



T.C.
TOKAT GAZİOSMANPAŞA ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI
BİLGİSAYAR MÜHENDİSLİĞİ YÜKSEK LİSANS PROGRAMI

DERİN ÖĞRENME MODELLERİ İLE BEŞ FARKLI CEVİZ
CİNSİNİN SINIFLANDIRILMASI

YÜKSEK LİSANS TEZİ

CİHAT ÖZİL

Danışman: Dr. Öğr. Üyesi. Mürsel ÖNDER

TOKAT – 2025

ETİK SÖZLEŞME

Tokat Gaziosmanpaşa Üniversitesi Lisansüstü Eğitim Enstitüsü tez yazım kılavuzuna göre, Dr. Öğr. Üyesi. Mürsel ÖNDER danışmanlığında hazırlamış olduğum “Derin Öğrenme Modelleri ile Beş Farklı Ceviz Cinsinin Sınıflandırılması” adlı Yüksek Lisans tezinin bilimsel etik değerlere ve kurallara uygun, özgün bir çalışma olduğunu, aksinin tespit edilmesi halinde her türlü yasal yaptırımını kabul edeceğimi beyan ederim.

.../.../...

Cihat ÖZİL

JÜRİ KABUL VE ONAY

Cihat ÖZİL tarafından hazırlanan “**Derin Öğrenme Modelleri ile Beş Farklı Ceviz Cinsinin Sınıflandırılması**” adlı tez çalışmasının savunma sınavı 21.07.2025 tarihinde yapılmış olup aşağıda verilen Jüri tarafından Oy Birliği ile Tokat Gaziosmanpaşa Üniversitesi Lisansüstü Eğitim Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı’nda Yüksek Lisans Tezi olarak kabul edilmiştir.

Jüri Üyeleri (Unvanı, Adı Soyadı)

İmzası

Üye (Başkan) :

Üye :

Üye :

ONAY

...../...../.....

Lisansüstü Eğitim Enstitüsü Müdürü

TEŞEKKÜR

Bu tez çalışmasının hazırlanmasında bilgi, deneyim ve desteğiyle bana rehberlik eden değerli danışmanım Dr. Öğr. Üyesi Mürsel ÖNDER'e en içten teşekkürlerimi sunarım. Akademik yolculuğum boyunca göstermiş olduğu sabır, anlayış ve yönlendirmeleri benim için son derece kıymetlidir.

Ayrıca bu sürecin her anında yanımda olan, sabrını ve sevgisini esirgemeyen sevgili eşime, varlıklarıyla bana güç veren kıymetli çocuklarım Yusuf ve Nisa'ya da en derin şükranlarımı sunarım. Onların desteği ve anlayışı olmadan bu çalışmayı tamamlamak mümkün olmazdı.

Cihat ÖZİL
TOKAT-2025

ÖZET

DERİN ÖĞRENME MODELLERİ İLE BEŞ FARKLI CEVİZ CİNSİNİN SINIFLANDIRILMASI

Özil, Cihat
Yüksek Lisans, Bilgisayar Mühendisliği Anabilim Dalı
Tez Danışmanı: Dr. Öğr. Üyesi Mürsel Önder
Temmuz 2025, xi+ 91

Ceviz, hem besin değeri hem de ekonomik getirisi bakımından önemli bir tarım ürünüdür. Türkiye, ceviz üretiminde dünyanın önde gelen ülkeleri arasında yer almakta ve farklı morfolojik özelliklere sahip birçok yerli ve yabancı ceviz cinsi yetiştirilmektedir. Ancak bu çeşitliliğin doğru şekilde sınıflandırılması, üretici seçimleri, verimlilik ve kalite kontrolü açısından kritik öneme sahiptir. Geleneksel sınıflandırma yöntemleri büyük ölçüde uzman görüşüne dayalıdır ve insan hatasına açıktır. Bu nedenle, ceviz sınıflandırmasının otomatik sistemler aracılığıyla gerçekleştirilmesi, tarımsal üretim süreçlerinde doğruluk, hız ve verimlilik sağlamaktadır. Son yıllarda, derin öğrenme tabanlı yaklaşımlar bu alanda önemli fırsatlar sunmakta ve geleneksel yöntemlere alternatif olarak öne çıkmaktadır.

Bu tez çalışması, farklı ceviz cinslerinin görüntü işleme teknikleri ile desteklenen derin öğrenme modelleri aracılığıyla sınıflandırılmasını amaçlamaktadır. Çalışma kapsamında, Tokat ili Niksar ilçesi Sorhun Köyü'ndeki yerel üreticilerden temin edilen beş farklı ceviz cinsine ait örneklerle özgün bir görüntü veri seti oluşturulmuştur. Bu veri seti, cevizlerin özel olarak geliştirilen bir düzenekle hem yatayda hem de dikeyde 5° aralıklarla döndürülmesiyle her bir ceviz için toplam 144 farklı açıdan görüntü elde edilerek oluşturulmuştur. Veriler Python programlama dili ve OpenCV kütüphanesi kullanılarak görüntü boyutlandırma, kontur kırpma ve arka plan temizleme gibi ön işleme adımlarından geçirilmiş; %50 eğitim, %25 doğrulama ve %25 test olacak şekilde rastgele ayrılmıştır.

Araştırmada, önerilen Evrişimli Sinir Ağı (ESA) mimarisi ile birlikte ResNet50, Xception, InceptionV3, MobileNet ve DenseNet121 gibi transfer öğrenme tabanlı modellerin performansları karşılaştırmalı olarak değerlendirilmiştir. Model karşılaştırmaları sonucunda, önerilen ESA mimarisinin düşük parametre sayısı, kısa eğitim süresi ve %99.78 gibi yüksek test doğruluğu ile dikkat çekici bir performans sergilediği gözlemlenmiştir. Ayrıca, karışıklık matrisleri, doğruluk-kayıp grafikleri ve değerlendirme metrikleri incelendiğinde önerilen ESA mimarisinin daha istikrarlı sonuçlar verdiği belirtilmiştir.

Anahtar Kelimeler: Derin Öğrenme, Ceviz Sınıflandırması, Evrişimli Sinir Ağı, Transfer Öğrenme, Görüntü İşleme, Özelleştirilmiş CNN Model

ABSTRACT
**CLASSIFICATION OF FIVE DIFFERENT TYPES OF WALNUTS USING
DEEP LEARNING MODELS**

Özil, Cihat
Master's Thesis, Department of Computer Engineering
Advisor: Asst. Prof. Dr. Mürsel Önder
July 2025, xi+ 91

Walnuts are an important agricultural product in terms of both nutritional value and economic return. Turkey ranks among the world's leading countries in walnut production, and many local and foreign walnut varieties with different morphological characteristics are cultivated. However, the correct classification of this diversity is critical in terms of producer selection, productivity, and quality control. Traditional classification methods are largely based on expert opinion and are prone to human error. Therefore, the automatic classification of walnuts through automated systems ensures accuracy, speed, and efficiency in agricultural production processes. In recent years, deep learning-based approaches have emerged as significant opportunities in this field and as alternatives to traditional methods.

This thesis aims to classify different walnut varieties using deep learning models supported by image processing techniques. Within the scope of the study, a unique image dataset was created using samples from five different walnut varieties obtained from local producers in Sorhun Village, Niksar District, Tokat Province. This dataset was created by obtaining images of each walnut from a total of 144 different angles, both horizontally and vertically, at 5° intervals using a specially developed device. The data was processed using the Python programming language and the OpenCV library to perform pre-processing steps such as image resizing, contour cropping, and background cleaning, and was randomly divided into 50% training, 25% validation, and 25% testing.

In the study, the performance of transfer learning-based models such as ResNet50, Xception, InceptionV3, MobileNet, and DenseNet121 was compared with the proposed Convolutional Neural Network (CNN) architecture. As a result of the model comparisons, it was observed that the proposed ESA architecture demonstrated remarkable performance with its low number of parameters, short training time, and high test accuracy of 99.78%. Furthermore, when confusion matrices, accuracy-loss graphs, and evaluation metrics were examined, it was noted that the proposed ESA architecture yielded more stable results.

Keywords: Deep Learning, Walnut Classification, Convolutional Neural Network, Transfer Learning, Image Processing, Customized CNN Model

İÇİNDEKİLER

	<u>Sayfa</u>
ETİK SÖZLEŞME.....	i
JÜRİ KABUL VE ONAY	ii
TEŞEKKÜR	iii
ÖZET	iv
ABSTRACT	v
İÇİNDEKİLER	vi
ŞEKİLLER LİSTESİ	ix
ÇİZELGELER LİSTESİ.....	x
KISALTMALAR LİSTESİ	xi
1. GİRİŞ	1
Tezin Amaçları	2
Tezin Kapsamı	3
Tezin Organizasyonu	3
2. LİTERATÜR ÖZETLERİ	4
3. MATERYAL YÖNTEM	16
3.1. Yapay Zeka	16
3.2. Makine Öğrenmesi	17
3.3. Derin Öğrenme	17
3.4. Evrişimli Sinir Ağları (ESA).....	18
3.4.1. Giriş katmanı (Input layer)	19
3.4.2. Konvolüsyon katmanı (Convolution layer)	20
3.4.3. Havuzlama katmanı (Pooling layer)	21
3.4.4. Tam bağlantılı katman (Fully connected layer).....	22
3.4.5. Seyretime katmanı (Dropout)	23
3.5. Derin Öğrenme Ağ Modelleri	24
3.5.1. ResNet50.....	24

3.5.2.	Xception.....	26
3.5.3.	InceptionV3	27
3.5.4.	MobileNet	28
3.5.5.	DenseNet121.....	29
3.6.	ESA’da Kullanılan Hiperparametreler	30
3.6.1.	Öğrenme oranı (Learning rate)	30
3.6.2.	Kayıp fonksiyonu (Loss function)	31
3.6.3.	Tur (epoch) sayısı	31
3.6.4.	Optimizasyon algoritmaları	31
3.6.5.	Yığın (Batch size) boyutu	32
3.7.	Değerlendirme Metrikleri.....	33
3.7.1.	Karışıklık matrisi (Confusion matrix)	33
3.7.2.	Doğruluk (Accuracy)	34
3.7.3.	Kesinlik (Precision)	35
3.7.4.	Duyarlılık (Recall)	35
3.7.5.	F1 Skoru (F1-Score)	35
3.8.	Veri Artırma	36
3.9.	Çalışmada Kullanılan Yazılımlar ve Kütüphaneler	37
3.9.1.	Python	37
3.9.2.	NumPy	37
3.9.3.	Pandas	37
3.9.4.	Matplotlib	37
3.9.5.	Seaborn	38
3.9.6.	Keras	38
3.9.7.	TensorFlow	38
3.9.8.	Scikit-learn.....	38

3.9.9.	OpenCV	38
3.9.10.	Bleak	38
3.9.11.	adb_shell	39
3.9.12.	Asyncio	39
3.9.13.	Os	39
3.9.14.	Arduino IDE	39
3.10.	Veri Seti Oluřturulması.....	39
3.10.1.	Ceviz cinsleri	40
3.10.2.	Kullanılan ekipmanlar	41
3.10.3.	Veri toplama prosedürü	42
3.10.4.	Veri ön işleme	46
3.10.5.	Klasör organizasyonu	48
4.	BULGULAR ve TARTIřMA.....	51
4.1.	Önerilen ESA Mimarisi.....	51
4.2.	DeneySEL Ortam ve Eđitim Yapılandırması	53
4.3.	Derin Öğrenme Modellerinin Performansı	54
4.3.1.	ResNet50 modelinin performans deđerlendirmesi	55
4.3.2.	Xception modelinin performans deđerlendirmesi	57
4.3.3.	InceptionV3 modelinin performans deđerlendirmesi	60
4.3.4.	MobileNet modelinin performans deđerlendirmesi	62
4.3.5.	DenseNet121 modelinin performans deđerlendirmesi	65
4.3.6.	Önerilen ESA mimarisi performans deđerlendirmesi.....	67
4.4.	Genel Tartıřma	70
5.	SONUÇ ve ÖNERİLER.....	72
6.	KAYNAKÇA	74
7.	ÖZGEÇMİř	79

ŞEKİLLER LİSTESİ

Şekil No	Sayfa No
Şekil 3.4.1. YZ, MÖ, DÖ arasındaki ilişki.....	18
(Akın ve Şahin, 2024)	18
Şekil 3.4.1 ESA mimarisi ve katmanlar	19
(Büyükarıkan ve Ülker, 2020).....	19
Şekil 3.3. Evrişim işlemi adımları.....	21
Şekil 3.4. Havuzlama katmanı Max pooling ve Average pooling işlemi	22
Şekil 3.5. Tam bağlantılı katman yapısı	23
Şekil 3.6. ESA seyreltme işlemi.....	24
Şekil 3.7. ResNet50 mimarisinin genel yapısı	25
(Fırat ve Hanbay, 2022)	25
Şekil 3.8. ResNet50 mimarisinde kullanılan artık blok yapısı.....	26
(Fırat ve Hanbay, 2022)	26
Şekil 3.9. Xception mimarisinin genel yapısı	27
(Westphal ve Seitz, 2021)	27
Şekil 3.10. InceptionV3 mimarisinin genel yapısı	28
(Nogueira ve ark., 2022)	28
Şekil 3.11. MobileNet mimarisinin katman yapısı.....	29
(Saini ve Devi, 2023)	29
Şekil 3.12. DenseNet121 mimarisinin genel yapısı	30
(Albelwi, 2022).....	30
Şekil 3.13. Karışıklık matrisi	34
Şekil 3.10.1 Beş farklı ceviz cinsine ait örnek görseller	41
Şekil 3.15. Görüntü toplama sisteminde kullanılan donanım bileşenleri.....	42
Şekil 3.16. Görüntü toplama, ön işleme ve veri seti oluşturma sürecinin akış diyagramı	43
Şekil 3.17. Veri seti oluşturma düzeneği genel görünümü	44
Şekil 3.18. Kontur kırpma ve arkaplan temizleme.....	47
Şekil 3.19. Veri seti oluşturmada kullanılan donanımlar	49
Şekil 3.10.5. Ceviz sınıflandırma sürecine ait genel iş akışı.....	51
Şekil 3.10.5. Önerilen ESA mimarisine ait ağ tasarımı	52
Şekil 4.3. Resnet50 doğruluk grafiği.....	55
Şekil 4.4. Resnet50 kayıp grafiği	56
Şekil 4.5. Resnet50 karışıklık matrisi	56
Şekil 4.6. Xception doğruluk grafiği.....	58
Şekil 4.3.27. Xception kayıp grafiği	58
Şekil 4.3.28. Xception karışıklık matrisi.....	59
Şekil 4.3.39. InceptionV3 doğruluk grafiği.....	60
Şekil 4.3.310. InceptionV3 kayıp grafiği	61
Şekil 4.3.311. InceptionV3 karışıklık matrisi	61
Şekil 4.3.4 MobileNet doğruluk grafiği	63
Şekil 4.3.4 MobileNet kayıp grafiği.....	63
Şekil 4.3.4. MobileNet karışıklık matrisi	64
Şekil 4.3.5. DenseNet121 doğruluk grafiği.....	65
Şekil 4.3.516. DenseNet121 kayıp grafiği	66
Şekil 4.3.57. DenseNet121 karışıklık matrisi.....	66
Şekil 4.3.618. Önerilen ESA mimarisi doğruluk grafiği.....	68
Şekil 4.3.619. Önerilen ESA mimarisi kayıp grafiği	68
Şekil 4.3.620. Önerilen ESA mimarisi karışıklık matrisi.....	69

