



**T.C.
BATMAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİLGİ TEKNOLOJİLERİ ANA BİLİM DALI**

YÜKSEK LİSANS TEZİ

**DERİN ÖĞRENME METOTLARI İLE ASMA YAPRAKLARININ
SINIFLANDIRILMASI**

Berivan AKDOĞAN

**Ağustos-2024
BATMAN**

**T.C.
BATMAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİLGİ TEKNOLOJİLERİ ANA BİLİM DALI**

YÜKSEK LİSANS TEZİ

**DERİN ÖĞRENME METOTLARI İLE ASMA YAPRAKLARININ
SINIFLANDIRILMASI**

Berivan AKDOĞAN

**Danışman
Prof. Dr. Necmettin SEZGİN**

**Ağustos-2024
BATMAN**

TEZ KABUL VE ONAYI

Berivan AKDOĞAN tarafından hazırlanan “Derin Öğrenme Metotları ile Asma Yapraklarının Sınıflandırılması” adlı tez çalışması 09/08/2024 tarihinde aşağıdaki jüri tarafından oy birliği ile Batman Üniversitesi Lisansüstü Eğitim Enstitüsü Bilgi Teknolojileri Ana Bilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Prof. Dr. Necmettin SEZGİN

.....

Danışman

Prof. Dr. Necmettin SEZGİN

.....

Üye

Doç. Dr. Yılmaz KAYA

.....

Üye

Doç. Dr. Melih KUNCAN

.....

Yukarıdaki sonucu onaylarım.

Dr. Öğr. Üyesi Ömer Murat ÖTER
Lisansüstü Eğitim Enstitüsü Müdürü

T EZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

Berivan AKDOĞAN

Tarih: 09/08/2024

ÖZET

YÜKSEK LİSANS TEZİ

DERİN ÖĞRENME METOTLARI İLE ASMA YAPRAKLARININ SINIFLANDIRILMASI

Berivan AKDOĞAN

Batman Üniversitesi Lisansüstü Eğitim Enstitüsü
Bilgi Teknolojileri Ana Bilim Dalı

Danışman: Prof. Dr. Necmettin SEZGİN

2024, 41 Sayfa

Jüri

Prof. Dr. Necmettin SEZGİN

Doç. Dr. Yılmaz KAYA

Doç. Dr. Melih KUNCAN

Asma yapraklarının sınıflandırılması, tarım ve gıda endüstrisinde önemli bir yer tutmaktadır. Özellikle yaprak hastalıklarının erken teşhisi, verimliliği artırmak ve ürün kalitesini korumak için kritik bir öneme sahiptir. Geleneksel yöntemler bu süreçte yetersiz kalabilirken, derin öğrenme teknikleri yüksek doğruluk ve hız sağlayarak etkili çözümler sunmaktadır.

Bu tez çalışmasında, 8 farklı asma türünden elde edilen toplam 4000 asma yaprağı görüntüsünü sınıflandırmak amacıyla derin öğrenme modelleri kullanılmıştır. Araştırmanın temel amacı, bu yaprak görüntülerini en yüksek doğrulukla sınıflandırabilecek modeli belirlemek ve tarımsal uygulamalarda kullanılabilecek bir sınıflandırma sistemi geliştirmektir. Çalışmada, ResNet50, ResNet101, ResNet152, MobileNet, Xception ve DenseNet169 modelleri kullanılarak performans karşılaştırmaları yapılmıştır.

Öncelikle asma yaprağı görüntüleri çeşitli ön işleme adımlarından geçirilerek veri seti oluşturulmuştur. Ardından bu veri seti, her bir model ile ayrı ayrı eğitilmiş ve değerlendirilmiştir. Modellerin performansı; doğruluk, eğitim süresi ve model karmaşıklığı gibi kriterler göz önünde bulundurularak analiz edilmiştir.

Deneysel sonuçlar, ResNet101 modelinin %88 doğruluk oranı ile en yüksek performansı sergilediğini, ancak 17 saatlik eğitim süresi ile uzun bir süreyi gerektirdiğini göstermiştir. Xception modeli %86 doğruluk oranı ile ResNet101 modeline yakın performans sunmuş ve ayrıca 10 saatlik işlem süresinin dikkate değer olduğu için tercih edilebileceği anlaşılmıştır. MobileNet modeli ise %80 doğruluk oranı ve daha hızlı (2 saat 20 dakika) sonuçlar üretmiş, bu da onu gerçek zamanlı uygulamalar için uygun hale getirmiştir. DenseNet169 modeli ise %73 doğruluk oranı ile en düşük performansı sergilemiştir.

Bu bulgular, derin öğrenme modellerinin asma yaprağı sınıflandırmasında etkili bir şekilde kullanılabileceğini ve doğru model seçiminin hem doğruluk hem de verimlilik açısından kritik olduğunu ortaya koymaktadır. Gelecekteki çalışmalarda, literatürde yer alan farklı sinir ağı modelleri ile başarı oranının artırılması ve görüntü işleme tekniklerinin geliştirilmesi hedeflenmektedir. Ayrıca en yüksek doğruluğa sahip model temel alınarak tarımsal üreticiler ve tüketiciler için pratik bir mobil uygulama geliştirilmesi planlanmaktadır.

Anahtar Kelimeler: Asma Yaprağı Sınıflandırması, DenseNet, Derin Öğrenme, MobileNet, ResNet, Tarımsal Uygulamalar, Xception

ABSTRACT

MS THESIS

CLASSIFICATION OF VINE LEAVES USING DEEP LEARNING METHODS

Berivan AKDOĞAN

Batman University Graduate Education Institute

Information Technologies Department of Science

Advisor: Prof. Dr. Necmettin SEZGİN

2024, 41 Pages

Jury

Prof. Dr. Necmettin SEZGİN

Doç. Dr. Yılmaz KAYA

Doç. Dr. Melih KUNCAN

Classification of vine leaves holds significant importance in the agriculture and food industries. Early detection of leaf diseases is critical for increasing productivity and maintaining product quality. Traditional methods can be inadequate in this process, whereas deep learning techniques offer effective solutions by providing high accuracy and speed.

In this thesis, deep learning models were used to classify a total of 4000 vine leaf images obtained from 8 different vine species. The main objective of the research is to identify the model that can classify these leaf images with the highest accuracy and to develop a classification system that can be used in agricultural applications. Performance comparisons were made using ResNet50, ResNet101, ResNet152, MobileNet, Xception and DenseNet169 models.

First, a dataset was created by processing vine leaf images through various preprocessing steps. Then, this dataset was trained and evaluated with each model separately. The performance of the models was analyzed considering criteria such as accuracy, training time, and model complexity.

Experimental results showed that the ResNet101 model exhibited the highest performance with an accuracy rate of 88%, but it required a long training time of 17 hours. The Xception model demonstrated a performance close to ResNet101 with an accuracy rate of 86%, and it was considered preferable due to its notable processing time of 10 hours. The MobileNet model, with an accuracy rate of 80% and faster results (2 hours and 20 minutes), made it suitable for real-time applications. The DenseNet169 model, on the other hand, exhibited the lowest performance with an accuracy rate of 73%.

These findings demonstrate that deep learning models can be effectively used for vine leaf classification, and selecting the right model is critical for both accuracy and efficiency. Future studies aim to increase the success rate with different neural network models in the literature and to improve image processing techniques. Additionally, based on the model with the highest accuracy, it is planned to develop a practical mobile application for agricultural producers and consumers.

Keywords: Agricultural Applications, Deep Learning, DenseNet, MobileNet, ResNet, Vine Leaf Classification, Xception

ÖNSÖZ

Tez sürecinde bana rehberlik eden, her aşamada destek olan ve bana olan güvenini her defasında dile getirip cesaretlendiren maddi ve manevi desteğini esirgemeyen danışmanım Prof. Dr. Necmettin SEZGİN'e sonsuz teşekkürlerimi sunarım. Teşvik ve motivasyonlarından dolayı kendisine minnettarım.

Çalışmam boyunca görüş ve düşüncelerinden yararlandığım, kıymetli vaktini ayıran ve değerli katkılarını esirgemeyen Doç. Dr. Yılmaz KAYA'ya da teşekkürü bir borç bilirim.

Ayrıca tez yazma sürecinde samimi dostluğu ve motivasyonu ile yanımda olan sevgili sınıf arkadaşım Evin Ortaç'a özel teşekkürlerimi sunmak isterim. Tez yazma sürecindeki karşılıklı destek ve yardımlarla bu süreci daha keyifli ve çok daha kolay hale getirdi.

Son olarak, her konuda olduğu gibi bu süreçte de desteğini esirgemeyen, özellikle veri seti toplama aşamasında kendisine bir görev bilip yardımcı olan canım anneme en derin sevgi ve şükranlarımı sunarım.

Berivan AKDOĞAN
BATMAN-2024

İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
ÖNSÖZ	vi
İÇİNDEKİLER.....	vii
SİMGELER VE KISALTMALAR.....	viii
ÇİZELGE LİSTESİ.....	ix
ŞEKİL DİZİNİ	x
1. GİRİŞ	1
2. LİTERATÜR ÇALIŞMALARI	5
3. MATERYAL VE METOD.....	13
3.1. Materyal	13
3.2. Metod	15
3.2.1. Yapay zeka (AI).....	15
3.2.2. Makine öğrenmesi.....	16
3.2.3. Derin öğrenme	17
3.2.4. Makine öğrenmesi ile derin öğrenme arasındaki fark	18
3.2.5. Önceden eğitilmiş modeller ve bitki sınıflandırmasındaki rolü.....	19
3.2.6. Evrişimli sinir ağı (CNN)	20
3.3. Önceden Eğitilmiş CNN Modelleri.....	21
3.3.1. ResNet-50	21
3.3.2. ResNet-101	22
3.3.3. ResNet-152	23
3.3.4. MobileNet	23
3.3.5. Xception.....	24
3.3.6. DenseNet.....	24
3.4. Karışıklık Matrisi	25
3.5. Performans Metrikleri	26
4. BULGULAR.....	29
5. TARTIŞMA	35
5.1. Gelecek Çalışmalar	36
KAYNAKLAR	37
ÖZGEÇMİŞ	41

SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış bazı simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

<u>Simgeler</u>	<u>Acıklama</u>	
AI	Artificial Intelligence	Yapay Zekâ
YSA	Artificial Neural Network	Yapay Sinir Ağı
CNN, ESA	Convolutional Neural Networks	Evrişimli Sinir Ağları
RELU	Rectified Linear Unit	Rektifiye Lineer Ünite
ResNet	Residual Network	Artık Ağ
TP	True Positive	Doğru Pozitif
TN	True Negative	Doğru Negatif
FP	False Positive	Yanlış Pozitif
FN	False Negative	Yanlış Negatif
AUC	Area Under the ROC Curve	ROC Eğrisi Altındaki Alan
SVM, DVM	Support Vector Machine	Destek Vektör Makinesi
VGG	Visual Geometry Group	Görsel Geometri Grubu
SSD	Single Shot Multibox Detector	Tek Atış Çok Kutulu Detektörü
R-CNN	Region Based Convolutional Neural Network	Bölge Tabanlı Konvolüsyonel Sinir Ağı
ADAM	Adaptive Moment	Uyarlanabilir Moment Tahmini
MobileNet	Mobile Network	
Xception	Extreme Inception	Aşırı Inception
DenseNet	Dense Convolutional Network	Yoğun Evrişimli Ağlar
YAA	Yerel Alıcı Alanlar	
AÖM	Aşırı Öğrenme Makineleri	

ÇİZELGE LİSTESİ

Çizelge 1.1. Dünya bağ alanları ve üzüm üretimi sıralaması (Anonim, 2018-2021a)	1
Çizelge 1.2. Türkiye’de üzüm üretiminde ilk 5 il (Tüik, 2021).....	2
Çizelge 3.1. Çalışmada kullanılan 8 türe ait asma yaprakları örnekleri	14
Çizelge 3.2. İki sınıflı karışıklık matrisi	26
Çizelge 3.3. Performans metrikleri formülleri.....	27
Çizelge 4.1 Derin öğrenme modellerinin hiperparametre değerleri	30
Çizelge 4.2. Test veri seti ile derin öğrenme modellerinin performans değerlendirmeleri	30
Çizelge 4.3. Derin öğrenme modelleri ile sınıflandırma başarı oranları ve harcanan süreler.....	31

ŞEKİL DİZİNİ

Şekil 3.1. Asma yaprağı görüntüleri elde etmek için kullanılan sistem.	14
Şekil 3.2. Yapay zeka, makine öğrenmesi ve derin öğrenme	16
Şekil 3.3. Makine öğrenmesi: yeni bir programlama paradigması	17
Şekil 3.4. Derin öğrenmenin üç katmanlı örnek modellemesi.....	17
Şekil 3.5. Yaprak görüntülerinin sınıflandırma yapılırken derin öğrenme ve makine öğrenmesinin karşılaştırılması	19
Şekil 3.6. Evrişimli sinir ağları yapısı.....	20
Şekil 3.7. DenseNet mimarisi.	25
Şekil 4.1. Derin öğrenme modelleri ile sınıflandırma başarı oranları	31
Şekil 4.2. Derin öğrenme modellerine ait başarı oranları	32
Şekil 4.3. Derin öğrenme modellerine ait Loss değerleri	33
Şekil 4.4. Modellerin karışıklık matrisi	34

1. GİRİŞ

Bağcılık, insanlığın en eski tarımsal faaliyetlerinden biri olmakla beraber halen önemini kaybetmeden günümüzde iklimi elverişli olan ülkelerde tarımsal geçim kaynakları arasında en yaygın faaliyet olarak varlığını sürdürmektedir (Luglio, 2024).

