resim 4. 3. Veri setinden örnek yaprak görüntüleri	21

KISALTMALAR DİZİNİ

Bu çalışmada kullanılmış bazı kısaltmalar yanda açıklamaları verilmek üzere aşağıda sunulmuştur.

Kısaltmalar	Açıklama
ACC	Accuracy
CNN	Convolutional neural network
COLAB	Colaboratory
CPU	Central process unit
CVPR	Computer vision and pattern recognition
DenseNet	Densely connected convolutional neural networks
ESA	Evrişimli sinir ağı
GPU	Graphics processing unit
LoRa	Long range
MATLAB	Matrix laboratory
NLP	Neuro linguistic programming
RCCN	Region based convolutional neural networks
ReLU	Rectified linear unit
ResNet	Residual networks
RGB	Red green blue
SSD	Single shot detector
SVM	Support vector machine
VGG	Visual geometry group
YOLO	You only look once
YSA	Yapay sinir ağı

1. GİRİŞ

Asma, ekonomik önemi, değerlendirilme yöntemleri ve geniş çeşitliliği bakımından dünya genelinde en yaygın ve en eski kültür bitkilerinden biri olarak öne çıkmaktadır. Ayrıca, iklim ve toprak istekleri konusunda oldukça esnek olması, asmanın çeşitli coğrafyalarda başarılı bir şekilde yetiştirilebilmesine olanak tanımaktadır (Özben, 2011).

İnsanlık tarihi boyunca, bağcılık en eski ve en köklü tarımsal üretim alanlarından biri olmuştur. İnsanlar binlerce yıl öncesinde bile üzüm bağları oluşturarak, üzüm yetiştirme ve şarap üretme süreçlerine başlamışlardır. Bağcılık, kültürel ve tarihi önemi olan bir sektördür ve günümüzde hala büyük bir ekonomik değere sahiptir (Yazıcı, 2018).

Bağcılığın kökenleri, tarih öncesi dönemlere kadar uzanmaktadır. İnsanlar avcılık ve toplayıcılıktan tarıma geçiş yaparken, doğal olarak yetişen üzüm asmalarının besin ve içecek kaynağı olarak keşfedilmesiyle bağcılık başlamıştır. İlk bağlar Orta Doğu ve Mezopotamya gibi bölgelerde ortaya çıkmıştır ve daha sonra diğer medeniyetler tarafından da benimsenmiştir.

Bağcılık, kültürler arasında geçmişten bugüne farklı şekillerde uygulanmıştır. Antik Mısır'da, Roma İmparatorluğu'nda ve Antik Yunan'da bağcılık büyük bir öneme sahipti. Bu medeniyetler, üzüm yetiştirme tekniklerini geliştirmiş, şarap üretiminde ustalaşmış ve bağcılığı ticari bir faaliyet haline getirmişlerdir (Yazıcı, 2018).

Bağcılık, sadece üzüm üretimiyle sınırlı kalmamıştır. İnsanlar aynı zamanda asma yapraklarını tüketmiş, şarap üretiminde kullanmış ve farklı ürünler elde etmek için üzüm suyunu işlemiştir. Bağcılık, hem gıda hem de içecek sektöründe önemli bir rol oynamıştır.

Bugün, bağcılık dünya genelinde yaygın olarak yapılan bir tarımsal faaliyettir. İnsanlar farklı üzüm çeşitlerini yetiştirerek şarap, pekmez, kurutulmuş üzüm gibi ürünler elde etmektedir.

Bağcılık, insanlığın geçmişine ve kültürel mirasına derinlemesine bağlı olan bir faaliyettir. Zengin tarihi ve ekonomik değeriyle bağcılık, dünya çapında büyük bir öneme sahip olmaya devam etmektedir (Yazıcı, 2018).

M.Ö. 2000 yıllarında Anadolu'da kurulan büyük Hitit uygarlığı, günümüze ulaşan arkeolojik buluntularla bağcılığın o dönemdeki büyük önemini ortaya koymaktadır. Kaya resimleri ve heykellerde sıkça rastlanan üzüm ve şarap figürleri, Hitit toplumunun bu tarım ürünlerine verdiği değeri yansıtmaktadır. Ayrıca, Hitit kanunlarında bağların ve ürünlerin korunmasına dair özel hükümler bulunması ve Boğazköy metinlerinde kuru üzümlerden bahsedilmesi, Anadolu bağcılığının o dönemdeki sosyolojik ve ekonomik önemini günümüze taşıyan belgeler arasındadır (Sağlam ve Sağlam, 2018).

Dünyada olduğu gibi Türkiye’de de bağcılık önemli tarım alanlarından biridir. Üzüm meyvesi, iklim ve toprak açısından çok seçici olmayan yapısı ve farklı üretim alternatiflerine sahip olması sebebiyle dünyada ve özellikle Türkiye’de yaygın olarak yetiştirilen önemli bir kültür bitkisidir (Alsancak Sırlı vd., 2015).

Bağcılık sektörü, Türkiye'nin üretim yaptığı sektörler arasında önemli bir konuma sahiptir. Tarıma elverişli olmayan eğimli alanlarda bile bağ ürünlerinin yetiştirilebilmesi, bu alanların değerlendirilmesi, toprağı erozyon etkilerinden koruması ve bölgede yaşayan insanlar için geçim kaynağı oluşturması açısından büyük bir öneme sahiptir. Bağcılık faaliyeti, üreticilerin geçimini sağlarken aynı zamanda milli ekonomiye de önemli katkı sağlamaktadır (Bashimov, 2017).

Türkiye, çeşitlilik açısından zengin bir üzüm yetiştirme alanına sahiptir ve çeşitli bölgelerinde farklı üzüm çeşitleri yetiştirilmektedir. Türkiye’de yaygın olarak yetişen bazı üzüm çeşitleri şunlardır: sultaniye, çavuş, razaki, boğazkere, kalecik karası, horoz karası, şiraz, narince sayılabilir. Bu sadece Türkiye’de yetişen üzüm çeşitlerinden bazılarını örnekler. Üzüm yetiştiriciliği yapılan farklı bölgelerde daha pek çok çeşit mevcuttur.

Türkiye gibi bazı ülkelerde asma yaprakları da gıda olarak tüketilir ve ekonomik değer taşır. Salamura asma yaprağına olan talebin gün geçtikçe artması, bağcılıkta yeni bir üretim modeline yol açmıştır. Salamura, et, balık veya sebzelerin tuz ve su karışımında bekletilmesi yoluyla korunmasını sağlayan bir yöntemdir. Bu işlem, yiyeceklerin dayanıklılığını ve lezzetlerini artırır. Çeşitli kültürlerde salamura, yiyecekleri bozulmadan saklamak için kullanılır. Örneğin, turşu üretiminde salamura kullanılır.

Anadolu'da salamura yaprak üretimi, asırlardır devam eden bir gelenek ve koruma yöntemidir. Bağlarda gerçekleştirilen yaz budaması sırasında özenle seçilen yaprakların zamanında ve uygun düzeyde alınması, sadece olumsuz bir etki bırakmaz; aynı zamanda renkli üzüm çeşitlerinde tanelerin daha canlı renklere bürünmesine ve tatlanmasına katkı sağlar. Özellikle yağışlı bölgelerde yapılan bu işlem, iyi bir havalanma sağlayarak hastalıkları da kısmen önler (Gülcü ve Demirci, 2011).

Narince, Tokat bölgesinde özenle yetiştirilen bir beyaz üzüm çeşididir. Sofralık üzüm tüketiminin yanı sıra beyaz şarap üretiminde de tercih edilen narince üzümü, Anadolu'nun zengin üzüm mirasında önemli bir konuma sahiptir. Bu çeşidin yaprakları salamura için oldukça elverişlidir. Ülkemizdeki salamuralık yaprak ihtiyacının büyük bir bölümünü, yüksek kaliteli yemeklik yapraklarıyla öne çıkan Tokat yöresinin Narince çeşidi karşılamaktadır. Narince yaprakları, özel tat profili ve sağlam dokusu ile salamura yaprak üretiminde talep görmekte ve Anadolu'nun zengin tarım geleneğine önemli bir katkıda bulunmaktadır.

Erbaa narince bağ yaprağı 05.12.2017 tarihinden itibaren coğrafi işaret almıştır. Coğrafi işaret, bir ürünün belirli bir coğrafi bölgede üretildiğini, işlendiğini veya diğer bir şekilde elde edildiğini gösteren bir işaretlemedir. Bölgeye özgü iklim ve toprak koşullarından kaynaklanan benzersiz tat, aroma veya diğer özelliklere sahip olan bu ürün, bölge ekonomisine katkıda bulunmanın yanı sıra kültürel zenginliği ve gelenekleri de yansıtmaktadır.

Asma yaprakları genellikle ilkbaharın sonunda ve yaz aylarının başında toplanır. Bitkinin tomurcuklanma ve çiçeklenme aşamaları arasında, yaprakların en lezzetli ve besleyici olduğu ilkbahar mevsimidir. Asma yaprakları üreticiler tarafından toplanmaya başladıktan itibaren yaklaşık her on günde bir toplanır. Asma yaprakları, bitkinin büyüme hızına ve yaprakların olgunlaşma seviyesine göre yaklaşık bir buçuk iki ay boyunca toplanır. Bununla birlikte, bitkinin türü, coğrafi konumu ve iklim koşulları bu durumu değiştirebilir. Çünkü güneş ışığı ve sıcaklık arttıkça yaprakların su içeriği azalır ve lezzetinde azalma başlar. Asma yaprakları genellikle sabah erken saatlerde toplanır.

Tarım bitkilerinin hemen hemen tamamında olduğu gibi asma bitkisinde çeşitli hastalıklar görülebilmektedir. Bu hastalıklar hem yapraklarda hem de üzüm meyvelerinde önemli

verim kayıplarına sebep olmaktadır. Bu durum bölgedeki üreticileri ve ülke ekonomisini olumsuz yönde etkilemektedir.

Ürün kaybını engellemek ve yüksek verim elde etmek için bağlarda çeşitli kültürel yöntemler uygulamak aynı zamanda hastalıkları erken teşhis ederek gerekli önlemleri almak bağcılıkta önem teşkil etmektedir.

1.1. Bağ Yaprak Hastalıkları

Bitki hastalıklarının önceden tespiti bitki verimini etkileyen önemli faktörler arasında yer almaktadır. Bitki hastalıkları tüm bir bitkiyi etkileyebileceği gibi bitkiyi bölgesel olarak ta etkileyebilir. Bitkiler türlerine göre farklı farklı hastalıklara yakalanabilmekte, bu hastalıklar bakteri, mantar, pestisit, zararlı böcekler ve diğer bitkilerden taşınabilmektedir. Zirai uzmanlar genellikle gözlem yoluyla hastalık tespitini gerçekleştirmektedir (Küçükyumuk ve Bayındır, 2023).

Bitki hastalıkları, tarımın üretim sistemlerinde önemli bir rol oynayarak bitki korumanın temel bir unsuru haline gelmiştir. Tarımda, bitki hastalıkları hem ürün miktarını hem de kalitesini belirgin bir şekilde düşürmektedir. Bu hastalıkların etkisiyle bulaşık (enfekte) bitkilerin normal gelişimi ve fizyolojik fonksiyonları bozulur, sonucunda bitkiler ciddi zarar görebilir (Şimşek, 2021).

Uzmanlar bitkinin hastalığını tespit ederken bitkinin yaprak, kök, gövde ve çekirdek barındıran kısımlarını incelerler ve tetkiklerini yaparlar. Hastalıklar bitki verimini etkileyebileceği gibi bitkilere kısmi veya kalıcı hasarlar da verebilmektedirler. Bu nedenle tespitlerinin doğru şekilde yapılması doğru müdahale için kritik bir husustur. Diğer taraftan, uzmanların yanı sıra tetkik yapılması amacıyla bilgisayar destekli uygulamalar da geliştirilmektedir.

Bağlarda kalite ve verimi düşürerek ekonomik kayıplar veren birçok hastalık ve zararlı bulunmaktadır (Altaş vd., 2021). Bölgemizde yaygın olarak görülen ve ekonomik sorun oluşturan başlıca bağ yaprak hastalıkları bağ uyuzu, mildiyö, antraknoz ve küllemedir. Bu hastalıklar içerisinde asma yaprağı üreticilerin en sık rastladığı ve yoğun mücadele ettikleri mildiyö ve bağ uyuzudur.

1.1.1. Baę yaprak uyuzu

Baę yaprak uyuzu (*colomerus vitis*), lkemizde baę alanlarında yaygın olarak bulunan zararlılar arasında en byk tehditlerden biridir. Bu zararlı, baęlarda ciddi hasarlara neden olmaktadır. Yeni yapraklar ortaya ıktıęında, baharın gelmesiyle birlikte beslenmeye baęlar ve byme sreci boyunca zararlarını srdrr.

En ok yapraklara zarar veren bu hastalıęa, gzle grlemeyecek kadar kk bir bcek sebep olmaktadır. Bu zararlının nimf ve ergin evreleri, ilkbaharda tomurcukların aılmasından baēlayarak ge sonbahara kadar yaprakların alt kısmına yerleēir ve bitkinin zsuyunu tketir. Beslenme sonucunda, ncelikle asma yapraklarının altında ukurlar ve st yzeylerinde kabarcıklar oluēur. Zamanla bu ukurlarda tyl bir dokunun kahverengi renge dnēmesiyle erineum adı verilen yapı oluēur. Zararın ēiddeti, bu oluēumun yoęunluęuyla doęru orantılı olarak artar (Avgın ve Bahadıroęlu, 2004).

Baę yaprak uyuzu genel olarak yapraklarda bulunur, ancak bazen iek tomurcukları ve ieklerde de grlebilir. Zarar grmē yapraklar, tam olarak fotosentez yapamazlar ve hasarın ēiddetine baęlı olarak rn miktarı ve zmn ēeker oranı dēer. Ek olarak, salamuralık yaprakların kalitesi ve pazar deęeri, lkemizin nemli bir yemek kltrne sahiptir. Sonu olarak, kaliteli ve ucuz bir retim iin baęlarda bitki saęlıęının izlenmesi, zararlıların erken teēhisi ve gerekli nlemlerin alınması gerekmektedir (Altaē vd., 2021).

Resim 1.1’de baę uyuzu hastalıęına yakalanmıē bir asma yapraęı fotoęrafı grlmektedir. Bu yapraklar kaliteden dn vermemek adına, salamuralık yaprak reten tarım iēileri tarafından toplanmamakta bu da ekonomik aıdan ciddi kayıplar oluēmasına neden olmaktadır.



Resim 1. 1. Baę uyuzu grlen bir asma yapraęı

1.1.2. Baę mildiys

Baę mildiys, plasmopara viticola obligat parazitinin neden olduęu baę retiminde kalite ve verimi olumsuz etkileyen en nemli hastalıklardan biridir. Asma bitkisinin her yeřil blmnde grlen bu hastalık, hastalıklı yapraklarda oospor olarak kışı geirir. imlenme iin ideal sıcaklık 22-25 °C'dir. Yaprak yařı, eřit, hava nefesi ve sıcaklık, inkbasyon sresini doęrudan etkileyen faktrlerdir. Sıcaklık arttıķa inkbasyon sresi genel olarak kısalır. Fungus, 6 °C'nin altında bymez ve 30 °C'yi getięinde lr. Srgnler yaklaşık 25 cm'ye ulařtıęında, yapraklar belirli belirtilere sahiptir. İlk olarak, yapraęın alt yzeyi beyaz bir mantar rtsyle kaplanır ve st yzeyi tipik sarı yaę lekeleriyle kaplanır. Zamanla lekeler kahverengileřir, kurur ve dklr. Srgnler, eliptik lekeler ve hastalık řiddetliyse kuruyabilir. Enfekte iekler kahverengileřir, kurur ve dklr, bu da seyrek taneli salkımlara neden olur. Baę mildiys hastalıęı, asmanın tm yeřil kısımlarını ve rn doęrudan etkiledięi iin ok nemlidir. lkemizde zm yetiřtiren her yerde grlebilir (Yntem, 2021).

Resim 1.2'de baęcılık sektrnde ciddi bir tehdit oluřturan baę mildiys hastalıęına ait bir asma yapraęı grnts verilmiřtir. Salamuralık yaprak ve meyve verimini dřrerek kaliteyi olumsuz etkileyen nemli bir sorundur ve ekonomik olarak ta byk bir nem arz etmektedir.



Resim 1. 2. Baę mildiyösü görülen bir asma yapraęı

1.1.3. Baę antraknozu hastalıęı

Baę antraknozu hastalıęı daha çok yağışlı veya sürekli nemli olan baęlarda görülür. Sporlarının çimlenebilmesi için havanın nemli olması yeterli değildir; yaprak veya taneler üzerinde birkaç su damlası da gereklidir. Bu nedenle, hastalık nemli ve sıcak havalarda yaygındır. Etmen asma bitkisini etkilediğinde, genellikle hastalık belirtileri tüm yeşil kısımları kapsar, ancak özellikle yeni sürgünlerde ve salkımlarda daha belirgin hale gelir. Yapraklarda küçük lekeler oluşur. Sonrasında bu alanların merkezi gri tonunda, kenarları ise kırmızımsı-kahverengi veya mor renkte deęişiklik göstermektedir. Süre içinde, bu lekeler genellikle kurur ve yapraklar delinir. Hastalık şiddetli bir seviyeye ulaştığında, yapraklar tamamen kuruyarak etkilenmiş olabilir. Başlangıçta taneler üzerinde siyah lekeler belirir. Bu lekeler zaman içinde genişler ve gri bir renk tonu kazanır. Bu belirgin görünüm nedeniyle, hastalıęa genellikle "kuşgözü çürüklüğü" adı verilmektedir. Aynı hastalık, bilhassa tarım literatüründe "çelik marazı" olarak da anılmaktadır (Altaş, 2023).