ÇİZELGELER LİSTESİ

Tablo No	Sayfa No
Tablo 3.1. Eğitim, doğrulama ve test kümelerine ait görüntü sayıları	50
Tablo 4.2. Önerilen ESA mimarisinin katman çıktıları ve parametre özeti	53
Tablo 4.3. Eğitimde kullanılan yazılım ve donanım bileşenleri.....	54
Tablo 4.4. Modellerde kullanılan eğitim parametreleri.....	54
Tablo 4.5. Resnet50 parametre sayısı, eğitim süresi ve doğruluk değerleri.....	57
Tablo 4.6. Resnet50 performans metrikleri.....	57
Tablo 4.7. Xception parametre sayısı, eğitim süresi ve doğruluk değerleri	59
Tablo 4.8. Xception performans metrikleri.....	60
Tablo 4.9. InceptionV3 parametre sayısı, eğitim süresi ve doğruluk değerleri.....	62
Tablo 4.10. InceptionV3 performans metrikleri.....	62
Tablo 4.11. MobileNet parametre sayısı, eğitim süresi ve doğruluk değerleri	64
Tablo 4.12. MobileNet performans metrikleri	64
Tablo 4.13. DenseNet121 parametre sayısı, eğitim süresi ve doğruluk değerleri.....	67
Tablo 4.14. DenseNet121 performans metrikleri.....	67
Tablo 4.15. Önerilen ESA mimarisi parametre sayısı, eğitim süresi ve doğruluk değerleri.....	69
Tablo 4.16. Önerilen ESA mimarisi performans metrikleri.....	70
Tablo 4.17. Derin öğrenme modellerinin karşılaştırmalı performans özeti	71

KISALTMALAR LİSTESİ

Kısaltmalar	Açıklamalar
YZ	Yapay Zeka
MÖ	Makine öğrenmesi
DÖ	Derin Öğrenme
ESA	Evrişimli Sinir Ağ
CNN	Convolutional Neural Networks
YSA	Yapay Sinir Ağ
RGB	Red Green Blue
GPU	Grafik İşlem Birimi
FC	Fully Connected
Adam	Adaptive Moment Estimation
SGD	Stochastic Gradient Descent
TP	True Positive
TN	True Negative
FP	False Positive
FN	False Negative
USB	Universal Serial Bus
BLE	Bluetooth Low Energy
ADB	Android Debug Bridge

1. GİRİŞ

Günümüzde tarım sektörü, teknolojik gelişmelerin etkisiyle köklü bir dönüşüm geçirmektedir. Özellikle meyve yetiştiriciliği alanında, ürün kalitesini ve verimliliğini artırmaya yönelik çeşitli çalışmalar yapılmaktadır. Bu çalışmaların başında yapay zeka ve derin öğrenme algoritmalarının tarımsal süreçlere entegrasyonu gelmektedir (Çam, 2023). Derin öğrenme modelleri, karmaşık ve yüksek boyutlu veri setlerinden örüntüleri öğrenme yetenekleri sayesinde, insan gözüyle ayırt edilmesi güç olan detayları dahi tespit edebilmektedir (Selamet, 2023). Bu özellikleri sayesinde, özellikle meyve sınıflandırması gibi görüntü tabanlı uygulamalarda önemli başarılar elde edilmiştir.

Ceviz, besin değeri yüksek ve ekonomik öneme sahip bir tarım ürünüdür. Türkiye, iklim çeşitliliği ve tarımsal potansiyeli sayesinde ceviz üretiminde önde gelen ülkeler arasında yer almaktadır. Ülkede farklı morfolojik özelliklere sahip birçok ceviz cinsi yetiştirilmektedir (Bayazit ve ark., 2016). Ancak, bu cinslerin doğru şekilde sınıflandırılması, uzmanlık ve deneyim gerektiren bir süreçtir. Bu süreçte yapılan insan kaynaklı hatalar, kalite ve verimliliği olumsuz etkileyebilmektedir (Özil ve Önder, 2025). Bu nedenle, ceviz cinslerinin otomatik olarak sınıflandırılmasına yönelik teknolojik çözümler, hem üreticiler hem de tüketiciler için önemli avantajlar sunmaktadır.

Literatürde ceviz üzerine yapılan çalışmaların büyük bir kısmının yaprak, sürgün veya yaprak altı damar yapıları gibi bitki parçaları üzerinden yürütüldüğü görülmektedir. Örneğin, ceviz sürgünlerinden elde edilen görüntüler ile yapılan sınıflandırma çalışmalarında, çeşitli makine öğrenmesi yöntemlerinin başarıyla kullanıldığı bildirilmiştir (Altınalan ve Kayaalp, 2023). Buna karşılık, ceviz tanelerini doğrudan esas alan sınıflandırma çalışmaları oldukça sınırlıdır. Bunun başlıca nedeni, tanelerin şekil, kabuk yapısı ve yüzey dokusu gibi morfolojik özelliklerinin yüksek çeşitlilik göstermesi ve bu durumun sınıflandırma sürecini zorlaştırmasıdır. Ancak son yıllarda, derin öğrenme mimarilerinde yaşanan ilerlemeler bu sorunu aşmak adına önemli fırsatlar sunmaktadır. Örneğin, InceptionV3, VGG-19 ve VGG-16 gibi transfer öğrenme tabanlı derin öğrenme modelleri kullanılarak ceviz tanelerinin %98'in üzerinde doğrulukla sınıflandırılabilirdiği gösterilmiştir (Yılmaz, 2025). Bu gelişmeler, ceviz tanelerinden fenotipik çeşitliliğe

dayalı cins ayrımı yapılabileceğini ve geleneksel sınıflandırma yöntemlerine alternatif olarak derin öğrenme tabanlı sistemlerin tarım sektöründe yaygınlaşabileceğini ortaya koymaktadır.

Bu tez çalışmasında, farklı ceviz cinslerinin görüntü işleme teknikleriyle desteklenen derin öğrenme modelleri aracılığıyla sınıflandırılması amaçlanmıştır. Bu amaç doğrultusunda, Tokat ili Niksar ilçesi Sorhun köyündeki yerel üreticilerden temin edilen beş farklı ceviz cinsine ait örneklerle özgün bir görüntü veri seti oluşturulmuştur. Veri toplama sürecinde, cevizler özel olarak geliştirilen bir düzeneğe yerleştirilerek, hem yatayda hem de dikeyde 5° aralıklarla döndürülmüş ve her bir ceviz için toplam 144 farklı açıdan görüntü elde edilmiştir. Bu yöntemle veri setinin çeşitliliği ve temsil gücü artırılmıştır.

Oluşturulan veri seti, derin öğrenme modellerinin eğitimi için uygun hale getirilmek amacıyla çeşitli ön işleme adımlarına tabi tutulmuştur. Bu adımlar arasında görüntü boyutlandırma, kontur kırpma ve arka plan temizleme gibi işlemler yer almaktadır. Tüm bu işlemler, Python programlama dili ve OpenCV kütüphanesi kullanılarak gerçekleştirilmiştir. Veri seti, Python'daki train_test_split fonksiyonu aracılığıyla %50 eğitim, %25 doğrulama ve %25 test olacak şekilde rastgele ayrıştırılmıştır.

Bu çalışma, ceviz tanelerinin sınıflandırılmasına yönelik derin öğrenme temelli kapsamlı ve özgün veri setlerinden birini sunmakta ve alana katkı sağlamayı hedeflemektedir. Literatürde bu konuya dair sınırlı sayıda çalışma bulunması, çalışmanın önemini ve özgünlüğünü artırmaktadır. Ayrıca, kullanılan yöntemlerin başarısı, gelecekte yapılacak araştırmalara da yön gösterecek niteliktedir.

Tezin Amaçları

Bu tezin temel amaçları şunlardır:

- Farklı ceviz cinslerine ait detaylı bir veri seti oluşturmak.
- Derin öğrenme modellerini kullanarak ceviz cinslerini yüksek doğrulukla sınıflandırmak.

- Farklı derin öğrenme modellerinin performansını karşılaştırmak ve en uygun modeli belirlemek.
- Ceviz cinslerinin sınıflandırılması için yeni bir yaklaşım geliştirmek.
- Literatüre katkıda bulunmak ve gelecekteki çalışmalara yol göstermek.

Tezin Kapsamı

Bu tez çalışması, Tokat İli Niksar İlçesi Sorhun köyü yerel üreticilerinden toplanan 5 farklı ceviz cinsi ile sınırlıdır. Farklı ceviz cinsleri ve farklı coğrafi bölgelerden toplanan örnekler ile daha kapsamlı çalışmalar yapılabilir. Ayrıca, bu tezde kullanılan derin öğrenme modelleri ile farklı modeller de denenebilir.

Tezin Organizasyonu

Bu tez aşağıdaki gibi organize edilmiştir:

- Giriş: Bu bölüm, problemin tanımını, motivasyonu, amaçları ve kapsamını içermektedir.
- Literatür Taraması: Bu bölümde, ceviz ve meyve sınıflandırması üzerine yapılan çalışmalar incelenmektedir.
- Materyal ve Metot: Bu bölümde, veri seti oluşturma süreci, kullanılan derin öğrenme modelleri ve eğitim yöntemleri detaylı olarak anlatılmaktadır.
- Bulgular ve Tartışma: Bu bölümde, derin öğrenme modelleri ile yapılan sınıflandırma sonuçları sunulmakta ve modellerin performansları çeşitli metrikler (doğruluk, hassasiyet, geri çağırma, F1 skoru vb.) üzerinden karşılaştırılmaktadır. Ayrıca, elde edilen bulgular detaylı şekilde tartışılarak yorumlanmakta ve bu sonuçların literatür ile ilişkisi değerlendirilmektedir.
- Sonuç ve Öneriler: Bu bölümde, tezin sonuçları özetlenmekte ve gelecekteki çalışmalar için öneriler sunulmaktadır.

2. LİTERATÜR ÖZETLERİ

Günümüzde tarım ürünlerinin kalite kontrolü ve otomatik tanımlanması için yapay zeka ve görüntü işleme tabanlı yöntemler yaygın biçimde kullanılmaya başlanmıştır. Özellikle Evrişimli Sinir Ağları (ESA) gibi derin öğrenme modelleri, meyve sınıflandırması gibi karmaşık görevlerde yüksek başarı oranları sunmakta ve manuel değerlendirme süreçlerine alternatif oluşturmaktadır (Naranjo-Torres ve ark., 2020). Bununla birlikte, transfer öğrenme yaklaşımı sayesinde, daha önceden geniş veri kümeleri üzerinde eğitilmiş modeller, yeni ve sınırlı veri setlerine uyarlanabilmekte; bu da tarım alanında pratik uygulamaları mümkün kılmaktadır (Knott ve ark., 2022).

Ancak, literatür taraması yapıldığında ceviz tanelerinin görüntü üzerinden doğrudan sınıflandırılmasına yönelik çalışma sayısının oldukça sınırlı olduğu görülmektedir. Mevcut çalışmalar genellikle ceviz yaprakları, sürgünleri ya da kabuk kalitesi üzerine odaklanmıştır (Karadeniz ve ark., 2023). Bu nedenle, ceviz tanelerine yönelik geliştirilen derin öğrenme tabanlı yaklaşımlar literatüre anlamlı katkılar sunma potansiyeli taşımaktadır.

Özil ve Önder (2025), ceviz cinslerinin sınıflandırılması amacıyla otomatik görüntü toplama sistemi geliştirerek beş farklı ceviz türüne ait yüksek çözünürlüklü ve çok açılı bir veri seti oluşturmuştur. ESP32 mikrodenetleyici, step motor ve akıllı telefon kamerasının entegre kullanımıyla her cevizden 144 farklı açıdan görüntü elde edilmiştir. Görşeller, kontur kırpma ve arka plan temizleme gibi ön işleme adımlarından geçirilerek eğitim, doğrulama ve test kümelerine ayrılmıştır. Çalışma, görüntü tabanlı sınıflandırma için özgün bir altyapı sunarken, sistemin diğer tarım ürünlerine uyarlanabilirliği ile literatürde önemli bir boşluğu doldurmaktadır.

Kilif ve ark., (2025), Türkiye’de yaygın olarak yetiştirilen beş farklı ceviz türünün (Chandler, Fernor, Kaman¹, Yalova³ ve Maras¹⁸) sınıflandırılması amacıyla, derin öğrenme tabanlı bir otomatik tanı sistemi geliştirilmiştir. Toplam 2540 görüntüden oluşan özgün veri seti, sabit kamera düzeneği ve kontrollü ışık koşulları altında her ceviz sadece bir kez olacak şekilde Canon EOS 600D kullanılarak elde edilmiştir. Görüntüler, 600x600

piksele yeniden boyutlandırılıp siyah arka planla ön işleme tabi tutulmuştur. Sınıflandırma işlemleri, transfer öğrenme yaklaşımı ile önceden eğitilmiş VGG16, VGG19, ResNet-50, DenseNet-121 ve Xception modelleri kullanılarak gerçekleştirilmiştir. Veri seti, farklı eğitim stratejileriyle (veri artırma, ağırlıklı kayıp fonksiyonu, standart eğitim) değerlendirilmiştir. Veri artırma ile en yüksek doğruluk ResNet-50 modelinde %97.95, Xception modelinde ise %97.28 olarak elde edilmiştir. Ağırlıklı kayıp fonksiyonu uygulandığında Xception %98.54 ile en iyi sonucu vermiştir. Karşılaştırmalı olarak kullanılan makine öğrenmesi algoritmaları arasında en iyi performans %90.10 doğrulukla SVM modeline aittir. Bu sonuçlar, Xception ve ResNet-50 gibi derin öğrenme mimarilerinin, geleneksel yöntemlere kıyasla çok daha yüksek başarı sağladığını ortaya koymakta ve ceviz türlerinin otomatik sınıflandırılmasında derin öğrenmenin etkinliğini vurgulamaktadır

Aktaş (2022), Antep fıstıklarının dış kabuk rengine göre sınıflandırılması amacıyla AlexNet tabanlı bir derin öğrenme modeli geliştirmiş ve bu model için endüstriyel koşulları taklit eden özgün bir veri seti oluşturmuştur. Serbest düşme sırasında fıstıkların farklı açılardan görüntülenmesini sağlayan sistem ile toplam 3983 görüntü toplanmış, görüntüler blob analizi ile işlenerek sınıflandırmaya uygun hale getirilmiştir. Eğitim-veri oranlarının (%70-%15-%15 ve %60-%20-%20) ve veri sayısının sınıflandırma başarısına etkisini test eden çalışmada, en yüksek doğruluk oranı %98.44 olarak raporlanmıştır. Çalışma, sadece sabit görüntülere dayalı masaüstü veri setlerinin ötesine geçerek, endüstriyel uygulamalara daha yakın gerçekçi veri üretimi ve yüksek doğruluk oranı ile literatürdeki pek çok çalışmadan ayrılmaktadır. Bu yönüyle, tarım ürünlerinin otomatik sınıflandırılmasında derin öğrenme ve görüntü işleme tekniklerinin sahaya aktarılabilirliğini göstermesi açısından önemli bir katkı sunmaktadır.