Asma, diğer meyve veren bitkilere göre en fazla çeşidi bulunan türlerden biridir. Tahminlere göre, dünya çapında 10.000'den fazla üzüm çeşidi bulunmaktadır. Ülkemiz, üzümün genetik çeşitliliği yönünden önemli bir bölge olarak görülmektedir. Anadolu'nun üzüm yetiştiriciliğinin ilk kez gerçekleştiği ve çok eski bir geçmişi olduğu bilinmektedir. Bu da bölgenin zengin bir üzüm genetik çeşitliliğe sahip olmasını sağlamıştır (Karataş ve ark., 2009).

Türkiye; bulunduğu coğrafi konum bakımından, iklim koşulları ve yetiştirme şartlarına uygunluğu neticesiyle bağcılık ve üzüm üretiminde dünyanın sayılı ülkeleri arasında yer almaktadır. 2021 yılında elde edilen verilere göre Türkiye, bağ alanları açısından dünya genelinde beşinci sırada yer alıp yaş üzüm üretimi bakımından da dünyada altıncı sıradadır. 1990-2013 yılları arasında edinilen istatistiki verilere göre Türkiye’de bulunan bağ sahalarında yaklaşık olarak %20’lik bir azalma görülürken aynı dönemde üzüm üretimi miktarında ise %14.61’lik artış olduğu gösterilmiştir (Tüik,2021).

Çizelge 1.1. Dünya bağ alanları ve üzüm üretimi sıralaması (Anonim, 2018-2021a)

Ülke	Bağ Alanı(ha)	Üretim(ton)
İspanya	1.123.644	6.673.481
Çin	797.935	13.494.811
Fransa	752.837	6.198.323
İtalya	675.818	8.513.643
Türkiye	417.041	3.933.000
A.B.D.	379.190	6.890.970
Hindistan	139.000	2.920.000

Türkiye'deki bağcılık faaliyetlerinin en yaygın olduğu bölge, %35'lik bir payla Güneydoğu Anadolu Bölgesi'dir (Tüik,2021). Çizelge 1.2.'de gösterildiği gibi ülke

genelinde en geniş bağ alanına sahip il ise %29 pay ile Manisa ilidir. Mardin ili ise %3.6 ile bağ üretim alanında beşinci sırada olduğu görülmektedir (Tüik,2021).

Çizelge 1.2. Türkiye’de üzüm üretiminde ilk 5 il (Tüik, 2021)

Sıra No	İller	Üretim Alanı(ha)	Oran (%)	Üretim Miktarı (Ton)	Oran(%)
1	Manisa	115634.6	28.83	744987	15.89
2	Denizli	31815.0	7.93	327988	7.00
3	Mersin	25057.0	6.25	203070	4.33
4	Kahramanmaraş	21524.9	5.37	332673	7.10
5	Mardin	14536.5	3.62	279800	5.97
Toplam (ilk 5 Şehir)		208568.0	51.99	1888518	40.28
Toplam (Türkiye)		401140.9	100.00	4687922	100.00

Türkiye'de üretilen üzümlerin yaklaşık %30'u sofralık, %37'si kurutmalık, %30'u pekmez, pestil, sucuk, sıra olarak kullanılırken, %3'ü ise şaraplık olarak değerlendirilmektedir (Nazlı, 2007)

Bağcılık ülkemizde önemli bir geçim kaynağı olmakla birlikte ülke ekonomisine de önemli katma değer sağlamaktadır. Yıllık olarak tarımsal gelirin %6-7'si bağcılıktan sağlanmaktadır (Anonim 2008a). Türkiye asma yetiştiriciliğinin anavatanı olması sebebiyle 1200'den fazla üzüm çeşidi yetiştirildiği bilinmektedir. Fakat bu üzüm çeşitlerinden sadece 50-60 çeşit kadarının ekonomik önemi bulunmakta ve geniş çapta yetiştirilmektedir (Göktaş, 2008). Bu nedenden dolayı ekonomik açıdan geliri yüksek ve kaliteli üzüm çeşidinin belirlenmesi büyük bir önem taşımaktadır. Asmanın ana ürünü taze veya işlenerek tüketilen üzüm olmasına rağmen, üzüm türlerini belirlemede asma yaprağı daha fazla tercih edilmektedir. Bunun en önemli sebeplerinden biri, bitkinin meyve verme dönemi beklenmeden büyüme döngüsünün çoğu aşamasında yaprak örneklerinin elde edilebilir olmasıdır.

Asma yaprakları Türk mutfağında yaygın olarak kullanılan ve geleneksel olarak salamura, konservasyon ve dondurarak muhafaza edilen önemli bir malzemedir. Asma çeşitleri kalınlık, tüylülük, dilimlilik gibi kriterler açısından çok farklı özellikler gösteren yapraklara sahiptir (Akın ve ark., 2011). Farklı türlerde şekil ve yapı

farklılıkları görülse de, ışık ve su gibi çevresel faktörler asma yapraklarının şeklini etkileyebilir (Yu ve ark., 2020). Ayrıca asmaların yaprak şekilleri de büyüme sürecinde farklılık gösterebilmektedir. Bazı türlerin arasında yüksek benzerlikler vardır ve onları ayırt etmek uzun zaman alabilir (Putz ve Mooney, 1991). Bu sebeplerden ötürü bir uzman için kaliteli, verimi yüksek asma çeşitlerini sınıflandırmak oldukça zordur ve pratik değildir. Bunun yerine, asma yaprağı çeşitlerini doğru bir şekilde ayırt etmek için özel yöntem ve tekniklerin geliştirilmesi ve uygulanması gerekmektedir (Köklü ve ark., 2022).

Tarımda bitkilerden elde edilen görsel verilerin tanımlanması konusunda halen çalışmalara ihtiyaç vardır. Bitkilerin meyve, çiçek ve yapraklarından görsel veriler kullanılarak sınıflandırılır. Ancak çiçekler ve meyveler uzun süreli bitki tanımlama problemlerinde kullanılamaz, çünkü belirli bir dönemde oluşurlar. Bununla birlikte, yaprakların kullanımı bitki tanımlama için daha uygundur. Çünkü bitkiye özgü özellikleri içerir, bol miktardadır ve yılın büyük bir bölümünde elde edilebilirler (Aakif ve Khan, 2015).

Günümüzde tarımsal faaliyetlerde yapay zeka yöntemlerinin kullanımının artmasıyla beraber bu alandaki sorunlara çözümler üretmekte ve aynı zamanda bugüne kadar kullanılmakta olan yöntemlere de alternatif yöntemler sunmaktadır. Tarım alanlarında bitki görsel verilerin teşhisi konusunda halen pratik yöntemlere gereksinim vardır (Li ve ark., 2020).

Derin öğrenme teknikleri, bilgisayarlı görme konusunda yenilikçi bir yöntem olarak gelişti ve geleneksel makine öğrenimi tekniklerinin başarabileceğinin ötesinde karmaşık ayrıntıları ortaya çıkarma kapasitesi sunuyor (Tan ve ark., 2020). Bilhassa son yıllarda derin öğrenme, özellikleri otonom olarak çıkarabilme yeteneği nedeniyle ön plana çıkmıştır. Derin öğrenme genellikle görüntülerin girildiği ve modelin ilgili özellikleri otomatik olarak ayırt ettiği bir kara kutu metodolojisi olarak tanımlanır. Daha sonra bu özelliklere göre sınıflandırma yapılır (Kamilaris ve Boldú, 2018). Geçtiğimiz birkaç yılda bitki yapraklarının sınıflandırılmasına yönelik çok sayıda derin öğrenmeye dayalı yöntem tanıtıldı.

Yenilebilir asma yapraklarının çok sayıda ayırt edici özelliklerinin bulunması ve en iyi ekonomik değere sahip olanları bu niteliklere göre sınıflandırmayı zorunlu kılmaktadır. Ayrıca tüketilebilir asma yapraklarının kalitelerine göre ayrıştırılması da pazarlama çalışmalarında büyük önem taşıyor (Köklü ve ark., 2022). Bu çalışma, uzmanlık gerektiren ve görsel tanımlama zorlukları bulunan asma yaprakları için bir

teşhis sistemi oluşturmayı amaçlamaktadır. Mevcut araştırmalar öncelikle asma yapraklarındaki hastalıkların teşhisine odaklanırken, yaprak sınıflandırması için şu ana kadar geleneksel ve manuel ölçüm teknikleri kullanılmıştır. Bu sorunları çözmek için bu çalışma, asma yaprakları görüntülerini türlerine göre otomatik olarak sınıflandıran derin öğrenme yöntemleri önerilmiştir.

Çeşitli bitkilerin yaprak özelliklerine göre sınıflandırılmasına yönelik bazı araştırmalar bulunmakla birlikte, bu çalışmaların sayısı oldukça sınırlıdır ve yaprak türlerini birbirinden ayırmak, yakın benzerlikleri nedeniyle zorlayıcıdır. Ayrıca, literatür incelendiğinde, mevcut çalışmaların ağırlıklı olarak hastalıkların tanımlanması ve yaprak görüntüleri kullanılarak farklı bitki türlerinin sınıflandırılması odaklandığı ortaya çıkmaktadır. Üzüm yapraklarında hastalık sınıflandırması üzerine yapılan bazı araştırmalara rağmen, aynı bölgeden çeşitli asma yaprağı türlerinin ayrımı konusunda literatürde henüz az sayıda çalışma olduğu görülmektedir.

Bu çalışmada, Mardin ilinin Dargeçit ilçesinde üretilen sekiz farklı asma çeşidinin sınıflandırılması amacıyla asma yaprakları görüntülerinin derin öğrenme yöntemleri ile analizine dayalı olarak uygun maliyetli ve otomatik yöntem olan derin öğrenme teknikleri sunulmaktadır. Sınıflandırma işlemi için Xception, MobileNet, DenseNet, ResNet50, ResNet101, ResNet152 gibi önde gelen aktarım derin öğrenme yöntemlerinden yararlanıldı. Bu bağlamda, yapay zeka alanında sinir ağları kullanarak derin öğrenme tekniklerini uygulayarak büyük ölçüde eğitim ve test aşamaları uygulandı ve sonuç olarak yaprak görüntülerini sınıflandırma işlemini gerçekleştirildi. İkinci bölümde, araştırma alanıyla ilgili geniş çaplı bir literatür incelemesi gerçekleştirildi ve bu çalışmaların analizi yapılarak çeşitli sonuçlar elde edildi. Üçüncü aşamada, oluşturulan veri setinin tanıtımıyla birlikte kullanılacak yöntemler belirlenmiş ve eğitim ile test süreçleri gerçekleştirilmiştir. Son bölümde ise eğitim ve test verileri incelenmiş ve kullanılan aktarım derin öğrenme teknikleri karşılaştırılarak bu yöntemlerin eksi ve artıları belirlenmiştir. Tüm çalışmaların sonucunda başarı düzeyleri tablolar ve karışıklık matrisi şeklinde sunulmuştur.

2. LİTERATÜR ÇALIŞMALARI

Literatürde asma yaprakları görüntüleri kullanılarak ve farklı yapay zeka yöntemleri ile tür belirleme üzerine çok az sayıda çalışma mevcuttur. Genellikle yaprak görüntüleri kullanılarak yapılan çalışmalarda hastalık tahmini ve farklı bitkilerin türlerini sınıflandırmaya yönelik çalışmalar olduğu görülmektedir. Asma yaprağı üzerine yapılan çalışmalar incelendiğinde bitkiye has hastalıkların sınıflandırılması ile ilgili çalışmalar olmasına rağmen asma yaprağı türlerini belirlemeye yönelik yeterli çalışmaların olmadığı görülmüştür. Genel olarak farklı bitki türlerinin belirlenmesinde ve yaprak görüntülerinden hastalık tespit etme üzerinde durdukları sonucuna varılmıştır.

Karadeniz ve arkadaşları, 18 farklı ceviz çeşidinden alınan toplam 1751 yaprak görüntüsü ile oluşturdukları veri setiyle otomatik sınıflandırma için çeşitli derin öğrenme yöntemlerini kullanmış ve bu yöntemlerle elde ettikleri sonuçları karşılaştırmıştır. Ayrıca, hem özgün veri seti hem de ön işleme ve veri artırma yöntemleri ile oluşturulan veri seti üzerinde deneysel testler yaparak sınıflandırma başarılarını değerlendirmişlerdir. Veri seti üzerinde, literatürde en çok tercih edilen 9 Evrişimli Sinir Ağı (ESA) algoritması ile yapılan sınıflandırma testlerinde elde edilen doğruluk oranları şu şekildedir: AlexNet %77.71, DarkNet19 %76.95, GoogleNet %75.24, InceptionV3 %76.95, ResNet101 %85.52, Vgg16 %84.00 ve Vgg19 %74.67 (Karadeniz ve ark., 2023).

Andaç İmak ve arkadaşları, tüketim için kullanılacak asma yapraklarının türünü sınıflandırmak amacıyla yeni bir yöntem önerisinde bulunmuşlardır. Önerdikleri bu yöntemde, Köklü ve arkadaşlarının oluşturmuş olduğu 5 farklı asma yaprağı çeşidinden elde edilmiş toplam 500 görüntüden oluşan bir veri seti kullanmışlardır. Bu veri setinde her bir asma yaprağı çeşidinden yalnızca 100 görüntü olduğu için veri artırma teknikleri kullanılarak görüntü sayısı 3500'e çıkarılmıştır. Ayrıca, görüntülerin kalitesini artırmak ve daha ayrıntılı dokular elde etmek amacıyla ESRGAN modeli uygulanmıştır. Veri setindeki görüntülerden öznitelik çıkarımı yapmak için önceden eğitilmiş derin öğrenme modellerinden biri olan VGG 19 modeli kullanılmıştır. Daha sonra elde edilen bu özniteliklerden en etkisiz olanların atılması ve en anlamlı özniteliklerin seçilmesi için Temel Bileşenler Analizi (Principal Component Analysis/PCA) yöntemi uygulanmıştır. Seçilen bu en önemli özniteliklerin asma yaprağı çeşitlerini tanımlamadaki başarısını sınamak için Destek Vektör Makineleri

(DVM) algoritması uygulanmış ve sonuç olarak %96,14 oranında doğruluk elde edilmiştir (İmak ve ark., 2022).