Resim 1.3'te antraknoz hastalıęı tutulumuna sahip bir asma yapraęı fotoğrafı görülmektedir. Dięer hastalık türlerinde olduęu gibi salamuralık bir asma yapraęı olarak deęerlendirilemeyecek bir üründür.



Resim 1. 3. Antraknoz olan bir asma yaprağı (Liu vd., 2020)

1.1.4. Külleme hastalığı

Mantari bir hastalıktır. Küllemeye neden olan fungus obligat bir parazittir. Hastalık etmeni nemli, sıcak ve kurak havalarda her yıl görülebilmektedir. Ancak hastalığın gelişiminde, nemden çok, sıcaklığın daha kritik bir rol oynadığı bilinmektedir. Bu mantar türü, kurak koşullarda dahi gelişim gösterebilen bir özellik taşır. En uygun gelişim sıcaklığı 20-27°C aralığında olan bu hastalık, özellikle havalanması kısıtlı, gölge veya yarı ışıklı alanlarda daha hızlı yayılım göstermektedir. Bu sebeple, asma bitkisinin sağlıklı gelişimi için yaz budamaları önemlidir; zira bu budama şekli, asmanın daha iyi havalanmasını ve iç kısımlarının ışık almasını sağlayarak hastalığın yayılmasını sınırlandırabilir. Asma bitkisinin bütün yeşil kısımları, külleme hastalığına yakalanabilir.

Hastalığın ilk gelişim döneminde, genç yapraklarda hastalığın belirtileri genellikle zor görülür. Yaprığın alt yüzünde bir yağ lekesi işareti vardır ve üst yüzünde de renk açılması vardır. Yaprak yaşlandıkça parlaklığı, kalınlığı ve gevrekliği azalır. İleri dönemde, yaprağın alt ve üst yüzleri kirli beyaz bir renge dönüşür ve kül serpilmiş gibi görünürler. Hastalıklı yaprakların kenarları içe doğru kıvrılır ve normal formlarını kaybederler. Sürgünler yeşil olduğunda, enfekteli bölgeler siyaha yakın koyu kahverengi renktedir. Kışın bu lekeler kahverengi bir renk alır. Hastalığa erken yakalanan taneler salkımda çok küçük kalmaktadır. Enfekte olmuş tanelerin, olgunlaşmadan hemen önceki dönemde sapı doğrultusunda çatladığı görülmektedir. Ben düşme devresine kadar taneler enfeksiyona

duyarlıdır. Her yıl Türkiye'nin bağ bölgelerinde ortaya çıkan hastalık, mücadele edilmediğinde %90'a varan ürün kaybına neden olabilir (Altaş, 2023).

Resim 1.4'te külleme hastalığına yakalanmış bir asma yaprağı görülmektedir. Diğer asma yaprağı hastalıklarında olduğu gibi tarım işçileri tarafından salamuralık yaprak olarak değerlendirilmemekte ve verim kaybına neden olmaktadır.



Resim 1. 4. Külleme hastalığı olan bir asma yaprağı (Liu vd., 2020)

2. İLİŞKİLİ ÇALIŞMALAR

İnsanlık için temel bir gereksinim olan tarım, gıda üretimi, sağlıklı beslenme, ekonomik kalkınma, çevresel sürdürülebilirlik ve iklim değişikliğiyle mücadele gibi alanlarda vazgeçilmez bir öneme sahiptir (Soylu, 2022). Bu bağlamda tarım endüstrisinde bitkilerin korunması ve verimliliğinin artırılabilmesi de büyük önem arz etmektedir. Tarım, insanların yaşam kalitesini iyileştirir ve sürdürülebilir bir gelecek için temel bir bileşen olarak kabul edilir.

Bugün tarım sektöründe, gıda üretimini artırmak ve mahsul verimliliğini sağlamak için yalnızca uzman görüşlerine ve çiftçilerin deneyimlerine dayanmak yetersiz kalmaktadır. Geleneksel bilgi ve tecrübelerin yanı sıra, teknolojik gelişmelerden de yararlanmak gerekmektedir. Bu, çiftçilere, doğru kararlar vermek ve daha etkili tarım uygulamaları geliştirmek için gerekli olan verilere dayalı bilgilere erişim sağlamaktır (Pakdemirli vd., 2021).

Bilgi ve iletişim teknolojileri, tarımda büyük bir rol oynamaktadır. Sensörler, uzaktan algılama, yapay zeka ve büyük veri analizi gibi teknolojik gelişmeler, tarım sektöründe önemli bir dönüşüm sağlamaktadır. Bu teknolojiler sayesinde, tarım alanlarında toplanan veriler kullanılarak tarımsal faaliyetlerin yönetimi optimize edilebilir, hastalık ve zararlıların erken tespiti mümkün hale gelerek ilaçlama, sulama ve gübreleme gibi uygulamaların verimliliği artırılabilir (Kaya, 2019).

Ayrıca, tarımda dijitalleşme ve otomasyon da önemli bir yer tutmaktadır. Akıllı tarım sistemleri, tarım makineleri ve ekipmanlarındaki otomatikleştirme teknolojileri, işgücünün verimliliğini artırırken, iş süreçlerini de daha etkili hale getirmektedir. Bu da tarım sektöründe üretkenliği ve sürdürülebilirliği artırmaya yardımcı olmaktadır.

Sonuç olarak, günümüzde tarım sektöründe yalnızca uzman görüşlerine ve çiftçi deneyimlerine dayanmak yeterli değildir. Teknolojik gelişmeler, tarımda veri odaklı karar alma süreçlerini destekleyerek gıda üretimini artırma ve mahsul verimliliğini sağlama potansiyelini artırmaktadır. Bu sayede tarım sektörü daha verimli, sürdürülebilir ve yenilikçi hale gelir.

Tarım sektöründe, geleneksel yöntemlerin yerini bilgisayar destekli tarım analiz sistemleri almıştır. Özellikle bitki fizyolojisi ve hastalık tespiti gibi alanlarda kullanılan bu sistemler, büyük veri miktarını hızla işleyerek anlamlı sonuçlar elde edilmesini sağlar. Bu sebeple, farklı bitki hastalıklarını önceden tespit etmek ve bitkilerin yaprak ve gövdelerindeki semptomları (bulguları) otomatik olarak algılamak için dijital görüntü işleme ve yapay öğrenme temelli metotlar sıkça kullanılmaktadır (Sandıkçı ve Aydılek, 2018).

Bilgisayar destekli tespit sistemi, bilgisayar teknolojisi ve yapay zeka algoritmaları kullanılarak belirli bir nesne, olay veya durumu tespit etmek için tasarlanmış bir sistemdir. Bu tür sistemler, genellikle büyük miktarda veriyi hızlı bir şekilde işleyebilme, karmaşık desenleri tanıyabilme ve kararlar alabilme yeteneğine sahiptir.

Tarım alanında bilgisayar destekli tespit sistemleri, bitkilerin hastalık belirtilerini ve ya zararlıları otomatik olarak algılamak amacıyla kullanılır. Bu sistemler genellikle dijital görüntü işleme ve yapay öğrenme tekniklerini kullanır. Bitkilerin yaprakları, gövdeleri veya kökleri üzerindeki semptomları tanımak için görüntü işleme algoritmaları kullanılır ve bu veriler yapay öğrenme algoritmalarına zemin oluşturur. Bu sayede, hastalıkları veya zararlıları belirlemek ve bitkilerin sağlık durumunu değerlendirmek için veri analizi yapılır.

Bilgisayar destekli tespit sistemleri, tarım alanında daha hızlı, daha hassas ve daha etkili bir tespit süreci sağlar. Bu sistemler, tarımsal üretimde kaynakları optimize ederek verimliliği artırabilir, hastalık ve ya zararlılara erken müdahale edilmesini sağlayabilir ve bitki sağlığına yönelik önlemlerin alınmasını kolaylaştırabilir. Aynı zamanda, tarım uzmanlarına ve çiftçilere daha doğru ve zamanında bilgi sağlayarak karar alma sürecini iyileştirir (Pakdemirli vd., 2021).

Asma yaprak hastalıklarına ilişkin yerli ve yabancı literatürde bu konuyla ilgili birçok çalışmanın yapıldığı görülmüştür. Araştırmanın bu bölümünde yapılan çalışmalara değinilmiştir. Çalışmalardan bazıları şunlardır:

G. Köklü (1999), hazırlamış olduğu doktora tezinde Trakya bölgesi bağlarında asma yaprak kıvrılma virüs hastalığının karakterizasyonunu incelemiştir.

Özata (2012), sunmuş olduğu yüksek lisans tezinde Tokat yöresinde üretilen salamuralık asma yapraklarında pestisit kalıntı düzeylerini belirlemiştir. Araştırmasında Tokat merkez ve ilçelerinde Narince üzüm çeşidi ekili bağlarda yetiştirilen salamuralık asma yapraklarında pestisit ve ilaç kalıntılarını tespit etmiştir.

Önder (2016), yapmış olduğu doktora tez çalışmasında 2011-2015 yılları arasında ege bölgesinde bağcılığın yoğun olarak yapıldığı illerde asma yaprak kıvrılma hastalığına ilişkin virüsler üzerine çalışmıştır. Denizli, İzmir, Aydın, Uşak gibi illerden topladığı örnekleri analiz ederek yaprak kıvrılma hastalığına ilişkin virüsleri tespit etmiştir.

Yazıcı (2018), hazırlamış olduğu yüksek lisans tezinde narince üzüm çeşidinde salamuralık asma yaprağı üretiminde bağ uyuzuna karşı kullanılabilecek alternatif tedavi yöntemleri araştırmıştır. 2014-2015 yılları arasında Tokat ilinde yürüttükleri çalışmada Tokat Niksar ilçesine bağlı Gözpınar köyünde narince üzüm çeşidi ile tesis edilmiş bağda, bağ uyuzunu tedavi edebilecek çeşitli ilaçları uygulanmış ve sonuçlarını tartışmışlardır.

Türkoğlu (2019), yaptığı doktora çalışmasında bitki türlerinin tanınması, yeni türlerin tespit edilmesi, zararlı bitkilerin belirlenmesi ve bitki hastalıklarının erken tespiti gibi konular esas olmak üzere tarımsal problemlerin çözümü için yapay zekâ ve görüntü işleme tabanlı sistemler geliştirilmesine odaklanmıştır. Yaygın olarak görülen bitki hastalıklarını incelemiş ve farklı bitki türlerine ait 15 farklı hastalık tespit etmiştir. Yapılan araştırmalar sonucunda doğal ortamlardan elde edilen 3000 hastalık görüntüsünden oluşan bir veri seti inşa etmiştir.

Ghoury (2019), hazırlamış olduğu yüksek lisans tezinde üzüm ve asma yapraklarında hastalıkları derin öğrenme ile tespit etmiştir. İki farklı derin öğrenme modeli kullanarak üzüm ve asma yapraklardaki hastalıkları tespit etmişlerdir. Bu modellerden birincisi Faster R-CNN Inception V2 ve SSD_MobileNet V1 'dir. Faster R-CNN Inception V2 modeli ile %95,57 sınıflandırma doğruluğu oranına ulaşmışlar, SSD_MobileNet V1 modeli ile ise %91,61 sınıflandırma doğruluğunu elde etmişlerdir.

Boulent ve arkadaşları (2019), asma yapraklarında tüylü küf hastalığı için kullandıkları derin öğrenme yöntemlerinden ResNet mimarisi kullanarak %95,48 doğruluk ile sınıflandırma başarısını elde etmişlerdir.

Yazıcı ve Yeşilayer (2020), yaptığı çalışmada yemeklik asma yaprağı üretiminin ve pazarlamasının geliştirilmesinde, ürünün standart kalitede olması ve gıda güvenilirliğinin sağlanarak tüketiciye ulaştırılması, en kritik hususların başında geldiğini belirtmiş, aynı zamanda, bağda asma üzerindeyken başlayan ve yaprak sarması olarak sofralara gelene kadar geçen süreçte, gıda üretimi için gerekli olan asgari teknik ve hijyenik şartlara bağlı kalınarak sağlık açısından zararlı olabilecek her türlü riskin önlenmesinin yasal olarak zorunlu olmasının yanı sıra, ürünün iç ve dış pazarlarda ticaretinin sürdürülmesi ve tüketicilerin algısındaki imajının korunmasının önemli olduğunu belirtmişlerdir.

Xie ve arkadaşları (2020), yaptıkları çalışmada asma yapraklarındaki dört farklı hastalığı gerçek zamanlı tespit eden bir sistem tasarlamışlardır. Bunun için Faster R-CNN ve Faster DR-IACNN modellerini kullanmışlardır. Ayrıca Inception-v1 modülü, inception-Resnet-v2 modülü ve SE blokları da kullanmışlardır. Faster R-CNN algılama modelini le %81,1 Map hassasiyetine ulaşmışlardır.

Altaş ve arkadaşları (2021), hazırlamış olduğu araştırma makalesinde, bağ yaprak uyuzunun neden olduğu zarar, MATLAB'ın görüntü işleme araçları modülü kullanılarak başarılı bir şekilde belirlenmiştir. Görüntü işleme yöntemi, hasar tespitinde düşük maliyetli, hızlı ve etkili bir çözüm sunarak olumlu sonuçlar elde etmiştir.

Çetiner (2021), yaptığı bir çalışmada elma ağaç yapraklarında oluşan herhangi bir hastalık durumunda, scab, rust ve her ikisinin bir arada kullanılabileceği çoklu hastalık gruplarını sınıflandırabilmek için konvolüsyonel sinir ağı (CNN) yöntemi tabanlı bir derin öğrenme modeli geliştirmiştir. Önerilen yaklaşım popüler transfer öğrenim teknikleri olan DenseNet201, MobileNetV2, ResNet50V2, ResNet101V2, ResNet152V2 algoritmalarını giriş katmanı olarak kullanan CNN katmanlarının birleşiminden oluşmaktadır. Geliştirilen yöntem farklı seviyelerde aydınlatma, gürültü, arka planı homojen olmama durumlarını içeren zorluk seviyesi yüksek bir veri seti üzerinde denenmiştir. Test işlemlerinde önerilen CNN tabanlı yöntemle %97 sınıflandırma doğruluk oranı değerine ulaşılmıştır.

Sanath Rao ve arkadaşları (2021), yaptıkları transfer öğrenmeyle asma ve mango yaprağı hastalığının tespiti adlı çalışmada derin evrişimli sinir ağı (CNN) modellerinden AlexNet adı verilen önceden eğitilmiş bir CNN mimarisi ile asma yapraklarını % 99 doğruluk oranı ile sınıflandırmayı başarmışlardır.

Yaman ve Tuncer (2022), yaptığı çalışmada derin öğrenme ve özellik seçme yöntemi kullanılarak yaprak hastalığı tespit etmişlerdir. Önerilen yöntem için ceviz yapraklarından oluşan 726 görüntü toplamış ve bu görüntüleri sağlıklı ve hastalıklı olmak üzere iki sınıfta ayırmışlardır. Bu görüntülerden özellik çıkarımı yapmak için derini öğrenme modelleri kullanmışlardır. 17 adet derin öğrenme modeli test etmiş ve en iyi iki model seçmiştir. Bu iki modeli DarkNet53 ve ResNet101 olarak belirlemişlerdir. Bu iki modelden elde edilen özellikleri birleştirmişler ve böylece hibrit bir özellik çıkarımı oluşturmuşlardır. Önerilen yöntem ile %99,58 doğruluk elde edilmiştir.

Zhang ve arkadaşları (2022), asma yapraklarında tüylü küf hastalığını gerçek zamanlı nesne tespit çalışması yapmışlardır. Dört farklı yöntemle (Faster R-CNN, YOLOv4, YOLOv5, YOLOv5-CA) yapraklar üzerindeki tüylü küf hastalığını tespit etmişlerdir. YOLOv5-CA ile %85,59 kesinlik , %83,70 duyarlılık değerine ulaşmışlardır.

M. Köklü ve arkadaşları (2022), İç Anadolu bölgesindeki yemeklik asma yapraklarından beş tanesini derin öğrenme modellerinden MobilNetv2 ile sınıflandırmışlardır. Bu asma çeşitleri ak, ala idris, büzgülü, dimnit ve nazlı çeşitleridir. Çıkardıkları derin özellikleri SVM'nin çeşitli kernelleri ile sınıflandırmışlardır. En iyi sınıflandırma doğruluğunu %97,60 ile elde etmişlerdir.

Lin ve arkadaşları (2022), yaptıkları çalışmada asma yapraklarını ön eğitilmiş CNN modellerinden GoogLeNet, Vgg16, ResNet34, DenseNet121, MobileNetV2, MobileNetV3_large ile sınıflandırmışlar ve sırasıyla %82,99; %84,01; %82,74; %84,77; %80,96 ve %82,74 sonuçlarını elde etmişlerdir. Ayrıca ön eğitilmiş CNN modellerinden ShuffleNetV2_×1.0, EfficientNetV2_s ve GrapeNet modelini uygulamışlar en iyi sonucu GrapeNet modeli ile elde etmişlerdir.

Bir diğer çalışmada Fraiwan ve arkadaşları (2022), derin öğrenme görüntü tabanlı uygulamaları üç yaygın asma yaprak hastalığını sınıflandırmak için kullanmışlardır. 3639 asma yaprağı görüntüsünden oluşan bir veri seti (1383 siyah kıyamık, 1180 siyah çürük, 1076 isariopsis yaprak lekesi ve 423 sağlıklı) ile dört sınıfı sınıflandırmak üzere 11 evrişimli ağ modelini özelleştirmek ve yeniden eğitmek için kullanmışlardır. Yapılan analiz sonucunda %99,1 sınıflandırma başarısı elde etmişlerdir.