Karadeniz ve ark., (2023), tarafından gerçekleştirilen çalışmada, ceviz yapraklarından çeşit tespiti yapmak amacıyla derin öğrenme temelli bir sınıflandırma yaklaşımı önerilmiştir. Çalışmada, Yalova Atatürk Bahçe Kùltürleri Merkez Araştırma Enstitüsü'nden temin edilen 18 farklı ceviz çeşidine ait 1751 yaprak görselinden oluşan özgün bir veri seti oluşturulmuştur. Görseller üzerinde gürültü giderme, kontur alma ve yeniden boyutlandırma gibi ön işleme teknikleri uygulanmış; ardından veri artırma

yöntemiyle veri seti genişletilmiştir. Sınıflandırma işlemi, literatürde yaygın olarak kullanılan AlexNet, VGG16, VGG19, ResNet, InceptionV3, EfficientNet ve GoogleNet gibi dokuz farklı ESA mimarisiyle gerçekleştirilmiştir. En yüksek doğruluk oranı, %90.55 ile artırılmış veri seti üzerinde VGG16 modeli ile elde edilmiştir. Bu çalışma, özellikle benzer görsel özelliklere sahip ceviz çeşitlerinin ayrımında insan gözüyle yapılan tanılamamanın zorluklarını aşmak için derin öğrenme algoritmalarının etkinliğini vurgulamakta ve otomatik sınıflandırma sistemlerinin tarımsal üretimdeki uygulama potansiyelini ortaya koymaktadır.

Wang ve ark., (2024), ceviz kabuğundaki yüzey kusurlarının otomatik olarak tespit edilmesi amacıyla derin öğrenme temelli bir sınıflandırma ve ayıklama sistemi geliştirmiştir. Çalışmada, Xiangling ceviz çeşidi kullanılarak prototip bir makine tasarlanmış ve görüntüleme mekanizması ile birlikte U-net, PSPNet ve Deeplabv3+ gibi üç farklı semantik segmentasyon modeli karşılaştırılmıştır. Sonuçlar, özellikle U-net mimarisinin üstün performans sergilediğini; ortalama Intersection over Union (MIoU) değerinin %96,71 ve ortalama piksel doğruluk (MPA) oranının %98,52 olarak elde edildiğini göstermiştir. Ayrıca sistem, dakikada yaklaşık 51,7 kg ceviz işleme kapasitesi ve %92,98 doğruluk oranı ile çalışmıştır. Bu çalışma, ceviz gibi düzensiz yüzey yapısına sahip tarım ürünlerinde yüksek doğrulukla sınıflandırma yapabilen sistemlerin tasarımı açısından literatüre önemli katkılar sunmakta ve derin öğrenme tabanlı yöntemlerin pratikte başarılı bir şekilde uygulanabileceğini ortaya koymaktadır.

Anagnostis ve ark., (2021), ceviz bahçelerinde görülen antraknoz hastalığının tespiti için derin öğrenme tabanlı bir nesne tanıma sistemi geliştirerek, tarım alanında gerçek zamanlı hastalık sınıflandırmasına yönelik önemli bir katkı sunmuşlardır. Çalışmada, geleneksel yöntemlerin aksine, yapay zeka destekli SSD (Single Shot Detector) algoritması kullanılarak, doğrudan sahada ağaç düzeyinde hastalıklı yapraklar tespit edilmiştir. Bu yaklaşım, yüksek çözünürlüklü görüntülerin alt parçalara bölünmesi ve ResNet50 gibi önceden eğitilmiş ESA modelleriyle yeniden eğitilmesiyle gerçekleştirilmiştir. Elde edilen model, ortalama %63 doğrulukla yaprak düzeyinde antraknoz bulgularını tespit etmiş ve %87'lik doğruluk oranıyla ağaçları sağlıklı ya da hastalıklı olarak sınıflandırmıştır. Gerçek tarla koşullarında gerçekleştirilen bu uygulama, ceviz gibi

meyve ağaçlarında hastalık haritalamasının otomatik olarak yapılmasına olanak tanımakta ve hassas tarım uygulamaları için etkili bir karar destek sistemi potansiyeli taşımaktadır.

Rong ve ark., (2019), ceviz işleme sürecinde karşılaşılan yabancı cisimlerin tespiti için derin öğrenmeye dayalı bir görüntü işleme yaklaşımı geliştirmiştir. Geleneksel yöntemlerin düşük doğruluk ve yüksek iş gücü gerektiren yapısına karşılık, çalışmada kullanılan iki farklı konvolüsyonel sinir ağı (CNN) mimarisi sayesinde hem doğal (örneğin yaprak parçaları, toz) hem de insan kaynaklı (örneğin plastik, metal) yabancı nesneler başarıyla tespit edilmiştir. 781 görüntüden oluşan bir veri setiyle gerçekleştirilen çalışmada, segmentasyon başarısı %99,5'e, sınıflandırma doğruluğu ise %95'e ulaşmıştır. Geliştirilen sistem, görüntü başına 50 ms altında işlem süresi ile gerçek zamanlı taramalarda kullanılabilecek düzeyde hızlıdır. Ayrıca, çalışmada UNet mimarisine dayalı özel bir segmentasyon modeli ile sınıflandırma için 4 sınıflı CNN yapısı tasarlanmıştır. Bu yaklaşım, ceviz gibi düzensiz yapıya sahip tarımsal ürünlerdeki yabancı cisimlerin tespiti için derin öğrenmenin etkinliğini göstermesi açısından literatüre önemli bir katkı sağlamaktadır.

Altınalan ve Kayaalp (2023), tarafından gerçekleştirilen çalışmada, ceviz sürgün görüntüleri kullanılarak ceviz çeşitlerinin sınıflandırılması hedeflenmiş ve bu yönüyle literatürde nadir görülen bir yaklaşım sunulmuştur. Geleneksel olarak meyve olgunlaştıktan sonra yapılan ceviz sınıflandırmasının, en az 4-5 yıl süren bir bekleme gerektirdiği belirtilmiş; bu süreci kısaltmak amacıyla sürgün görüntüleri üzerinden sınıflandırma yapılmasının önemi vurgulanmıştır. Çalışmada, 10 farklı ceviz çeşidine ait toplam 3552 sürgün görüntüsü kullanılmış ve bu veri seti çeşitli görüntü artırma teknikleriyle genişletilerek yedi farklı önceden eğitilmiş derin öğrenme modeli ile test edilmiştir. En yüksek test başarımı %91,87 doğruluk oranı ile EfficientNetB0 modeliyle elde edilmiş, bu sonuç sürgün görüntülerinin sınıflandırma başarısında etkili bir girdi olarak değerlendirilebileceğini göstermiştir. Bu çalışma, ceviz fidanı dikim sürecinde erken ve isabetli tür tespiti yapılmasına katkı sağlayarak, tarımsal üretim verimliliği açısından önemli bir potansiyel taşımaktadır.

Yılmaz (2025), tarafından yapılan çalışmada, ceviz fenotip çeşitlerinin sınıflandırılmasına yönelik derin öğrenme temelli yöntemlerin etkinliği incelenmiştir. Chandler, Fernor, Howard ve Oğuzlar ceviz çeşitlerinden oluşan 952 görüntüden oluşan özel bir veri seti oluşturulmuş ve bu görüntüler derin öğrenme modelleriyle analiz edilmiştir. Çalışmada iki farklı yaklaşım benimsenmiştir: ilki, InceptionV3, VGG-16 ve VGG-19 gibi önceden eğitilmiş modellerin doğrudan sınıflandırma amacıyla kullanılması; ikincisi ise bu modellerle öznetelik çıkarımı yapılarak, elde edilen özneteliklerin Lojistik Regresyon (LR), Destek Vektör Makineleri (SVM) ve k-En Yakın Komşu (k-NN) gibi geleneksel makine öğrenmesi algoritmaları ile sınıflandırılmasıdır. Elde edilen sonuçlara göre en yüksek doğruluk oranı, InceptionV3 modeli ile LR algoritmasının birlikte kullanıldığı hibrit yapıda elde edilmiştir (CA = %96.1). Bu çalışma, derin öğrenme tabanlı yöntemlerin ceviz gibi tarım ürünlerinde fenotip sınıflandırmasında yüksek başarı sağladığını ve endüstriyel uygulamalara entegre edilebilecek potansiyelde olduğunu ortaya koymaktadır.

Güneş (2022), tarafından hazırlanan "Derin Öğrenme Yaklaşımı ile Fındık Meyvesinin Sınıflandırılması" başlıklı yüksek lisans tezinde, tarımsal üretimde kalite kontrol süreçlerini otomatikleştirmeye yönelik derin öğrenme tabanlı bir yaklaşım sunulmuştur. Çalışmada, fındıkların sağlam, iç ve bozuk olmak üzere üç farklı sınıfa ayrılması hedeflenmiş ve bu amaçla VGG16, InceptionV3 ve ResNet50 olmak üzere üç farklı CNN modeli uygulanmıştır. Uzman tarafından oluşturulan ve 15.770 görsel içeren veri setiyle gerçekleştirilen deneylerde, VGG16 modeli yaklaşık %99 doğrulukla en iyi performansı göstermiştir. Ayrıca, veri seti boyutunun azaltılmasının model performansını önemli ölçüde düşürdüğü gözlemlenmiştir. Bu çalışma, derin öğrenmenin tarımda sınıflandırma problemlerine uygulanabilirliğini göstermesi ve insan hatalarını en aza indirerek kaliteyi artırması bakımından literatürde dikkat çeken bir örnek teşkil etmektedir. Özellikle ceviz gibi kabuklu meyvelerin sınıflandırılmasına yönelik çalışmalara da önemli bir metodolojik referans sağlamaktadır.

Bilgin (2015), tarafından gerçekleştirilen çalışmada, yerli (Şen 1, Şen 2, Şebin, Bilecik) ve yabancı (Chandler, Fernor, Fernet, Pedro, Midland) ceviz çeşitlerinin Menemen ekolojik koşullarındaki morfolojik, pomolojik ve kimyasal özellikleri detaylı biçimde

incelenmiştir. Araştırmada, çeşitlerin ağaç boyu, meyve eni, boyu, iç randımanı, yağ asidi kompozisyonları gibi birçok tarımsal özellikleri karşılaştırılmış ve bazı çeşitlerin antraknoz hastalığına karşı direnç seviyeleri belirlenmiştir. Ancak çalışmada herhangi bir görüntü işleme ya da derin öğrenme temelli sınıflandırma yöntemi kullanılmamış, değerlendirmeler geleneksel fenotipik ölçümler ve analizler üzerinden yapılmıştır. Bu yönüyle çalışma, farklı genotiplerin bölgesel adaptasyon kabiliyetlerini ortaya koyarken, makine öğrenmesi ve CNN gibi modern otomatik sınıflandırma teknikleriyle desteklenmediği için görsel tanıma temelli yaklaşımlar açısından sınırlı bir veri sunmaktadır.

Rahman ve Barua (2021), gerçekleştirilen çalışmada, 20 farklı meyve çekirdeğini sınıflandırmak amacıyla temel bir CNN modeli geliştirilmiş ve bu modelin performansı farklı evrimsel katman sayıları ile test edilmiştir. Ayrıca transfer öğrenme yöntemiyle VGG16, InceptionV3, Xception ve ResNet gibi önceden eğitilmiş modeller kullanılarak dört yeni model daha oluşturulmuştur. Bu modellerin performansları analiz edildikten sonra, doğruluk oranlarını artırmak amacıyla bir topluluk (ensemble) yaklaşımı benimsenmiştir. Beş modelin birleşimiyle oluşturulan ilk topluluk modeli %88 doğruluk elde ederken, dört modelin birleşiminden oluşan ikinci topluluk modeli %87 doğruluk sağlamıştır. Her iki topluluk modeli, Precision, Recall ve F1-Skoru gibi diğer değerlendirme metriklerinde de bireysel modellere kıyasla üstün performans göstermiştir. Bu çalışma, meyve sınıflandırmasında çekirdek görüntülerinin kullanılabilirliğini ve topluluk yöntemlerinin başarımlar üzerindeki olumlu etkisini ortaya koymaktadır.

Basri ve ark., (2018), tarafından gerçekleştirilen çalışmada, çoklu meyve sınıflandırmasını gerçek zamanlı olarak gerçekleştirebilecek bir Derin Öğrenme yöntemi önerilmiştir. Araştırmada mango ve pitaya meyveleri kullanılarak oluşturulan veri seti, hasat döneminde doğrudan bir çiftçiden temin edilmiştir ve nesne algılama eğitimi için iki sınıfa ayrılmıştır. TensorFlow platformu kullanılarak MobileNet mimarisi üzerine kurulu bir Faster R-CNN modeli eğitilmiştir. Model yaklaşık %99 doğruluk oranı ile oldukça başarılı sonuçlar vermiştir. Elde edilen bu yüksek performans, meyvelerin hızlı ve otomatik şekilde sınıflandırılmasına olanak tanıyarak, kalite kaybını önleyecek ve hasat sonrası işleme süreçlerini iyileştirecek potansiyele sahiptir.