Fuat Kara, sıkça kullanılan PlantVillage veri setinden 8 yeni veri seti oluşturmuş ve bu sayede CNN mimarisinin çoklu sınıf ve farklı özelliklere sahip veri setleri üzerindeki başarısını hesaplayarak çeşitli derin öğrenme modellerinin kapsamlı karşılaştırmasını yapmıştır. Bu yeni veri setlerini kullanarak bitki çeşitlerini sınıflandırma, bitki hastalıklarını tahmin etme ve bitki hastalıklarını sınıflandırma gibi deneysel işlemler gerçekleştirmiş ve en başarılı modelleri belirlemeye çalışmıştır. Bitki türlerini sınıflandırmada en etkili derin öğrenme yönteminin %99,88 başarı oranı ile AlexNet modeli olduğu saptanmıştır. Bitki hastalıklarının tahmininde en iyi modelin, 3 kez çapraz doğrulama ile %99,91 başarı sağlayan GoogleNet/Inception olduğu belirlenmiştir. Bitki hastalıklarını sınıflandırmada ise en iyi modelin, 10 kez çapraz doğrulama ile %99,14 başarı sağlayan DenseNet olduğu sonucuna ulaşılmıştır. Kara, çalışmasında veri setlerindeki sınıf sayısı arttıkça başarının düştüğünü ve çapraz doğrulama yönteminde çoklu sınıf içeren veri setlerinde 10 kat çapraz doğrulamanın, 3 kat çapraz doğrulamaya göre daha yüksek başarı sağladığını tespit etmiştir. Ayrıca, veri setindeki görüntü sayısının yüksek olmasının hem eğitim başarısını hem de test başarısını artırdığını ve derin öğrenme modellerinin özellikle görüntü sınıflandırma işlemlerinde oldukça başarılı sonuçlar verdiğini savunmuştur (Kara, 2022).

Duman, bitki yaprak hastalıklarını sınıflandırmada derin öğrenme yöntemlerinden MobileNet ve ResNet50V2 mimarilerinin başarı oranlarını karşılaştıran bir çalışma yapmıştır. Bu çalışmada, karşılaştırmaları yapmak için Kaggle sitesinde bulunan ve 3642 görüntüden oluşan elma yaprakları veri setini kullanmıştır. Modelleri eğitme ve test etme işlemlerinde, veri setindeki görüntülerin sayısal olarak farklı oranları denenip karşılaştırılmış ve yüksek başarı için en iyi oran belirlenmeye çalışılmıştır. Çalışmada, bitki yaprakları hastalıklarını tanı ve sınıflandırma için en çok tercih edilen CNN mimarilerinden ResNet50V2 ve MobileNet mimarileri kullanılmıştır. Sonuçlara göre, ResNet50V2 yaklaşık olarak %96.72'lik bir başarı gösterirken, MobileNet yaklaşık olarak %96.35'lik bir başarı elde etmiştir. Bu sonuçlara dayanarak, ResNet50V2 modelinin MobileNet modeline göre daha yüksek bir başarı gösterdiği sonucuna varılmıştır. Bu sonuçlarla birlikte, her iki modelin de hastalık sınıflandırma işleminde yüksek başarı oranları gösterdiği ve bu nedenle diğer klasik makine öğrenmesi yöntemlerine ve manuel sınıflandırmalara göre daha kullanışlı bir alternatif olduğu önerilmiştir (Duman, 2022).

Köklü ve arkadaşları, aynı bölgeye ait Ak, Ala İdris, Büzgülü, Dimnit ve Nazlı adlarında 5 çeşit asma yaprağı görüntüleri kullanarak derin öğrenme modelleri ile tür belirleme üzerine bir çalışma yapmışlardır. Çalışmada, asma yapraklarının türlerini otomatik olarak sınıflandıran üç sistem önermişlerdir. Sınıflandırma işlemi için CNN modellerinden MobileNetv2 kullanılmıştır. Önerilen yaklaşımlardan ilki, ince ayarlı MobileNetv2 kullanılarak gerçekleştirilmiştir. İkinci yaklaşımda, önceden eğitilmiş MobileNetv2'nin Logits katmanından öznitelikler çıkarılmış ve çeşitli SVM çekirdekleri kullanılmıştır. Üçüncü yaklaşımda ise çıkarılan 1000 öznitelik, Ki-Kare yöntemiyle seçilerek 250'ye düşürülmüş ve SVM çekirdekleriyle sınıflandırma yapılmıştır. Uygulanan sistemler arasında en başarılı SVM çekirdeğinin Cubic olduğu ve bu sistemin başarısının %97,60 olarak belirlendiği sonucuna varılmıştır. Çalışmada, sınıflandırma için kullanılan öznitelik sayısı azalsa da öznitelik seçiminin sınıflandırmanın başarısını artırdığı sonucuna varılmıştır (Köklü ve ark., 2022).

Altaş ve arkadaşları, bağ yaprak uyuzu zararlısının bitkiye verdiği hasarı görüntü işleme yöntemleri ile uzman kişi değerlendirmesi arasındaki farkı karşılaştırarak incelemişlerdir. Çalışmada MATLAB programının image processing toolbox modülü kullanılmış olup, 50 görüntü içerisindeki yaprak uyuzunun vermiş olduğu hasar seviyesi en düşük %10 ve en yüksek %87 oranlarında tespit edilmiştir. Elde edilen sonuçlar doğrultusunda, görüntü işleme ile uzman kişi değerlendirmesi sonuçları arasında $R^2=0.968$, $p<0.01$ değerinde regresyon katsayısı ve $r=0.984$, $p<0.01$ değerinde Pearson korelasyon katsayısı hesaplanmıştır. Bu istatistiksel ilişki, görüntü işleme teknikleri ile uzman kişi değerlendirmesinin bağ yaprak uyuzu zararlısının hasar tespit oranlarının birbirine oldukça yakın olduğunu göstermiştir. Çalışmada, uzman değerlendirmesi kullanılan görüntülerde hasar oranını %20 olarak tespit ederken, görüntü işleme yöntemleriyle bu oran %18 olarak hesaplanmıştır. Görüntü işleme yönteminin bağ yaprak uyuzu hasar tespitinde uzman değerlendirmesine göre daha az zaman alması, maliyet açısından daha düşük olması ve hata yapma oranının daha az olması nedeniyle daha avantajlı olduğu belirlenmiştir. Böylece, yapılan çalışmanın sonucunda görüntü işleme yönteminin yararları ortaya konmuş ve uzman değerlendirmesine bir alternatif olarak kullanılabileceği gösterilmiştir (Altaş ve ark., 2021)..

Miaomiao Ji ve arkadaşları, CNN tabanlı derin öğrenme modelleri kullanarak farklı bitki türleri yaprak hastalıklarını otomatik olarak tespit eden, miktarını belirleyen ve ayrıca sınıflandırmasını yapan piksel düzeyinde semantik segmentasyon modelini tanıtmışlardır. Yaptıkları deneyler sonucunda, DeepLabV3Plus-ResNet50 modelinin

bitki yaprak hastalıklarının şiddet değerlendirmesi için daha verimli bir model olduğunu belirlemişlerdir. Uzatma testi veri setinde, 5 seviyeye ayrılmış patates hastalığı için %92,00 ve 4 seviyeye ayrılmış üzüm hastalığı için ise %94,67 sınıflandırma doğruluğu elde edilmiştir (Miaomiao Ji, 2020).

Saini ve arkadaşları, bitki yapraklarının sınıflandırılması için geleneksel yöntemler olan k-en yakın komşu, olasılıksal sinir ağı, destek vektör makinesi, genetik algoritma ve temel yöntemler yerine derin öğrenme yöntemlerinden CNN modelinin daha etkili olduğunu yaptıkları çalışmayla desteklemişlerdir. Bu çalışmada, iki farklı bitki türüne ait toplam 5000 yaprak görüntüsü içeren bir veri seti kullanmışlardır. Bu görüntülerden rastgele seçtikleri 4000 tanesini eğitim, 1000 tanesini ise test aşaması için kullanmışlardır. Önerilen CNN modeli ile yapılan bitki sınıflandırma işleminde, eğitim doğruluğu olarak %99,96 ve test doğruluğu olarak %99,90 gibi yüksek performans elde etmişlerdir. Sonuç olarak CNN yardımıyla öznelik çıkarımlarının hem otomatik olarak hem de klasik yöntemlere göre daha yüksek doğruluk oranı ile ve çok daha hızlı yapıldığını göstermişlerdir (Saini ve ark., 2020).

Türkoğlu, bitki tanıma ve bitki hastalıklarının erken teşhisi için 15 farklı bitki hastalık ve zararlı görüntüleri üzerinde çalışmalar yaparak mevcut yöntemleri geliştirmiş ve yeni yöntemler önermiştir. Kullanılan veri seti üzerinde özellik çıkarma ve sınıflandırma işlemleri için Çoklu-ESA (Ensemble of Convolutional Neural Networks) PlantDiseaseNet modelini kullanmış ve yüksek başarı elde etmiştir. Bu sistem, önceden eğitim ve test işlemleri yapılarak yeni görüntülerden öznelikler çıkarır, bu öznelikleri test eder ve sınıfını belirler. Türkoğlu, geliştirdiği bu sistemi "Bitki Hastalık Tespit Yazılımı" adıyla MATLAB GUI ortamında hazırlamış ve bir masaüstü uygulaması olarak tasarlamıştır (Türkoğlu, 2019).

Shekofa Ghoury yaptığı çalışmada üzüm ve asma yaprağı üzerinde oluşan hastalıkları tespit etme ve sınıflandırma için önceden eğitilmiş derin öğrenme modellerinden SSD MobileNet v1 ve Faster R-CNN Inception v2 modellerini kullanmıştır. Çalışma kapsamında 2 farklı veri seti üzerinde bu modelleri yeniden eğitmiştir. İlk veri seti için yapılan testlerde, Faster R-CNN Inception v2 modeli %95,57 doğruluk oranı ile başarılı bir sınıflandırma gösterirken, SSD MobileNet v1 modeli %59,29 doğruluk oranı ile daha düşük bir performans sergilemiştir. İkinci veri seti testlerinde ise, Faster R-CNN Inception v2 modeli %91,61 doğruluk oranı elde ederken, SSD MobileNet v1 modeli %18 doğruluk oranı ile başarısız sonuçlar vermiştir. Ghoury'nin çalışması sırasında elde edilen bulgular; Faster R-CNN Inception v2

modelinin daha yüksek başarı sağladığını ancak işlem süresinin daha uzun olduğunu, SSD MobileNet v1 modelinin ise işlem süresinin kısa olmasına rağmen sınıflandırmada başarısız olduğunu göstermiştir. Bu nedenle üzüm meyvesi ve asma yaprağı hastalık tespiti ve sınıflandırma işlemlerinde SSD MobileNet v1 modelinin kullanımının uygun olmayabileceği sonucuna varılmıştır (Ghoury, 2019).

Sharma ve arkadaşları yayımladıkları makalede, 18 farklı türe ait 1900 yaprak görüntüsünden oluşan bir veri seti kullanarak yaprak sınıflandırma işlemi gerçekleştirmişlerdir. Makineyi eğitmek için kullandıkları görüntü tanımlama süreci üç ana adımdan oluşmaktadır: görüntü ön işleme, öznitelik çıkarma ve sınıflandırma. İlk adımda, görüntü ön işleme sürecinde gri tonlamalı dönüşüm işlemi uygulanmıştır. İkinci adımda ise HOG (Yönlendirilmiş Gradyanların Histogramı) yöntemi kullanılarak her görüntüden 900 öznitelik çıkarılmıştır. Son adımda ise MATLAB programı üzerinde K-en yakın komşu (KNN) ve yapay sinir ağları (YSA) yöntemleriyle sınıflandırma işlemi yapılmıştır. Sharma ve arkadaşlarının çalışmasında, bu iki yöntem olan KNN ve YSA karşılaştırıldığında, yapay sinir ağları yönteminin %97 doğruluk oranıyla daha iyi performans gösterdiği sonucuna ulaşılmıştır (Sharma, 2019).

Tan ve arkadaşları, önceden eğitilmiş CNN modellerini kullanarak 43 farklı bitki türünün özellik çıkarımını yapmayı önermişlerdir. Çalışmalarında önceden eğitilmiş AlexNet, ince ayarlanmış AlexNet ve kendi önerdikleri yeni bir yöntem olan D-Leaf modeli olmak üzere üç farklı model kullanılmıştır. Bu modellerden elde edilen öznitelikler SVM, ANN, k-NN ve NB gibi derin öğrenme yöntemleri kullanılarak sınıflandırılmıştır. Klasik morfometrik ölçümlerde %66.55 doğruluk elde edilirken, önceden eğitilmiş AlexNet modelinden %93.26, ince ayarlı AlexNet modelinden %95.54 ve kendi önerdikleri D-Leaf modelinden %94.88 gibi yüksek doğruluk sonuçları elde edilmiştir. Bu sonuçlar, özellikle D-Leaf modelinin farklı bitki türlerini sınıflandırmada etkili bir yöntem olabileceğini göstermektedir. Araştırmacılar, D-Leaf modelinin diğer geleneksel ve uygulanan diğer CNN modellerine kıyasla daha yüksek bir doğruluk oranı sağladığını belirterek, bu modelin bitki türlerinin sınıflandırılmasında potansiyel bir yöntem olarak öne çıktığını vurgulamışlardır (Tan ve ark., 2018).