Yin ve arkadaşları (2022), yaptıkları bir araştırmada, asma yapraklarının ortak özelliklerini çıkarmak için ImageNet veri seti kullanmışlardır. MobileNetV3 eğitilerek bir ön eğitim modeli elde etmişler ve yeni bir model ortaya koymuşlardır. Sonuçta, önerilen yaklaşımın bazı yeni yaklaşımlardan daha iyi performansa sahip olduğunu elde etmişlerdir. Tanımlama doğruluğunu ise %99,84 elde etmişlerdir.

Qiao ve arkadaşları (2022), yaptıkları çalışmada, derin öğrenmeye dayalı bir SE-ResNet18 yaklaşımı ile üzüm küfü hastalığını sınıflandırmış, %96,25'lik doğruluk elde etmişlerdir.

Zinonos ve arkadaşları (2022), düşük çözünürlüklü görüntüler kullanarak asma yaprakları hastalıklarını verimli bir şekilde tanımlayabilen entegre bir LoRa ve derin öğrenme tabanlı bilgisayarlı görme sistemi ile hastalıkların tanınmasını mümkün kılabilmek için kullandıkları yöntem ile etkin bir şekilde sınıflandırabilmişlerdir.

Adeel ve arkadaşları (2022), asma yaprakları hastalıklarını belirlemek için kullandıkları önceden eğitilmiş derin modeller olan AlexNet ve ResNet101 üzerinde yaptıkları çalışmalarda %99 doğruluk oranı ile hastalık sınıflandırması elde etmişlerdir.

Ökten (2022), derin öğrenme yöntemleri ve yapay sinir ağı tabanlı Ndzi değerleri ile çeltik bitkisi hastalıkların tespiti adlı doktora çalışmasında, çeltik bitkisine ait üç hastalığı tespit etmek için derin öğrenme modellerinden Evrişimli Sinir Ağı (CNN: Convolution Neural Networks) kullanılmıştır. Çeltik bitkisinin üç önemli hastalığını (Brown Spot, Leaf Blast ve Hispa) elde etmek için RGB yaprak görüntülerinden derin öğrenme modeli kullanmış, ağın eğitimi için çeltik bitkisine ait RGB görüntülerini kullanılarak %92,78 doğruluk elde etmiştir.

Biçer (2022), drone görüntülerinden derin öğrenme teknikleri ile kayısı rekolte tahmini adlı yüksek lisans tez çalışmasında, Malatya ilinden seçilen bir kayısı bahçesinin görüntülerinden oluşturulan veri seti ile derin öğrenme algoritmaları YOLOv4, YOLOv5 ve Faster R-CNN ile model eğitimleri yapılarak üç algoritmanın sonuçlarını karşılaştırmıştır. Testler sonucunda YOLOv4, YOLOv5 ve Faster R-CNN ile sırasıyla %94,7, %69 ve %41 nesne tespiti doğruluk oranı ve toplam tahmini rekolte için ise %93,81; %43,2 ve %0,68 oranında başarılı sonuçlar elde etmiştir.

Duman (2022), derin öğrenme yöntemleri ile bitki sınıflandırma adlı yüksek lisans tez çalışmasında bitki yaprak hastalıkları sınıflandırmasında derin öğrenme mimarilerini incelemiş ve bu konuda önerilen modellerden Resnet50V2 ve MobileNet'in performansları karşılaştırılmıştır. Bu çalışmada Resnet50V2, MobileNet modeline göre daha iyi sonuçlar vermiştir.

Sofuoğlu ve Birant (2023), Evrişimli sinir ağının üzüm bitkisi hastalık sınıflandırması için kullanılması adlı çalışmada, bitkilerin yaprak görüntülerinden hastalık türünün belirlenmesi için makine öğrenmesi tekniklerinin kullanmışlardır. Yaptıkları çalışmada tarım sektörü için bitki yapraklarındaki hastalıkları doğru bir şekilde sınıflandıran yeni bir evrişimli sinir ağı modeli önermişlerdir. Bir derin öğrenme mimarisi tasarlayarak özellikle asma yapraklarındaki hastalıkların sınıflandırılması üzerine çalışmışlar, tarım işçilerine yardımcı olması için bir web uygulaması da geliştirmişlerdir. Görüntüleri üzerinde yapılan denemelerde, önerilen modelin doğruluk açısından %98,53 son teknoloji modellere göre ortalamada %8,7 önemli bir iyileştirme sağladığını gözlemlemişlerdir.

Terzi ve arkadaşları (2023), bazı üzüm çeşitlerinin derin öğrenme teknikleriyle tespiti adlı çalışmalarında, üzüm çeşitlerinin ampelografik özelliklerini derin öğrenme teknikleriyle kullanarak sınıflandırmak istemişlerdir. Çalışma için 15 katmandan oluşan bir yeni CNN modeli geliştirmişlerdir. MATLAB programında yeni oluşturulan CNN modeli %96,10'luk bir sınıflandırma başarı oranı elde etmişlerdir. Analizler sonucunda, CNN modelinin başarılı olduğunu ve üzüm çeşitlerini sınıflandırmak için kullanılabileceğini belirtmişlerdir.

Altaş (2023), derin öğrenme teknikleri ile bazı bağ hastalıklarının belirlenmesi adlı doktora tezi çalışmasında, yapay zeka yaklaşımı olan Faster R-CNN, SSD Multibox ve özgün olarak yeni geliştirilen derin öğrenme modeli, belirli bağ hastalıklarını tespit edip sınıflandırmak amacıyla kullanılmış ve başarıyla uygulanmıştır. Deneysel değerlendirmeler sonucunda hastalıkların tespiti ve sınıflandırılmasında Faster R-CNN %92, SSD Multibox %92,21 ve geliştirilen model ile %96,95 genel doğruluk oranlarını elde etmiştir.

Ulutaş (2023), domates hastalıklarının sınıflandırılması için makine öğrenmesi ve derin öğrenme temelli yeni yaklaşımlar adlı doktora tez çalışmasında, Evrişimli Sinir Ağı (ESA) modelleri ve topluluk öğrenmesi yöntemleri yardımıyla domates yaprağı hastalıklarının doğru bir şekilde tespitini gerçekleştirmiştir. Kullanılan algoritmalar arasında Rastgele

Orman algoritması ve yeni ESA mimarileriyle oluşturulan topluluk öğrenmesi modellerinde sırasıyla %99,8 ile %99,60 doğruluk oranlarını elde etmiştir.

İmak ve arkadaşları (2023), asma yaprağı türünün sınıflandırılması için doğal ve sentetik verilerden derin öznitelikler çıkarma, birleştirme ve seçmeye dayalı yeni bir yöntem adlı yaptıkları çalışmada, Ak, Ala İdris, Büzgülü, Dimnit ve Nazlı olmak üzere 5 farklı asma yaprak türünden 500 görüntü içeren bir veri seti kullanılmışlardır. Elde edilen görüntülere ESRGAN modeli uygulayarak daha ayrıntılı dokulardan oluşan bir veri kümesi elde etmişler, bu görüntülerden öznitelik çıkarmı yapmak için VGG19 derin öğrenme modelini kullanmışlardır. Elde edilen özniteliklerin sınıflandırılması için Destek Vektör Makinesi (DVM) kullanarak %96,14 oranında doğruluk elde etmişlerdir.

3. PROBLEM TANIMI VE ÖN-BİLGİ

3.1. Problemin Durumu

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

3.2. Araştırmanın Amacı

Bu tez çalışmasında amaç, ülkemizde üretimi yoğun bir şekilde gerçekleştirilen asma bitkisine ait yaprak hastalıklarının yaprak görüntüleri üzerinden derin öğrenme yaklaşımlarıyla tespitini gerçekleştirmektir. Bu amaç doğrultusunda büyük tarım alanlarında bitki hastalıkları hızlı ve hassas bir şekilde tespit edilebilir. Bu, manuel gözlemlere göre daha verimli ve güvenilir bir teşhis süreci sunar. Görüntü işleme, bu büyük veri setlerini etkili bir şekilde analiz ederek bitki hastalıkları hakkında daha geniş bir perspektif sunabilir.

4. MATERİYAL VE YÖNTEM

4.1. Veri Seti

Bu tez çalışması için kendi veri setimiz oluşturulmuştur. Resimler narince üzüm çeşidinin olduğu bağdan 2023 yılı Haziran ayında alınmıştır. Resimlerin alındığı bağ Tokat ili Erbaa ilçesi Tepekışla köyü sınırlarında bulunmaktadır. Asma bağında yer alan asma ağaçları boyut ve şekil olarak homojen bir dizilim teşkil etmemekle birlikte her biri 10 (on) yaşındadır. Veri setinin oluşturulduğu bölgede yaygın olarak iki çeşit hastalık görülmektedir. Asma yapraklarında daha fazla hastalık görülebilmesine rağmen hastalıkların görülme çeşitliği yıllara göre farklılaşabilmektedir. İklim durumu değişkenlik arz ettiğinden, özellikle diğer yıllara oranla çok yağışlı ve uzun süren bir ilkbahar ayı dönemi olmuştur. Bu durum bu tez çalışmasında ancak iki hastalık (bağ uyuzu ve mildiyö) ile sağlam asma yaprağı görüntülerini alabilmemize imkan tanımıştır. Oluşturduğumuz veri setinde 2250x4000 boyutlarında 750 adet jpg resmi yer almaktadır. Resimler Samsung SM-A21F kamera modeli ile sRGB renk formatında 24 bit derinliğinde 72 dpi yatay ve dikey çözünürlükte 35mm odak uzunluğu olan bir fotoğraf makinası ile flaşsız bir şekilde yaklaşık 30 cm mesafeden çekilmiştir. Görüntüler aynı yıla ait olmasına rağmen farklı gün ve farklı saatlerde çekildiğinden farklı gün ışık etmenine maruz kalmışlar bu da resimler arasında görüntü farklılığını artırmıştır. Veriler zirai uzman tarafından üç grup olarak etiketlenmiştir. Görüntüler tek tek kontrol edilerek tekrar sınıflandırılmış, hatalı sınıflandırılan görüntüler veri setinden çıkarılmışlardır. Görüntüler “Mildiyö”, “Bağ Uyuzu” ve “Sağlıklı” olarak üç kategoriye ayrılmıştır. Mildiyö hastalıklı asma yaprağı sayısı 292 adet, bağ uyuzu hastalıklı resim sayısı 175 adet ve sağlıklı asma yaprağı sayısı 283 adettir. Bu bağa ait görüntüler Resim 4.1 ve Resim 4.2’de verilmiştir. Bu görüntülerden %80’i eğitim için geriye kalan %20’si de test amacıyla kullanılmıştır. 750 adet resmin %80’i 600 resim eğitim aşamasında, %20’si 150 adet resim ise test aşamasında kullanılmıştır.




Resim 4. 1. Asma bağına ait bir görüntü



Resim 4. 2. Bağ görüntüsü

Asma yaprağı görüntülerine ait örnekler, Resim 4.3'te gösterilmiştir.



Resim 4. 3. Veri setinden örnek yaprak görüntüleri (Üst: Sağlıklı, Orta: Bağ Uyuzu, Alt: Mildiyö)

Resim 4.3'te üst sıradan üç resmin sağlıklı asma yapraklarına, orta sıra üç resmin bağ uyuzuna yakalanmış asma yapraklarına ve alt satırda bulunan üç resmin ise mildiyö hastalığına yakalanmış asma yapraklarına ait olduğu görülmektedir. Üst sırada yer alan sağlıklı yapraklara ait görüntülerden de anlaşılacağı üzere, yapraklar canlı, parlak ve yeşil renkte üzerinde her hangi bir leke, form bozukluğu ve kendi içinde renk farklılığı bulunmayan biçimdedirler. Orta sırada yer alan bağ uyuzu yapraklarına ait görüntülerden de anlaşılacağı üzere, yapraklarda yoğunluğu hastalığın safhasına göre değişen çok sayıda kabarcık şeklinde yapılar görülmektedir. Alt sıradaki mildiyö hastalığı bulaşmış yapraklarda ise sarı lekelerle birlikte yer yer solgunlaşma ve kurumalar dikkat çekmektedir.

Literatürde birçok ön eğitilmiş evrişimli sinir ağı modeli mevcuttur. Bu tez çalışmasında bu ön eğitilmiş ağ modellerinin tamamı denenmiş ve başarılı sonuç veren ön eğitilmiş ağ modelleri tez çalışmasında kullanılmıştır.

4.2. Derin Öğrenme

Bir tür yapay zeka öğrenme yöntemi olan derin öğrenme, çok çeşitli alanlarda kullanılabilir. Görüntü ve Ses Tanıma, Doğal Dil İşleme, Oyunlar ve Strateji, Sağlık, Otomotiv, Finansal Tahmin ve Ticaret, Üretim ve Endüstriyel Otomasyon, Enerji ve Kaynak Yönetimi, derin öğrenmenin kullanıldığı bazı ana alanlar arasındadır.

Derin öğrenme, karmaşık desenleri öğrenme yeteneği ve büyük veri setlerini işleme yeteneği nedeniyle birçok alanda uygulanabilir. Bu teknoloji sürekli olarak geliştirilmekte ve yeni kullanım alanları keşfedilmektedir.

Derin öğrenme, yapay zekâ kavramını içeren makine öğrenmesi konusunun birçok farklı disiplini kapsayan, insanın düşünce yapısını veri setlerinde inceleyerek bilgisayara öğreten bir yaklaşımdır (Çalışkan ve Demir, 2022).

Derin öğrenme, biyolojik öğrenme sürecine dayalı olarak geliştirilen, yapay sinir ağlarını içeren makine öğrenimi temelli bir yaklaşımdır. Derin öğrenme, bilgisayar görmesi, ses işleme-tanıma ve nesne algılama gibi birçok yapay zekâ uygulamasında kullanılır (Doğan ve Türkoğlu, 2019).

Derin öğrenme, temel olarak veri temsili üzerinden öğrenme ilkesine dayanmaktadır. Özellikle görüntü analizine odaklandığımızda, temsil kavramı piksel yoğunluklarından oluşan vektörlerden, kenar kümelerine veya özel şekil özelliklerine kadar geniş bir yelpazede düşünülebilir. Bu özellikler arasında, veriyi en etkili şekilde temsil edenleri seçmek önemlidir (Şeker vd., 2017).

Derin öğrenme yöntemleri, geleneksel olarak manuel olarak çıkarılan özellikler yerine, hiyerarşik özellik çıkarımını en iyi sağlayan algoritmaları kullanma avantajına sahiptir. Bu sayede, derin öğrenme modelleri, veri setlerinin karmaşıklığına daha iyi uyum sağlayabilir ve daha genel ve öğrenilebilir temsiller oluşturabilir. Derin öğrenme, bu hiyerarşik özelliklerin katmanlar halinde öğrenilmesi sayesinde, verinin daha karmaşık yapılarını anlama ve bu yapıları temsil etme yeteneğini artırarak birçok uygulama alanında başarıyla kullanılmaktadır.

Derin öğrenme terimi, genellikle ardışık temsil katmanlarını ifade eder. Bir modelin derinliği, sahip olduğu katman sayısı tarafından belirlenir. Derin öğrenmede çok sayıda temsil katmanı vardır. Sinir ağları şeklinde yapılandırılmış modeller, temsil katmanlarını otomatik olarak eğitim verilerinden öğrenir.

Kullanıcının açıkça talimat veya komut vermesine gerek kalmadan bilgisayar sistemlerinin önceden belirlenmiş belirli bir görevi yerine getirmesine olanak tanıyan istatistiksel modellerin bilimsel olarak incelenmesi, makine öğrenimi olarak bilinir. Makine öğrenimi, yapay zeka araştırmalarının bir alt dalını oluşturur. Makine öğrenimi, görüntü ve görüntü tanıma uygulamalarında yaygın olarak kullanılmaktadır. Bilgisayarın söz konusu görüntüyü öğrenebilmesi için görüntü tanıma uygulamalarında bilgisayar benzeri görüntülerin devreye girmesi gerekmektedir. Sistem artık görseller arasındaki farkları hızlı bir şekilde tespit edebiliyor ve benzer görsellerin ortak özelliklerini tanımlayabiliyor (Akmeşe vd., 2023).

Yapay öğrenme biyolojik canlıların sinir sistemlerindeki öğrenme, hafızada tutma ve güncelleme modelini bilgisayar ortamında modellemeye yönelik bir yaklaşım/yöntemdir. Yapay öğrenmeye dayalı olarak çok sayıda sınıflandırma ve regresyon problemlerinin çözümü mümkündür. Hizmetten endüstriye, ulaşımdan eğitime, sağlıktan tarıma vb. birçok sektörde yapay öğrenme sistemlerinin geliştirildiği görülmektedir. Bu sistemler sağlamış oldukları yüksek karar verme becerisi ile hem karar destek sistemi olarak hem de doğrudan karar verici olarak kullanılabilmektedirler.

Derin öğrenme, bitkisel üretim ve tarım alanlarında ise bitki hastalığı teşhisi ve kontrolü, hasat tahminleri, toprak analizi ve verimlilik, bitki genetikleri ve ıslah, tarla yönetimi ve otomatik tarım, meyve ve sebze sınıflandırma, ilaçlama ve zararlı kontrolü alanlarında kullanılmaktadır. Bu uygulamalar, derin öğrenmenin tarım sektöründeki potansiyelini göstermektedir. Bu teknolojiler, tarım verimliliğini artırmak, kaynakları daha etkili kullanmak ve sürdürülebilir tarım uygulamalarını desteklemek amacıyla geliştirilmektedir.

Bu uygulamaların geliştirilmesinde temel kaynak zirai uzman kararlarına dayanmaktadır. Son yıllarda geleneksel yapay öğrenme yaklaşımlarının yerini derin öğrenme yöntemleri olarak ta bilinen evrişimli sinir ağı modelleri almıştır.