Büyükarıkın ve Ülker (2020), farklı aydınlatma koşullarının meyve sınıflandırma üzerindeki etkisini incelemek amacıyla ALOI-COL veri setini kullanarak AlexNet, VGG16 ve VGG19 gibi Evrişimsel Sinir Ağı (ESA) mimarilerini değerlendirmiştir. Çalışmada, 12 farklı renk sıcaklığında elde edilen meyve görüntüleri çeşitli görüntü işleme teknikleriyle (döndürme, gürültü ekleme, histogram eşitleme vb.) zenginleştirilmiş ve her sınıf için 51 örnek oluşturulmuştur. Model eğitimi %80-%20 ve %60-%40 eğitim-test oranlarıyla gerçekleştirilmiş, AlexNet ve VGG16 mimarileri ile %100 sınıflandırma başarısı elde edilmiştir. VGG19 mimarisi ise %86,49 doğruluk oranına ulaşmıştır. Sonuçlar, derin öğrenme tabanlı ESA mimarilerinin, özellikle aydınlatma varyasyonlarına rağmen yüksek sınıflandırma başarısı gösterebildiğini ortaya koymakta ve aydınlatma koşullarının sınıflandırma performansı üzerindeki kritik rolünü vurgulamaktadır. Bu çalışma, meyve sınıflandırma problemlerinde uygun ön işleme ve model seçiminin, sınıflandırma doğruluğunu önemli ölçüde artırabileceğini göstermesi açısından literatürde dikkat çekicidir.

Veziroğlu ve ark., (2023), çeltik bitkisinin yaprak hastalıklarının erken teşhisi amacıyla derin evrişimli sinir ağı (CNN) mimarilerini kullanarak kapsamlı bir sınıflandırma sistemi geliştirmiştir. Araştırmada, VGG16, ResNet34/50, DenseNet-121, Xception, InceptionV3, MobileNetv3 (Small/Large) ve EfficientNetv2 (Small/Medium) gibi modern CNN mimarileri, Paddy Doctor veri seti üzerinde test edilmiştir. Veri seti 10.407 yüksek çözünürlüklü çeltik yaprağı görüntüsünden oluşmakta ve 10 farklı hastalık sınıfını içermektedir. Eğitim sürecinde veri ön işleme, görüntü artırma, öğrenme aktarımı ve hiperparametre optimizasyonu gibi teknikler uygulanmış; modellerin doğruluk, kesinlik, duyarlılık ve F1 skoru gibi metriklerle performansları değerlendirilmiştir. Elde edilen sonuçlara göre, EfficientNetv2_Small modeli %98.01 test doğruluğu ve %97.99 F1 skoru ile en başarılı performansı göstermiştir. Bu çalışma, CNN tabanlı modellerin tarımsal hastalık sınıflandırmasında yüksek doğruluk sağladığını ve öğrenme aktarımının küçük veri kümelerinde bile ciddi performans artışı sunduğunu ortaya koyarak, derin öğrenmenin akıllı tarım uygulamaları için potansiyelini net biçimde göstermektedir.

Gülem ve ark., (2025), tarafından geliştirilen çalışmada, domateslerin türlerine göre

ayrıştırılmasına yönelik düşük maliyetli ve modüler bir sistem tasarlanmıştır. Bu sistemde, Rio ve Fujimaru cinsi domatesler, görüntü işleme teknikleri ve derin öğrenme algoritmaları kullanılarak sınıflandırılmıştır. CNN, R-CNN ve Fast R-CNN modelleri karşılaştırmalı olarak değerlendirilmiş; deneysel sonuçlar, basit CNN modelinin %94.1 doğruluk ile Rio ve %92.4 doğruluk ile Fujimaru cinsi domatesleri en yüksek başarıyla ayırdığını ortaya koymuştur. Kullanılan görüntü ön işleme adımları (yeniden boyutlandırma, renk normalizasyonu ve Gaussian filtreleme) ve veri setinin sabit aydınlatma ve homojen arka plan koşullarında toplanması, sınıflandırma başarısına katkı sağlamıştır. Çalışma, gerçek zamanlı sınıflandırma süreçlerinde CNN tabanlı modellerin hem doğruluk hem de hız açısından avantajlı olduğunu ortaya koyarak, ceviz gibi benzer tarımsal ürünlerin sınıflandırılmasına yönelik araştırmalara önemli bir referans oluşturmaktadır.

Atban ve İlhan (2022), tarafından gerçekleştirilen çalışmada, farklı kuruyemiş türlerinin sınıflandırılması amacıyla ResNet50 ve DenseNet201 gibi önceden eğitilmiş derin öğrenme mimarileri kullanılarak öznitelik çıkarımı yapılmış ve bu öznitelikler destek vektör makineleri (SVM) ile sınıflandırılmıştır. Çalışmada, 11 sınıfa ayrılmış kuruyemiş veri seti üzerinde yapılan deneylerde, yalnızca tek bir ağdan elde edilen özniteliklerle %97,86 (ResNet50) ve %98,09 (DenseNet201) doğruluk değerlerine ulaşılmış, bu özniteliklerin füzyonu ile doğruluk %98,68'e çıkarılmıştır. 5 katlı çapraz doğrulama yöntemi ile test edilen model, özellikle Cashew, Chestnut ve Pecan gibi türlerde hatasız tahmin performansı göstermiştir. Bu sonuçlar, derin öğrenme tabanlı öznitelik füzyon yaklaşımlarının sınıflandırma başarısını artırabileceğini ve gıda teknolojileri alanında güvenilir tanı sistemlerinin geliştirilmesine katkı sağlayabileceğini göstermektedir. Sunulan yöntem, farklı derin ağlardan elde edilen sayısal özniteliklerin birleşimi ile daha yoğun ve anlamlı temsil alanlarının oluşmasını sağlamış, bu da sınıflandırma performansını kayda değer biçimde iyileştirmiştir.

Xiao ve arkadaşları (2023), derin öğrenme tekniklerinin otomatik meyve hasadındaki rolünü kapsamlı şekilde inceleyerek, bu alandaki güncel yöntemleri, karşılaşılan zorlukları ve potansiyel çözüm yollarını sistematik biçimde özetlemişlerdir. Çalışmada, YOLO, SSD, AlexNet, VGGNet, ResNet, Faster R-CNN gibi CNN tabanlı modellerin

çeşitli meyve türleri üzerindeki doğruluk ve hız performansları değerlendirilmiştir. Özellikle YOLO ve SSD gibi tek aşamalı modellerin gerçek zamanlı uygulamalarda öne çıktığı; Faster R-CNN ve Mask R-CNN gibi iki aşamalı modellerin ise daha yüksek doğruluk sağladığı ancak hesaplama maliyetlerinin daha fazla olduğu belirtilmiştir. Ayrıca, yüksek kaliteli veri setlerinin eksikliği, küçük ve örtüşen meyvelerin tespiti, çok ölçekli ve çok türlü tanıma sorunları ile hafif modellerin geliştirilmesi gibi temel araştırma problemleri vurgulanmıştır. Bu çalışma, meyve sınıflandırma sistemlerinin özellikle tarımda uygulamaya dönük olarak geliştirilebilmesi için önemli bir referans niteliği taşımaktadır ve ceviz gibi farklı meyve türlerinin tanınmasına yönelik özgün model geliştirme çabaları için de yön göstericidir

Wang ve ark., (2023), kivi meyvesinin dış kusurlarının tespiti için ResNet34 ile dikkat mekanizması CBAM'ı (Convolutional Block Attention Module) birleştirerek yüksek doğruluklu bir derin öğrenme modeli geliştirmiştir. Çalışmada, Shaanxi bölgesinden temin edilen Xu Xiang ve Cui Xiang çeşitlerine ait toplam 1020 örnekten oluşan bir veri seti hazırlanmış ve görüntüleme sistemi, endüstriyel kamera ve özel ışıklandırma düzeneğiyle desteklenmiştir. Görüntüler işlenip 224×224 boyutuna indirgenerek veri genişletme teknikleri uygulanmıştır. Model eğitimi sırasında Adam optimizasyon algoritması ve öğrenme oranı için kosinüs azalım stratejisi kullanılmıştır. Elde edilen sonuçlar, ResNet34+CBAM modelinin %99,6 doğruluk oranına ulaştığını ve AlexNet, VGG16, InceptionV3 gibi klasik CNN modellerine kıyasla daha yüksek performans gösterdiğini ortaya koymuştur. Bu çalışma, meyve yüzey kusurlarının tespiti için derin öğrenme tabanlı yaklaşımların özellikle dikkat mekanizmalarıyla birlikte kullanıldığında, doğruluk ve kararlılık açısından önemli avantajlar sağladığını göstermektedir.

Vidyarthi ve ark., (2021), badem çekirdeklerinin sınıflandırılmasında derin öğrenme tabanlı bir yaklaşım geliştirerek, görüntü işleme teknikleriyle desteklenen dört farklı derin konvolüsyonel sinir ağı (DCNN) modeli olan Inception-V3, ResNet50, VGG-16 ve özel olarak tasarlanmış bir modelin performanslarını karşılaştırmıştır. Çalışmada, bütün badem çekirdeklerine belirli oranlarda (0–35%) kırık çekirdek karıştırılarak beş farklı kalite sınıfı oluşturulmuş ve bu sınıflar DCNN modelleri ile yüksek doğrulukla ayırt edilmiştir. Özellikle ResNet50 modeli %99'luk doğruluk oranı ile en başarılı sonuçları

vermiş, bunu sırasıyla Inception-V3 (%98.8) ve VGG-16 (%98.4) takip etmiştir. Özel modelin doğruluk oranı ise %93.9'da kalmıştır. Bu çalışma, transfer öğrenme, görüntü artırma ve dropout gibi tekniklerin endüstriyel tarımsal ürün sınıflandırmalarında model başarımını artırmada kritik rol oynadığını göstermektedir. Badem gibi kabuklu yemişlerin otomatik kalite sınıflandırmasında derin öğrenmenin etkinliğini ortaya koyan bu çalışma, ceviz sınıflandırması gibi benzer tarımsal uygulamalar için önemli bir referans niteliği taşımaktadır.

Balcı ve ark., (2016), tarafından yürütülen çalışmada, Türkiye'de yaygın olarak yetiştirilen Napolyon kirazlarının çaplarına göre kalibre sınıflandırması görüntü işleme teknikleri kullanılarak gerçekleştirilmiştir. Araştırmada, Matlab ortamında geliştirilen algoritma aracılığıyla 13 MP çözünürlüklü bir kamera ile elde edilen kiraz görüntüleri işlenmiş; gri tonlamaya dönüştürme, ikili eşikleme, morfolojik işlemler (genişletme, aşındırma vb.) ve alan hesaplamaları gibi yöntemlerle her kirazın çapı milimetre cinsinden tespit edilmiştir. Saha uygulamalarında manuel kalibre kalıpları yerine bu yöntemin kullanılabilirliğini test eden çalışma, özellikle %85 oranında doğru sınıflandırma başarısı ile dikkat çekmiştir. Görüntü işleme tabanlı sistemin herhangi bir özel düzeneğe gerek duymadan çalışabilmesi, bu yöntemi üretici-tüccar etkileşiminde pratik bir araç haline getirmektedir. Bu yönüyle, tarımsal ürünlerin sınıflandırılmasında görüntü işleme tekniklerinin doğruluk, hız ve ekonomik katkı açısından önemli avantajlar sunduğu bir kez daha ortaya konmuştur.

Gerdan (2020), tarafından gerçekleştirilen çalışmada, meyve sınıflandırması için görüntü işleme algoritmaları ile veri madenciliği teknikleri bir araya getirilerek hem boyut hem de renk temelli sınıflandırma gerçekleştirilmiştir. Çalışmada elma (Starkrimson ve Golden Delicious), portakal (Washington Navel ve Valencia Midnight) ve ayva (Ekmek ve Eşme) çeşitlerinden 300 adet örnek kullanılmış; dijital kumpas ve spektrofotometre ile elde edilen ölçümler, geliştirilmiş algoritmaya entegre edilmiştir. Boyut temelli sınıflandırma başarı oranları %82 ile %100 arasında değişirken, renk bazlı sınıflandırmada elma çeşitleri için %100 doğruluk elde edilmiştir. Ayrıca KNN, Karar Ağacı, Naive Bayes, MLP ve Rastgele Orman gibi farklı makine öğrenmesi algoritmaları ile yapılan testlerde, en yüksek başarı oranı %94,3 ile Random Forest algoritmasında

gözlemlenmiştir. Bu çalışma, klasik ölçüm cihazları ile desteklenen görüntü işleme uygulamalarının, meyve sınıflandırmasında hem etkin hem de doğruluk oranı yüksek bir yaklaşım sunduğunu göstermektedir.

Gill ve ark., (2022), meyve tanıma ve sınıflandırma problemini derin öğrenme temelli bir yaklaşımla ele alarak, meyve görüntülerinin otomatik sınıflandırılmasında yüksek doğruluk oranlarına ulaşan bir model geliştirmiştir. Çalışmada, meyve görüntüleri önce Type-II Fuzzy tabanlı bir görüntü iyileştirme sürecinden geçirilmiş, ardından TLBO-MCET algoritması ile segmentasyon uygulanmış ve son olarak CNN, RNN ve LSTM modelleri kullanılarak sınıflandırma gerçekleştirilmiştir. Özellikle hibrit CNN-RNN-LSTM mimarisi, hem kaba hem de ince etiket düzeylerinde sınıflandırma başarımını artırmak üzere kurgulanmıştır. Modelin farklı veri bölüştürme oranlarıyla yapılan testlerde %96'ya varan doğruluklara ulaştığı belirtilmiş; ayrıca diğer yöntemlerle (SVM, FFNN, ANFIS) karşılaştırıldığında daha düşük hata oranları ve daha yüksek korelasyon katsayıları elde edilmiştir. Bu çalışma, görüntü tabanlı meyve sınıflandırma sistemlerinin başarımını artırmak için çok katmanlı ve entegre derin öğrenme mimarilerinin önemini vurgulamakta ve tarımsal ürün tanıma alanında literatüre önemli bir katkı sunmaktadır.

Li ve ark., (2021), elma kalite sınıflandırmasını hedefleyen çalışmalarında, karmaşık arka plan bilgisi içeren görüntüler üzerinde çalışan yeni bir konvolüsyonel sinir ağı (CNN) tabanlı model önermiştir. Çalışmada, farklı kalite sınıflarına (yüksek, orta ve düşük) ait 36.000 adet görüntü ile model eğitilmiş; veri artırma teknikleri sayesinde modelin öğrenme kapasitesi ve genelleme yeteneği iyileştirilmiştir. Önerilen model, %99 eğitim ve %98.98 doğrulama doğruluğu elde etmiş; bu performans, hem Google Inception v3 modeli (%92) hem de geleneksel HOG+GLCM+SVM yöntemleri (%78.14) ile karşılaştırıldığında daha yüksek başarı sağlamıştır. Bağımsız test verisinde %95.33 genel doğruluk elde edilen modelin, elma kalite sınıflandırmasında hızlı, doğru ve endüstriyel uygulamalara uygun bir çözüm sunduğu ifade edilmiştir. Bu çalışma, ceviz gibi diğer tarım ürünleri üzerinde geliştirilecek CNN temelli sınıflandırma modelleri için önemli bir referans niteliğindedir.