Doğan ve Türkoğlu'nun yaptıkları çalışmada, çeşitli bitkilerin yaprak görüntülerinden oluşan 32 sınıflı bir veri seti üzerinde derin öğrenme algoritmalarının performansını değerlendirmişlerdir. Bu veri seti, her bir sınıfta ortalama 60 adet olmak üzere toplamda yaklaşık 1900 adet görüntü içermektedir. Görüntü sayısını artırmak için yansıma ve tersleme gibi işlemler uygulanarak yaklaşık 7600 görüntü elde edilmiştir.

Elde edilen bu görüntüler üzerinde AlexNet, Vgg16, Vgg19, ResNet50, GoogleNet gibi derin öğrenme modelleri kullanılarak yaprak sınıflandırma işlemi gerçekleştirilmiştir. Yapılan değerlendirmeler sonucunda her bir derin öğrenme yönteminin %97,77 ile %99,72 aralığında yüksek başarı oranları elde ettiği gözlemlenmiştir. Araştırmacılar, bu yüksek başarı oranlarının CNN iterasyon sayısının düşük olmasına dayandığını düşünmüşlerdir ve iterasyon sayısının artırılmasıyla bu başarı oranlarının daha da yükseltilebileceğini öne sürmüşlerdir. Doğan ve Türkoğlu'nun çalışması, yaprak görüntülerinden bitki sınıflandırma işleminde derin öğrenme yöntemlerinin diğer yöntemlere kıyasla daha hızlı ve yüksek doğruluk oranına sahip olduğunu göstermiştir. Bu sonuçlar, derin öğrenme yöntemlerinin bitki sınıflandırma gibi karmaşık görevlerde etkili bir tercih olabileceğini vurgulamaktadır (Doğan ve Türkoğlu, 2018).

A. Beikmohammadi ve K. Faez'in çalışmasında, bitki yapraklarının sınıflandırılması için Flavia ve Leafsnap gibi veri setlerini kullanarak derin öğrenme yöntemlerini değerlendirdikleri belirtilmiştir. Bu çalışmada özellikle MobileNet mimarisini kullanarak yaprak sınıflandırması üzerinde yüksek doğruluk elde ettiklerini ifade etmişlerdir. Flavia veri setinde 32 sınıf, Leafsnap veri setinde ise 184 sınıf bulunmaktadır. Araştırmacılar, bu veri setlerindeki görüntü sayısının makine eğitimi ve test süreci için yeterli olmadığını düşünerek, görüntüleri çoğaltma yöntemiyle öznitelik çıkarma işlemlerini gerçekleştirmişlerdir. Bu sayede Flavia veri seti üzerinde %99,6 doğruluk payı, Leafsnap veri seti üzerinde ise %90,54 doğruluk payı elde etmişlerdir. Çalışmanın sonucunda, Flavia ve Leafsnap gibi sınırlı sınıf sayısına sahip veri setlerinde dahi önerilen yöntemin yüksek bir performans gösterdiği ve diğer geleneksel yöntemlere göre daha başarılı olduğu sonucuna varılmıştır. Bu durum, derin öğrenme yöntemlerinin, özellikle büyük ve karmaşık veri setlerinde olduğu kadar sınırlı veri setlerinde de etkili bir şekilde kullanılabileceğini göstermektedir (Beikmohammadi ve Faez, 2018).

Berna Arı'nın çalışmasında, 7 farklı kayısı yaprağı görüntüsünden oluşan bir veri seti kullanılarak yaprak sınıflandırma işlemi yapılmıştır. İki farklı derin öğrenme yöntemi olan Evrişimsel Sinir Ağları (ESA) ve Yerel Alıcı Ağları-Aşırı Öğrenme Makinesi (YAA-AÖM) yöntemleri karşılaştırılmıştır. ESA yöntemi kullanılarak elde edilen sonuçlar $91,34 \pm 0,77$ doğru sınıflandırma başarısı göstermiştir. Diğer yöntem olan YAA-AÖM yöntemi ise $97,26 \pm 0,95$ doğru sınıflandırma başarısı elde etmiştir. Her iki yöntem arasında yapılan karşılaştırmada, YAA-AÖM yönteminin daha yüksek doğruluk oranlarına sahip olduğu görülmüştür. Çalışmanın sonuçlarına göre, ESA

yöntemi YAA-AÖM yöntemine göre daha basit ve kullanışlı bulunmasına rağmen, görüntü tanıma işlemleri için YAA-AÖM yönteminin daha etkili olduğu sonucuna varılmıştır. Bu durum, derin öğrenme modellerinin farklı uygulamalarında farklı yöntemlerin performanslarının önemli olduğunu ve problem domainine göre en uygun yöntemin seçilmesi gerektiğini göstermektedir (Arı, 2017).

Lee ve arkadaşları, Malayakew adlı 44 farklı bitkiden elde edilen, benzer görünümlü yaprak görüntülerinden oluşan bir veri setini kullanarak derin öğrenme yöntemlerini geleneksel yöntemlerle karşılaştırmışlardır. Çalışmalarında CNN (Evrişimsel Sinir Ağı) yöntemini kullanarak elde edilen özniteliklerin, el yapımı özniteliklere göre daha iyi sonuçlar verdiğini gözlemlemişlerdir. Veri setindeki toplam 2288 yaprak görüntüsünü eğitim için, 528 yaprak görüntüsünü ise test için kullanarak %98,10 doğruluk oranı elde etmişlerdir. Bu sonuçlar, derin öğrenme yöntemlerinin yaprak sınıflandırma görevlerinde etkili olduğunu ve geleneksel yöntemlere göre daha yüksek doğruluk sağladığını desteklemektedir. Ancak, Lee ve arkadaşları çalışmalarında yakın akraba bitkilerin yaprak şekilleri üzerinden ayırt edilmesinin zorluğuna da dikkat çekmişlerdir. Bu durum, yaprak şeklinin tek başına bitki türlerini ayırt etmede yeterli olmayabileceğini göstermektedir. Sonuç olarak, Lee ve arkadaşları tarafından yapılan bu çalışma, derin öğrenme yöntemlerinin bitki yapraklarının sınıflandırılmasında başarılı bir şekilde kullanılabileceğini ve bu yöntemlerin el yapımı öznitelik tabanlı geleneksel yöntemlere göre avantajlı olduğunu ortaya koymuştur (Lee ve ark., 2017).

Barré ve arkadaşları, yaprak görüntülerinin ayırt edici özelliklerini kullanarak bitki türlerini sınıflandırmak amacıyla CNN tabanlı LeafNet sistemini geliştirmişlerdir. Yaptıkları çalışmada elde ettikleri sonuçları, LeafNet sisteminin diğer yöntemlerle karşılaştırarak değerlendirmişlerdir. Özellikle LeafSnap gibi özelleştirilmiş sistemlerle ve el yapımı özelliklerle kıyasladıklarında, LeafNet sisteminin daha yüksek başarı gösterdiğini bulmuşlardır. LeafNet sistemi, CNN (Evrişimsel Sinir Ağı) tabanlı bir yaprak sınıflandırma modelidir. Bu sistem, yaprak görüntülerinden otomatik olarak öznitelik çıkarır ve bu öznitelikleri kullanarak bitki türlerini sınıflandırır. Barré ve arkadaşları, LeafNet'in diğer yöntemlere göre daha iyi performans gösterdiğini özellikle vurgulamışlardır. Bu çalışma, derin öğrenme yöntemlerinin bitki türlerini sınıflandırmada ne kadar etkili olabileceğini gösteren önemli bir örnektir. Yapılan karşılaştırmalar, el yapımı özelliklerin ve özelleştirilmiş sistemlerin LeafNet gibi derin

öğrenme modellerine göre genellikle geride kaldığını göstermektedir (Barré ve ark., 2017).

Türkoğlu ve Hanbay, asma yapraklarından bitki sınıflandırması için Çoklu-Sınıf Destek Vektör Makineleri (ÇSDVM) yöntemini geliştirmişlerdir. Çalışmada kullanılan veri seti 18 farklı asma yaprağı türünden toplamda 270 yaprak görüntüsünden oluşmaktadır. Bu görüntüler üzerinde özellik çıkarma işlemi yapılmış ve 6 geometrik özellikten (en, boy, alan, ağırlık merkezi, çevre, çap) ve 9 farklı morfolojik özellikten öznitelikler elde edilmiştir. Görüntülerin %80'i eğitim, %20'si ise test için kullanılmıştır. Eğitim verileri üzerinde ÇSDVM ile sınıflandırma işlemi gerçekleştirilmiş ve yapılan çalışma sonucunda %90.7 başarı oranı elde edilmiştir. Geriye kalan %9.3'lük hata payının, görüntü sayısının az olması ve görüntülerin net olmamasından kaynaklandığı düşünülmüştür. Bu çalışma, bitki yapraklarının sınıflandırılmasında görüntü işlemenin kritik bir adım olduğunu vurgulamaktadır. ÇSDVM yönteminin, sınıflandırma performansını artırmak için öznitelik çıkarma aşamasında elde edilen geometrik ve morfolojik özellikleri etkin bir şekilde kullandığı ve bu sayede yüksek başarı oranları elde edildiği görülmüştür (Turkoglu ve Hanbay, 2015).


Aakif ve Khan, bitki yapraklarını otomatik olarak tanımlayan bir sistem önermişlerdir. Önerdikleri sistem, üç farklı aşamadan oluşmaktadır: ön işleme, öznitelik çıkarma ve sınıflandırma. Çalışmalarında 14 farklı meyve ağacından elde edilen toplam 817 yaprak görüntüsünün morfolojik özellikleri, Fourier tanımlayıcıları (FD) ve yeni geliştirdikleri şekil tanımlama özelliği olan SDF kullanılarak öznitelikler çıkarılmıştır. Bu öznitelikler daha sonra yapay sinir ağı (YSA) ile eğitilmiştir. Yapılan çalışmada elde edilen sonuçlar oldukça başarılı olmuştur. Yapay sinir ağı aracılığıyla elde edilen sistem %96'nın üzerinde doğruluk sağlamıştır. Ayrıca, önerilen yöntemin etkinliği Flavia ve ICL adlı iki farklı veri setinde de test edilmiş ve her iki veri setinde de %96 doğruluk oranı elde edilmiştir. Bu çalışma, bitki yapraklarının otomatik tanımlanması için morfolojik özelliklerin, Fourier tanımlayıcılarının ve özel olarak geliştirilen SDF gibi özelliklerin etkin bir şekilde kullanılabileceğini ve yapay sinir ağlarının bu özniteliklerle eğitilerek yüksek doğruluk sağlayabileceğini göstermektedir (Aakif ve Khan, 2015).

3. MATERYAL VE METOD

3.1. Materyal

Veri seti, Dargeçit ve çevresinde en çok yetiştirilen 8 çeşit asma bitkisinin her bir çeşidinden 500'er adet olmak üzere toplamda 4000 adet yaprak görüntüsünden oluşmaktadır. Görüntüleri oluşturmak için ilk olarak belirlenen türlere ait belirli sayıda yaprak toplandı. Toplanan orijinal asma yaprakların görüntülerini elde etmek için çekim esnasında yaprakların dış ortam ışığından etkilenmeyecek şekilde bir sistem tasarlanmıştır. Yüksek çözünürlüğe sahip bir telefon kamerasından alınan görüntülerde gölge oluşumunu önlemek ve gürültüyü azaltmak amacıyla geliştirilen sistem, sadece telefon ışığını alacak şekilde düzenlenmiştir. Sistemde kullanılan telefonun özellikleri; 6 çekirdek ve 3.22 GHz CPU, Ram 6 GB, 12 MP ve 1170x2532 çözünürlükte 4 adet arka kamera, piksel yoğunluğu 460 ppi ve kapasitesi 512 GB olan bir akıllı telefondur. Şekilde yapılan sistem görülmektedir.

Önerilen sistemde telefon, numunelerin yaklaşık 30 cm yukarısında kutunun tepesine yerleştirilmiştir. Kutunun içine asma yapraklarının kolayca işlenebilmesi için arka plan olarak beyaz bir fon kağıdı yerleştirilmiştir. Görüntü yakalama esnasında, dış ortam ışığından kaynaklanan gölge oluşumunu engellemek ve iç ışığın eşit yayılmasını sağlamak amacıyla kutu tamamen kapalı durumda tutulmuştur. Çekim için kullanılan yapraklar; üzüm hasadından hemen önce toplanmış, üzerindeki tozlar silinerek tek tek sistemin içine yerleştirilmiştir. Bu sistemle birlikte Benitat, Bilbizeki, Deywani, Hazirani, Kerkuş, Mazrone, Payizi ve Tayfi olmak üzere 8 çeşit asma yaprağının her bir çeşidinden 500'er adet görüntü elde edilmiştir.



Şekil 3.1. Asma yaprağı görüntüleri elde etmek için kullanılan sistemi

Oluşturulan sistem aracılığıyla elde edilmiş bu görüntüler, belirlenen derin öğrenme modelleri için orijinal asma yaprağı görüntüleri içerir. Çalışmada kullanılan her görsel 3024x4032 piksel olarak boyutlandırılmıştır. Veri setindeki 8 türe ait örnek asma yaprakları görüntüleri Çizelge 3.1. 'de verilmiştir.