4.3. CNN (Convolutional Neural Network-Evrişimli Sinir Ağları)

Derin öğrenme, büyük veri setlerinden öğrenen yapay sinir ağlarının bir alt kümesini oluşturan makine öğrenimi alanının bir parçasıdır. Derin öğrenme içerisinde çok sayıda sınıflandırma modeli yer almaktadır ve birçok farklı alanda uygulanmaktadır. Evrişimli Sinir Ağları (ESA) ise derin öğrenme modelleri arasında en çok kullanılan ağ modellerinden biridir.


Evrişimli sinir ağları (ESA), ağdaki katmanlardan bazılarının etkili bir şekilde eğitildiği, önemli derin öğrenme tekniklerinden biridir (Ayyüce Kızrak ve Bolat, 2018)

Evrişimli sinir ağı (Convolutional Neural Network), özel olarak geliştirilmiş bir yapay sinir ağı türüdür ve genellikle görüntü tanıma ve işleme konularında kullanılır. Derin öğrenme tekniklerini benimseyen CNN'ler, genellikle öneri sistemleri ve doğal dil işleme (NLP) ile birleştirilerek, görüntü ve video tanıma dahil olmak üzere geniş bir yelpazede güçlü görüntü işleme ve yapay zeka uygulamalarının geliştirilmesine olanak tanır. Evrişimli sinir ağı modelleri, geleneksel yöntemlerde uygulanan görüntü üzerinde öznitelik çıkarımı yöntemleri ile öznitelik elde edilmesi ve bu özniteliklerin sınıflandırılması sürecini daha verimli bir hale getirmiştir. Evrişimli sinir ağları, öznitelikleri üçüncü parti bir yöntemle ihtiyaç duymadan çok katmanlı bir mimari içindeki konvolüsyon vb. aritmetik işlemler kullanarak belirlemektedir. CNN'lerin katmanları, genellikle bir giriş katmanı, bir çıkış katmanı ve bir gizli katmanı içerir. Gizli katman, evrişim katmanları, havuz katmanları, tam bağlantılı katmanlar ve normalleştirme katmanları gibi birçok özel bileşeni içerir. Bu katmanlar, görüntü işleme süreçlerinde özellik çıkarımını, öğrenmeyi ve genelleştirmeyi sağlayarak, CNN'nin başarılı bir şekilde görsel verilerle çalışabilmesine olanak tanır. Elde edilen öznitelikler ağın son katmanındaki softmax sınıflandırıcı yönteminin eğitilmesinde veya doğrudan bir başka sınıflandırıcı yöntemi eğitimi için kullanılabilir. Bu ağların kullanılmasıyla birlikte elde edilen öznitelikler veri setinin belirgin özelliklerinin çıkarımında temsil düzeyini de artırmaktadır.

ESA'nın yapısı, klasik yapay sinir ağlarından farklı olarak evrişim özellik çıkarma ve sınıflandırma katmanları içerir. Bir evrişimli sinir ağ mimarisi, yüksek boyuttaki verilerden düşük boyuttakileri çıkarmak için dört katmandan oluşur: evrişim, aktivasyon, havuzlama ve tam bağlı katman. Sınıflandırma, bu katmanlardan elde edilen özellikleri kullanarak

sınıflandırıcılardan her hangi biri kullanılarak gerçekleştirilir. Şekil 4.1’de Evrişimli Sinir Ağı mimarisinin katmanları görüntülenmektedir.

Evrişimli sinir ağları (ESA) derin öğrenmenin en iyi modellerinden biridir. ESA, yapay sinir ağları gibi girdi, çıktı ve birkaç gizli katmandan oluşan çok katmanlı bir yapıya sahiptir. Bir evrişimli sinir ağının üç ana katmanı vardır: bir evrişim katmanı, bir havuzlama katmanı ve bir tam bağlantılı katman bulunmaktadır. İlk iki katmanda girdi olarak alınan görüntüden özellikler çıkarılır ve bu çıktılar çıkış katmanına eşleştirilir (Daşkın vd., 2018).



Şekil 4. 1. Evrişimli Sinir Ağı Mimarisi (CNN)

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

4.3.1. Giriş katmanı (Input layer)

Veri giriş katmanı olarak da adlandırılır. Sinir ağlarında oluşturulacak veri seti, ağların mimarisine göre belirlenmelidir. Sinir ağına girecek olan her örneklem giriş katmanına girdi verisi olarak kullanılır ve ağın eğitimi için kullanılır. Bir veri seti, her bir öğeye ait verileri birleştirerek oluşur. Ağ hızını, test süresini ve bellek ihtiyacını bu veri boyutu artırır (Doğan ve Türkoğlu, 2019).

4.3.2. Konvolüsyon katmanı (Convolution layer)

Evrişimli sinir ağlarının en önemli katmanıdır. Bu katmandan gelen görüntü bir filtreden geçer. Öznitelik matrisi, filtreleme yoluyla elde edilen değerlerle oluşturulur. Bu matris, girdi olarak gelen tüm matris üzerinde bir filtre hareket ettirerek oluşturulur. Modele renkli bir girdi verilirse, her bir renk katmanı (örneğin, RGB, Kırmızı-Yeşil-Mavi vb.) belirli prosedürleri gerçekleştirir (Karaoğlu, 2022).

Bir konvolüsyon katmanı kullanmadan, görüntülerdeki her piksel için modele bir girdi katmanı eklenebilir. Bu, her girdi için gerekli bağlantıları sağlar. Bununla birlikte, çok fazla bağlantı ve işlem gücü gerektireceğinden, bu işlemi doğrudan yapmak yerine öznitelik matrisinden yararlanarak daha az bağlantı kullanılabilir. Görüntülerde sadece ihtiyaç duyulan özellikler belirlenir. Aynı arka plan veya özellikler gibi farklılaştırmayan unsurlar sürece dahil edilmez. Daha sonraki katmanlarda, nesnelerin şekil ve boyutları gibi karmaşık özellikler çıkarılır. ESA'nın sonuna doğru, nesneler tamamen konvolüsyon katmanlarında çıkarılmaya başlar.

4.3.3. Aktivasyon katmanı (Activation layer)

Aktivasyon işlevlerinin yürütüldüğü katmandır. Aktivasyon fonksiyonu, bilgisayar biliminde kullanılan yapay sinir ağlarının temel bir bileşeni olarak, insan beynindeki nöronların işlevine benzer bir şekilde çalışır. Bu fonksiyonlar, bir nöronun bir sonraki nörona hangi bilgileri ileteceğini belirlemede kilit bir rol oynar. Doğrusal olmayan (non-linear) aktivasyon fonksiyonları, modele lineer olmayan özellikler kazandırarak daha karmaşık veri yapılarını öğrenme kapasitesini artırır ve böylece modelin genel doğruluğunu optimize eder (Naes, 2023). Bir nöron tüm girdi değerlerini topladıktan sonra aktivasyon fonksiyonuna gönderilir. Bir sonraki katmana aktarılacak çıktı miktarı, aktivasyon fonksiyonu tarafından belirlenir. Çıktı değerleri 0 ile 1 veya -1 ile 1 arasında değişen eğerler alır. ReLU (doğrultulmuş lineer birim) genellikle aktivasyon fonksiyonu olarak kullanılır. Bunun nedeni, ReLU'nun ileri besleme ve geri yayılma gibi yaygın aktivasyon fonksiyonları için daha hızlı çıktı üretmesidir (Karasu, 2019).

4.3.4. Havuzlama katmanı (Pooling layer)

Evrişimden sonra havuzlama yapılır. Ağdaki hesaplama ve parametreleri azaltmak için gösterimin uzamsal boyutunu kademeli olarak küçültmek gerekmekte böylece fazla uydurma işlemi de kontrol edilmektedir. Havuzlama katmanı, girdinin her derinlik diliminde kendi kendine çalışır ve uzamsal olarak yeniden boyutlandırır. Maksimum ve ortalama havuzlama en yaygın iki türdür. Ortalama havuzlama, pencereyi özellik haritasının üzerine kaydırıp ortalama değerini alırken, maksimum havuzlama, pencerenin maksimum değerini alır. Evrişim ve havuz katmanları birlikte özellik çıkarma görevini yerine getirir (Benli, 2021).

4.3.5. Tam bağlı katman (Fully connected layer)

Bu katmandaki tüm nöronlar bir dizi olarak görünmektedir. Katmandaki nöronlar, önceki katmandaki tüm aktivasyonların hepsine tamamen bağlıdır. Tam bağlı katman önceki katmanın özelliklerine bağlıdır. Özelliklerin hangi sınıfla ilgili olduğu belirlenir. Bir resimde bir kişinin bulunmasını sağlayan özellikler, aktivasyon haritalarında yüksek değere sahip bir nöronda bulunacaktır. Bir tam bağlı katman, sınıfla ilişkisi yüksek olan yüksek seviyeli özellikleri inceler. Bu özellikleri gösteren ağırlıkların bulunduğu nöronlara göre hangi sınıfa ait olduğu belirlenir (Doğan ve Türkoğlu, 2019).

Önceki evrişim ve havuzlama katmanlarından elde edilen özellikleri sınıflandırmak için tam bağlantılı katman düzleştirilir. Bir matrisi vektöre dönüştürmek, düzleştirme olarak bilinir. Ağ eğitimi aşamasında en iyi performansı elde etmek için de ayarlanabilir.

4.3.6. Sadeleştirme katmanı (Dropout layer)

YSA'larda veriler eğitilirken benzer verilerin çok fazla kullanılması aşırı öğrenmeye neden olur ve sinir ağları ezberler, ezber yapan sinir ağı da sonuç üretirken uydurur. Aşırı uydurmayı önlemek için sinir seyreltme (dropout) işlemi uygulanır. Çok sayıda parametresi olan derin sinir ağları, çok güçlü makine öğrenimi sistemleridir. Bu tür ağlarda aşırı uyum ciddi bir sorundur. Büyük ağların kullanımı da yavaştır, bu da test zamanında birçok farklı büyük sinir ağının tahminlerini birleştirerek aşırı uydurma ile başa çıkmayı zorlaştırır. Bu sorunu çözmek için seyreltme (dropout) yöntemi kullanılır. Seyreltme

işlemi, görüntü tanıma, konuşma tanıma, belge sınıflandırması ve hesaplamalı biyolojide denetimli öğrenme görevlerinde sinir ağlarının performansını artırdığına dair birçok kıyaslama veri setinde başarılı sonuçlar ortaya koymaktadır. Seyrelme işlemi ile bir sinir düğümü yok sayılarak yok sayılan düğümün tüm bağlantıları kesilir yani o düğümün önceki ve sonraki katmanlarla olan bilgi akışı engellenir. Bu teknik nesne sınıflandırma, basamak tanıma, konuşma tanıma, belge sınıflandırması ve hesaplamalı biyoloji verilerinin analizi dahil olmak üzere çok çeşitli uygulama alanlarında YSA'ların performansını iyileştirdiği tespit edilmiştir (Bozkurt, 2021).


4.4. VGG16 Modeli

Vgg16 modeli, 16 katmandan oluşan ImageNet veri kümesi ile eğitilmiş bir evrişimli sinir ağıdır. Modelin yapısı AlexNet'in yapısına benzer. Bu model, yapısında üç tam bağlantılı katman ve on üç evrişim katmanı bulunmaktadır (Çoban ve Özyurt, 2022).

Konvolüsyon (convolution) katmanı, giriş özellik haritasından parçalar çıkarır ve bu parçalara aynı dönüşümü uygulayarak bir çıktı özellik haritası oluşturur. Diğer bir deyişle, giriş verisini işleyerek özellikleri çıkarır ve bu özellikleri kullanarak yeni bir harita oluşturur. Öte yandan, havuzlama (pooling) katmanı giriş matrisinin kanal sayısını sabit tutar ancak yükseklik ve genişlik bilgisini azaltır. Bu sayede, önemli bilgilerin korunmasını sağlarken hesaplama karmaşıklığını azaltır (Buluş, 2022).

VGG16 modeli, girişten başlayarak önce iki konvolüsyon katmanına ve ardından bir havuzlama katmanına girer. Daha sonra, bir kez daha iki konvolüsyon katmanı ve bir havuzlama katmanı ile devam eder. Modelin ilerleyen kısımlarında, sırasıyla 3 konvolüsyon katmanı, 1 havuzlama katmanı, 3 konvolüsyon katmanı, 1 havuzlama katmanı gibi yapılarla devam eder. Son olarak, 3 adet yoğun (dense) katmanı ile devam ederek çıktıyı oluşturur.

Bu modelin mimarisi, özellikle konvolüsyon ve havuzlama katmanlarını sırayla kullanarak özellik çıkarımını artırır. Yoğun katmanlar ise bu çıkarılan özellikleri kullanarak nihai çıktıyı oluşturur. VGG16'nın bu katman düzenlemesi, genellikle görüntü sınıflandırma görevlerinde başarılı sonuçlar elde etmek için kullanılan bir derin öğrenme modeli olarak bilinir. Şekil 4.2'de VGG16 mimarisinin katmanları gösterilmiştir.




Şekil 4. 2. VGG16 Model Yapısı

4.5. VGG19 Modeli

VGG19 modeli, 19 katmandan oluşan bir evrişimli sinir ağı yöntemidir. Temelde, VGG16 modelinin daha derinleştirilmiş bir versiyonu olarak yapılandırılmıştır (Çoban ve Özyurt, 2022).

VGG19 mimarisi, beş blok evrişim katmanı ile başlar ve bunları takiben üç tam bağlantılı katman ile devam eder. Evrişimli katmanlarda 3 x 3 boyutunda filtreler kullanılır ve her evrişim katmanının ardından ReLU aktivasyonu uygulanır. Bu aktivasyon işleminden sonra ise 2 x 2 boyutunda havuzlama işlemi gerçekleştirilir, bu da özellik haritalarının boyutunu azaltmaya yardımcı olur (Karadeniz, 2023).

Toplamda 1000 tam bağlantılı katman, çıkış katmanında softmax aktivasyon fonksiyonu kullanılarak yapılandırılmıştır. Bu yapı, modelin 1000 sınıflı sınıflandırma görevleri için uyarlandığını gösterir. VGG19 modelinin kullanımıyla, özellik çıkarımının ve sınıflandırmanın derin ve etkili bir şekilde gerçekleştirilmesi amaçlanır. Mimari, evrişim ve havuzlama katmanlarını sıralı bir şekilde kullanarak geniş bir görüntü özellik yelpazesi oluşturmayı hedefler. Model, 16 evrişim katmanı ve 3 tam bağlantılı katman içermektedir. VGG19 genel mimarisi Şekil 4.3'te gösterilmiştir.




Şekil 4. 3. VGG19 Model Yapısı

4.6. Inception V3 Modeli

GoogleNet üzerine inşa edilen CNN modellerinden biri olan Inception, daha önceki algoritmalara göre hem daha düşük hata oranını hem de gelişmiş performansı ele alacak şekilde tasarlanmıştır. Bu model GoogleNet'in üçüncü versiyonudur. Modelin temel amacı bağlantı sayısını en aza indirmektir. Daha az bağlantıyla bile modelin verimliliği iyi bir performans sağlar (Örenç vd., 2023).


Inception ailesinin güncellenmiş versiyonlarından biri olan InceptionV3 modeli genellikle görüntü işleme ve nesne tespiti için kullanılır. Bu model, her katman için filtre boyutunu manuel olarak seçmek yerine filtreleri arka arkaya ekler ve verilen görüntü için en uygun filtreyi seçer. Şekil 4.4'te Inception V3 model yapısı görülmektedir.



Şekil 4. 4. Inception V3 Model Yapısı

4.7. Xception Modeli

Google mühendislerinin "Network-In-Network" çalışmasından esinlenerek GoogLeNET (Inception V1) kurulmuştur. Daha sonra Inception V2 ve V3 oluşturulmuştur. Inception mimarisinin bir uzantısı olan Xception mimarisi, standart Inception modüllerini derinlemesine ayrılabilir evrişimle değiştirir. ImageNet veritabanında bulunan bir milyondan fazla fotoğraf üzerinde önceden eğitilmiştir. Xception ağında 299 x 299 piksel boyutlarında bir görüntü girişi kullanılır. Girdi verileri sıkıştırılmış parçalara bölmek yerine, her bir çıktı kanalı için uzamsal korelasyonları ayrı eşler ve kanallar arası korelasyona ulaşmak için 1 x 1 derinlikte evrişim gerçekleştirir (Şener ve Ergen, 2022). Şekil 4.5'te Xception modelinin yapısı gösterilmiştir.




Şekil 4. 5. Xception Model Yapısı

4.8. MobileNet Modeli

Hafif bir model olarak bilinen MobileNet, Google geliştiricilerinden oluşan bir ekip tarafından CVPR 2017'de piyasaya sürüldü. Ağın birincil yapı elemanı olan, tam evrişimli bir katman olan ilk katman, derinlikli ayrılabilir evrişim ağı olarak da bilinir. Ağ, her RGB giriş kanalında ayrı ayrı tek bir evrişim gerçekleştirmek için derinlik ve nokta bazında evrişimlerin ortalamasını kullanır. Yeni bir temsil oluşturmak için tek bir aşamada evrişimli çekirdekler kullanarak girişi filtreleyen ve entegre eden önceki modellerin aksine, MobileNet bilgileri iki farklı adımda filtreler ve birleştirir (Alhawas ve Tüfekci, 2022).


Bu ağ, diğer ağlara göre hesaplama açısından yani GPU yükü açısından oldukça verimli bir mimaridir. MobileNet, özellikle gerçek dünya uygulamaları için oldukça tercih edilen bir ağıdır. Bunun temel nedeni ise daha az hesaplama yükü getirmesi ve böylece gerçek zamanlı uygulamalar için daha popülerdir. MobileNet derinlemesine ayrılabilir konvolüsyonlar kullanmaktadır. Aynı derinliğe sahip düzenli evrişimlere sahip ağlara kıyasla parametre sayısını önemli ölçüde azaltır, bu da daha hafif derin sinir ağları yani bu ağı meydana getirmektedir (Kılıçarslan ve Paçal, 2023). Şekil 4.6'da MobilNet model yapısı gösterilmiştir.