Literatürde, derin öğrenme ve transfer öğrenme tabanlı modellerin meyve sınıflandırması

alanında yüksek başarı sağladığı çok sayıda çalışma bulunmaktadır. Ancak ceviz taneleri üzerinden yapılan doğrudan sınıflandırma çalışmaları sınırlıdır. Mevcut araştırmalar çoğunlukla ceviz yaprağı, sürgünü ya da kabuk kalitesine odaklanmakta; ceviz tanesinin bütünsel morfolojik yapısına dair görüntü analizleri nadiren yapılmaktadır. Bu tez, ceviz tanelerini doğrudan kullanarak, görüntü işleme ve derin öğrenme yöntemleriyle sınıflandırma yapan sayılı çalışmalardan biri olması nedeniyle literatüre önemli bir katkı sağlamaktadır. Ayrıca, veri seti oluşturma yöntemi ve model karşılaştırmaları ile gelecekteki araştırmalar için özgün bir kaynak niteliğindedir.



3. MATERYAL YÖNTEM

Bu bölümde, ceviz cinslerinin otomatik sınıflandırılması problemine yönelik geliştirilen tez çalışmasının bilimsel metodolojisi ve uygulama detayları ayrıntılı bir şekilde sunulmaktadır. Çalışmanın tekrar üretilebilirliğini ve anlaşılabilirliğini en üst düzeyde sağlamak amacıyla, kullanılan veri setinin oluşturulma süreci, benimsenen yapay zeka yaklaşımı, ve bu bağlamda önerilen ESA mimarisi, ResNet50, Xception, InceptionV3, MobileNet ve DenseNet121 gibi derin öğrenme modelleri ile birlikte, modellerin eğitimi, optimizasyonu ve değerlendirilmesi için kullanılan yazılımlar ile kütüphaneler sistematik bir şekilde açıklanmıştır. Her bir aşamada uygulanan yöntemler, seçilen parametreler ve kullanılan spesifik araçlar, detaylı bir şekilde belirtilerek okuyucunun çalışmanın tüm adımlarını net bir şekilde anlaması hedeflenmiştir.

3.1. Yapay Zeka

Yapay zeka (YZ), insan zekâsını taklit ederek öğrenme, akıl yürütme, problem çözme ve karar verme gibi bilişsel işlevleri gerçekleştirebilen sistemlerin tasarımı ve geliştirilmesini konu alan bir disiplindir (İncemen ve Öztürk, 2024). Alan Turing'in "makinelere düşünebilir mi?" sorusuyla temelleri atılan YZ, günümüzde sağlık, finans, tarım ve savunma sanayi gibi pek çok alanda yaygın şekilde kullanılmaktadır (Buchanan, 2019). YZ sistemleri, geleneksel algoritmalardan farklı olarak, çevresinden gelen verileri analiz ederek kendi karar mekanizmasını şekillendirme yetisine sahiptir (İnce ve ark., 2021).

Bu tez kapsamında yapay zeka, görüntü işleme tabanlı sınıflandırma görevlerinde kullanılmış ve ceviz cinslerinin otomatik olarak ayrıştırılması hedeflenmiştir. Bu amaçla, görüntülerden elde edilen özniteliklerin işlenmesi ve uygun sınıflara atanması sürecinde yapay zeka alanının alt dallarından olan derin öğrenme yöntemleri kullanılarak belirli bir problem çözülmüştür.

3.2. Makine Öğrenmesi

Makine öğrenmesi (MÖ), açıkça programlanmadan verilerden öğrenebilen ve öğrendiklerini genelleyerek yeni durumlar hakkında tahmin yapabilen sistemler geliştirmeye odaklanan bir yapay zeka alt dalıdır (Ersöz ve Çınar, 2021). Geleneksel algoritmalar, belirli kurallar dizisine dayanırken; makine öğrenmesi, verilerden örüntüleri çıkararak kendi modelini oluşturur. Bu yönüyle özellikle büyük ve karmaşık veri kümeleriyle çalışmaya oldukça uygundur.

Makine öğrenmesi, genellikle üç temel kategoriye ayrılır: denetimli öğrenme (supervised learning), denetimsiz öğrenme (unsupervised learning) ve pekiştirmeli öğrenme (reinforcement learning) (Gökalp, 2022). Bu tezde kullanılan yöntem denetimli öğrenme olup, ceviz görüntüleri ile bu görüntülere ait sınıf etiketleri (ceviz cinsi) modele sağlanarak eğitim gerçekleştirilmiştir. Model, görüntülerin hangi sınıfa ait olduğunu öğrenmiş ve test aşamasında daha önce görmediği görüntüler üzerinde sınıflandırma yapabilmektedir.

Makine öğrenmesinin özellikle tarımsal üretimde kalite kontrol, hastalık tespiti ve ürün sınıflandırması gibi uygulamalarda kullanımı artmaktadır (Karadeniz, 2024). Bu bağlamda, çalışmada yer alan ceviz cinsi tanıma problemi, makine öğrenmesinin tarım sektöründe uygulama alanına dair önemli bir örnek teşkil etmektedir.


3.3. Derin Öğrenme

Derin öğrenme (DÖ), çok katmanlı yapay sinir ağları kullanarak verilerdeki karmaşık yapıları ve örüntüleri öğrenebilen bir makine öğrenmesi yaklaşımıdır. Geleneksel yöntemlerin öğrenemediği soyut ve yüksek boyutlu temsil düzeylerini öğrenme yeteneği sayesinde, özellikle görüntü, ses ve metin gibi yapılandırılmamış veriler üzerinde oldukça başarılı sonuçlar vermektedir (Şeker ve ark., 2017).

Derin öğrenme mimarileri, genellikle giriş katmanı, birden fazla gizli katman ve çıkış katmanından oluşur. Her bir gizli katman, önceki katmandan aldığı çıktıyı işleyerek daha

üst düzey özellikler oluşturur. Özellikle konvolüsyonel sinir ağları (CNN) gibi yapılar, görüntü işleme problemlerinde derin öğrenmenin en etkili uygulamaları arasında yer alır. Bu ağlar, insan gözüyle fark edilmesi zor olan detayları öğrenebilir ve sınıflandırma görevlerinde yüksek doğruluk sağlayabilir (Camkıran, 2023).

Bu tez çalışmasında, derin öğrenme yöntemleri aracılığıyla ceviz görüntülerinin sınıflandırılması hedeflenmiştir. Transfer öğrenme yaklaşımı ile önceden büyük veri kümeleri (ImageNet) üzerinde eğitilmiş modeller kullanılarak sınırlı veri ile yüksek başarılı sınıflandırma gerçekleştirilmiştir. Derin öğrenmenin sağladığı çok katmanlı öğrenme yeteneği sayesinde, ceviz görüntülerindeki küçük detaylar dahi ayırt edici özellik olarak öğrenilebilmiştir. Şekil 3.1.'de Yapay Zeka (YZ), Makine Öğrenmesi (MÖ) ve Derin Öğrenme (DÖ) arasındaki hiyerarşik ve kapsayıcı ilişkiyi görselleştirilmiştir.



Şekil 3.4.1. YZ, MÖ, DÖ arasındaki ilişki
(Akın ve Şahin, 2024)


3.4. Evrişimli Sinir Ağları (ESA)

Evrişimli Sinir Ağları (ESA) ya da İngilizce adıyla Convolutional Neural Networks (CNN), özellikle görüntü tanıma, sınıflandırma ve segmentasyon gibi bilgisayarla görme problemlerinde en sık tercih edilen derin öğrenme mimarilerindendir. Bu ağlar,

görüntülerden öznitelik çıkarımı yaparak sınıflandırma işlemini otomatik şekilde gerçekleştirme yeteneğine sahiptir (Gürbüz ve Yılmaz, 2023).

ESA'lar, görüntülerin yerel yapısını koruyarak farklı katmanlarda giderek soyutlaşan öznitelikleri öğrenir. Bu katmanlar, görüntüdeki kenarlar, köşeler, doku desenleri gibi yapısal bilgileri çıkaran konvolüsyon katmanları, bu bilgilerin boyutlarını azaltan havuzlama katmanları, sınıflandırma için karar veren tam bağlantılı katmanlar gibi yapılardan oluşur (Dikici ve ark., 2022).

Bu mimari, geleneksel yapay sinir ağlarından (YSA) farklı olarak, görüntünün piksel düzeyindeki yapısal ilişkilerini dikkate alır. Böylece yüksek çözünürlüklü görsellerde bile önemli öznitelikler kaybolmadan öğrenilebilir (Öztürk ve Şahin, 2018). ESA'ların bu özelliği, ceviz gibi yapısal çeşitlilik gösteren doğal objelerin görüntü analizi ve sınıflandırılmasında büyük avantaj sağlar (Şeker ve ark., 2017). Şekil 3.2.'de ESA genel mimarisi ve temel katmanları verilmiştir.



Şekil 3.4.1 ESA mimarisi ve katmanlar
(Büyükarıkan ve Ülker, 2020)

Aşağıdaki başlıklarda ESA'nın temel yapı taşları detaylı şekilde açıklanmıştır:

3.4.1. Giriş katmanı (Input layer)

Giriş katmanı, modelin alacağı verinin boyutlarını tanımlar ve ağın ilk katmanıdır.


Görüntü sınıflandırma problemlerinde bu katman, her bir görselin piksel değerlerini alarak ağıın iç katmanlarına iletir. Bu çalışmada tüm görüntüler 224x224 piksel boyutunda ve 3 kanallı (RGB) olacak şekilde giriş katmanına aktarılmıştır (Dağlı ve Öztürk, 2021). Giriş verisinin boyutsal olarak sabitlenmesi, hem model mimarisiyle uyumu sağlamakta hem de grafik işlem birimi (GPU) bellek yönetimini optimize etmektedir. Ayrıca tüm pikseller 0-1 aralığında normalize edilerek modelin daha hızlı ve kararlı öğrenmesi hedeflenmiştir (Wu ve ark., 2015).

3.4.2. Konvolüsyon katmanı (Convolution layer)

Konvolüsyon katmanı, Evrişimli Sinir Ağları'nın temel yapı taşlarından biridir ve giriş görüntüsünden anlamlı öznitelikler (kenarlar, dokular, desenler) çıkarmak için kullanılır. Bu katman, belirli boyuttaki filtreleri (örneğin 3×3 veya 5×5) görüntü üzerinde kaydırarak, yerel bölgelerdeki uzamsal ilişkileri analiz eder ve öznitelik haritaları (feature maps) üretir (Karaali ve Eminağaoğlu 2021).

Her filtre, görüntüde belirli bir deseni tanımak üzere eğitilir ve farklı konvolüsyon katmanları derinleştikçe daha soyut özellikleri (örneğin ceviz kabuğu dokusu, şekil yapısı) öğrenir. Bu süreçte, çıktı boyutu filtre sayısı kadar artarken, *padding* ve *stride* gibi hiperparametrelerle hem işlem yükü hem de çıktı boyutu kontrol altında tutulur. Filtre sayısı arttıkça modelin öğrenme kapasitesi artar, ancak bu durum bellekte daha fazla yer kullanımına ve hesaplama maliyetine neden olur (İnik ve Ülker 2017).

Bu çalışmada kullanılan derin modellerin erken katmanlarında düşük seviyeli, ileri katmanlarında ise yüksek seviyeli ceviz görüntü özellikleri öğrenilmiştir. Şekil 3.3'te, 5x5 boyutundaki bir giriş görüntüsüne 3x3 boyutundaki bir filtre uygulanarak evrişim (konvolüsyon) işleminin adım adım nasıl gerçekleştirildiği görselleştirilmiştir.




Şekil 3.3. Evrişim işlemi adımları

3.4.3. Havuzlama katmanı (Pooling layer)

Havuzlama katmanı, konvolüsyon katmanlarından elde edilen öznitelik haritalarının boyutunu azaltarak hem hesaplama maliyetini düşürmek hem de modelin genelleme yeteneğini artırmak amacıyla kullanılır. En yaygın kullanılan türü maksimum havuzlama (max pooling) olup, her bölgedeki en yüksek değeri seçerek önemli bilgileri korurken boyutu küçültür (Dağlı ve Öztürk, 2021).

Örneğin, 2x2 boyutunda ve stride=2 ile uygulanan bir max pooling işlemi, 224x224'lük bir öznitelik haritasını 112x112 boyutuna indirir. Bu sayede model daha az bellek kullanır ve gereksiz ayrıntılardan arındırılarak önemli yapıları öğrenmeye odaklanır. Aynı zamanda havuzlama, konum varyasyonlarına karşı modele dayanıklılık kazandırır; ceviz görüntüsünde objenin küçük kaymaları sınıflandırma performansını etkilemez (İnik ve Ülker 2017).

Bu çalışmada kullanılan tüm derin öğrenme modellerinde, konvolüsyon katmanlarının ardından yer alan havuzlama katmanları ile öznitelik yoğunluğu azaltılmış, eğitim süreci hızlandırılmıştır. Şekil 3.4.'te, öznitelik haritası üzerinde uygulanan Max Pooling ve Average Pooling işlemleri örneklenmiştir.



Şekil 3.4. Havuzlama katmanı Max pooling ve Average pooling işlemi


3.4.4. Tam bağlantılı katman (Fully connected layer)

Tam bağlantılı katman (Fully Connected – FC Layer), Evrişimli Sinir Ağı'nın sınıflandırma görevini gerçekleştiren son aşamasıdır. Bu katmanda, konvolüsyon ve havuzlama katmanlarında çıkarılan öznitelikler düzleştirilerek (*Flatten* veya *GlobalAveragePooling2D* gibi işlemlerle) tek boyutlu bir vektöre dönüştürülür.

Bu vektör, sınıflandırma için nöronlara tam bağlantı kurularak iletilir. Bu çalışmada kullanılan hazır modeller (*ResNet50*, *Xception*, *InceptionV3*, *MobileNet* ve *DenseNet121*), transfer öğrenme amacıyla `include_top=False` parametresiyle yüklenmiş ve sınıflandırma katmanları kaldırılmıştır. Bu modellerin sonuna, *GlobalAveragePooling2D* katmanı eklenmiş, ardından 5 çıkışlı ve *softmax* aktivasyonlu bir *Dense* katman yerleştirilerek 5 ceviz sınıfına yönelik çıktı alınması sağlanmıştır.

Ayrıca önerilen ESA mimarisinde, 64 nöron içeren bir adet tam bağlantılı katman yer almakta olup, bu katmandan sonra 5 sınıf için sınıflandırma işlemini gerçekleştiren *softmax* aktivasyonlu çıktı katmanı kullanılmıştır. Bu yapı, modelin hesaplama karmaşıklığını düşük tutarken yüksek doğruluk oranı elde etmesine olanak sağlamıştır.