Çizelge 3.1. Çalışmada kullanılan 8 türe ait asma yaprakları örnekleri

Sıra	Asma Yaprığı Çeşidi	Asma Yaprığı Görüntü	Görüntü Sayısı
0	Benitat		500
1	Bilbizeki		500
2	Deywani		500
3	Hazirani		500

4	Kerkuş		500
5	Mazrone		500
6	Payizi		500
7	Tayfi		500


3.2. Metod

3.2.1. Yapay zeka (AI)

Yapay zeka kavramı ilk olarak 1950’li yıllarda bilgisayarların “düşünebilme” yeteneğinin verilir verilemeyeceğinin sorulmasıyla ortaya çıkmıştır (Pirim, 2006). En basit tanımıyla kendisine verilen komutları yerine getirirken insan beynini taklit etmeyi amaçlayan ve her geçen gün edinmiş oldukları bilgilere göre kendilerini geliştirebilen makineler veya sistemlerdir.

Yapay zeka; öğrenme, problem çözme, algılama konuşma tanıma ve karar verme gibi işlevleri gerçekleştirmek için algoritmalar ve veriler kullanır. Yapay zeka teknolojisi, geniş bir uygulama yelpazesıyla sağlık, otomotiv, finans, e-ticaret gibi birçok alanda kullanılmaktadır (Dündar ve Ağaçayak, 2024).

Yapay zeka, makine öğrenmesi ve derin öğrenme kavramları arasında ilişki Şekil 3.2. ‘de gösterilmiştir.




Şekil 3.2. Yapay zeka, makine öğrenmesi ve derin öğrenme (Chollet, 2017)

Makine öğrenmesi yapay zeka alanının bir alt dalıdır ve bilgisayar sistemlerinin verilerden öğrenme ve tahmin etme teknikleri kullanır. Derin öğrenme ise makine öğrenmesinin bir alt kategorisidir ve yapay sinir ağları gibi karmaşık algoritmaları kullanarak büyük miktarda veriden öğrenmeyi amaçlar. Dolayısıyla derin öğrenme, makine öğrenmesinin bir türüdür ve her ikisi de genel olarak yapay zeka alanı içinde yer almaktadır.

3.2.2. Makine öğrenmesi

Makine öğrenmesi, bilgisayar ve sistemlerinin veri analizi yaparak örüntüleri tanımlamayı, ilişkileri keşfetmeyi ve tahminlerde bulunmayı öğrendiği bir yapay zeka dalıdır. Makine öğrenimi, büyük miktarda veriye dayalı olarak algoritmaların geliştirilmesini ve optimize edilmesini sağlar. Temel olarak makine öğrenimi, bilgisayarların programlanmadan önce belirli görevleri gerçekleştirmeleri için veri kullanarak kendi kendine öğrenmelerine olanak tanır.

Makine öğrenimi ve yapay zeka gibi alanlar, geleneksel programlama paradigmasından farklı bir yaklaşım gerektirir. Şekil 3.3.de gösterildiği gibi klasik programlama, belirli bir algoritmanın belirli bir girdiye dayalı olarak belirli bir çıktı üretmesini sağlamak üzerine kuruludur. Ancak makine öğrenimi, veri analizi ve örüntü tanıma gibi yöntemlerle, algoritmaların belirli bir işlevi öğrenmesine ve daha karmaşık, öngörülemez veri setlerinde çalışmasına izin verir. Bu, klasik programlama paradigmasından farklı bir düşünme ve problem çözme yaklaşımı gerektirir.




Şekil 3.3. Makine öğrenmesi: yeni bir programlama paradigması (Chollet, 2017)

Makine öğrenimi algoritmaları, veri tabanlı kararlar almak ve insan müdahalesini azaltmak için gün geçtikçe daha çok kullanılmaktadır (Ghoury, 2019).

3.2.3. Derin öğrenme

Derin öğrenme (Deep Learning), çok katmanlı yapay sinir ağlarının yapısını kullanarak karmaşık desenleri ve ilişkileri öğrenme yeteneğine dayalı bir makine öğrenimi alt dalıdır. Derin öğrenme, birçok karmaşık problemin çözümünde son derece etkilidir ve birçok alanda, özellikle de görüntü tanıma, konuşma tanıma, doğal dil işleme gibi alanlarda büyük başarı elde etmiştir (Ergün, 2023)

Derin öğrenme genellikle çok katmanlı sinir ağları (deep neural networks) kullanılarak gerçekleştirilir (Hicks, 2023). Bu ağlar, birçok katmanı olan bir yapıya sahiptir ve her katman, giriş verilerini daha karmaşık özellikler ve temsiller haline getirmek için birbirine bağlı bir dizi nöron içerir.



Şekil 3.4. Derin öğrenmenin üç katmanlı örnek modellenmesi (Ateş, 2021)

Derin öğrenmenin temel bileşenleri şunlardır:

1. Giriş Katmanı (Input Layer): Giriş verilerinin (örneğin, bir görüntü veya metin) sisteme verildiği katmandır.

2. Gizli Katmanlar (Hidden Layers): Bir veya daha fazla gizli katman, giriş verilerinden karmaşık özellikler ve temsilleri çıkarmak için kullanılır. Her bir gizli katman, bir önceki katmandan gelen çıktıları alır, bunları ağırlıklarla çarpar, bir aktivasyon fonksiyonuna sokar ve ardından bir sonraki katmana iletilir.

3. Çıktı Katmanı (Output Layer): Son katmandır ve genellikle belirli bir problem türüne göre şekillendirilir. Sınıflandırma problemlerinde sınıf etiketlerini tahmin etmek için bir aktivasyon fonksiyonu kullanılırken regresyon problemlerinde sayısal bir değer elde etmek için farklı bir aktivasyon fonksiyonu kullanılabilir.

Derin öğrenme, sinir ağlarının çok katmanlı ve genellikle büyük ölçekte eğitilmesini gerektirir. Yüksek hesaplama gücü ve büyük veri setleri genellikle derin öğrenme modellerinin eğitiminde önemli rol oynar.

Eğitim süreci, genellikle veri seti üzerinde iteratif olarak gerçekleştirilir. Veri seti model üzerinde birçok kez geçirilir, modelin çıktıları gerçek etiketlerle karşılaştırılır ve bir kayıp fonksiyonu kullanılarak modelin performansı değerlendirilir. Ardından, geriye yayılma algoritması (backpropagation algorithm) kullanılarak modelin parametreleri (ağırlıklar ve biaslar) güncellenir ve daha iyi sonuçlar elde etmek için model tekrar eğitilir.

Derin öğrenme, özellikle karmaşık problem ve büyük veri setleriyle uğraşırken son derece etkili olabilir, ancak eğitim süreci zaman alıcı ve hesaplama gücü gerektirebilir (Aalami, 2020).


3.2.4. Makine öğrenmesi ile derin öğrenme arasındaki fark

Makine öğrenmesi, bilgisayar sistemlerinin veriden öğrenme yeteneği kazandığı geniş bir kavramdır. Bu, algoritmaların belirli bir görevi belirli bir performans ölçütüne göre daha iyi hale getirmek için veriden öğrenme yeteneği kazandığı anlamına gelir. Makine öğrenimi, çeşitli algoritmaları içerir ve genellikle daha küçük veri setleriyle çalışabilir.

Derin öğrenme ise makine öğreniminin alt bir alanıdır. Derin öğrenme, genellikle çok katmanlı yapay sinir ağlarını kullanarak karmaşık veri yapılarını öğrenme

ve analiz etme yeteneğine odaklanır. Bu, özellikle büyük veri setleri ve karmaşık problemlerle uğraşırken etkili olan bir yaklaşımdır. Derin öğrenme, genellikle yüksek hesaplama gücü ve büyük miktarda veri gerektirir.

Kısacası, makine öğrenimi genel bir terimken derin öğrenme daha spesifik bir alt alanı temsil eder ve genellikle daha karmaşık problemleri çözmek için kullanılan bir tekniktir.



Şekil 3.5. Yaprak görüntülerinin sınıflandırma yapılırken derin öğrenme ve makine öğrenmesinin karşılaştırılması (Karunakaran, 2018)

Makine öğrenmesi ve derin öğrenmenin arasındaki farklardan biri de Şekil 3.5.'te de gösterildiği gibi özellik çıkarma işlemidir. Özellik çıkarma, makine öğreniminde sınıflandırma işleminden önce insan tarafından yapılırken derin öğrenmede ise otomatik olarak yapılmaktadır (Karunakaran, 2018).


3.2.5. Önceden eğitilmiş modeller ve bitki sınıflandırmasındaki rolü

Bitki sınıflandırması, bitkilerin türlerine veya türevlerine göre sınıflandırılması işlemidir. Bitki sınıflandırması; tarım, ormancılık, çevre bilimi ve botanik gibi birçok alanda önemli uygulamalara sahiptir. Bitki sınıflandırması için kullanılan geleneksel yöntemler, genellikle öznitelik çıkarma ve destek vektör makineleri (SVM) gibi teknikleri kullanır. Bu yöntemler, genellikle yüksek doğruluk oranları elde edebilir, ancak veri kümesinin boyutuna ve kalitesine bağlı olarak performansları değişebilir. Derin öğrenme, bitki sınıflandırması için oldukça etkili bir tekniktir. Derin öğrenme

modelleri, görüntülerin temel özelliklerini yakalayarak sınıflandırma işlemini gerçekleştirirler (Mohanty ve ark, 2016).

3.2.6. Evrişimli sinir ağı (CNN)

CNN son dönemlerde popüler bir yöntem haline gelmiş, sayısı fazla olan veriden özellikleri çıkarmak ve tanımlamak için kullanılan çok katmanlı derin öğrenme ağıdır. CNN genellikle iki boyutlu verilerde özellikle görüntü tanıma ve işleme alanında kullanılır. Girdi olarak sunulan veriler üzerinde farklı özelliklerin vurgulanması ve belirli desenlerin tespit edilmesi işlemleri yaparak özelliklerin öğrenilmesini sağlar. Ardından bu özellikleri sınıflandırma veya tanıma gibi görevlerde kullanılır. CNN yapıları içerisinde 4 ana katman barındırmaktadır.



Şekil 3.6. Evrişimli sinir ağları yapısı (Panwar, 2018)

Evrişim (Convolutional) Katmanı: Evrişim katmanı görüntüdeki özelliklerin çıkarılmasını sağlayan en önemli katmandır. Girdi verileri (genellikle görüntülerin) üzerinde özellik haritalarını çıkarmak için evrişim işlemleri uygulanır. Görüntülerin özellikleri çıkarılırken görüntüye bir dizi filtre veya çekirdek (kernel) uygulanır. Bu filtreler, girdi görüntü üzerinde gezerek özellikleri (kenarlar, köşeler, vb.) vurgular.

Aktivasyon (Activation) Katmanı: (Doğrusal Olmayan Katman): Aktivasyon katmanı, görüntülerdeki her piksel için doğrusal olmayan bir fonksiyonun uygulandığı katmandır. Son yıllarda en sık kullanılan sigmoid ve hiperbolik tanjant aktivasyon fonksiyonlarının yerine doğrultulmuş lineer birimler (ReLU) aktivasyon fonksiyonu kullanılmaya başlanmıştır.

Havuzlama (Pooling) Katmanı: CNN mimarisinin bir diğer önemli katmanlarından olan havuzlama katmanı, parametre sayısını ve ağıdaki hesaplama

miktarını azaltır, bunun iki faydası vardır. Birincisi bir sonraki katman için hesaplama miktarını azaltmak, ikincisi ise ağıın ezberlemesini engellemektir. Ortalama, maksimum, toplam ve ortalama havuzlama, havuzlama katmanı için yaygın olarak kullanılan yöntemlerdir.

Katmanı Düzleştir: Bu katmanın görevi, son katman için girdi verilerini hazırlamaktır. Yapay sinir ağıları, girdi verilerini tek boyutlu diziler olarak aldığından, diğer katmanlardan gelen matris tipi verilerin tek boyutlu dizilere dönüştürüldüğü katmandır. Görüntünün her bir pikseli tek bir çizgi ile temsil edildiğinden bu işleme yumuşatma denir.

Tamamen Bağlı (Fully Connected) Katmanlar: Bu katman, bir önceki katmanın tüm alanlarına bağımlıdır. Bu katmanın sayısı farklı mimarilerde değişebilir. Bu katmanlardaki düğümlerde öznitelikler korunur, ağırlık ve bias değerleri değiştirilerek öğrenme işlemi gerçekleştirilir. Tüm çeşitli öznitelik çıkarma aşamalarından girdi alarak gerçek işlemeyi gerçekleştirmekten sorumlu olan bu katman, tüm işleme katmanlarının çıktılarını analiz eder.

3.3. Önceden Eğitilmiş CNN Modelleri

Literatürde birçok CNN mimarisi vardır. Bu mimarilerden hangisinin kullanılacağına karar verilirken sınıflandırma başarıları, model boyutları ve hızları dikkate alınır. Bu çalışmada Xception, DenseNet, MobileNet, ResNet50, ResNet101 ve ResNet152 derin öğrenme modelleri tercih edilmiştir.

3.3.1. ResNet-50

ResNet50, 2015 yılında Microsoft Research tarafından geliştirilen, evrişimli sinir ağıları (CNN) mimarisinin adıdır. ImageNet Büyük Ölçekli Görsel Tanıma Yarışmasında (ILSVRC), önceki en iyi performansı %26.2'ye kıyasla %15.3'lük bir hata oranıyla kazanarak derin öğrenmede bir dönüm noktası olarak kabul edilmiştir. ResNet 50, 50 katmandan oluşan bir mimariye sahiptir. Bu katmanlar; ardışık olarak bağlanmış evrişimsel katmanlar, maksimum havuzlama katmanları ve küresel olarak bağlı katmanlardan oluşur. Evrişimsel katmanlar, görüntü verilerinin özelliklerini çıkarmak için kullanılırken, maksimum havuzlama katmanları, bu özelliklerin boyutunu azaltmak

için kullanılır ve küresel olarak bağlı katmanlar, bu özellikleri sınıflandırmak için kullanılmaktadır.