Şekil 4. 6. MobileNet Model Yapısı

4.9. DenseNet 201 Modeli

DenseNet201 mimarisi 201 adet katman içeren derin öğrenme ağıdır. Şekil 4.7’de görüldüğü gibi her katman doğrudan diğer tüm katmanlarla bağlantılıdır. Başka bir deyişle bir katmana kendisinden önceki katman ile birlikte arkasında kalan bütün katmanlardan bilgi girişi bulunmaktadır. DenseNet201 ağının katmanlar arasındaki direk bağlantıları sayesinde bir özneteliği tekrardan kullanmaya teşvik etme avantajı vardır. Buna ek olarak, katmanlar arasındaki bu bağlantılar nedeniyle yüksek sistem gereksinimine ihtiyaç duyulması ağı dezavantajıdır. Ağ yapısında bulunan her katmanın girişi aynı yapıda bulunan önceki bütün katmanların öznetelik haritalarının birleşimidir. Bu yapı öznetelik çeşitliliğini arttırmaktadır (Koç, 2022).



Şekil 4. 7. DenseNet201 Diyagram şeması

4.10. Performans Metrikleri

Bir modelin performansını değerlendirmek yapılan çalışmanın en önemli kısımlarından biridir. Model performansını ölçmek için kullanılan çeşitli başarımlı ölçütleri bulunmaktadır.

Geliştirilen bir modelin etkinliğini değerlendirmek, bir araştırmanın temel aşamalarından biridir. Modelin performansını objektif bir biçimde ölçmek için çeşitli başarı metrikleri kullanılmaktadır. Bu metrikler, modelin genel başarı düzeyini nicel olarak değerlendirmeye ve karşılaştırmaya imkân sağlar.

4.10.1. Karışıklık matrisi

Karışıklık matrisi (confusion matrix), sınıflandırma problemlerinde bir modelin başarısını değerlendirmek için kullanılan önemli bir araçtır. Bu matris, modelin gerçekleştirdiği sınıflandırma tahminlerini ve gerçek sınıfları karşılaştırarak farklı performans metriklerini hesaplamak için kullanılır (Aktaş, 2020).

Matrisin sol tarafı gerçek değerleri verirken üst taraf tahmin edilen değerleri vermektedir. Her sınıf için hangi sınıfın gerçekte ne olması gerektiği fakat ne olarak tahmin edildiğine

ilişkin bilgiler matris üzerinden alınabilmektedir. Çizelge 4.1’ de ikili sınıflandırma için gerçek ve tahmin değerlerini gösteren bir karışıklık matrisi yer almaktadır. Bu matristeki;

Doğru Pozitifler (DP), sınıflandırıcı tarafından pozitif olarak sınıflandırılmış ve gerçek değerleri de pozitif olan değerleri,

Yanlış Pozitifler (YP), sınıflandırıcı tarafından pozitif olarak sınıflandırılmamış ancak gerçek değerleri pozitif olan değerleri,

Doğru Negatifler (DN), sınıflandırıcı tarafından negatif olarak sınıflandırılmış ve gerçek değerleri de negatif olan değerleri,

Yanlış Negatifler (YN), sınıflandırıcı tarafından negatif olarak sınıflandırılmamış ancak gerçek değerleri negatif olan değerleri ifade etmektedir.

DP ve DN tahminin doğru yapıldığını, YP ve YN ise tahminin yanlış yapıldığını belirtmektedir (Yıldırım vd., 2021).

Analizde kullanılan modellerin elde ettiği sonuçların anlaşılabilir bir şekilde yorumlanabilmesi ve tahmin edilen değerlerin doğruluğunu, hata oranlarını çaprazlama değerlendirmek için karışıklık matrisi kullanılmıştır. Çizelge 4.1’de ikili sınıflandırma için karışıklık matrisin dayalı olduğu sistem belirtilmiştir.

Çizelge 4. 1. İkili sınıflandırma için karışıklık matrisi

KARIŞIKLIK MATRİSİ		TAHMİN EDİLEN DEĞER	
		Pozitif	Negatif
GERÇEK DEĞER	Pozitif	Doğru Pozitif (DP)	Yanlış Pozitif (YP)
	Negatif	Yanlış Negatif (YN)	Doğru Negatif (DN)

Doğruluk

Tüm sınıflar için hesaplanan performans ölçüsüdür. Doğru tahmin edilen sınıfların toplam örnek sayısına oranı şeklinde hesaplanmaktadır. 0 ile 1 arasında değer almaktadır (Ciran ve Özbay, 2022). Doğruluk ölçütü Denklem 1'deki gibi hesaplanmaktadır.

$$\text{Doğruluk} = \frac{DP + DN}{DP + YP + YN + DN} \quad (1)$$

Kesinlik

Pozitif tahmin değeri olarak da bilinmektedir. Pozitif sınıflandırmaların ne kadarının gerçekten doğru olduğunu tahmin etmeye yarayan, gerçek pozitiflerin pozitif olarak sınıflandırılanlara bölünmesi ile elde edilen, 0 ile 1 arasında değer alan ölçüttür (Ciran & Özbay, 2022). Kesinlik değerinin yüksek olması bizim için model seçiminde önemli bir kriterdir. Kesinlik ölçütü Denklem 2'deki gibi hesaplanmaktadır.

$$\text{Kesinlik} = \frac{DP}{DP + YP} \quad (2)$$

Duyarlılık

Gerçek pozitiflerin ne kadarının doğru tahmin edildiğini bulmamıza yarar. Yani pozitif tahmin edilmesi gerekenlerin ne kadarının pozitif tahmin edildiğini gösteren, tüm pozitifler arasındaki gerçek pozitiflerin oranı veren, 0 ile 1 arasında değişen ölçüttür (Korkmaz, 2021). Mümkün olduğunca yüksek olması gereklidir. Duyarlılık ölçütü Denklem 3'teki gibi hesaplanmaktadır.

$$\text{Duyarlılık} = \frac{DP}{DP + YN} \quad (3)$$

F1 skor

Kesinlik ve duyarlılık değerlerinin harmonik ortalamasına dayanan F1 skoru, bir performans ölçütü olarak kullanılmaktadır. Eşit dağılım olmayan veri setlerinde daha doğru değerlendirmeler yapabilmek için doğruluk değerinin yerine kullanımı tavsiye edilmektedir (Ciran ve Özbay, 2022). Hem yanlış negatifleri hem de yanlış pozitifleri hesaba katan, 0 ile 1 arasında değişen bir ölçüttür. F1 Skor ölçütü Denklem 4'teki gibi hesaplanmaktadır.

$$F1\ Skor = 2x \frac{Kesinlik * Duyarlilik}{Kesinlik + Duyarlilik} \quad (4)$$

5. DENEYLER VE GÖZLEMLER

5.1. Deney Konfigürasyonu

Deneysel çalışmalar COLAB üzerinde Intel ® Xeon (R) 2.20 GHz CPU, NVIDIA Tesla T4 16 GB GDDR6 GPU ve 16 GB ram belleğe sahip çevrimiçi (online) platformda gerçekleştirilmiştir.

Tezde kullanılan derin öğrenme modellerine ait parametre değerleri Çizelge 5.1’de verilmiştir.

Çizelge 5. 1. Derin öğrenme modellerinde kullanılan parametre değerleri.

Model Adı	Görüntü Boyutu	Optimize Edici	Öğrenme Oranı	Devir
VGG16	224x224	Adam	1e-5	50
VGG19	224x224	Adam	1e-5	50
Inception V3	299x299	Adam	1e-5	50
Xception	299x299	Adam	1e-5	50
MobileNet	224x224	Adam	1e-5	50
DenseNet 201	224x224	Adam	1e-5	50

Bu tez çalışmasında 6 adet ön eğitilmiş evrişimli sinir ağı modeli ile sınıflandırma yapılmıştır. VGG16, VGG19, MobileNet ve DenseNet201 modelleri için resim giriş boyutu 224x224 piksel olarak ayarlanmıştır. InceptionV3 ve Xception modeli için ise resim giriş boyutu 299x299 piksel olarak ayarlanmıştır. Bütün ön eğitilmiş ağ modelleri için Optimize edici (Optimizer) olarak Adam kullanılmıştır. Adam optimizasyon algoritması, derin öğrenme modellerinde sıkça kullanılan bir optimizasyon algoritmasıdır. Adam optimizasyon algoritması, gradient tabanlı optimizasyon algoritmalarından biridir ve birçok avantajı vardır. Öğrenme oranı (Learning rate) olarak 1e-5 kullanılmıştır. Learning rate, derin öğrenme modellerinde oldukça önemli bir hiperparametredir ve doğru bir öğrenme oranı seçimi, modelin başarısını etkileyebilir. Ancak, en uygun öğrenme oranı genellikle probleme ve kullanılan model mimarisine bağlı olarak değişir. Bu tez çalışmasında 1e-5 parametresini

kullanmamızdaki neden benzer deneysel çalışmalarda bu değerin sıklıkla kullanılmasıdır. Devir (epoch) değeri 50 olarak alınmıştır. Devir değeri, eğitim sırasında bir modelin tam veri kümesi üzerinden geçme sayısını ifade eder. Devir sayısı, bir derin öğrenme modelinin eğitim sürecinin ne kadar süreceğini belirler. Devir sayısı değerini grafiğe göre yorumlamak, modelin performansını ve eğitim ilerlemesini anlamak için önemlidir. Bu değerin seçilme nedeni ise eğitim-doğrulama ve kayıp grafiklerindeki deneysel gözlemlerdir. Grafiklerden görüleceği üzere belirli devirden itibaren devir sayısı, bir noktadan sonra modelin daha fazla eğitilmesinin performansı artırmayabileceği bir noktaya ulaşmıştır. Grafik üzerindeki yatay bir düzlük, modelin daha fazla eğitilmemesi gerektiğini gösterir.

5.2. Deney Sonuçları

Deney sonuçlarına göre, “bağ uyuzu”, “mildiyö” ve “sağlıklı” etiketleri için sınıflandırma performans metrikleri aşağıda verilen Çizelge 5.2, Çizelge 5.3, Çizelge 5.4, Çizelge 5.5, Çizelge 5.6 ve Çizelge 5.7’de ki gibi elde edilmiştir. Veri-setinde her bir model için ayrı sınıflandırma performans metrikleri başarımları çıkarılmıştır. Şekil 5.1, Şekil 5.4, Şekil 5.7, Şekil 5.10, Şekil 5.13 ve Şekil 5.16’da her bir evrişimli sinir ağı modeli için eğitim-doğrulama grafikleri verilmiştir. Şekil 5.2, Şekil 5.5, Şekil 5.8, Şekil 5.11, Şekil 5.14 ve Şekil 5.17’de ise her bir model için kayıp grafikleri verilmiştir. Deneysel çalışmalardan elde edilen karmaşıklık matrisleri her bir model için ayrı ayrı Şekil 5.3, Şekil 5.6, Şekil 5.9, Şekil 5.12, Şekil 5.15 ve Şekil 5.18’de verilmiştir. Her bir modele ait bağ uyuzu görüntülerde sınıflandırma raporu Çizelge 5.8’de, mildiyö görüntülerde sınıflandırma raporu Çizelge 5.9’da ve sağlıklı görüntülerde sınıflandırma raporu Çizelge 5.10’da verilmiştir. Modellerin sınıflandırma raporu ise Çizelge 5.11’de verilmiştir. Böylece her bir sınıfta elde edilen genel başarımları ortaya çıkarılmıştır.

Çizelge 5.8’den görüleceği üzere bağ uyuzu görüntülerde InceptionV3 modeli ile sınıflandırmada en iyi sonuçlar sağlanmaktadır. InceptionV3 ile sınıflandırma sonucunda kesinlik (precision), duyarlılık (recall) ve F1-Skor ölçütlerindeki değerleri sırasıyla, 0,92; 1,00 ve %95,89 olarak hesaplanmıştır. Bu deneysel çalışmada tüm performans değerlendirme ölçütlerinde en düşük sınıflandırma sonucunu VGG16 göstermiştir. VGG16’nın sırasıyla kesinlik, duyarlılık ve F1-Skor ölçütlerindeki değerleri ise 1,00; 0,80 ve %88,89’dur.

Çizelge 5.9'da mildiyö görüntülerde VGG16 ve VGG19 modelleri ile sınıflandırmada en iyi benzer sonuçlar sağlanmaktadır. VGG16 ve VGG19 ile sınıflandırma sonucunda her iki model içinde kesinlik (precision), duyarlılık (recall) ve F1-Skor ölçütlerindeki değerleri sırasıyla, 1,00; 1,00 ve %100 olarak hesaplanmıştır. Bu deneysel çalışmada tüm performans değerlendirme ölçütlerinde en düşük sınıflandırma sonucunu MobileNet göstermiştir. MobilNet'in sırasıyla kesinlik, duyarlılık ve F1-Skor ölçütlerindeki değerleri ise 1,00; 0,94 ve %97,35'tir.

Çizelge 5.10'dan görüleceği üzere sağlıklı görüntülerde VGG19 modeli ile sınıflandırmada en iyi sonuçlar sağlanmaktadır. VGG19 ile sınıflandırma sonucunda kesinlik (precision), duyarlılık (recall) ve F1-Skor ölçütlerindeki değerleri sırasıyla, 0,98; 0,96 ve %97,35 olarak hesaplanmıştır. Bu deneysel çalışmada tüm performans değerlendirme ölçütlerinde en düşük sınıflandırma sonucunu VGG16 göstermiştir. VGG16'nın sırasıyla kesinlik, duyarlılık ve F1-Skor ölçütlerindeki değerleri ise 0,89; 1,00 ve %94,21'dir.

Çizelge 5.11'den görüleceği üzere tüm modellerin sınıflandırma başarımlarında VGG19 en iyi sonucu sağlamaktadır. Bu çizelgede VGG16, VGG19, InceptionV3, Xception, MobileNet ve DenseNet201 modellerinin doğruluk (accuracy) başarımları sırasıyla %95,33; %98,00; % 96,67; %94,67; % 96,00 ve %96,00'dır.

5.3. VGG16 Analiz Sonuçları

Veri setindeki görüntüler VGG16 modeli ile eğitilerek sınıflandırma başarımları ortaya konmuştur. Bu ön eğitilmiş ağ ile veri setindeki görüntüler VGG16 sinir ağında eğitilmiştir. 224x224 piksel şeklinde boyutlandırılmış görüntülerde Softmax aktivasyon fonksiyonu kullanılmıştır. Görüntüler bağ uyuzu, mildiyö ve sağlıklı şeklinde kategorilere ayrılarak analiz işlemi yapılmıştır.


Çalışma kapsamında VGG16 modeline ait sınıflandırma performans metrikleri Çizelge 5.2'de belirtilmiştir.

Çizelge 5. 2. Sınıflandırma performans metrikleri (VGG16)

	Kesinlik	Duyarlılık	F1-Skor	Destek
Bağ Uyuzu	1,0000	0,8000	0,8889	35
Mildiyö	1,0000	1,0000	1,0000	58
Sağlıklı	0,8906	1,0000	0,9421	57
Doğruluk			0,9533	150
Makro Ortalama	0,9635	0,9333	0,9437	150
Ağırlıklı Ortalama	0,9584	0,9533	0,9521	150

VGG16 modeli ile yapılan eğitimler sonucunda mildiyö görüntülerinin F1 skor değeri 1,00 olarak tespit edilmiştir. Bağ uyuzu F1 skor değeri ise 0,88 olarak tespit edilmiştir. Sistem genel doğruluk oranı ise %95,33 olarak elde edilmiştir. Bir modelin doğru değerlendirilebilmesi için doğruluk (Accuracy) ve kayıp (Loss) değerlerini incelemek gerekmektedir (Foto, 2022). Çalışmada eğitim tekrarına bağlı olarak oluşan doğruluk ve Loss grafikleri Şekil 5.1 ve Şekil 5.2’de belirtilmiştir.


Şekil 5.1’de asma yaprağı görüntülerinin VGG16 modeli ile analizi esnasında elde edilen eğitim ve doğrulama grafiği görülmektedir. Modelin eğitimi sırasında eğitim doğruluk grafiği, 8. eğitim turundan itibaren %70 değerlerine ulaşmış olup ilerleyen eğitim tur sayılarında başarı oranın giderek artarak en yüksek doğruluk oranı %95,33 değeri elde edilmiştir.



Şekil 5. 1. VGG16 mimarisi için eğitim ve doğrulama grafiği

Şekil 5.2’de asma yaprağı görüntülerinin VGG16 modeli ile analizi esnasında elde edilen eğitim ve doğrulama kaybı grafiği görülmektedir. Şekil 5.2 incelendiğinde, eğitim doğruluk grafiğine paralel olarak kayıpların doğruluk seviyesinde azaldığı ve 10. eğitim tur sayısından itibaren yatay bir seyir gösterdiği görülmektedir.

Bir modelin doğruluğunun (accuracy) yaklaşık olarak 1 olması, modelin eğitim başarısını gösterdiği gibi, kayıp (loss) oranlarının da yaklaşık olarak 0 olması, eğitimin doğruluğunu destekleyen önemli bir göstergedir (Foto, 2022).



Şekil 5. 2. VGG16 mimarisi için eğitim ve doğrulama kaybı grafiği

Şekil 5.3’te VGG16 modelinin kategorilendirilmiş asma yaprağı görüntülerini tahmin değerleri gösterilmiştir. Modele ait karşıtlık matrisi incelendiğinde test veri setinde yer alan 58 adet mildiyö sınıflandırmadaki görüntüden tamamının doğru olarak tespit edilirken, 35 adet bağ uyuzu sınıflandırmasındaki görüntüden 28 adet görüntünün doğru olarak tespit edildiği 7 adet görüntünün ise hatalı tespit edildiği görülmektedir. Bağ uyuzu görüntüleri tahmin oranı nispeten diğer sınıflara göre düşük çıkmıştır. Fakat mildiyö görüntüleri tahmin oranı çok başarılı çıkmıştır.