(İnik ve Ülker, 2017). Şekil 3.5.'te, konvolüsyonel katmanlardan sonra elde edilen öznitelik haritasının düzleştirilerek tam bağlantılı katmanlara aktarılması süreci gösterilmektedir.




Şekil 3.5. Tam bağlantılı katman yapısı

FC katmanları yüksek sayıda ağırlık içerdiğinden modelin parametre yükü burada artar. Bu nedenle, aşırı öğrenmeyi önlemek amacıyla *dropout* ve *batch normalization* (BN) gibi tekniklerle birlikte kullanılmıştır (Gülle ve Temurtaş, 2024).

3.4.5. Seyreltme katmanı (Dropout)

Seyreltme katmanı (*Dropout*), derin öğrenme modellerinde aşırı öğrenmeyi (*overfitting*) önlemek amacıyla geliştirilen düzenleme (*regularization*) yöntemlerinden biridir. Bu katmanda, eğitim süreci boyunca her iterasyonda nöronların belirli bir oranı (örneğin %50) rastgele devre dışı bırakılır. Böylece modelin belirli özniteliklere aşırı bağımlılığı engellenir ve genelleme yeteneği artar (Farahmand, 2022). Şekil 3.6.'da, Evrişimli Sinir Ağı (ESA) yapısında seyreltme (*Dropout*) tekniğinin uygulanma biçimi gösterilmektedir.



Şekil 3.6. ESA seyreltme işlemi

Dropout, tam bağlantılı katmanlarda yüksek sayıda parametre bulunduğu için özellikle bu bölümlerde tercih edilir. Bu çalışmada kullanılan modellerde %50 oranında dropout uygulanarak hem modelin daha dengeli öğrenmesi hem de farklı örüntü kombinasyonlarını keşfetmesi sağlanmıştır (Çiftci, 2025).

3.5. Derin Öğrenme Ağ Modelleri


Bu çalışmada, görüntü sınıflandırma görevinde transfer öğrenmeye dayalı olarak beş farklı derin öğrenme modeli kullanılmıştır. Bu modeller, *ImageNet* veri seti üzerinde önceden eğitilmiş olup, özgün ceviz veri seti üzerinde yeniden eğitilerek özel sınıflandırma görevine adapte edilmiştir. Her modelin mimari yapısı ve sınıflandırma başarımı farklılık göstermektedir. Aşağıda her bir modelin yapısı özetlenmiştir:

3.5.1. ResNet50

ResNet50, derin öğrenme literatüründe çığır açan artık öğrenme (residual learning) kavramını tanıtan bir Evrişimli Sinir Ağı modelidir. 50 katman derinliğinden oluşan bu mimari, derin ağlarda sıklıkla karşılaşılan gradyan kaybı problemini, skip connection adı verilen atlamalı bağlantılarla çözerek çok daha derin yapıların eğitilebilmesine olanak sağlamıştır (Fırat ve Hanbay, 2022).


ResNet50, ceviz görüntülerinden yüksek seviyeli öznitelikleri öğrenmede oldukça başarılı olmuş ve yüksek doğruluk oranları elde etmiştir. Ayrıca, artık blok yapısı sayesinde eğitim sırasında parametre güncellemeleri daha stabil hale gelmiştir.

Şekil 3.7’de, ResNet50 mimarisinin genel yapısı gösterilmiştir. Model, giriş katmanında 7×7 evrişim ve maksimum havuzlama işlemi ile başlamakta; ardından çok katmanlı evrişim ve kimlik bloklarıyla derinleştirilmektedir. Son kısımda ortalama havuzlama ve tam bağlantılı katman kullanılarak sınıflandırma işlemi tamamlanmaktadır (Fırat ve Hanbay, 2022).



Şekil 3.7. ResNet50 mimarisinin genel yapısı
(Fırat ve Hanbay, 2022)

ResNet50 mimarisinin temel yapı taşı olan artık (residual) blok yapısı ise Şekil 3.8’de gösterilmiştir. Bu yapıda, girişten gelen veri X , ardışık evrişim katmanları ve ReLU aktivasyonları ile işlenerek $F(x)$ dönüşümüne uğratılır. Ardından giriş verisi doğrudan çıkışa eklenerek $H(x) = F(x) + x$ ifadesi elde edilir. Bu mekanizma, hem bilgi kaybını önler hem de öğrenmeyi kolaylaştırır (Fırat ve Hanbay, 2022).




Şekil 3.8. ResNet50 mimarisinde kullanılan artık blok yapısı
(Fırat ve Hanbay, 2022)

3.5.2. Xception

Xception modeli, Inception mimarisine alternatif olarak geliştirilmiş ve tamamen derinlik ayrıştırılmalı konvolüsyonlar (depthwise separable convolutions) üzerine inşa edilmiştir. Bu yapı, standart konvolüsyonları iki ayrı adımda — önce uzamsal, ardından kanalsal — uygulayarak hem hesaplama maliyetini azaltır hem de daha etkili öznetelik çıkarımı sağlar (Chollet, 2017). Özellikle karmaşık desenlere sahip görüntülerde başarılı sonuçlar vermektedir.

Bu çalışmada, Xception modeli ceviz kabuğundaki girintili yapılar, çizgiler ve yüzey detayları gibi mikro düzeydeki ayırt edici özneteliklerin yakalanmasında etkili olmuştur. Derinlik ayrıştırılmalı yapı sayesinde model, her bir filtreyi daha bağımsız ve verimli şekilde optimize edebilmiştir.

Şekil 3.9’da, Xception mimarisinin genel yapısı sunulmaktadır. Mimari üç ana bloktan oluşmaktadır: *Entry Flow*, *Middle Flow* ve *Exit Flow*. Giriş bloğunda temel özellikler çıkarılırken, orta akış bölümünde aynı yapılar sekiz kez tekrar edilerek daha soyut öznetelikler öğrenilir. Çıkış bloğunda ise sınıflandırma için kullanılan *Global Average Pooling* ve *softmax* katmanları yer almaktadır (Westphal ve Seitz, 2021).



Şekil 3.9. Xception mimarisinin genel yapısı (Westphal ve Seitz, 2021)


Bu modüler yapı, modelin esnekliğini artırmakta ve farklı görevlerde yeniden kullanılabilirliğini mümkün kılmaktadır.

3.5.3. InceptionV3

InceptionV3, farklı boyutlardaki konvolüsyon filtrelerini aynı anda uygulayarak çok yönlü öznitelik çıkarımı gerçekleştiren gelişmiş bir Evrişimli Sinir Ağı mimarisidir. Bu yapı, hem düşük seviyeli kenar bilgilerini hem de yüksek seviyeli desen yapılarını eşzamanlı öğrenmeyi mümkün kılar (Özdemir, 2023). Model, özellikle karmaşık sahnelerde çok boyutlu bilgi işleme avantajı sunar.

Ceviz sınıflandırma gibi doğal nesnelerin analiz edildiği bu çalışmada, InceptionV3 modeli hem genel hem de yerel görsel özellikleri başarıyla yakalamış; kabuk yapısı, doku dağılımı gibi ayırt edici detayların çıkarılmasında etkili olmuştur. Optimize edilmiş yapısı sayesinde daha az bellek tüketimi ve işlem gücü ile yüksek doğruluk elde edilmiştir.

Şekil 3.10'da, InceptionV3 mimarisinin genel blok yapısı görselleştirilmiştir. Modeldeki temel prensip, her katmanda birden fazla boyutta filtre ile işlem yapılması ve ardından bu bilgilerin birleştirilmesidir. Böylece bilgi kaybı minimize edilirken detaylı öznitelik temsili sağlanır (Nogueira ve ark., 2022).



Şekil 3.10. InceptionV3 mimarisinin genel yapısı

(Nogueira ve ark., 2022)

Bu yapı, ceviz görüntülerindeki şekil çeşitliliği ve dokusal karmaşıklığın modellenmesinde büyük avantaj sağlamıştır.


3.5.4. MobileNet

MobileNet, mobil ve gömülü sistemlerde kullanılmak üzere tasarlanmış hafif ve verimli bir Evrişimli Sinir Ağı (ESA) mimarisidir. Bu model, derinlik ayrıştırılabilir konvolüsyonlar kullanarak parametre sayısını ve hesaplama yükünü önemli ölçüde azaltır. Böylece, düşük kaynaklı cihazlarda dahi yüksek doğrulukla çalışabilen bir yapı elde edilmiş olur (Howard ve ark., 2017).

Bu çalışmada MobileNet, sınırlı donanım koşulları altında yüksek performans sunabilen yapısıyla tercih edilmiştir. Ceviz sınıflandırma görevinde eğitim süresi oldukça kısalmış, bazı senaryolarda daha büyük mimarilerle karşılaştırılabilir doğruluk değerleri elde edilmiştir (Bakır ve Eker, 2023).

Şekil 3.11’de MobileNet mimarisinin genel yapısı gösterilmektedir. Giriş görüntüsü, öncelikle 3×3 konvolüsyon katmanları ve ardından ardışık derinlik ayrıştırılabilir evrişim blokları ile işlenmektedir. Bu bloklarda her konvolüsyon işlemi, önce uzamsal olarak sonra da kanalsal olarak ayrılarak uygulanır. Modelin ilerleyen katmanlarında öznetelik

haritaları giderek daraltılırken, kanal sayısı artırılır. Son bölümde ortalama havuzlama, tam bağlantılı katman ve softmax aktivasyonu ile sınıflandırma tamamlanır (Saini ve Devi, 2023).



Şekil 3.11. MobileNet mimarisinin katman yapısı
(Saini ve Devi, 2023)

Bu kompakt yapı, özellikle mobil uygulamalarda, gerçek zamanlı görüntü işleme sistemlerinde ve düşük bellekli gömülü cihazlarda kullanılmak üzere oldukça uygundur.


3.5.5. DenseNet121

DenseNet121, her katmanın önceki tüm katmanların çıktılarıyla bağlantılı olduğu yoğun bağlantı prensibine (dense connectivity) dayalı bir Evrişimli Sinir Ağı mimarisidir. Bu yapı, bilgi akışını ve gradyan yayılımını artırarak modelin öğrenme kapasitesini geliştirirken, aynı zamanda parametre sayısını da azaltmaktadır (Kılıçarslan ve Pacal, 2023).

Bu çalışmada DenseNet121, ceviz sınıflandırma gibi detay ayrımı gerektiren görüntü işleme görevlerinde etkili bir performans sergilemiştir. Her katmanın önceki tüm katmanlardan bilgi alması sayesinde, model daha zengin öznetelik temsilleri oluşturabilmiş ve özellikle benzer ceviz türleri arasında ayırım yapmada üstünlük

sağlamıştır. Ayrıca, çok derin olmamasına rağmen verimli eğitim süreci ve hızlı yakınsama özelliği ile tercih edilmiştir.

Şekil 3.12’de DenseNet121 mimarisinin genel yapısı sunulmaktadır. Model dört adet Dense Block içermektedir ve her bloğun arasında yer alan geçiş katmanları (Transition Layers), evrişim ve havuzlama işlemleri ile boyutları düzenlemektedir. Tüm ağ boyunca yoğun bağlantılar korunarak bilgi akışı maksimize edilir. Son bloktan sonra ortalama havuzlama ve softmax katmanları aracılığıyla sınıflandırma işlemi tamamlanmaktadır (Albelwi, 2022).



Şekil 3.12. DenseNet121 mimarisinin genel yapısı

(Albelwi, 2022)

Bu kompakt ve etkin yapı, sınırlı veri ile çalışan derin öğrenme uygulamaları için güçlü bir seçenek sunmaktadır.

3.6. ESA’da Kullanılan Hiperparametreler

3.6.1. Öğrenme oranı (Learning rate)

Öğrenme oranı, modelin her adımda ağırlıklarının ne kadar değiştireceğini belirleyen bir

parametredir. Çok düşük bir öğrenme oranı, modelin öğrenme sürecini yavaşlatırken; çok yüksek bir oran, modelin optimal çözüme ulaşmadan sapmasına neden olabilir. Bu tez çalışmasında, istikrarlı ve dengeli bir eğitim süreci için 0.0001 ($1e-4$) değerinde sabit öğrenme oranı kullanılmıştır. *Adam optimizatörü* ile birlikte kullanılan bu oran, yavaş ama kararlı bir yakınsama sağlamıştır (Altun ve Talu, 2021).

3.6.2. Kayıp fonksiyonu (Loss function)

Kayıp fonksiyonu, modelin tahmin ettiği değer ile gerçek etiket arasındaki farkı sayısal olarak ifade eder. Çok sınıflı sınıflandırma problemleri için en yaygın kullanılan fonksiyon olan categorical crossentropy bu çalışmada tercih edilmiştir. Bu fonksiyon, modelin hangi sınıfı ne kadar yanlış tahmin ettiğini ölçerek ağırlıkların güncellenmesini sağlar (Bulut, 2023).

3.6.3. Tur (epoch) sayısı

Epoch, tüm eğitim verisinin model tarafından bir kez görülmesi anlamına gelir. Bu çalışmada her model için eğitim 60 epoch boyunca sürdürülmüştür. Bu sayede model, veri setindeki örüntüleri yeterince öğrenmiş, ancak aşırı öğrenmeye düşmeden genelleme yapabilecek seviyeye gelmiştir. Eğitim süresince doğruluk ve kayıp değerleri grafiklerle takip edilerek erken durdurma gerekmeden öğrenme tamamlanmıştır (Kayalı ve Omurca, 2021).

3.6.4. Optimizasyon algoritmaları

Optimizasyon algoritmaları, derin öğrenme modellerinde ağırlıkların güncelleyerek modelin hata oranını (kayıp fonksiyonunu) minimize etmeyi amaçlayan yöntemlerdir. Bu algoritmaların amacı, modelin öğrenme sürecini yönlendirmek, daha hızlı ve kararlı bir şekilde en iyi ağırlık değerlerine ulaşmasını sağlamaktır. Bu çalışmada *Adam (Adaptive Moment Estimation)* tercih edilmiştir. Adam, hem momentum hem de adaptif öğrenme oranlarını birleştirerek daha hızlı ve istikrarlı bir öğrenme süreci sunar. Özellikle konvolüsyonel mimarilerde yaygın olarak kullanılmakta ve birçok çalışmada *Stochastic Gradient Descent (SGD)*'ye kıyasla daha hızlı yakınsama sağlamaktadır (Seyyarer ve

ark., 2020). Derin öğrenmede en yaygın kullanılan optimizasyon algoritmalarından bazıları aşağıda özetlenmiştir:

SGD: En temel optimizasyon algoritmasıdır. Her adımda veri setinden rastgele bir alt küme (*mini batch*) seçilerek gradyan hesaplanır ve ağırlıklar güncellenir. Basit yapısına rağmen, öğrenme hızı yavaş olabilir ve lokal minimumlara takılma riski vardır.