ResNet50'nin en önemli yeniliği, kısırlı geçişler olarak bilinen bir tekniktir. Kısırlı geçişler, bir katmanın çıktısını sonraki bir katmanın girdisine eklemek için kullanılır. Bu, daha derin ağların eğitim sürecini stabilize etmeye yardımcı olur ve daha yüksek performans elde edilmesini sağlar.

ResNet50, derin öğrenmenin bilgisayar görüşü, doğal dil işleme ve makine öğreniminin diğer alanlarında yaygın olarak kullanılmasına yol açtı. Bu alanlarda, ResNet50'nin performansı, önceki tekniklerden önemli ölçüde daha iyidir (He ve ark., 2015).

3.3.2. ResNet-101

ResNet101, 2015 yılında Microsoft Research tarafından geliştirilen, evrimsel sinir ağları (CNN) mimarisinin güçlü bir temsilcisidir. ResNet-50'nin atası sayılabilecek bu mimari, ImageNet Büyük Ölçekli Görsel Tanıma Yarışması'nda (ILSVRC) %5.7 ile ikincilik ödülünü kazanarak, derin öğrenme alanında dikkatleri üzerine çekmiştir. ResNet101, ismine de yansıdığı gibi, 101 katmandan oluşan bir mimariye sahiptir. Bu artırılmış derinlik, ResNet50'nin zaten etkileyici olan görsel tanıma yeteneklerini daha da ileriye taşımaktadır. Mimarinin yapısı, ResNet50'ye benzer şekilde ardışık evrimsel katmanlar, maksimum havuzlama katmanları ve küresel olarak bağlı katmanlardan oluşur. ResNet101'nin kilit özelliği olan kısırlı geçişler, bu mimaride de mevcuttur. Bu teknik, bir katmanın çıktısını doğrudan sonraki katmana ekleyerek, derin ağların eğitimini kolaylaştırır ve performanslarını artırır (Aksoy & Salman, 2022).

ResNet101, benzeri olan ResNet50 ile karşılaştırıldığında, daha yüksek doğruluk sunar ancak hesaplama karmaşıklığı ve bellek gereksinimi de daha yüksektir. Bu nedenle seçimin genellikle, hedeflenen görevin doğruluğu mu yoksa hız ve kaynak kısıtlamaları mı daha önemli olduğuna bağlı olarak yapılması gerekir. ResNet101, güçlü ve esnek bir mimari olarak, derin öğrenmenin çeşitli uygulamalarda yüksek doğruluk ve performans sağlamasına katkıda bulunmuştur. Kısırlı geçişler gibi yenilikçi teknikleri sayesinde, karmaşık görsel tanıma görevlerinde güvenilir bir seçim haline gelmiştir (Er, 2021).

3.3.3. ResNet-152

ResNet152, 2015 yılında Microsoft Research tarafından geliştirilen, evrişimli sinir ağları (CNN) mimarilerinin zirve noktalarından biridir. ImageNet Büyük Ölçekli Görsel Tanıma Yarışması'nda %5.07 hata oranıyla üçüncülük ödülünü kazanarak, derin öğrenme alanında bıraktığı iz ve sağladığı performans ile adeta bir mihenk taşı haline gelmiştir. ResNet152, isminde de yansıdığı gibi, 152 katmandan oluşan devasa bir mimariye sahiptir. Bu derinlik, önceki ResNet sürümlerinin (50 ve 101) görsel tanıma yeteneklerini daha da ileriye taşıyarak, karmaşık sahneleri ve ince nüansları bile yüksek doğrulukla ayırt etme becerisini kazandırır.

Mimarinin yapısı, yine ardışık evrişimsel katmanlar, maksimum havuzlama katmanları ve küresel olarak bağlı katmanlardan oluşur. ResNet152'nin olmazsa olmazı olan kısırlı geçişler tekniği, bu dev mimaride de varlığını sürdürür. Bir katmanın çıktısını doğrudan sonraki katmana ekleyerek, derin ağların eğitimini kolaylaştırır ve performanslarını artırır. Bu teknik, ResNet152'nin olağanüstü derinliğini eğitebilir hale getirerek, onun üstün yeteneklerinin temelini oluşturmaktadır (İnik ve Ülker, 2017).

ResNet152, her ne kadar üstün doğruluk sunsa da hesaplama maliyeti ve bellek gereksinimi diğer ResNet sürümlerinden (50 ve 101) daha yüksektir. Bu nedenle, kullanımı genellikle yüksek performansın kritik olduğu ve gerekli kaynakların mevcut olduğu durumlarda tercih edilir. ResNet152, derin öğrenme teknolojisinin gelişiminde önemli bir yer tutar. Görsel tanıma alanında devrim yaratan yüksek doğruluğu ve olağanüstü derinliği sayesinde, çeşitli karmaşık uygulamalarda güvenilir bir seçim haline gelmiştir. Kısırlı geçişler gibi yenilikçi teknikleri sayesinde, derin öğrenmenin sınırlarını zorlamaya ve yeni ufuklar açmaya devam etmektedir.

3.3.4. MobileNet

MobileNet, Google AI tarafından 2017 yılında geliştirilen, hafif ve hızlı bir evrişimli sinir ağı (CNN) mimarisidir. Klasik CNN'lere kıyasla MobileNet olağanüstü bir özelliğe sahiptir: daha az parametre kullanarak benzer veya hatta daha iyi performans sergilemek. Bu özelliği nedeniyle, mobil cihazlar, gömülü sistemler ve IoT gibi kısıtlı kaynaklara sahip platformlarda kullanılması idealdir (Meşeci, 2022).

MobileNet, mobil platformlarda gerçek zamanlı uygulamalar için idealdir. Örneğin; akıllı telefonlarda nesne algılama, artırılmış gerçeklik filtreleri, mobil

bankacılıkta kimlik doğrulama ve otonom araçlarda çevre algılaması gibi uygulamalarda kullanılabilir. MobileNet, derin öğrenme teknolojisinde önemli bir gelişmedir. Daha az parametreyle yüksek performans sunan mimarisi nedeniyle, mobil cihazlar, gömülü sistemler ve IoT gibi kısıtlı kaynaklara sahip platformlarda devrim yaratma potansiyeline sahiptir (Gökalp ve Aydın, 2021).

3.3.5. Xception

Xception modeli, François Chollet tarafından geliştirilen ve ilk kez 2017 yılında tanıtılan bir derin öğrenme modelidir. Bu model, Inception mimarisinin daha ileri bir versiyonu olarak ortaya çıkmıştır. InceptionV3 mimarisine kıyasla daha verimli parametre kullanımıyla dikkat çekmektedir ve benzer parametre sayısına sahip olmasına rağmen performans açısından üstünlük göstermektedir.

Xception modeli, derin ayrılabilir evrişim katmanlarına (depthwise separable convolution) dayanmaktadır. Bu katmanlar, her kanal için ayrı ayrı uzaysal evrişimler gerçekleştirir ve ardından bu kanalları yeni bir kanal uzayına projeler. Bu yöntem, hesaplama maliyetlerini düşürürken modelin performansını artırır (Chollet, 2017).

Xception mimarisi 36 evrişim katmanından oluşur ve bu katmanlar lineer olarak sıralanmıştır. Bu katmanların çoğu, linear residual bağlantılarla birbirine bağlanmıştır. Model, görüntü sınıflandırma gibi görevlerde kullanılmak üzere tasarlanmıştır (Chollet, 2017).


Bu model, özellikle derin öğrenme topluluğunda yüksek doğruluk ve düşük hesaplama maliyetleri ile dikkat çeker ve genellikle görüntü tanıma ve sınıflandırma görevlerinde kullanılır.

3.3.6. DenseNet

DenseNet, 2017 yılında Gao Huang, Zhuang Liu, Laurens van der Maaten ve Kilian Q. Weinberger tarafından geliştirilen bir derin öğrenme modelidir. DenseNet, yoğun bağlantılar sayesinde önceki katmanlardan gelen tüm özellik haritalarını her katmana iletir. Bu yoğun bağlantılar, her katmanın doğrudan önceki katmanların çıktıklarına bağlanmasını sağlar. Bu sayede, daha az parametre kullanarak daha derin ağlar oluşturabilir ve ağırlık gradyanlarının daha iyi akışını sağlar. DenseNet'in bu yoğun

bağlantı yapısı, ağıın öğrenme kapasitesini artırır ve genellikle daha iyi eğitim verimliliği ve daha iyi sonuçlar elde etmek için kullanılır (G. Huang ve ark., 2017).

DenseNet'in temel özelliği, önceki katmanlardan gelen bilgiyi daha sonraki katmanlara doğrudan ileten yoğun bağlantılar kullanmasıdır. Bu yoğun bağlantılar, ağıın öğrenme kapasitesini artırırken, aynı zamanda parametre sayısını azaltır ve ağıın daha verimli bir şekilde eğitilmesini sağlar (Kumar, 2020).



Şekil 3.7. DenseNet mimarisi (Li ve ark., 2020).

DenseNet'in avantajları, daha az parametre kullanarak öğrenebilme, gradientin daha etkili bir şekilde akabilmesi, daha düşük eğitim hataları ve daha iyi genelleme yetenekleri olarak öne çıkıyor. Bu nedenle, DenseNet, özellikle sınırlı veri setlerinde ve bilgisayar görüşü görevlerinde başarılı bir şekilde kullanılmıştır.

3.4. Karışıklık Matrisi

Karışıklık matrisi (Confusion Matrix), makine öğrenimi ve istatistiksel sınıflandırma problemlerinde, bir sınıflandırıcı modelin performansını değerlendirmek için kullanılan bir matristir. Bu matris, modelin doğru ve yanlış sınıflandırdığı örneklerin sayısını gösterir. Karışıklık matrisi, gerçek sınıfla modelin tahmin ettiği sınıf arasındaki ilişkiyi tablo olarak görselleştirir ve sınıflandırma algoritmalarının doğruluğunu değerlendirmeye yardımcı olur.

Karmaşıklık matrisi, eğitim ve test verilerinin tahmini performansını değerlendirmek için kullanılır. Matristeki değerler, sınıflandırma problemlerinin performans ölçümü için yaygın olarak kullanılmaktadır (Koklu ve Tutuncu, 2017).

Karışıklık matrisinin kolay anlaşılır bir yapısı vardır. Karışıklık matrisi genellikle Çizelge 3.2. 'teki gibi bir yapıya sahiptir.

Çizelge 3.2. İki sınıflı karışıklık matrisi

		GERÇEK	
		Pozitif	Negatif
TAHMİN	Pozitif	TP	FP
	Negatif	FN	TN

Karışıklık matrisi, sınıflandırma problemlerinde genellikle 2x2 veya daha büyük boyutlarda olabilir, ancak en temel haliyle bir sınıflandırma problemi için 2x2 boyutunda olur. 2x2 karışıklık matrisinde dört ana terim bulunur.

1. **True Positive (TP):** Gerçek pozitiflerin sayısı. Yani modelin pozitif bir sınıfı doğru bir şekilde tahmin ettiği durum sayısıdır.
2. **False Positive (FP):** Yanlış pozitiflerin sayısı. Modelin yanlışlıkla pozitif olarak sınıflandırdığı ancak gerçekte negatif olan örneklerin sayısıdır.
3. **True Negative (TN):** Gerçek negatiflerin sayısı. Yani Modelin negatif bir sınıfı doğru bir şekilde tahmin ettiği durum sayısıdır.
4. **False Negative (FN):** Yanlış negatiflerin sayısı. Modelin yanlışlıkla negatif olarak sınıflandırdığı ancak gerçekte pozitif olan örneklerin sayısıdır.

Karışıklık matrisi, modelin sınıflar arasındaki performansını daha ayrıntılı bir şekilde analiz etmeye olanak tanır. Bunlar arasında doğruluk (accuracy), hassasiyet (precision), duyarlılık (recall), F1 puanı (F1 score) gibi değerler bulunur. Bu ölçütler, TP, FP, TN ve FN değerlerinin kombinasyonlarına dayanır ve modelin sınıflandırma performansını farklı açılardan değerlendirir.

Bu çalışmada çoklu sınıf içeren karışıklık matrisi kullanılmıştır.

3.5. Performans Metrikleri

Performans metrikleri, bir makine öğrenimi modelinin veya bir sınıflandırıcı algoritmasının performansını ölçmek için kullanılan ölçümlerdir. Bu metrikler, modelin

doğruluğunu, kesinliğini, duyarlılığını, özel olumlu oranını ve diğer performans özelliklerini değerlendirmeye yardımcı olur.

Yaygın olarak kullanılan bazı performans metrikleri:

1. Doğruluk (Accuracy):

Doğruluk, toplam doğru tahminlerin toplam örnek sayısına oranı olarak hesaplanır. Genellikle dengeli sınıflandırma problemlerinde iyi bir metrik olarak kabul edilir. Ancak, dengesiz sınıflara sahip veri setlerinde yanıltıcı olabilir.

2. Hassasiyet (Precision):

Modelin pozitif olarak tahmin edilen örneklerin gerçekten pozitif olma oranını ifade eder. Yanlış pozitiflerin etkilerini değerlendirmek için kullanılır.

3. Duyarlılık (Recall veya Sensitivity): Gerçek pozitifleri doğru bir şekilde tanınma yüzdesidir. Duyarlılık, doğru pozitiflerin sayısı ile gerçek pozitiflerin sayısının toplamına bölünerek hesaplanır.

4. Özgünlük (Specificity): Gerçek negatiflerin doğru bir şekilde tahmin edilme oranını ifade eder.

5. F1 Puanı (F1 Score): Duyarlılık ve hassasiyet birleştiren bir metriktir. F1 puanı, hassasiyet ve duyarlılık arasında bir denge kurar. Özellikle dengesiz sınıflandırma problemlerinde kullanışlıdır.