Gerçek Değer	Bağ Uyuzu	28	0	7
	Mildiyö	0	58	0
	Sağlıklı	0	0	57
		Bağ Uyuzu	Mildiyö	Sağlıklı
		Tahmin Değeri		

Şekil 5. 3. VGG16 modeli karışıklık matrisi

5.4. VGG19 Analiz Sonuçları

Veri setindeki görüntüler VGG19 modeli ile eğitilerek sınıflandırma başarı değerleri ortaya konmuştur. Bu ön eğitilmiş ağ ile veri setindeki görüntüler VGG19 sinir ağında eğitilmiştir. 224x224 piksel şeklinde boyutlandırılmış görüntülerde Softmax aktivasyon fonksiyonu kullanılmıştır. Görüntüler bağ uyuzu, mildiyö ve sağlıklı şeklinde kategorilere ayrılarak analiz işlemi yapılmıştır.


Çalışma kapsamında VGG19 modeline ait sınıflandırma performans metrikleri Çizelge 5.3'te belirtilmiştir.

Çizelge 5. 3. Sınıflandırma performans metrikleri (VGG19)

	Kesinlik	Duyarlılık	F1-Skor	Destek
Bağ Uyuzu	0,9444	0,9714	0,9577	35
Mildiyö	1,0000	1,0000	1,0000	58
Sağlıklı	0,9821	0,9649	0,9735	57
Doğruluk			0,9800	150
Makro Ortalama	0,9755	0,9788	0,9771	150
Ağırlıklı Ortalama	0,9803	0,9800	0,9801	150


VGG19 modeli ile yapılan eğitimler sonucunda mildiyö görüntülerinin F1 skor değeri 1,00 olarak tespit edilmiştir. Bağ uyuzu F1 skor değeri 0,95 olarak tespit edilmiştir. Sistem genel doğruluk oranı ise %98,00 olarak elde edilmiştir.

Şekil 5.4'te asma yaprağı görüntülerinin VGG19 modeli ile analizi esnasında elde edilen eğitim ve doğrulama grafiği görülmektedir. Modelin eğitimi sırasında eğitim doğruluk grafiği, 15. eğitim turundan itibaren %80 değerlerine ulaşmış ve ilerleyen eğitim tur sayılarında başarı oranı yatay seyretmiştir. En yüksek doğruluk oranı olarak %98,00 değeri elde edilmiştir.



Şekil 5. 4. VGG19 mimarisi için eğitim ve doğrulama grafiği

Şekil 5.5'te asma yaprağı görüntülerinin VGG19 modeli ile analizi esnasında elde edilen eğitim ve doğrulama kaybı grafiği görülmektedir. Şekil 5.5 incelendiğinde, eğitim doğruluk grafiğine paralel olarak kayıpların doğruluk seviyesinde azaldığı ve 15. eğitim tur sayısından itibaren yatay bir seyir gösterdiği görülmektedir.



Şekil 5. 5. VGG19 mimarisi için eğitim ve doğrulama kaybı grafiği

Şekil 5.6'da VGG19 modelinin kategorilendirilmiş asma yaprağı görüntülerini tahmin değerleri gösterilmiştir. Modele ait karşıtlık matrisi incelendiğinde test veri setinde yer alan 58 adet mildiyö sınıflandırmadaki görüntüden tamamı doğru olarak tespit edilmiştir. 35 adet Bağ uyuzu sınıflandırmasındaki görüntüden 34'ü doğru olarak tespit edilmiş 1 adet görüntünün ise hatalı tespit edildiği görülmektedir. Sağlıklı 57 adet görüntüden 55'i doğru tahmin edilmiş, 2 görüntü ise hatalı olarak tespit edilmiştir. Mildiyö görüntüleri tahmin oranı çok başarılı çıkmıştır.

Gerçek Değer	Bağ Uyuzu	34	0	1
	Mildiyö	0	58	0
	Sağlıklı	2	0	55
		Bağ Uyuzu	Mildiyö	Sağlıklı
		Tahmin Değeri		

Şekil 5. 6. VGG19 modeli karışıklık matrisi

5.5. InceptionV3 Analiz Sonuçları


Veri setindeki görüntüler InceptionV3 modeli ile eğitilerek sınıflandırma başarı değerleri ortaya konmuştur. Bu ön eğitilmiş ağ ile veri setindeki görüntüler InceptionV3 evrişimli sinir ağında eğitilmiştir. 299x299 piksel şeklinde boyutlandırılmış görüntülerde Softmax aktivasyon fonksiyonu kullanılmıştır. Görüntüler bağ uyuzu, mildiyö ve sağlıklı şeklinde kategorilere ayrılarak analiz işlemi yapılmıştır. Çalışma kapsamında InceptionV3 modeline ait sınıflandırma performans metrikleri Çizelge 5.4'te belirtilmiştir.

Çizelge 5. 4. Sınıflandırma performans metrikleri (InceptionV3)

	Kesinlik	Duyarlılık	F1-Skor	Destek
Bağ Uyuzu	0,9211	1,0000	0,9589	35
Mildiyö	0,9667	1,0000	0,9831	58
Sağlıklı	1,0000	0,9123	0,9541	57
Doğruluk			0,9667	150
Makro Ortalama	0,9623	0,9708	0,9654	150
Ağırlıklı Ortalama	0,9687	0,9667	0,9664	150


InceptionV3 modeli ile yapılan eğitimler sonucunda mildiyö görüntülerinin F1 skor değeri 0,98 olarak tespit edilmiştir. Sağlıklı görüntülerin F1 skor değeri 0,95 olarak tespit edilmiştir. Sistem genel doğruluk oranı ise %96,67 olarak elde edilmiştir.

Şekil 5.7’de asma yaprağı görüntülerinin InceptionV3 modeli ile analizi esnasında elde edilen eğitim ve doğrulama grafiği görülmektedir. Modelin eğitimi sırasında eğitim doğruluk grafiği, 8. eğitim turundan itibaren %90 civarı değerlere ulaşmış, ilerleyen eğitim tur sayılarında başarı oranı eğitim grafiğine paralel değerler elde edilmiştir. En yüksek doğruluk oranı %96,67 elde edilmiştir.



Şekil 5. 7. InceptionV3 mimarisi için eğitim ve doğrulama grafiği

Şekil 5.8’de asma yaprağı görüntülerinin InceptionV3 modeli ile analizi esnasında elde edilen eğitim ve doğrulama kaybı grafiği görülmektedir. Şekil 5.11 incelendiğinde, eğitim doğruluk grafiğine paralel olarak kayıpların doğruluk seviyesinde azaldığı ve giderek yatay bir seyir gösterdiği görülmektedir. Kayıp oranlarının 0’a yakın olması eğitim doğruluğunu destekler niteliktedir.



Şekil 5. 8. InceptionV3 mimarisi için eğitim ve doğrulama kaybı grafiği

Şekil 5.9’da InceptionV3 modelinin kategorilendirilmiş asma yaprağı görüntülerini tahmin değerleri gösterilmiştir. Modele ait karışıklık matrisi incelendiğinde test veri setinde yer alan 58 adet mildiyö sınıflandırmasındaki görüntünün tamamı doğru olarak tespit edilmiştir. 35 adet bağ uyuzu görüntüsünden 28’inin doğru olarak tespit edildiği 7’sinin hatalı tespit edildiği görülmektedir. Mildiyö görüntüleri tahmin oranının başarılı çıktığı görülmektedir.

Gerçek Değer	Bağ Uyuzu	Mildiyö	Sağlıklı
	35	0	1
	0	58	0
Tahmin Değeri	Bağ Uyuzu	Mildiyö	Sağlıklı
	3	2	55

Şekil 5. 9. Inception V3 modeli karışıklık matrisi

5.6. Xception Analiz Sonuçları


Veri setindeki görüntüler Xception mimarisi ile eğitilerek sınıflandırma başarı değerleri elde edilmiştir. Bu ön eğitilmiş ağ ile veri setindeki görüntüler Xception sınır ağında eğitilmiştir. 224x224 piksel şeklinde boyutlandırılmış görüntülerde Softmax aktivasyon fonksiyonu kullanılmıştır. Görüntüler bağ uyuzu, mildiyö ve sağlıklı şeklinde kategorilere ayrılarak analiz işlemi yapılmıştır. Çalışma kapsamında Xception modeline ait sınıflandırma performans metrikleri Çizelge 5.5'te belirtilmiştir.

Çizelge 5. 5. Sınıflandırma performans metrikleri (Xception)

	Kesinlik	Duyarlılık	F1-Skor	Destek
Bağ Uyuzu	0,8500	0,9714	0,9067	35
Mildiyö	0,9825	0,9655	0,9739	58
Sağlıklı	0,9811	0,9123	0,9455	57
Doğruluk			0,9467	150
Makro Ortalama	0,9379	0,9497	0,9420	150
Ağırlıklı Ortalama	0,9510	0,9467	0,9474	150


Xception modeli ile yapılan eğitimler sonucunda mildiyö görüntülerinin F1 skor değeri 0,97 olarak tespit edilmiştir. Bağ uyuzu F1 skor değeri 0,90 olarak tespit edilmiştir. Sistem genel doğruluk oranı ise %94,67'dir. Çalışmada eğitim tekrarına bağlı olarak oluşan doğruluk (accuracy) ve kayıp (loss) grafikleri Şekil 5.10 ve Şekil 5.11'de belirtilmiştir.

Şekil 5.10'da asma yaprağı görüntülerinin Xception modeli ile analizi esnasında elde edilen eğitim ve doğrulama grafiği görülmektedir. Modelin eğitimi sırasında eğitim doğruluk grafiği, 10. eğitim turundan itibaren %90 değerlerine ulaşmış, ilerleyen eğitim tur sayılarında başarı oranının eğitim grafiğine paralel bir seyir izlemiştir.



Şekil 5. 10. Xception mimarisi için eğitim ve doğrulama grafiği

Şekil 5.11’de asma yaprağı görüntülerinin Xception modeli ile analizi esnasında elde edilen eğitim ve doğrulama kaybı grafiği görülmektedir. Şekil 5.11 incelendiğinde, eğitim doğruluk grafiğine paralel olarak kayıpların doğruluk seviyesinde azaldığı ve yatay bir seyir izlediği görülmektedir.



Şekil 5. 11. Xception mimarisi için eğitim ve doğrulama kaybı grafiği

Şekil 5.12’de Xception modelinin kategorilendirilmiş asma yaprağı görüntülerinin tahmin değerleri gösterilmiştir. Modele ait karışıklık matrisi incelendiğinde test veri setinde yer alan 58 adet mildiyö öznitelikli görüntüden 56’sının doğru olarak tespit edilirken 2 tanesi hatalı tespit edilmiştir. 57 adet sağlıklı görüntüden 52’sinin doğru tespit edildiği 5’inin hatalı tespit edildiği görülmektedir. Diğer sınıflara göre mildiyö görüntüleri tahmin oranı başarılı çıkmıştır.

Gerçek Değer	Bağ Uyuzu	Mildiyö	Sağlıklı
	34	0	1
	2	56	0
Sağlıklı	4	1	52
	Bağ Uyuzu	Mildiyö	Sağlıklı
		Tahmin Değeri	

Şekil 5. 12. Xception modeli karışıklık matrisi

5.7. MobileNet Analiz Sonuçları

Veri setindeki görüntüler MobileNet modeli ile eğitilerek sınıflandırma başarı değerleri ortaya konmuştur. Bu ön eğitilmiş ağ ile veri setindeki görüntüler MobileNet evrişimli sinir ağında eğitilmiştir. 224x224 piksel şeklinde boyutlandırılmış görüntülerde Softmax aktivasyon fonksiyonu kullanılmıştır. Görüntüler bağ uyuzu, mildiyö ve sağlıklı şeklinde kategorilere ayrılarak analiz işlemi yapılmıştır.


Çalışma kapsamında MobileNet modeline ait sınıflandırma performans metrikleri Çizelge 5.6’da belirtilmiştir.

Çizelge 5. 6. Sınıflandırma performans metrikleri (MobileNet)

	Kesinlik	Duyarlılık	F1-Skor	Destek
Bağ Uyuzu	0,9412	0,9143	0,9275	35
Mildiyö	1,0000	0,9483	0,9735	58
Sağlıklı	0,9344	1,0000	0,9661	57
Doğruluk			0,9600	150
Makro Ortalama	0,9585	0,9542	0,9557	150
Ağırlıklı Ortalama	0,9614	0,9600	0,9599	150


MobileNet modeli ile yapılan eğitimler sonucunda mildiyö görüntülerinin F1 skor değeri 0,97 olarak tespit edilmiştir. Bağ uyuzu F1 skor değeri 0,92 olarak tespit edilmiştir. Sistem genel doğruluk oranı ise %96,00 olarak elde edilmiştir. Çalışmada eğitim tekrarına bağlı olarak oluşan doğruluk (accuracy) ve kayıp (loss) grafikleri Şekil 5.13 ve Şekil 5.14'te belirtilmiştir.

Şekil 5.13'de asma yaprağı görüntülerinin MobileNet modeli ile analizi esnasında elde edilen eğitim ve doğrulama grafiği görülmektedir. Modelin eğitimi sırasında eğitim doğruluk grafiği, 12. eğitim turundan itibaren %80 değerlerine ulaşmış, ilerleyen eğitim tur sayılarında başarı oranının eğitim grafiğine paralel bir seyir izlemiştir.



Şekil 5. 13. MobileNet mimarisi için eğitim ve doğrulama grafiği

Şekil 5.14’da asma yaprağı görüntülerinin MobileNet modeli ile analizi esnasında elde edilen eğitim ve doğrulama kaybı grafiği görülmektedir. Şekil 5.14 incelendiğinde, eğitim doğruluk grafiğine paralel olarak kayıpların doğruluk seviyesinde azaldığı ve 8. eğitim tur sayısından itibaren yatay bir seyir gösterdiği görülmektedir.



Şekil 5. 14. MobileNet mimarisi için eğitim ve doğrulama kaybı grafiği

Şekil 5.15’te MobileNet modelinin kategorilendirilmiş asma yaprağı görüntülerini tahmin değerleri gösterilmiştir. Modele ait karışıklık matrisi incelendiğinde test veri setinde yer alan 58 adet mildiyö sınıflandırmadaki görüntüden 55’i doğru tespit edilmiş, 3 tanesi hatalı tespit edilmiştir. 35 adet bağ uyuzu sınıflandırmasındaki görüntüden 32’si doğru, 3 tanesi ise hatalı olarak tespit edilmiştir. Mildiyö görüntülerin diğer sınıflara oranla daha başarılı olduğu görülmektedir.

Gerçek Değer	Bağ Uyuzu	32	0	3
	Mildiyö	2	55	1
	Sağlıklı	0	0	57
	Tahmin Değeri	Bağ Uyuzu	Mildiyö	Sağlıklı

Şekil 5. 15. MobileNet modeli karışıklık matrisi

5.8. DenseNet201 Analiz Sonuçları

Veri setindeki görüntüler DenseNet201 modeli ile eğitilerek sınıflandırma başarı değerleri ortaya konmuştur. Bu ön eğitilmiş ağ ile veri setindeki görüntüler DenseNet201 sinir ağında eğitilmiştir. 224x224 piksel şeklinde boyutlandırılmış görüntülerde Softmax aktivasyon fonksiyonu kullanılmıştır. Görüntüler bağ uyuzu, mildiyö ve sağlıklı şeklinde kategorilere ayrılarak analiz işlemi yapılmıştır.


Çalışma kapsamında DenseNet201 modeline ait sınıflandırma performans metrikleri Çizelge 5.7’de belirtilmiştir.

Çizelge 5. 7. Sınıflandırma performans metrikleri (DenseNet201)

	Kesinlik	Duyarlılık	F1-Skor	Destek
Bağ Uyuzu	0,8947	0,9714	0,9315	35
Mildiyö	1,0000	0,9828	0,9913	58
Sağlıklı	0,9818	0,9474	0,9643	57
Doğruluk			0,9600	150
Makro Ortalama	0,9589	0,9672	0,9624	150
Ağırlıklı Ortalama	0,9685	0,9667	0,9671	150


DenseNet201 modeli ile yapılan eğitimler sonucunda mildiyö görüntülerinin F1 skor değeri 0,99 olarak tespit edilmiştir. Bağ uyuzu F1 skor değeri 0,93 olarak tespit edilmiştir. Sistemin genel doğruluk oranı ise %96,00 olarak elde edilmiştir. Çalışmada eğitim tekrarına bağlı olarak oluşan doğrulama (accuracy) ve kayıp (loss) grafikleri Şekil 5.16 ve Şekil 5.17’de belirtilmiştir.

Şekil 5.16’da asma yaprağı görüntülerinin DenseNet201 modeli ile analizi esnasında elde edilen eğitim ve doğrulama grafiği görülmektedir. Modelin eğitimi sırasında eğitim doğruluk grafiği, 11. eğitim turundan itibaren %80 değerlerine ulaşmış, ilerleyen eğitim tur sayılarında başarı oranının eğitim grafiğine paralel bir seyir izlemiştir.



Şekil 5. 16. DenseNet201 mimarisi için eğitim ve doğrulama grafiği

Şekil 5.17’te asma yaprağı görüntülerinin DenseNet201 modeli ile analizi esnasında elde edilen eğitim ve doğrulama kaybı grafiği görülmektedir. Şekil 5.23 incelendiğinde, eğitim doğruluk grafiğine paralel olarak kayıpların doğruluk seviyesinde azaldığı ve 8. eğitim tur sayısından itibaren yatay bir seyir gösterdiği görülmektedir.