Momentum: SGD'ye bir "momentum" etkisi ekleyerek, önceki güncellemelerin yönünü korur ve öğrenmenin daha kararlı olmasını sağlar. Özellikle dalgalı gradyanlarda faydalıdır.

AdaGrad: Öğrenme oranını her parametre için ayrı ayrı uyarlayan bir algoritmadır. Sık güncellenen parametrelerin öğrenme oranını zamanla azaltarak aşırı öğrenmeyi engeller. Ancak uzun vadede öğrenme oranı çok küçülebilir.

RMSProp: AdaGrad'in zayıf yönünü geliştirerek öğrenme oranını sabit tutar. Özellikle zaman serisi ve döngüsel sinir ağlarında etkili sonuçlar verir.

Adam (Adaptive Moment Estimation): AdaGrad ve RMSProp'un avantajlarını birleştirir. Hem momentum hem de adaptif öğrenme oranı içerir. Her bir ağırlık için ayrı öğrenme oranı hesaplar. Derin öğrenme uygulamalarında en yaygın tercih edilen optimizatörlerden biridir (Seyyarer ve ark., 2020).

3.6.5. Yığın (Batch size) boyutu

Yığın boyutu (Batch size), modelin her ağırlık güncellemesi sırasında işlediği örnek sayısını ifade eder. Eğitim verisi, bu yığınlarla bölünerek ardışık şekilde modele sunulur. Bu parametre, hem eğitim süresini hem de modelin öğrenme dinamiklerini doğrudan etkileyen kritik bir hiperparametredir (Akman, 2022).

Genel olarak, batch size boyutu aşağıda belirtilen üç ana senaryoya ayrılır:

- Mini-batch (ör. 16, 32, 64): Hem donanım verimliliği sağlar hem de gradyan hesaplamalarında istikrar sunar. Derin öğrenmede en yaygın kullanılan yöntemdir.
- Batch learning (tüm veri tek seferde): Bellek maliyeti çok yüksektir, büyük veri

setlerinde pratik değildir.

- Stochastic (batch size = 1): Her seferde tek örnek işlenir, gürültülü gradyan nedeniyle kararsız öğrenmeye yol açabilir.

Bu çalışmada, modelin eğitim sürecinde batch size = 20 olarak belirlenmiştir. Bu değer, aşağıdaki faktörler dikkate alınarak deneysel olarak seçilmiştir:

- Bellek Kullanımı (GPU belleği): 20 örnek, her bir iterasyonda yaklaşık 12 MB'lık giriş belleği kullanımı ile sistem kaynakları açısından verimli çalışmayı sağlamıştır.
- Gradyan kararlılığı: Batch size çok küçük olduğunda gürültülü gradyanlar nedeniyle model kararsız öğrenebilir; çok büyük olduğunda ise genelleme yeteneği zayıflayabilir. 20'lik mini-yığın, doğruluk ve kayıp değerlerinde dengeli bir seyir sağlamıştır.
- Eğitim süresi ve epoch sayısı dengesi: Daha küçük yığınlarla daha fazla iterasyon yapılırken, bu yapı öğrenme sürecini daha ayrıntılı yönlendirmiştir.

Ayrıca kullanılan veri artırma teknikleri, her batch içerisinde rastgele yeni görüntüler ürettiğinden, küçük yığın boyutları modelin daha fazla çeşitlilikte veriyle karşılaşmasına ve böylece aşırı öğrenmenin azaltılmasına katkı sağlamıştır.

3.7. Değerlendirme Metrikleri

Derin öğrenme modellerinin başarımını ölçmek ve modeller arasında karşılaştırma yapabilmek için çeşitli performans metriklerine ihtiyaç vardır. Bu çalışmada sınıflandırma performansını ölçmek için beş temel metrik kullanılmıştır: Karışıklık Matrisi, Doğruluk, Kesinlik, Duyarlılık ve F1 Skoru. Her biri farklı bir açıdan modeli değerlendirdiğinden birlikte yorumlanmaları önemlidir (Al-Doori, 2022).

3.7.1. Karışıklık matrisi (Confusion matrix)

Karışıklık matrisi, modelin her sınıfa ait doğru ve yanlış tahminlerini görsel olarak sunan tablodur. Satırlar gerçek sınıfları, sütunlar ise modelin tahmin ettiği sınıfları temsil eder. Böylece hangi sınıfın hangi sınıflarla karıştırıldığı doğrudan gözlemlenebilir (Al-Doori,

2022). Şekil 3.13'te, sınıflandırma problemlerinde modelin performansını değerlendirmek için yaygın olarak kullanılan karışıklık matrisi (confusion matrix) yapısı gösterilmektedir.

KARIŞIKLIK MATRİSİ		TAHMİN EDİLEN DEĞER	
		POZİTİF	NEGATİF
GERÇEK DEĞER	POZİTİF	DOĞRU POZİTİF (TP)	YANLIŞ POZİTİF (FP)
	NEGATİF	YANLIŞ NEGATİF (FN)	DOĞRU NEGATİF (TN)

Şekil 3.13. Karışıklık matrisi

True Positive (TP): Gerçek pozitiflerin doğru pozitif olarak tahmini

True Negative (TN): Gerçek negatiflerin doğru bir şekilde negatif olarak tahmini

False Positive (FP): Gerçek negatiflerin yanlışlıkla pozitif olarak tahmini

False Negative (FN): Gerçek pozitiflerin yanlışlıkla negatif olarak tahmini

Bu tezde, her modelin test sonuçlarına ait karışıklık matrisleri oluşturulmuş ve Seaborn kütüphanesi kullanılarak görselleştirilmiştir. Bu sayede, hangi ceviz cinslerinin daha fazla karıştırıldığı analiz edilmiştir.

3.7.2. Doğruluk (Accuracy)

Doğruluk, modelin yaptığı toplam doğru tahminlerin, tüm tahminlere oranıdır. Çok sınıflı sınıflandırma problemlerinde genellikle ilk bakılan başarı ölçütüdür (Al-Doori, 2022). Doğruluk değeri aşağıdaki formül ile hesaplanır:

$$\text{Doğruluk} = \frac{(TP + TN)}{(TP + TN + FP + FN)} \quad (3.1)$$

Bu tezde kullanılan tüm ESA modelleri için eğitim, doğrulama ve test aşamalarında

doğruluk oranları ayrı ayrı hesaplanmış ve karşılaştırmalı tablolar ile görselleştirilmiştir.

3.7.3. Kesinlik (Precision)

Kesinlik, bir sınıfa ait olduğu tahmin edilen örneklerden gerçekten o sınıfa ait olanların oranını verir. Yanlış pozitiflerin (False Positive) çok önemli olduğu senaryolarda tercih edilir (Al-Doori, 2022). Kesinlik değeri aşağıdaki formül ile hesaplanır:

$$Kesinlik = \frac{TP}{(TP + FP)} \quad (3.2)$$

Özellikle sınıflar arasında dengesizlik varsa, sadece doğruluk yeterli değildir; kesinlik, modelin hatalı sınıf atamalarını ne kadar az yaptığını gösterir.

3.7.4. Duyarlılık (Recall)

Duyarlılık ya da duyarlık, bir sınıfa ait tüm gerçek örneklerin ne kadarının doğru tahmin edildiğini gösterir. Yani modelin, gerçek pozitifleri yakalama başarısını ifade eder (Al-Doori, 2022). Duyarlılık değeri aşağıdaki formül ile hesaplanır:

$$Duyarlılık = \frac{TP}{(TP + FN)} \quad (3.3)$$

Bu metrik, özellikle kaçırılan örneklerin (False Negatives) kritik olduğu uygulamalarda önemlidir. Örneğin, nadir bulunan bir ceviz türünü tanıma oranı, recall ile ölçülür.

3.7.5. F1 Skoru (F1-Score)

F1 Skoru, kesinlik ve duyarlılığın harmonik ortalamasıdır. Bu metrik, iki değeri birleştirerek daha dengeli bir performans ölçümü sağlar. Özellikle sınıf dengesizliği olan veri setlerinde daha anlamlıdır (Al-Doori, 2022). F1 Skoru değeri aşağıdaki formül ile hesaplanır:

$$F1\ Skoru = 2 \times \frac{(Kesinlik \times Duyarlılık)}{(Kesinlik + Duyarlılık)} \quad (3.4)$$

F1 skoru, bu çalışmada her bir model için ağırlıklı ortalama yöntemiyle hesaplanmış ve karşılaştırma tablolarında yer almıştır.

3.8. Veri Artırma

Veri artırma (Data Augmentation), sınırlı sayıda eğitim verisini yapay yollarla çoğaltarak modelin genelleme yeteneğini artırmak amacıyla kullanılan bir tekniktir. Derin öğrenme modelleri, yüksek başarıya ulaşabilmek için büyük ve çeşitli veri kümelerine ihtiyaç duyar. Ancak gerçek dünyada yeterli sayıda etiketli veri toplamak maliyetli ve zaman alıcı olabilir. Bu noktada veri artırma, mevcut görüntüler üzerinde çeşitli dönüşümler uygulanarak yeni örnekler oluşturulmasını sağlar (Shorten & Khoshgoftaar, 2019).

Bu çalışmada kullanılan *ImageDataGenerator* sınıfı aracılığıyla aşağıdaki veri artırma işlemleri uygulanmıştır:

Rastgele döndürme (*rotation_range=40*): Görüntüler $\pm 40^\circ$ arasında rastgele döndürülerek farklı açılardan bakış simüle edilmiştir.

Genişlik ve yükseklik kaydırma (*width_shift_range, height_shift_range=0.2*): Görüntüler yatay ve dikey ekseninde %20 oranında kaydırılarak pozisyon çeşitliliği kazandırılmıştır.

Kesme (*shear_range=0.2*): Görüntülerde paralaks (ıraklık açısı) benzeri geometrik bozulmalar oluşturularak modelin duyarlılığı artırılmıştır.

Yakınlaştırma (*zoom_range=0.2*): Görüntüler rastgele yakınlaştırılarak farklı ölçek seviyelerinde eğitim sağlanmıştır

Yatay çevirme (*horizontal_flip=True*): Görüntüler yatay ekseninde çevrilerek yansıtılmış örnekler elde edilmiştir.

Boşluk doldurma (*fill_mode='nearest'*): Uygulanan dönüşümler sırasında ortaya çıkan boş pikseller, en yakın komşu piksel değeriyle doldurulmuştur.

Bu işlemler sayesinde model her epoch sırasında farklı varyasyonlarla karşılaşmış ve eğitim süreci daha çeşitli veri örnekleriyle desteklenmiştir. Böylece modelin sadece ezberleyici değil, genelleme bir yapıya ulaşması sağlanmış, aşırı öğrenme (overfitting) riski azaltılmıştır.

Ayrıca, ceviz görsellerinin doğal olarak çeşitli şekil, boyut ve yüzey desenlerine sahip olması nedeniyle, bu dönüşümler gerçek dünyadaki varyasyonu yansıtmaya açısından oldukça uygun olmuştur.

3.9. Çalışmada Kullanılan Yazılımlar ve Kütüphaneler

Bu tez çalışmasında tüm analizler, model eğitimleri ve görselleştirmeler Python programlama dili ve ilgili açık kaynak kütüphaneler kullanılarak gerçekleştirilmiştir. Python'un zengin ekosistemi, hem görüntü işleme hem de derin öğrenme uygulamaları için güçlü araçlar sunmaktadır.

3.9.1. Python

Python, okunabilir sözdizimi, geniş kütüphane desteği ve topluluk katkıları sayesinde bilimsel hesaplama, makine öğrenmesi ve yapay zeka alanlarında yaygın olarak kullanılan bir programlama dilidir (Çetinkaya ve Sertbaş, 2022).

3.9.2. NumPy

NumPy, çok boyutlu diziler (arrays) üzerinde yüksek performanslı sayısal işlemler yapılmasını sağlayan temel kütüphanedir. Görüntü verilerinin matris formatında işlenmesinde kullanılmıştır (Çetinkaya ve Sertbaş, 2022).

3.9.3. Pandas

Pandas, tablo yapısındaki verilerin düzenlenmesi, filtrelenmesi ve analiz edilmesi için kullanılır. Model sonuçlarının analizinde ve doğruluk/performans tablolarının oluşturulmasında kullanılmıştır (Kacı ve ark., 2025).

3.9.4. Matplotlib

Matplotlib, grafik ve görsel çıktılar üretmek için kullanılan bir kütüphanedir. Eğitim ve doğrulama süreçlerine ait doğruluk/kayıp grafiklerinin çiziminde kullanılmıştır (Kacı ve ark., 2025).

3.9.5. Seaborn

Seaborn, istatistiksel veri görselleştirilmesi için Matplotlib'e dayalı daha gelişmiş bir kütüphanedir. Özellikle karışıklık matrisi gibi ısı haritalarının oluşturulmasında kullanılmıştır (Kacır ve ark., 2025).

3.9.6. Keras

Keras, kullanıcı dostu arayüzüyle derin öğrenme modellerinin hızlı ve esnek şekilde oluşturulmasını sağlar (Aktürk ve Serbest, 2022). Bu tezde model mimarilerinin kurulumu, eğitim ve değerlendirme işlemleri Keras ile gerçekleştirilmiştir.

3.9.7. TensorFlow

TensorFlow, Google tarafından geliştirilen açık kaynak bir derin öğrenme kütüphanesidir. Keras arka planında çalışarak modelin eğitimi sırasında GPU desteği ve otomatik türev hesaplamaları sağlamıştır (Aktürk ve Serbest, 2022).

3.9.8. Scikit-learn

Scikit-learn, makine öğrenmesi algoritmaları ve değerlendirme metriklerini içeren bir Python kütüphanesidir (Kacır ve ark., 2025). Doğruluk, kesinlik, duyarlılık, F1 skoru gibi sınıflandırma metriklerinin hesaplanmasında kullanılmıştır.

3.9.9. OpenCV

OpenCV, görüntü işleme alanında yaygın olarak kullanılan bir açık kaynak kütüphanedir. Görsellerin kırılması, kontur tespiti, boyutlandırma ve arka plan temizleme gibi işlemler bu kütüphane ile yapılmıştır (Kahya ve Özdüven, 2023).

3.9.10. Bleak

Bleak, Bluetooth üzerinden cihazlarla haberleşmek için kullanılan bir Python kütüphanesidir (Gamauf, 2025). ESP32 kartı ile Bluetooth bağlantısının kontrol edilmesinde görev almıştır.