Bu metrikler, modelin performansını farklı açılardan değerlendirmeye yardımcı olur. Hangi metriklerin kullanılacağı, spesifik bir sınıflandırma problemine ve veri setinin özelliğine göre değişebilir. Örneğin, dengesiz sınıflara sahip bir veri setinde doğruluk yerine hassasiyet, duyarlılık ve F1 puanına odaklanmak daha bilgilendirici olabilir.

Çizelge 3.3. Performans metrikleri formülleri

Performans Metrikleri	formüller
Kesinlik	$\frac{TP+TN}{TP+TN+FP+FN}$
F-1 Puanı	$\frac{2TP}{2TP+FP+FN}$
Duyarlılık	$\frac{TP}{TP+FN}$
Hassas	$\frac{TP}{TP+FP}$
özgüllük	$\frac{TN}{TN+FP}$

Performans metrikleri, sınıflandırıcı performanslarını değerlendirmek için kullanılır. Bu çalışma kapsamında doğru-pozitif (TP), doğru-negatif (TN), yanlış-pozitif (FP), yanlış-negatif (FN) değerleri ile doğruluk, F-1 puanı, duyarlılık temel performans ölçütleri, kesinlik ve özgüllük hesaplandı.

4. BULGULAR

Bu bölümde asma yaprakları görsellerinin sınıflandırılmasına yönelik farklı derin öğrenme modelleri ile sınıflandırma analizleri yapılmıştır. Modeller, transfer öğrenme yöntemi kullanılarak önceden eğitilmiş ResNet50, ResNet101, ResNet152, MobileNet, Xception ve DenseNet169 modelleri ile asma yaprakları görüntüleri aracılığıyla eğitilmiştir. Transfer derin öğrenme, bir görevde elde edilen bilgilerin başka bir göreve aktarılmasını hedefleyen bir öğrenme yöntemidir. Bu yaklaşımda model, bir görevdeki deneyimlerini başka bir göreve uygulayarak genelleme yeteneğini geliştirmeye çalışır.

Çalışmada kullanılan derin öğrenme modelleri, aynı hiperparametre değerleriyle uygulanmıştır. Bu değerler, denemeler sonucunda belirlenmiştir. Denemeler sonucunda, en uygun optimizier yöntemi olarak 'adam' belirlenmiştir. Optimizier, makine öğrenimi modellerinin ağırlıklarını güncelleyerek modelin eğitim verisine daha iyi uyum sağlamasını amaçlayan bir optimizasyon işlemidir. Bu algoritmalar, Loss fonksiyonunun belirlediği hatayı minimize etmeyi hedefler.

Batch_size 32 olarak belirlenmiştir. Batch size, makine öğrenimi ve derin öğrenme modellerinin eğitim sürecinde kullanılan örnek veri gruplarının sayısını ifade eder. Model, eğitim verilerini toplu halde (Batch) işler ve her Batch'teki veriler kullanılarak modelin ağırlıkları güncellenir. Batch boyutunun değiştirilmesi, eğitim sürecinde hız, bellek kullanımı, stabilite, genelleme kabiliyeti ve hesaplama verimliliği üzerinde etkili olabilir.

Loss fonksiyonu olarak "CategoricalCrossentropy" tercih edilmiştir. Kayıp fonksiyonu, makine öğrenimi modellerinin tahminleri ile gerçek değerler arasındaki farkı ölçen bir matematiksel fonksiyondur. Bu fonksiyon, hatayı minimize ederek modelin doğruluğunu artırmayı hedefler. Kayıp fonksiyonları, modelin eğitim sürecinde yönlendirme sağlayarak, modelin parametrelerinin nasıl güncellenmesi gerektiğini belirler. Öğrenme oranı 0.001 olarak belirlenmiştir. Modellerin performansını incelemek amacıyla 'accuracy', 'loss', 'precision', 'recall', 'AUC' ve 'f1_score' metriklerinden yararlanılmıştır. Modellerin hiperparametreleri Çizelge 4.1'de gösterilmektedir."

Çizelge 4.1. Derin öğrenme modellerinin hiperparametre değerleri

Hiperparametre	Değer
batch_size	32
epoch	100
Metrikler	'accuracy', 'loss', 'precision', 'recall', 'AUC', 'f1_score'
Optimizer	Adam
learning_rate	0.001
losses fonksiyonu	CategoricalCrossentropy

Modeller çalışmada kullanılan sekiz sınıflı asma yaprakları veri setine uygun olarak ayarlandı. Modellerin eğitim ve test oranları %70-%30 olarak ayarlandı. Sınıflandırma için kullanılan veri seti ile ilgili daha detaylı bilgiler bölüm 3'te yer almaktadır. Deneyler Intel i7 -1068NG7 2,3 GHz işlemciye, 16 GB RAM'e ve Intel İris Plus ekran kartına sahip bir bilgisayar üzerinden gerçekleştirilmiştir. Veri setinde yer alan görüntüler 227x227 piksele dönüştürüldü. Modellerin eğitimi, 100 epoch büyüklüğü belirlenerek gerçekleştirildi. Çizelge 4.2.'de test veri seti ile elde edilen sonuçlar verilmiştir.

Çizelge 4.2. Test veri seti ile derin öğrenme modellerinin performans değerlendirmeleri


Model Adı	Başarı	Kesinlik (Precision)	Duyarlılık (Recall)	F1-Ölçütü	Support
ResNet 50	0,79	0,82	0,79	0,79	1200
Resnet 101	0,88	0,88	0,88	0,87	1200
Resnet 152	0,80	0,83	0,80	0,81	1200
MobileNet	0,79	0,83	0,79	0,79	1200
Xception	0,86	0,87	0,86	0,86	800
DenseNet 169	0,73	0,82	0,73	0,73	1200

Altı derin öğrenme yöntemi arasından ResNet101 modeli, gerçekleştirilen sınıflandırma işleminde en yüksek doğruluk oranını vermiştir. Genel olarak her derin öğrenme mimarisi başarı olarak birbirine yakın bir görüntü çizmiştir. Bununla birlikte sınıflandırma işlemini diğer modellere göre yüksek farkla kısa sürede bitiren derin öğrenme modeli ise MobileNet modeli olmuştur. 8 türden oluşan asma yaprağı veri seti kullanılarak derin öğrenme modelleriyle elde edilen doğruluk oranları ve harcanan süreler aşağıdaki tabloda yer almaktadır. "İterasyon sayısının artmasıyla birlikte doğruluk oranlarında kısmi değişiklikler gözlemlenmiştir. Sınıflandırma işleminde

kullanılan derin öğrenme modelleri ve başarı oranları Çizelge 4.3. ve Şekil 4.1. 'de gösterilmektedir."

Çizelge 4.3. Derin öğrenme modelleri ile sınıflandırma başarı oranları ve harcanan süreler


Model Adı	Başarı Oranları	Süre
ResNet 50	0,79	8 saat 35 dakika
ResNet 101	0,88	17 saat
ResNet 152	0,80	20 saat 47 dakika
MobileNet	0,79	2 saat 20 dakika
Xception	0,86	10 saat
DenseNet 169	0,73	7 saat 30 dakika



Şekil 4.1. Derin öğrenme modelleri ile sınıflandırma başarı oranları


Çizelge 4.3.'de gösterilen sonuçlar değerlendirildiğinde yaprak çeşitlerini sınıflandırma işleminde kullanılan derin öğrenme modelleri arasında ResNet101 0,88'lik başarı oranıyla en yüksek başarıyı göstermiştir. Xception modelinin %86 başarı oranı ile ikinci en iyi performansı sunduğu ve birçok durumda yüksek doğruluk sağladığı anlaşılmaktadır. Bu modeller arasında en düşük oran 0,73 ile DenseNet169 modeline aittir. Modellerin eğitim ve test işlemleri sırasında harcamış oldukları süreler karşılaştırıldığında ise MobileNet en hızlı sonuç verirken ResNet152 sonucu en uzun süre sonuçlanan model olduğu görülmektedir.

Modellerin başarı grafikleri iterasyon değerlerine göre Şekil 4.2. 'de sunulmuştur.



Şekil 4.2. Derin öğrenme modellerine ait başarı oranları


Modellerin Loss (hata) değerlerine ilişkin grafikler Şekil 4.3.'te gösterilmektedir.



Şekil 4.3. Derin öğrenme modellerine ait Loss değerleri

Modellerin sınıflandırma sonuçlarının karışıklık matrislerinin karşılaştırmaları Şekil 4.4. 'de gösterilmektedir. Karışıklık matrisi modellerin sınıflandırma performansını daha detaylı analiz etmeyi sağlar. Özellikle çoklu sınıflandırmalarda kullanılan karışıklık matrisi modelin tahminleriyle gerçek değerleri karşılaştırarak her bir sınıf için doğru ve yanlış tahminlerin sayısını hesaplar. Her bir hücre bir sınıfın diğerine karşı tahmin sayısını gösterir. Aşağıda Şekil 4.4.'de kullanılan her bir modele ait karışıklık matrislerinde satır ve sütunlarda asma yaprakları sınıflarına ait isimler yer almaktadır. Sol-üst köşeden sağ-alt köşeye doğru giden çapraz hücreler diğer hücrelere

göre daha koyu olup doğru tahmin sayısını vermektedir. Daha açık renkte olan hücreler ise yanlış tahmin sayılarını ve hangi asma yaprağı sınıfı ile karıştırıldığını gösteren sonucu vermektedir.



Şekil 8. Modellerin karışıklık matrisi

5. TARTIŞMA

Asma bitkisi, Türkiye'de çeşitli alanlarda geniş bir kullanım yelpazesine sahiptir. En yaygın kullanımı, üzüm meyvesi olup hem taze hem de kuru üzüm olarak tüketilir. Üzüm ayrıca şarap, pekmez ve sirke yapımında kullanılır. Üzüm dışında asma yaprağı Türk mutfağı için değerli bir malzemedir. Salamura, konserve ve dondurulmuş olarak saklanan yapraklar, özellikle dolma yapımında kullanılır. Ayrıca üzüm çekirdeği yağı gibi ürünler de sağlık ve kozmetik alanlarında değerlendirilmektedir. Asma bitkisi bu çok yönlü kullanımlarıyla Türkiye'de hem ekonomik hem de kültürel açıdan büyük önem taşır.

Asma yaprakları türlerinin sınıflandırılması, farklı kullanım amaçlarına uygun olan yaprakları belirlemeyi ve daha yüksek kalitede ürünler elde etmeyi sağlar. Ancak yaprak türlerinin belirlenmesi uzman olmayanlar için oldukça zordur. Yaprak sınıflandırmak için derin öğrenme kullanmak, daha doğru ve güvenilir sonuçlar elde etmemize yardımcı olur. Geleneksel yöntemler insan denetimine dayanır ve subjektif değerlendirmeler olduğu için bazen hatalara yol açabilir. Bunun yerine, derin öğrenme algoritmaları, büyük miktarda veriyi analiz ederek desenleri otomatik olarak tanımlayabilir ve öğrenebilir. Bu, asma yapraklarının farklı özelliklerini (örneğin boyut, şekil, renk) belirleyerek doğru sınıflandırma yapmayı sağlar. Derin öğrenme yöntemleri ayrıca sürekli olarak öğrenme yeteneklerine sahip olduklarından, yeni veri ve değişen koşullara adapte olabilirler.

Derin öğrenme yöntemleri, asma yapraklarının sınıflandırılmasında yüksek doğruluk ve hız sağlamaktadır. Özellikle CNN tabanlı modeller, görüntü işleme görevlerinde üstün performans göstermektedir. Son yıllarda CNN modelleri kullanılarak özellikle hastalıklı yaprakların tespitinde %95'i geçen yüksek oranda doğruluk elde ediliyor. Bu, geleneksel yöntemlere göre büyük bir gelişme olarak kabul edilmektedir. Ancak, modelin başarısı büyük ölçüde veri setinin kalitesine ve çeşitliliğine bağlıdır.

Bu çalışmada, asma yapraklarının sınıflandırılması için popüler CNN modellerinden olan ResNet50, ResNet101, ResNet152, MobileNet, Xception ve DenseNet169 modelleri kullanılarak sınıflandırılmıştır. Daha sonra bu modeller değerlendirilerek her bir modelin performansı karşılaştırılmıştır.

Çalışmada kullanılacak veri setini oluşturmak için belirlenen 8 farklı asma türünün yaprakları ayrı ayrı toplanmıştır. Asma yaprakları görsellerinin daha kolay ayırt

edilebilmesi için arka plan rengi olarak beyaz seçilmiştir. Veri seti oluşturulurken her 8 çeşit için 500'er görüntü alınarak toplamda 4000 görüntü elde edilmiştir.

Elde edilen sonuçlar, derin öğrenme modellerinin asma yapraklarını sınıflandırma konusundaki etkinliğini göstermektedir. Sınıflandırmada uygulanan ResNet50, ResNet101, ResNet152, MobileNet, Xception ve DenseNet169 modellerinin test doğruluk oranları sırasıyla %79, %88, %80, %79, %86 ve %73'tür. Eldeki bu verilere göre ResNet101 modeli en yüksek başarı oranına sahip modeldir. Xception modeli de başarı olarak ResNet101 modeline yakın bir başarı oranı göstermiştir. Çalışma süreleri karşılaştırıldığında ise MobileNet modeli hafif yapısı nedeniyle 2 saat 20 dakika ile diğer modellere göre en kısa süreyi harcayan model olmuştur. DenseNet169 7 saat 30 dakikalık eğitim süresi makul olsa da, doğruluk oranı düşük olduğu için diğer modeller kadar etkili görülmemektedir.