Şekil 5. 17. DenseNet201 mimarisi için eğitim ve doğrulama kaybı grafiği

Şekil 5.18’de DenseNet201 modelinin kategorilendirilmiş asma yaprağı görüntülerini tahmin değerleri gösterilmiştir. Modele ait karışıklık matrisi incelendiğinde test veri setinde yer alan 58 adet mildiyö sınıflandırmadaki görüntüden 57 tanesi doğru olarak tespit edilirken 1 tanesi hatalı tespit edilmiştir. 35 adet bağ uyuzu sınıflandırmasındaki görüntüden 34 tanesi doğru tespit edilirken 1 tanesi hatalı tespit edilmiştir. Bağ uyuzu görüntüleri tahmin oranı nispeten diğer sınıflara göre düşük çıkmıştır. Fakat mildiyö görüntüleri tahmin oranı çok başarılı çıkmıştır.

Gerçek Değer	Bağ Uyuzu	34	0	1
	Mildiyö	1	57	0
	Sağlıklı	3	0	54
		Bağ Uyuzu	Mildiyö	Sağlıklı
		Tahmin Değeri		

Şekil 5. 18. DenseNet201 modeli karışıklık matrisi

5.9. Bağ Uyuzu Görüntülerinin Analiz Sonuçları

Çizelge 5.8’de Bağ uyuzu görüntülerinin sınıflandırma raporu yer almaktadır. F1-skor ölçütünde en başarılı sınıflandırma 0,95 oranı ile InceptionV3 modelinde gerçekleşmiştir. Diğer modellere oranla en düşük F1-skor değeri ise 0,88 ile VGG16 modelinde elde edilmiştir.

Çizelge 5. 8. Bağ uyuzu görüntülerde modellerin sınıflandırma raporu

Model Adı	Kesinlik	Duyarlılık	F1-Skor
VGG16	1,0000	0,8000	0,8889
VGG19	0,9444	0,9714	0,9577
InceptionV3	0,9211	1,0000	0,9589
Xception	0,8500	0,9714	0,9067
MobileNet	0,9412	0,9143	0,9275
DenseNet201	0,8947	0,9714	0,9315

5.10. Mildiyö Görüntülerinin Analiz Sonuçları

Çizelge 5.9’da Mildiyö görüntülerinin sınıflandırma raporu yer almaktadır. Diğer modellerde de Mildiyö görüntülerin çok başarılı sınıflandırılmasına karşın, F1-skor

ölçütünde en başarılı sınıflandırma 1,00 oranları ile VGG16 ve VGG19 modellerinde gerçekleşmiştir. Diğer modellere oranla nispeten en düşük F1-skor değeri ise 0,97 ile MobileNet modelinde elde edilmiştir. Bu çalışmada kullanılan tüm evrişimli sinir ağı modellerinde yüksek başarımlar oranları ile en iyi sınıflandırma mildiyö olmuştur. Bunun nedeninin bu hastalığın ayırt edici özelliğinin diğer hastalığa ait sınıf resimlerine göre renk ayırımından kaynaklandığı düşünülmektedir. Örneğin bağ uyuzu hastalığındaki yapraklarda renk farklılığından çok yaprakların formunda bozukluk oluşmaktadır. Bazı görüntülerde sağlıklı yaprak ile bağ uyuzu yaprakları arasındaki farkın fazla belirgin olmadığı düşünülmektedir.

Çizelge 5. 9. Mildiyö görüntülerde modellerin sınıflandırma raporu

Model Adı	Kesinlik	Duyarlılık	F1-Skor
VGG16	1,0000	1,0000	1,0000
VGG19	1,0000	1,0000	1,0000
InceptionV3	0,9667	1,0000	0,9831
Xception	0,9825	0,9655	0,9739
MobileNet	1,0000	0,9483	0,9735
DenseNet201	1,0000	0,9828	0,9913

5.11. Sağlıklı Görüntülerinin Analiz Sonuçları

Çizelge 5.10'da Sağlıklı görüntülerinin sınıflandırma raporu yer almaktadır. F1-skor ölçütünde en başarılı sınıflandırma 0,97 oranı ile VGG19 modelinde gerçekleşmiştir. En düşük F1-skor değeri ise 0,94 ile VGG16 modelinde elde edilmiştir.

Çizelge 5. 10. Sağlıklı görüntülerde modellerin sınıflandırma raporu

Model Adı	Kesinlik	Duyarlılık	F1-Skor
VGG16	0,8906	1,0000	0,9421
VGG19	0,9821	0,9649	0,9735
InceptionV3	1,0000	0,9123	0,9541
Xception	0,9811	0,9123	0,9455
MobileNet	0,9344	1,0000	0,9661
DenseNet201	0,9818	0,9474	0,9643

5.12. Modellerin Sınıflandırma Analiz Sonuçları

Çizelge 5.11’de modellerin sınıflandırma raporu yer almaktadır. Ön eğitilmiş ağlardan VGG16 ile %95,33, VGG19 ile %98,00, InceptionV3 ile %96,67, Xception ile %94,67, MobileNet ile %96 ve DenseNet201 ile %96 sınıflandırma doğruluğu elde edilmiştir. Doğruluk (accuracy) ölçütünde en başarılı sınıflandırma %98,00 oranı ile VGG19 modelinde gerçekleşmiştir. En düşük doğruluk ise %94,67 oranı ile Xception modelinde gerçekleşmiştir.

Çizelge 5. 11. Modellerin sınıflandırma raporu

Model Adı	Doğruluk % (Accuracy)
VGG16	95,33
VGG19	98,00
InceptionV3	96,67
Xception	94,67
MobileNet	96,00
DenseNet201	96,00

6. TARTIŞMA VE SONUÇ

Asma yaprağı ekonomik değeri olan bir tarım ürünüdür. Üreticiler dünya çapında üzüm üretimine odaklanmış olsalar da asma yaprağı ekonomik değeri yüksek bir yan üründür. Birçok kültür, asma yaprağını geleneksel bir yemek malzemesi olarak kullanır. Akdeniz mutfağında dolma yapımında ve çok sayıda diğer yemekte kullanılan asma yaprağı, gıda endüstrisi için önemli bir malzemedir. İçerdiği vitamin, mineral ve antioksidanlar nedeniyle asma yaprağı besleyicidir.

Asma yetiştiriciliği kırsalda yaşayanlar için önemli bir istihdamda sağlar. Birçok kişi, üzüm bağlarının bakımı, hasat ve işleme süreçlerinde istihdam edilerek ülke ve bölge ekonomisine katkı sağlamaktadır.

Asma yaprağı, Tokat ve Manisa bölgelerinde ekonomik değer açısından öne çıkan bir tarım ürünüdür. Yurt içi tüketiminin yanı sıra yurtdışına da ihraç edilen bir üründür. Aynı zamanda, doğru pazarlama stratejileriyle daha geniş pazarlara ulaşabilir.

Asma yaprağı, bu faktörlerin bir araya gelmesiyle ekonomik olarak değerli bir tarım ürünüdür. Onu, özellikle kültürel ve geleneksel kullanımları, sağlık faydaları ve yemek endüstrisinde oynadığı rol nedeniyle daha da önemli bir tarım ürünü haline getirmiştir.

Asma yaprak hastalıklarının erken ve doğru teşhisi, gerek asma yaprağı üretiminde gerekse de asma bitkisi meyvesi olan üzüm ve yan ürünlerinde verimliliği artırır ve hastalıkların yayılmasını önleyerek zararların minimize edilmesini sağlar.

Bağ hastalıklarının çıplak gözle tespiti çoğu zaman zor ve maliyetli olmaktadır. Aynı zamanda tarım uzmanlarına erişim her zaman mümkün olmayabilmektedir. Bu durumda tarımda görüntü işleme uygulamaları giderek önem kazanmaktadır. Son yıllarda bu alanda birçok bilimsel çalışma yapılmıştır.

Asma yaprağı hastalıklarına ait yapılan benzer derin öğrenme çalışmaları bir çizelge haline getirilerek Çizelge 6.1’de sunulmuştur.

Çizelge 6. 1. Asma yaprağı hastalıkları üzerine literatürde yer alan çalışmalar

Sıra No	Sınıf Sayısı	Veri Sayısı	Yöntem	Başarı Oranı (%)	Kaynak
1	7	656	Faster-R-CNN Inception v2 SSD MobileNet v1	%95,57 %91,61	(Ghoury, 2019)
2	2	800	ResNet	%95,48	(Boulent vd., 2019)
3	4	4449	Faster DR-IACNN	%81,10	(Xie vd., 2020)
4	4	50	Matlab	Determinasyon katsayısı R2=0,9689	(Altaş vd., 2021)
5	3	8438	AlexNet	%99,00 %89,00	(Sanath Rao vd., 2021)
6	2	820	Faster R-CNN YOLOv4 YOLOv5 YOLOv5-CA	%83,70 %83,15 %83,36 %89,55	(Zhang vd., 2022)
7	5	500	MobileNetV2	%97,60	(M. Köklü vd., 2022)
8	7	2850	GoogLeNet Vgg16 ResNet34 DenseNet121 MobileNetV, MobileNetV3_large	%82,99 %84,01 %82,74 %84,77 %80,96 %82,74	(Lin vd., 2022)
9	5	3639	SqueezeNet GoogLeNet Inceptionv3 DenseNet-201 MobileNetv2 Resnet101 Resnet50 Resnet18 Xception ShuffleNet DarkNet-53	%97,2 %99,7 %99,6 %99,3 %96,9 %99,0 %99,4 %97,5 %99,6 %99,6 %99,5	(Fraivan vd., 2022)
10	6	4344	MobilenetV3	%99,84	(Yin vd., 2022)
11	4	4089	Grad-CAM	%99,54	(Zinonos vd., 2022)
12	4	4062	AlexNet ResNet101	%99,00	(Adeel vd., 2022)
13	4	3251	A new CNN architecture	%98,53	(Sofuoğlu ve Birant, 2023)
14	5	11000	Faster R-CNN SSD Multibox	%92,21 %92,00	(Altaş, 2023)
15	3	750	VGG16 VGG19 Inception V3 Xception MobileNet DenseNet201	%95,33 %98,00 %96,67 %94,67 %96,00 %96,67	(Bu çalışma)

Çizelge 6.1’den de görüleceği üzere asma yaprak hastalıkları üzerine yapılan diğer bilimsel çalışmalarda derin öğrenme mimarilerinden bir çok model kullanılmıştır. Ayrıca çizelgede yer alan çalışmalarda sınıf sayısının dolayısıyla hastalık türlerinin farklılığı dikkat çekmektedir. Bazı çalışmalarda iki sınıf bulunurken bazı çalışmalarda ise yedi farklı sınıf yer almaktadır. Bununla birlikte veri setlerinde kullanılan görüntü sayıları da oldukça çeşitlilik ve farklılık arz etmektedir.

Bu tez çalışmasında ikisi hastalık birisi sağlıklı olmak üzere üç sınıf incelenmiştir. Ayrıca veri seti bu tez çalışması için tarafımdan oluşturulmuştur. Asma yaprak hastalıkları iklim kaynaklı değişkenlik gösterdiğinden veri setinin oluşturulduğu yılda özellikle iki hastalık (bağ uyuzu ve mildiyö) yoğun olarak görülmüştür. Diğer asma yaprağı hastalıklarına ise veri seti oluşturacak sayıda rastlanmadığından, veri seti iki hastalık sınıfı ve sağlıklı yaprak görüntüleri sınıfından oluşturulmuştur.

Yapılan literatür taramasında narince bağ yaprağı hastalıklarına ait veri setine rastlanmamıştır. Bu çalışma kapsamında oluşturulan veri seti bu asma yaprağı türü için yeni bir veri seti olarak diğer çalışmalara katkı sağlayacağı düşünülmektedir.

Bu tez çalışmasında evrişimli sinir ağı modelleri ile asma bitkisinin yapraklarında sıklıkla görülen bağ uyuzu hastalığı, mildiyö hastalığı ve sağlıklı bitki yapraklarının tespit edilmesi amaçlanmıştır. Bu amaçla Haziran ayında Tokat ili Erbaa ilçesi yöresine ait örnek bir bağdan, hastalıklı ve sağlam yapraklar toplanarak görüntüleri fotoğraflama yöntemiyle kaydedilmiş ve sınıflandırılmıştır. Sınıflandırılan görüntüler CNN modellerinde eğitilerek sınıflandırma başarıları incelenmiştir.

Bağ yaprak imgeleri ön-eğitilmiş CNN modellerinden VGG16, VGG19, InceptionV3, Xception, MobileNet ve Densenet201 ile sınıflandırılmıştır. Ön eğitilmiş evrişimli sinir ağı modelleriyle yapılan sınıflandırmada %98,00 oranı ile VGG19 en başarılı model olmuştur. %94,67 oranı ile Xception modeli ise en düşük sınıflama doğruluğuna sahip olmuştur.

Önerilen sistemin amacı, ülkemizde yüksek katma değeri olan asma yaprağı yetiştiriciliğindeki hastalıkları yapay öğrenme teknikleri kullanılarak belirlemektir. Asma yaprağı hastalıklarının erken teşhisi ve erken müdahalesinin, asma yaprağı yetiştiriciliğinde verimliliği artırabileceği düşünülmektedir.

Teknolojinin tarımda kullanılması giderek yaygınlaşmakta, günümüzde bu ve benzer çalışmalar ile tarımda bilgisayar destekli uygulamalar daha yaygın bir biçimde kullanılmaktadır. Gelecek çalışmalarda asma yapraklarında görülen daha fazla hastalık incelenebilir. Yapay zeka ve derin öğrenmenin başka modelleri gelecek çalışmalarda kullanılabilir. Ayrıca bu ve benzer bitkilerin hastalıklarının tespiti için mobil uygulamalar geliştirilebilir.



KAYNAKLAR

- Adeel, A., Khan, M. A., Akram, T., Sharif, A., Yasmin, M., Saba, T., and Javed, K. (2022). Entropy-controlled deep features selection framework for grape leaf diseases recognition. *Expert Systems*, 39(7), e12569. <https://doi.org/10.1111/exsy.12569>
- Akmeşe, Ö. F., Çizmeci, H., Özdem, S., Özdemir, F., Deniz, E., Mazman, R., Erdoğan, M., and Erdoğan, E. (2023). Prediction of Gender and Age Period from Periorbital Region with VGG16. *Chaos Theory and Applications*, 5(2), 105-110. <https://doi.org/10.51537/chaos.1257597>
- Aktaş, A. (2020). *Derin Öğrenme Yöntemleri İle Görüntü İşleme Uygulamaları*, Yayınlanmamış Yüksek Lisans Tezi, Marmara Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- Alhawas, N., ve Tüfekci, Z. (2022). The Identification of Red-Meat Types using The Fine-Tuned Vision Transformer and MobileNet Models. *European Journal of Science and Technology*. <https://doi.org/10.31590/ejosat.1112892>
- Alsancak Sırlı, B., Peşkirioğlu, M., Torunlar, H., Özaydın, K. A., Mermer, A., Kader, S., Tuğaç, M. G., Aydoğmuş, O., Emeklier, Y., Yıldırım, Y. E., ve Kodal, S. (2015). Türkiye’de Üzüm (Vitis spp.) Yetiştirmeye Uygun Potansiyel Alanların Coğrafi Bilgi Sistemleri (CBS) Teknikleri Kullanılarak. *Tarla Bitkileri Merkez Araştırma Enstitüsü Dergisi*, 24(1). <https://doi.org/10.21566/tbmaed.32457>
- Altaş, Z. (2023). *Derin Öğrenme Teknikleri İle Bazı Bağ Hastalıklarının Belirlenmesi*, Yayınlanmamış Doktora Tezi, Tokat Gaziosmanpaşa Üniversitesi Lisansüstü Eğitim Enstitüsü, Tokat.
- Altaş, Z., Özgüven, M. M., & Dilmaç, M. (2021). *Görüntü İşleme Teknikleri ile Bağ Yaprak Uyuzu Hasarının Belirlenmesi*, *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 10(3), 77-87.
- Avgın, S., ve Bahadıroğlu, C. (2004). İslahiye (Gaziantep) İlçesinde Bağ Yaprak Uyuzu Colomerus vitis (Pgst.) (Acarina: Eriophyidae)’in Üzümlerin Verim ve Kalitesine Etkileri, *Yüzyüncü Yıl Üniversitesi, Ziraat Fakültesi, Tarım Bilimleri Dergisi (J. Agric. Sci.)*, 2004, 14(2): 73-78.
- Ayyüce Kızrak, M., ve Bolat, B. (2018). Derin Öğrenme ile Kalabalık Analizi Üzerine Detaylı Bir Araştırma. *Bilişim Teknolojileri Dergisi*, 11(3), 263-286. <https://doi.org/10.17671/gazibtd.419205>
- Bashimov, G. (2017). Türkiye’de Üzüm Üretimi ve İhracat Performansı. *Uludağ Üniversitesi Ziraat Fakültesi Dergisi*, 31(2), 57-68.
- Benli, S. N. (2021). *Derin Evrişimli Yapay Sinir Ağı Kullanarak Meyve Yaprak Hastalık Tespiti*, Yayınlanmamış Yüksek Lisans Tezi, Bilecik Şeyh Edebali Üniversitesi Fen Bilimleri Enstitüsü, Bilecik.

- Biçer, R. (2022). *Drone Görüntülerinden Derin Öğrenme Teknikleri İle Kayısı Rekolte Tahmini*, Yayınlanmamış Yüksek Lisans Tezi, Harran Üniversitesi Fen Bilimleri Enstitüsü, Şanlıurfa.
- Boulent, J., Beaulieu, M., St-Charles, P.-L., Théau, J., and Foucher, S. (2019). Deep learning for in-field image-based grapevine downy mildew identification. *Precision agriculture '19*, 141-148. https://doi.org/10.3920/978-90-8686-888-9_16
- Bozkurt, K. (2021). *Ardışık Sayısal Görüntülerde Çok Sayıda Hareketli Nesnenin Tespiti, İzlenmesi, Tanımlanması ve Sınıflandırılması*, Yayınlanmamış Doktora Tezi, Gazi Üniversitesi Fen Bilimleri Enstitüsü, Ankara.
- Buluş, A. (2022). *Derin Öğrenme Yöntemleri İle Meyvelerin Tazelik Durumunun Belirlenmesi*, Yayınlanmamış Yüksek Lisans Tezi, Tekirdağ Namık Kemal Üniversitesi Fen Bilimleri Enstitüsü, Tekirdağ.
- Ciran, A., ve Özbay, E. (2022). Ön-Eğitilmiş CNN Mimarilerinin Füzyonu ile Mısır Yaprığı Hastalıklarının Sınıflandırılması. *European Journal of Science and Technology*. <https://doi.org/10.31590/ejosat.1216356>
- Çalışkan, D., ve Demir, Ö. (2022). Derin Öğrenme Yöntemleri İle Şüpheli Davranış Tespiti. *International Periodical of Recent Technologies in Applied Engineering*, Cilt: 3-Sayı: 1(Cilt: 3-Sayı: 1), 26-41. <https://doi.org/10.29228/porta.8>
- Çetiner, H. (2021). Yaprak Hastalıklarının Sınıflandırılabilmesi İçin Önceden Eğitilmiş Ağ Tabanlı Derin Ağ Modeli. *Adıyaman Üniversitesi Mühendislik Bilimleri Dergisi*, 8(15), 442-456. <https://doi.org/10.54365/adyumbd.988049>
- Çoban, A., ve Özyurt, F. (2022). Kapsül Ağları ile Yüz Verilerinin Sınıflandırılması. *European Journal of Science and Technology*. <https://doi.org/10.31590/ejosat.999055>
- Daşkın, Y. Ç., Balık Şanlı, F., Özkan, T., ve Kartal, H. (2018). Derin Öğrenme Yöntemleri İle Yüz Görüntülerinden Yaş Kestirimi. *VII. Uzaktan Algılama Ve Cbs Sempozyumu Uzal-Cbs2018*. VII. Uzaktan Algılama Ve Cbs Sempozyumu. <https://doi.org/10.15659/uzalcbs2018.6235>
- Doğan, F., ve Türkoğlu, İ. (2019). Derin Öğrenme Modelleri ve Uygulama Alanlarına İlişkin Bir Derleme. *DÜMF Mühendislik Dergisi*, 10(2), 409-445. <https://doi.org/10.24012/dumf.411130>
- Duman, B. (2022). *Derin Öğrenme Yöntemleri İle Bitki Sınıflandırma*, Yayınlanmamış Yüksek Lisans Tezi, Ankara Üniversitesi Fen Bilimleri Enstitüsü, Ankara.
- Foto, Ö. (2022). *Transfer Öğrenme Modelleri İle Akciğer X-Ray Görüntülerinden Covid-19 Tespiti*, Yayınlanmamış Yüksek Lisans Tezi, Aksaray Üniversitesi Sosyal Bilimler Enstitüsü, Aksaray.
- Fraiwan, M., Faouri, E., and Khasawneh, N. (2022). Multiclass Classification of Grape Diseases Using Deep Artificial Intelligence. *Agriculture*, 12(10), 1542. <https://doi.org/10.3390/agriculture12101542>

- Ghoury, S. (2019). *Konvolüsyonel Sinir Ağlarını Kullanarak Üzüm ve Üzüm Yapraklarının Hastalıklarının Tespit Edilmesi*, Yayınlanmamış Yüksek Lisans Tezi, Selçuk Üniversitesi Fen Bilimleri Enstitüsü, Konya.
- Gülcü, M., ve Demirci, A. Ş. (2011). *Salamuraya İşlenen Bazı Asma Yapraklarının Kalite Özellikleri Üzerine Bir Araştırma*. Tekirdağ Ziraat Fakültesi Dergisi, 8(3), 16-21.
- İmak, A., Doğan, G., Şengür, A., ve Ergen, B. (2023). Asma Yaprakları Türünün Sınıflandırılması için Doğal ve Sentetik Verilerden Derin Öznitelikler Çıkarma, Birleştirme ve Seçmeye Dayalı Yeni Bir Yöntem. *International Journal of Pure and Applied Sciences*, 9(1), 46-55. <https://doi.org/10.29132/ijpas.1144615>
- Karadeniz, A. T. (2023). *Yaprak Görüntülerini Kullanarak Derin Öğrenme ile Ceviz Türlerinin Belirlenmesi*, Yayınlanmamış Doktora Tezi, Karabük Üniversitesi Fen Bilimleri Enstitüsü, Karabük.
- Karaoğlu, B. (2022). *Görüntü İşlemenin Convolutional Neural Network(Cnn) Modeli Kullanılarak Tarımsal Alanda Uygulanması: Hastalıklı Yaprak Tespiti*, Yayınlanmamış Yüksek Lisans Tezi, Karabük Üniversitesi Lisansüstü Eğitim Enstitüsü, Karabük.
- Karasu, E. (2019). *Metin Madenciliği Tekniklerini Kullanarak Faaliyet Bazlı Proje Yönetiminde Bilgi Yönetimi Süreçleri İçin Derin Öğrenme Modeli*, Yayınlanmamış Yüksek Lisans Tezi, İstanbul Üniversitesi Cerrahpaşa Lisansüstü Eğitim Enstitüsü, İstanbul.
- Kaya, M. (2019). *Ağrı'nın Kalkınması İçin Akıllı Tarım (Tarım 4.0) Önerisi*. Akademikbakış Dergisi, (75), 132-133.
- Kılıçarslan, S., ve Paçal, İ. (2023). *Domates Yapraklarında Hastalık Tespiti İçin Transfer Öğrenme Metotlarının Kullanılması - Use of Transfer Learning Methods for Disease Detection in Tomato Leaves*. Mühendislik Bilimleri ve Araştırma Dergisi, 2023; 5(2) 215 - 222.
- Koç, Y. (2022). *Hasarlı Güneş Paneli Hücrelerinin Derin Öğrenme Yöntemleriyle Sınıflandırılması*, Yayınlanmamış Yüksek Lisans Tezi, Amasya Üniversitesi Fen Bilimleri Enstitüsü, Amasya.
- Korkmaz, A. (2021). *Derin Öğrenme Teknikleriyle Akciğer Röntgeninden Covid-19 Hastalığının Tespit edilmesi*, Yayınlanmamış Yüksek Lisans Tezi, Karabük Üniversitesi Lisansüstü Eğitimi Enstitüsü, Karabük.
- Köklü, G. (1999). *Trakya bölgesi bağlarında asma yaprak kıvrılma virüs (leafroll) hastalığının karakterizasyonu ve surveyi*, Yayınlanmamış Doktora Tezi, Çukurova Üniversitesi Fen Bilimleri Enstitüsü, Adana.
- Köklü, M., Unlarsen, M. F., Ozkan, I. A., Aslan, M. F., and Sabanci, K. (2022). A CNN-SVM study based on selected deep features for grapevine leaves classification. *Measurement*, 188, 110425. <https://doi.org/10.1016/j.measurement.2021.110425>

- Küçükyumuk, Z., ve Bayındır, Ü. (2023). Bitki Beslenmesi ve Bitki Hastalıkları İlişkisi. *Türk Bilim ve Mühendislik Dergisi*, 5(1), 42-49. <https://doi.org/10.55979/tjse.1192093>
- Lin, J., Chen, X., Pan, R., Cao, T., Cai, J., Chen, Y., Peng, X., Cernava, T., and Zhang, X. (2022). GrapeNet: A Lightweight Convolutional Neural Network Model for Identification of Grape Leaf Diseases. *Agriculture*, 12(6), 887. <https://doi.org/10.3390/agriculture12060887>
- Liu, B., Ding, Z., Tian, L., He, D., Li, S., and Wang, H. (2020). Grape Leaf Disease Identification Using Improved Deep Convolutional Neural Networks. *Frontiers in Plant Science*, 11, 1082. <https://doi.org/10.3389/fpls.2020.01082>
- Naes, M. (2023). *Glokom Hastalığının Derin Öğrenme Yöntemiyle Ön Tanısı*, Yayınlanmamış Yüksek Lisans Tezi, Karabük Üniversitesi Fen Bilimleri Enstitüsü, Karabük.
- Ökten, İ. (2022). *Derin Öğrenme Yöntemleri ve Yapay Sinir Ağı Tabanlı Ndvi Değerleri İle Çeltik Bitkisi Hastalıkların Tespiti*, Yayınlanmamış Doktora Tezi, Bilecik Şeyh Edebali Üniversitesi Fen Bilimleri Enstitüsü, Bilecik.
- Önder, S. (2016). *Ege Bölgesi Bağlarında Asma Yaprak Kıvrılma Hastalığı İle İlişkili Virüslerin Tanınması ve Karakterizasyonu*, Yayınlanmamış Doktora Tezi, Ege Üniversitesi Fen Bilimleri Enstitüsü, İzmir.
- Örenç, S., Acar, E., ve Özerdem, M. S. (2023). Utilizing the Ensemble of Deep Learning Approaches to Identify Monkeypox Disease. *DÜMF Mühendislik Dergisi*. <https://doi.org/10.24012/dumf.1199679>
- Özata, K. (2012). *Tokat Yöresinde Üretilen Salamuralık Asma Yapraklarında Pestisit Kalıntı Düzeylerinin Belirlenmesi*, Yayınlanmamış Yüksek Lisans Tezi, Gaziosmanpaşa Üniversitesi Fen Bilimleri Enstitüsü, Tokat.
- Özben, S. (2011). *Ankara İli Bağ Alanlarında Görülen Fungal Hastalıkların ve Yaygınlık Oranlarının Belirlenmesi*, Yayınlanmamış Yüksek Lisans Tezi, Ankara Üniversitesi Fen Bilimleri Enstitüsü, Ankara.
- Pakdemirli, B., Birişik, N., Aslan, İ., Sönmez, B., ve Gezici, M. (2021). Türk Tarımında Dijital Teknolojilerin Kullanımı ve Tarım-Gıda Zincirinde Tarım 4.0. *Toprak Su Dergisi*, 10(1), 78-87. <https://doi.org/10.21657/topraksu.898774>
- Qiao, Y., Zhang, Z., Guo, Y., and He, D. (2022). Deep learning based grape mildew disease severity classification. *2022 Houston, Texas July 17-20, 2022*. 2022 Houston, Texas July 17-20, 2022. <https://doi.org/10.13031/aim.202200369>
- Sağlam, Ö. Ç., ve Sağlam, H. (2018). *İnsanlık Tarihinde Üzümün Önemi*. Bilecik Şeyh Edebali Üniversitesi, Ziraat ve Doğa Bilimleri Fakültesi, Bahçe Bitkileri Bölümü, 1(2), 1-10.

- Sanath Rao, U., Swathi, R., Sanjana, V., Arpitha, L., Chandrasekhar, K., Chinmayi, and Naik, P. K. (2021). Deep Learning Precision Farming: Grapes and Mango Leaf Disease Detection by Transfer Learning. *Global Transitions Proceedings*, 2(2), 535-544. <https://doi.org/10.1016/j.gltp.2021.08.002>
- Sandıkçı, Y., ve Aydılek, İ. (2018). *Tarımsal Veri Analizlerinin Veri Madenciliği ile Yapılması*. Harran Üniversitesi Mühendislik Dergisi, 3(2), 1-7.
- Sofuoğlu, C. İ., & Birant, D. (2023). Using Convolutional Neural Network For Grape Plant Disease Classification. *Uludağ University Journal of The Faculty of Engineering*, 28(3), 809-820. <https://doi.org/10.17482/uumfd.1277418>
- Soylu, A. C. (2022). *Sürdürülebilir Kalkınma ve Gıda Güvenliği İlişkisi*. Paradigma: İktisadi ve İdari Araştırma Dergisi, 11(2), 100-111.
- Şeker, A., Diri, B., ve Balık, H. H. (2017). *Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme*. Gazi Mühendislik Bilimleri Dergisi. 3(3), 47-64.
- Şener, A., ve Ergen, B. (2022). Deprem Sonrası Bina Yüzeylerinde Meydana Gelen Çatlakların Tespitinde Sınıflandırma Modellerinin Karşılaştırılması. *Çukurova Üniversitesi Mühendislik Fakültesi Dergisi*, 37(4), 899-910. <https://doi.org/10.21605/cukurovaumfd.1230792>
- Şimşek, E. (2021). *Adıyaman ve Şanlıurfa İllerinde Bağlarda Enfeksiyonlara Sebep Olan Fitoplazmaların Saptanması, Moleküler Karakterizasyonu ve Bitki Savunma Tepkilerinin Araştırılması*, Yayınlanmamış Doktora Tezi, Harran Üniversitesi Fen Bilimleri Enstitüsü, Şanlıurfa.
- Terzi, İ., Özgüven, M. M., ve Yağcı, A. (2023). Derin Öğrenme Teknikleri ile Bazı Üzüm Çeşitlerinin Tespiti. *Turkish Journal of Agriculture - Food Science and Technology*, 11(1), 125-130. <https://doi.org/10.24925/turjaf.v11i1.125-130.5722>
- Türkoğlu, M. (2019). *Görüntü İşleme Tabanlı Bitki Türleri ve Hastalıkları Tanıma*, Yayınlanmamış Doktora Tezi, İnönü Üniversitesi Fen Bilimleri Enstitüsü, Malatya.
- Ulutaş, H. (2023). *Domates Hastalıklarının Sınıflandırılması İçin Makine Öğrenmesi ve Derin Öğrenme Temelli Yeni Yaklaşımlar*, Yayınlanmamış Doktora Tezi, Erciyes Üniversitesi Fen Bilimleri Enstitüsü, Kayseri.
- Xie, X., Ma, Y., Liu, B., He, J., Li, S., and Wang, H. (2020). A Deep-Learning-Based Real-Time Detector for Grape Leaf Diseases Using Improved Convolutional Neural Networks. *Frontiers in Plant Science*, 11, 751. <https://doi.org/10.3389/fpls.2020.00751>
- Yaman, O. ve Tuncer, T. (2022). *Bitkilerdeki Yaprak Hastalığı Tespiti için Derin Özellik Çıkarma ve Makine Öğrenmesi Yöntemi*. Fırat Üniversitesi Mühendislik Bilimleri Dergisi, 34(1), 123-132.

- Yazıcı, İ. (2018). *Narince Üzüm Çeşidi Salamuralık Asma Yaprığı Üretiminde Bağ Yaprak Uyuzu [Colomerus Vitis Pgst. (Acarina: Eriophyidae)]'na Karşı Kullanılabilecek Alternatif İlaçlar*, Yayınlanmamış Yüksek Lisans Tezi, Gaziosmanpaşa Üniversitesi Fen Bilimleri Enstitüsü, Tokat.
- Yazıcı, İ., ve Yeşilayer, A. (2020). Tokat İli Narince Üzüm Çeşidinde Farklı İlaç Uygulamalarının Bağ Yaprak Uyuzu [Colomerusvitis Pagenstecher (Acarina: Eriophyidae)]'na Karşı. *Türk Tarım ve Doğa Bilimleri Dergisi*, 7(1), 212-220. <https://doi.org/10.30910/turkjans.680071>
- Yıldırım, S., Yıldırım, G., ve Alataş, B. (2021). Anlaşılabilir Sınıflandırma Kurallarının Ayçiçeği Optimizasyon Algoritması ile Otomatik Keşfi. *Türk Doğa ve Fen Dergisi*, 10(2), 233-241. <https://doi.org/10.46810/tdfd.976397>
- Yin, X., Li, W., Li, Z., Yi, L., 1. School of Agricultural Engineering and Food Science, Shandong University of Technology, Zibo 255000, Shandong, China, and 2. School of Artificial Intelligence, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China. (2022). Recognition of grape leaf diseases using MobileNetV3 and deep transfer learning. *International Journal of Agricultural and Biological Engineering*, 15(3), 184-194. <https://doi.org/10.25165/j.ijabe.20221503.7062>
- Yöntem, G. (2021). *Bazı Üzüm Çeşitlerinin Bağ Mildiyösü (Plasmopara Viticola) Hastalığına Karşı Duyarlılıkları*, Yayınlanmamış Yüksek Lisans Tezi, Bursa Uludağ Üniversitesi Fen Bilimleri Enstitüsü, Bursa.
- Zhang, Z., Qiao, Y., Guo, Y., and He, D. (2022). Deep Learning Based Automatic Grape Downy Mildew Detection. *Frontiers in Plant Science*, 13, 872107. <https://doi.org/10.3389/fpls.2022.872107>
- Zinonos, Z., Gkelios, S., Khalifeh, A. F., Hadjimitsis, D. G., Boutalis, Y. S., and Chatzichristofis, S. A. (2022). Grape Leaf Diseases Identification System Using Convolutional Neural Networks and LoRa Technology. *IEEE Access*, 10, 122-133. <https://doi.org/10.1109/ACCESS.2021.3138050>

ÖZGEÇMİŞ

Adı-Soyadı

Yasin ÜNAL

Eğitim Derecesi

Okul/Program

Mezuniyet Yılı

Lisans

Kocaeli Üniversitesi
Bilgisayar Öğretmenliği

1998

İş Deneyimi/Yıl

Çalıştığı Yer

1998 – 2000

Muğla Ticaret Meslek Lisesi

2000 - Halen

Tokat Gaziosmanpaşa Üniversitesi / Erbaa MYO

Yabancı Dil

İngilizce

Bilimsel Faaliyetler (Yayınlar, Bildiriler, Katıldığı Projeler)

1-) Ünal, Y., Kara, M., Ünal, Y. (2023). Classification of Diseases on Grape Leaves With Pre-Trained Networks, 9. International May 19 Innovative Scientific Approaches Congress May 17-19, 2023 / Samsun, 308, ISBN - 978-625-367-096-2