ResNet 101, yüksek doğruluk oranı ile en başarılı modeldir; ancak 17 saatlik olan eğitim süresi uzundur. Xception, 10 saatlik işlem süresi ve Resnet101 modeline yakın performans sunması ile tercih edilebileceği anlaşılmıştır. MobileNet ise hızlı sonuçlar üretmesi ile öne çıkmış; ancak doğruluk oranı ResNet 101 kadar yüksek değildir. ResNet 50 ve ResNet 152 ise orta seviyede performans ve eğitim süresi ile dengeli seçenekler sunmuştur. Gerçek zamanlı uygulamalar için MobileNet tercih edilebilirken yüksek doğruluk gerektiren durumlarda ResNet 101 ve Xception modelleri daha uygun bir seçenek olabileceği görülmüştür.

5.1. Gelecek Çalışmalar

Asma yapraklarının derin öğrenme yöntemleri ile sınıflandırılması, tarım sektöründe büyük bir potansiyele sahiptir. Gelecekteki çalışmalarda, literatürdeki çeşitli sinir ağı modelleri kullanılarak sınıflandırma başarı oranını artırma hedeflenecektir. Daha büyük ve çeşitli veri setleriyle çalışmaların genişletilmesi ve diğer bitki türleri üzerine araştırmaların yapılması önerilmektedir. Ayrıca oluşturulan özgün asma yaprakları, veri setindeki görüntülere farklı görüntü işleme teknikleri uygulanarak modellerin performansı iyileştirilmeye çalışılacaktır. Buna ek olarak, en yüksek doğruluk oranına sahip modeli temel alarak geliştirilecek bir mobil uygulama, tüketiciler ve üreticiler için pratik bir çözüm sunabilir. Bu uygulama, kullanıcılara kolaylık sağlayarak asma yaprağı türlerini tanımada hızlı ve doğru bir şekilde teşhis etmelerine yardımcı olacaktır.

KAYNAKLAR

- Aakif, A., & Khan, M. F. (2015). Automatic classification of plants based on their leaves. *Biosystems Engineering*, 139, 66-75.
- Aalami, N. (2020). Derin öğrenme yöntemlerini kullanarak görüntülerin analizi. *Eskişehir Türk Dünyası Uygulama ve Araştırma Merkezi Bilişim Dergisi*, 1(1), 17-20.
- Akın, A., Çotur, E., & Değirmenci, A. Konya ve Kayseri'de Yetiştirilen Bazı Üzüm Çeşitlerinin Göz Verimliliklerinin Belirlenmesi. *Yuzuncu Yıl University Journal of Agricultural Sciences*, 21(3), 220-224.
- Aksoy, B., & Salman, O. K. M. (2022). Prediction of Covid-19 disease with Resnet-101 deep learning architecture using Computerized Tomography images. *Türk Doğa ve Fen Dergisi*, 11(2), 36-42.
- Altaş, Z., Özgüven, M. M., & Dilmaç, M. (2021). Görüntü işleme teknikleri ile bağ yaprak uyuzu hasarının belirlenmesi. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 10(3), 77-87.
- Anonim 2018-2023. Ülkelere göre dünya üzüm üretimi. <https://www.atlasbig.com/tr/ulkelerin-uzum-uretimi>
- Anonim, 2008a. <http://www.abengoabioenergy.com/bioethanol>.
- Arı, B. (2017). Kayısı Yapraklarının Evrişimsel Sinir Ağları Kullanılarak Sınıflandırılması. *Fen Bilimleri Enstitüsü, Elektrik-Elektronik Teknolojileri Mühendisliği, Fırat Üniversitesi*.
- Ateş, Emre. (2021). Derin Öğrenme (Deep Learning). https://www.researchgate.net/publication/354324986_Derin_Ogrenme_Deep_Learning
- Barré, P., Stöver, B. C., Müller, K. F., & Steinhage, V. (2017). LeafNet: A computer vision system for automatic plant species identification. *Ecological Informatics*, 40, 50-56.
- Beikmohammadi, A., & Faez, K. (2018, December). Leaf classification for plant recognition with deep transfer learning. In *2018 4th Iranian Conference on Signal Processing and Intelligent Systems (ICSPIS)* (pp. 21-26). IEEE.
- Chollet, F. (2017). Xception: Deep learning with depthwise separable convolutions. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 1251-1258).

- Doğan, F., & Türkoğlu, İ. (2018). Derin öğrenme algoritmalarının yaprak sınıflandırma başarımlarının karşılaştırılması. *Sakarya University Journal of Computer and Information Sciences*, 1(1), 10-21.
- Duman, B. Derin öğrenme yöntemleri ile bitki sınıflandırma.
- Dündar, K., & Ağaayak, A. (2024). Yapay zeka ve makine öğrenmesi ile insan ilişkileri analizi. *Mühendislikte Yenilikçi Yaklaşımlar-2*, 123.
- ER, M. B. (2021). Önceden Eğitilmiş Derin Ağlar İle Göğüs Röntgeni Görüntüleri Kullanarak Pnömoni Sınıflandırılması. *Konya Journal of Engineering Sciences*, 9(1), 193-204.
- Ergün, G. O. (2023), Machina Sapiens. *Ankara Üniversitesi Hukuk Fakültesi Dergisi*, 72(2), 717-758.
- Ghoury S., 2019, Konvolüsyonel sinir ağlarını kullanarak üzüm ve üzüm yapraklarının hastalıklarının tespit edilmesi, Yüksek lisans tezi, Selçuk Üniversitesi Fen Bilimleri Enstitüsü, Konya, 30,31.
- Gökarp, S., & Aydın, İ. (2021). Farklı Derin Sinir Ağı Modellerinin Duygu Tanımadaki Performanslarının Karşılaştırılması. *Muş Alparslan Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 2(1), 35-43.
- Göktaş, A. (2008), “Üzüm Yetiştiriciliği”, Eğirdir Bahçe Kùltürleri Araştırma Enstitüsü, Yayın No: 18, Isparta. <https://ekizfidancilik.com/tr/uzum-yetistirciligi> (Erişim tarihi: 2023).
- He, K., Zhang, X., Ren, S., & Sun, J. (2015). Deep residual learning for image recognition. *CoRR abs/1512.03385* (2015).
- Hicks Lucy. (2023), Is ChatGPT a Friend or Foe of Medical Publishing? - Medscape - Jun 08, 2023.
- Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2017). Densely connected convolutional networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 4700-4708).
- İmak, A., Doğan, G., Şengür, A., & Ergen, B. (2023). Asma Yaprığı 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.
- İnik, Ö., & Ülker, E. (2017). Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3), 85-104.
- Ji, M., Zhang, L., & Wu, Q. (2020). Automatic grape leaf diseases identification via UnitedModel based on multiple convolutional neural networks. *Information Processing in Agriculture*, 7(3), 418-426.

- Kamilaris, A., & Prenafeta-Boldú, F. X. (2018). Deep learning in agriculture: A survey. *Computers and electronics in agriculture*, 147, 70-90.
- Kara, F. (2022). *Konvolüsyonel sinir ağlarını kullanarak bitki türlerinin sınıflandırılması ve bitki hastalıklarının tanısı* (Master's thesis, Tekirdağ Namık Kemal Üniversitesi).
- Karadeniz, A. T., Çelik, Y., & Başaran, E. (2023). Classification of walnut varieties obtained from walnut leaf images by the recommended residual block based CNN model. *European Food Research and Technology*, 249(3), 727-738
- Karataş, H., Özdemir, G., Karataş, D., & Örmek, G. (2009). Mardin ili bağcılığının mevcut potansiyeli. *Türkiye*, 7, 5-9.
- Karunakaran, D., 2018a, *Deep learning series 1: Intro to deep learning* [online], <https://medium.com/intro-to-artificial-intelligence/deep-learning-series-1-intro-to-deep-learning-abb1780ee20>.
- Koklu, M., Unlersen, M. F., Ozkan, I. A., Aslan, M. F., & Sabanci, K. (2022). A CNN-SVM study based on selected deep features for grapevine leaves classification. *Measurement*, 188, 110425.
- Koklu, M.; Tutuncu, K. Classification of chronic kidney disease with most known data mining methods. *Int. J. Adv. Sci. Eng. Technol.* 2017, 5, 14–18.
- Koklu, M., Unlersen, M. F., Ozkan, I. A., Aslan, M. F., & Sabanci, K. (2022). A CNN-SVM study based on selected deep features for grapevine leaves classification. *Measurement*, 188, 110425.
- Kumar, R. (2020, February). Adding binary search connections to improve densenet performance. In *5th International Conference on Next Generation Computing Technologies (NGCT-2019)*.
- Lee, S. H., Chan, C. S., Mayo, S. J., & Remagnino, P. (2017). How deep learning extracts and learns leaf features for plant classification. *Pattern recognition*, 71, 1-13.
- Li, Z., Guo, R., Li, M., Chen, Y., & Li, G. (2020). A review of computer vision technologies for plant phenotyping. *Computers and Electronics in Agriculture*, 176, 105672.
- Li, X., Shen, X., Zhou, Y., Wang, X., & Li, T. Q. (2020). Classification of breast cancer histopathological images using interleaved DenseNet with SENet (IDSNet). *PloS one*, 15(5), e0232127.
- Luglio, S. M., Bucalossi, G., Lisci, R., Frasconi, C., Lombardo, S., Vieri, M., ... & Sarri, D. (2024). A Biodiversity Monitoring Case Study in Viticulture: Manual and Digitalized Collaborative Methodology to Pursue the European Commission's Sustainable Challenges. *Sustainability*, 16(8), 3469.

- Meşeci Elif, 2022, Tensorflow MobileNet, <https://elifmeseci.medium.com/tensorflow-mobilenet-9cd9560937c2>
- Mohanty, S. P., Hughes, D. P., & Salathé, M. (2016). Using deep learning for image-based plant disease detection. *Frontiers in plant science*, 7, 215232.
- Nazlı C, 2007. Üzüm. GTHB, TEAE – Bakış, Sayı:9, Nüsha:11. S.1. Ankara. <http://www.tgdf.org.tr/turkce/tgdfraporlari/11uzum.pdf>
- Panwar Nitin, 2018, Convolutional-neural-networks(CNN)-explanation-and-implementation-part-1, <https://nitin-panwar.github.io/>
- Pirim, A. G. H. (2006). Yapay zeka. *Yaşar Üniversitesi E-Dergisi*, 1(1), 81-93.
- Putz, FE ve Mooney, HA (1991). *Üzümlerin Biyolojisi*. Cambridge: Cambridge Üniversitesi Yayınları. doi: 10.5860/choice.30-0291.
- Saini, G., Khamparia, A., & Luhach, A. K. (2020). Classification of plants using convolutional neural network. In *First International Conference on Sustainable Technologies for Computational Intelligence: Proceedings of ICTSCI 2019* (pp. 551-561). Springer Singapore.
- Sharma, P., Aggarwal, A., Gupta, A., Garg, A. (2019). HOG, KNN ve Sinir Ağlarını Kullanarak Yaprak Tanımlaması. İçinde: Bhattacharyya, S., Hassanien, A., Gupta, D., Khanna, A., Pan, I. (eds) Uluslararası Yenilikçi Bilgisayar ve İletişim Konferansı. Ağlar ve Sistemlerde Ders Notları, cilt 56. Springer, Singapur. https://doi.org/10.1007/978-981-13-2354-6_10
- Tan, JW, Chang, S., Abdul-kareem, S., Yap, HJ ve Yong, K. (2020). Yaprak Damarı Morfometrik Yöntemi Kullanılarak Bitki Türlerinin Sınıflandırılmasına Yönelik Derin Öğrenme. *Hesaplamalı Biyoloji ve Biyoinformatik üzerine IEEE/ACM İşlemleri*, 17, 82-90.
- Turkoglu, M., & Hanbay, D. (2015). Destek vektör makinaları kullanılarak yaprak tanıma ile üzüm çeşitlerinin sınıflandırılması. In *Signal Processing and Communications Applications Conference (SIU)* (pp. 2674-2677).
- Tüik, (2021). Türkiye İstatistik Kurumu. http://tuik.gov.tr/PreTablo.do?alt_id=1001 (Erişim Tarihi: 24.03.2024).
- Türkoğlu, M., 2019, Görüntü işleme tabanlı bitki türleri ve hastalıkları tanıma
- Wei Tan, J., Chang, S. W., Abdul-Kareem, S., Yap, H. J., & Yong, K. T. (2018). Deep learning for plant species classification using leaf vein morphometric. *IEEE/ACM transactions on computational biology and bioinformatics*, 17(1), 82-90.
- Yu, X., Shi, P., Schrader, J. & Niklas, K. J. (2020). Nondestructive estimation of leaf area for 15 species of vines with different leaf shapes. *American Journal of Botany*, 107(11), 1481-1490. doi: <https://doi.org/10.1002/ajb2.1560>

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Berivan AKDOĞAN
Uyruğu : T.C.

EĞİTİM

<u>Derece</u>	<u>Adı, İl</u>	<u>Bitirme Yılı</u>
Lisans	: Gaziosmanpaşa Üniversitesi - TOKAT	2012
Yüksek Lisans	: Batman Üniversitesi-BATMAN	2024-Devam Ediyor

İŞ DENEYİMLERİ

<u>Yıl</u>	<u>Kurum</u>	<u>Görevi</u>
2013	Dargeçit İmam Hatip Lisesi	Bilişim Teknolojileri Öğretmenliği
2014	Dargeçit Ilısu Anadolu Lisesi	Bilişim Teknolojileri Öğretmenliği
2015	Dargeçit Anadolu Lisesi	Fatih Projesi Eğitimci
2018	Atatürk Ortaokulu	Bilişim Teknolojileri Öğretmenliği
2022	Dargeçit Ilısu Anadolu Lisesi	Fatih Projesi Eğitimci

UZMANLIK ALANI: Bilişim Teknolojileri, Robotik ve Kodlama

YABANCI DİLLER: İngilizce-Orta

İLETİŞİM

E-posta: berivanakdogan@hotmail.com