3.9.11. adb_shell

Bu kütüphane, Android cihazlara komut gönderilmesini sağlayan ADB (Android Debug Bridge) üzerinden bağlantı kurar (Prathiba, 2025). Xiaomi 13 Pro ile görüntü alma sürecinde Python üzerinden kamera tetikleme işlemlerinde kullanılmıştır.

3.9.12. Asyncio

Asyncio, Python'da eş zamanlı görevlerin (asynchronous tasks) yürütülmesi için kullanılan modüldür (Hassan ve ark., 2023). Bu çalışmada, Görüntü alma, kaydetme ve motor kontrol komutlarının senkronize yürütülmesinde tercih edilmiştir.

3.9.13. Os

OS modülü, Python programlama dilinin yerleşik bir bileşeni olup, kullanıcıların dosya sistemleri ve izinler üzerinde kolayca işlem yapmasına olanak tanır. Bu çalışmada Os modülü, dosya yolu tanımlamaları, klasör oluşturma, görsellerin taşınması ve sistem komutlarının çalıştırılması gibi işlemler için kullanılmıştır (Medium, 2019).

3.9.14. Arduino IDE

Arduino IDE, mikrodenetleyicilerin programlanması için kullanılan açık kaynaklı bir geliştirme ortamıdır (Yılmaz ve Ustun, 2023). Bu çalışmada, ESP32 kartının programlanması ve step motorun kontrol komutlarının oluşturulması için Arduino IDE kullanılmıştır. Arduino C/C++ diliyle yazılan komutlar sayesinde ESP32, Bluetooth bağlantısı ve motor sürüşü gibi görevleri yerine getirmiştir. Python tarafındaki sistem ile entegre çalışacak şekilde yapılandırılmış bu programlar, veri toplama sürecinin otomasyonunda kritik rol oynamıştır.

3.10. Veri Seti Oluşturulması


Bu tez çalışmasında, sınıflandırma modellerinin eğitilmesi için ihtiyaç duyulan görüntü verisi, hazır bir veri kümesi yerine tamamen özgün biçimde oluşturulmuştur. Veri toplama süreci, kontrollü koşullarda ve otomasyon desteğiyle gerçekleştirilmiş; yüksek kalitede, etiketli ve dengeli bir ceviz görüntü veri seti hazırlanmıştır.

3.10.1. Ceviz cinsleri

Bu çalışmada sınıflandırılması hedeflenen ceviz cinsleri, Tokat ili Niksar ilçesi Sorhun köyü ve çevresindeki yerel üreticilerden temin edilmiştir. Ceviz türleri, hem bölgesel çeşitliliği hem de morfolojik farkları temsil edebilecek şekilde seçilmiştir. Beş farklı cinsin her biri için beşer adet örnek kullanılmıştır. Aşağıda çalışmada kullanılan ceviz türleri ve temel özellikleri sunulmuştur:

- *Bilecik Cinsi*: Türkiye menşeli bu tür, özellikle Marmara ve İç Anadolu bölgelerinde yaygın olarak yetiştirilir. İnce kabuklu yapısı, kolay kırılabilirliği ve iç randıman oranının yüksek olması ile bilinir. Dış kabuğu açık kahverengi olup yüzeyinde belirgin çizgiler bulunur (Erkol ve ark., 2008).
- *Chandler Cinsi*: ABD orijinli olan Chandler, dünya genelinde en çok tercih edilen ticari ceviz türlerinden biridir. Geç çiçeklenmesi sayesinde ilkbahar geç donlarından etkilenmez (Olut, 2018).
- *Fernette Cinsi*: Fransız kökenli bu tür, Chandler ile birlikte tozlayıcı olarak kullanılır. Kabukları kalın fakat çatlamaya dirençlidir. İç kısmı yağ oranı bakımından zengindir ve derin kıvrımlı yapısı nedeniyle bazı mekanik ayırma sistemlerinde zorluk yaratabilir (Şen ve ark., 2018).
- *Yavuz Cinsi*: Türkiye'de son yıllarda geliştirilen yerli bir türdür. Soğuğa dayanıklı, verimli ve açık kabuk rengine sahip olması nedeniyle özellikle Karadeniz ve İç Anadolu'da yaygınlaşmaktadır. Oval yapısı ve homojen büyüklüğü ile sınıflandırmada ayırt edici özellikler taşır (Bayazıt ve ark., 2019).
- *Niksar Cinsi*: Bölgeye özgü, yerel üreticiler tarafından uzun süredir yetiştirilen bir ceviz türüdür. Bu tür, geleneksel yöntemlerle çoğaltılmıştır ve bölgenin iklimine yüksek adaptasyon göstermiştir. Kabuk yapısı orta kalınlıkta olup iç kısmı dolgun ve aromatiktir (Çukur ve ark., 2020).

Şekil 3.14'te bu tez çalışmasında sınıflandırılması hedeflenen beş farklı ceviz cinsine ait örnek görseller yer almaktadır.



Şekil 3.10.1 Beş farklı ceviz cinsine ait örnek görseller

Bu beş ceviz cinsi, morfolojik olarak birbirine yakın olmakla birlikte; kabuk rengi, yüzey desenleri, büyüklük, kıvrım yapısı ve iç doluluk gibi görsel özellikler bakımından ayırt edici nitelikler taşımaktadır. Bu farklılıklar, derin öğrenme modelleri tarafından öğrenilerek sınıflandırma yapılmasını mümkün kılmıştır.


3.10.2. Kullanılan ekipmanlar

Veri toplama işlemleri aşağıdaki donanım bileşenleri ile gerçekleştirilmiştir:

- ESP32 Mikrodenetleyici Kartı: Bu tez kapsamında, fotoğraf çekim işlemini otomatik hale getirmek ve step motoru kontrol etmek amacıyla ESP32 mikrodenetleyici tercih edilmiştir. İki çekirdekli işlemci mimarisine sahip olan bu cihaz, 4 MB'lık flaş bellek ile birlikte WiFi ve Bluetooth bağlantı olanaklarını sunmaktadır (Başçıftçi ve Gündüz, 2019). Programlama işlemleri Arduino IDE üzerinde gerçekleştirilmiş; C++ ve Python dilleri kullanılmıştır.
- Step Motor: Ceviz örneklerinin hem dikey hem de yatay düzlemde hassas şekilde döndürülmesi için redüktörlü step motor kullanılmıştır. Düşük devirli fakat yüksek hassasiyetli hareket kabiliyetine sahip olan bu motor, ULN2003 motor sürücü modülü aracılığıyla kontrol edilmiştir (Güler, 2018). Kompakt yapısı ve düşük enerji tüketimi sayesinde projede tercih edilmiştir.
- Xiaomi 13 Pro Akıllı Telefon: Görüntülerin yüksek çözünürlükle elde edilmesi amacıyla, bu cihaz ana kamera olarak kullanılmıştır. 50 megapiksel çözünürlüğe, 1 inçlik sensör boyutuna, f/1.9 diyafram açıklığına ve 23 mm odak uzaklığına sahip olan kamera, otomatik modda, otomatik netleme ve beyaz dengesi ayarları açık şekilde kullanılmıştır. Görüntüler JPEG formatında kaydedilmiştir (Xiaomi, t.y.).

- Arka Plan Düzenlemesi: Arka plan olarak düz beyaz bir karton kullanılmıştır. Bu seçim, görüntülerdeki ceviz konturlarının daha net şekilde ayrıştırılmasına ve arka plan kaynaklı gürültünün azaltılmasına katkı sağlamıştır.
- Işık Düzeni: Fotoğraf çekimleri ev ortamında, özellikle akşam saatlerinde ve sabit bir ışık düzeyi sağlanarak gerçekleştirilmiştir. Telefon kamerası, ceviz numunelerine yaklaşık 30 cm mesafede yerleştirilmiştir. Bu kurulum sayesinde, gölgelenmeler azaltılmış ve tüm görüntülerde tutarlı bir ışık dağılımı sağlanmıştır.
- Yardımcı Donanımlar: Ceviz örneklerinin sabit durmasını sağlamak amacıyla, PLA filament kullanılarak 3B yazıcıda özel bir platform tasarlanmış ve üretilmiştir. Bu platform sayesinde, her bir görüntü aynı açıda ve konumda alınabilmektedir. Görüntülerin bilgisayara aktarımı ise Universal Serial Bus (USB) kablosu aracılığıyla sağlanmıştır.

Şekil 3.15.'de, bu çalışmada ceviz görüntülerinin otomatik olarak alınmasını sağlayan sistemde kullanılan temel donanım bileşenleri gösterilmektedir.



Şekil 3.15. Görüntü toplama sisteminde kullanılan donanım bileşenleri


3.10.3. Veri toplama prosedürü

Bu çalışmada, her bir ceviz türünden beş adet örnek kullanılmıştır. Numune sayısının sınırlı olması, çalışmanın temel kısıtlarından biri olup, ilerleyen araştırmalarda daha fazla sayıda örnek ile veri setinin genişletilmesi önerilmektedir. Seçilen cevizler, olgun, orta boyutlu, kabuklarında çatlak ya da fiziksel kusur bulunmayan sağlıklı bireylerden oluşmuştur. Boyut ölçümleri cetvel yardımıyla gerçekleştirilmiş ve seçilen örneklerin benzer boyut aralığında olmasına özen gösterilmiştir. Bu yöntem, modelin belirli

boyutlara aşırı uyum göstermesini önleyerek daha dengeli bir öğrenme süreci sağlamayı amaçlamıştır.

Çalışmada yer alan Bilecik, Chandler, Fernette, Yavuz ve Niksar ceviz çeşitlerine ait örnekler, 2024 yılı Ekim ayında, hasat döneminde Tokat ili Niksar ilçesine bağlı Sorhun Köyü'ndeki yerel üreticilerden temin edilmiştir.


Her ceviz, yatay ve dikey eksenlerde 5°'lik artışlarla toplamda 144 farklı açıdan görüntülenmiştir. Bu yöntemle, cevizlerin 360 derece görünümü sağlanarak veri setine çeşitlilik kazandırılması hedeflenmiştir. 5 derecelik açı aralıkları, ayrıntılı bilgi sağlayacak düzeyde görüntü elde ederken, veri setinin boyutunu ve işlem süresini kontrol altında tutmak için uygun bir denge sunmuştur. Daha küçük adımlar (örneğin 2,5°) ile daha fazla görüntü elde edilebilse de bu, hem depolama hem de işlem yükünü ciddi oranda artıracaktır. Şekil 3.16'da, ceviz görsellerinin otomatik olarak toplanması, işlenmesi ve sınıflandırma veri setinin oluşturulmasına yönelik geliştirilen sistemin genel akış diyagramı sunulmuştur.



Şekil 3.16. Görüntü toplama, ön işleme ve veri seti oluşturma sürecinin akış diyagramı

Bu veri toplama sürecinde, ESP32 mikrodeneleyici, step motor ve akıllı telefonun kamera uygulaması senkronize bir şekilde çalıştırılmıştır. Step motor kontrolü ve Bluetooth Low Energy (BLE) üzerinden haberleşme, Arduino IDE ortamında C++ dili ile programlanan ESP32 kartı tarafından gerçekleştirilmiştir. Kamera uygulamasının tetiklenmesi ise Python dili ile yazılmış bir betik (script) üzerinden, BLE bağlantısı

yoluyla ESP32 ile iletişime geçilerek sağlanmıştır. Şekil 3.17.'de, ceviz sınıflandırması için geliştirilen otomatik görüntüleme sisteminin gerçek kurulumu görülmektedir.



Şekil 3.17. Veri seti oluşturma düzeneği genel görünümü

Sistemin işleyiş mantığı şu şekilde özetlenebilir: Python betiği, BLE protokolü ile ESP32 kartına "start" komutu göndererek motorun döndürülmesini başlatır. ESP32, motoru her 5 derecede bir döndürdükten sonra Python betiğine "Capture" mesajı iletir. Python betiği bu komutu aldığı anda, ADB (Android Debug Bridge) üzerinden gönderilen komutlarla telefon kamerasını tetikler ve görüntüyü kaydeder. Bir tam dönüş (360°) tamamlandığında, ESP32 kartı tarafından "StopCapture" mesajı ile fotoğraf çekme süreci sonlandırılır .

Bu işlem adımları aşağıdaki şekilde algoritmik olarak özetlenebilir:

- Başlatma (Python):
 - ESP32 ile BLE bağlantısı kurulur.
 - ADB komutları ile telefon kamerası açılır.
 - ESP32'ye "start" komutu gönderilir.
- Motor Döndürme (ESP32):
 - Step motor 5° döndürülür.
 - Python betiğine "Capture" mesajı gönderilir.

- Bu döngü 72 kez tekrar edilir.
- Fotoğraf Çekimi (Python):
 - ESP32'den gelen "Capture" mesajı alındığında,
 - input keyevent 27 komutu ile kamera tetiklenir.
 - Alternatif olarak input tap x y komutu kullanılarak ekran üzerindeki belirli bir noktaya dokunma simülasyonu yapılabilir.
 - Bu noktalar, Android geliştirici seçeneklerindeki "Pointer location" özelliği yardımıyla tespit edilmiştir (Android Developers, t.y.).
- Bitiş Aşaması:
 - ESP32, tam dönüşün ardından Python betiğine "StopCapture" mesajı gönderir.
 - Python betiği, bu mesajı aldıktan sonra işlemi sonlandırır.

Görüntüler telefonun dahili hafızasında saklandıktan sonra, USB bağlantısı aracılığıyla bilgisayara aktarılmıştır. Bu aşamada, dosya bütünlüğünü korumak adına güvenilir aktarım protokolleri kullanılmıştır.

Veri Toplama Sürecinde Karşılaşılan Zorluklar ve Alınan Önlemler:

- Aydınlatma Koşullarındaki Değişkenlik: Fotoğraflar, sabit ışık koşullarının sağlanabildiği akşam saatlerinde ve aynı ortamda çekilmiştir. Beyaz dengesi önceden ayarlanarak tutarsızlıklar minimize edilmiştir.
- Motor Atlama Problemleri: Motorun belirli açılarda atlama yapması durumunda ilgili çekimler tekrar edilmiştir. Sürücü akımı, bağlantı sağlamlığı ve mikro adım yapılandırması kontrol edilerek sorunun önüne geçilmiştir.
- Bluetooth Bağlantı Kopmaları: Zaman zaman yaşanan BLE bağlantı kesintileri durumunda sistem yeniden başlatılarak Python betiğinin stabil çalışması sağlanmıştır.
- ADB Bağlantı Sorunları: Komut iletiminde yaşanan sorunlar USB kablusunun, telefonun hata ayıklama modunun ve ADB sürücülerinin kontrolüyle giderilmiştir.

Tüm bu zorluklar ve çözüm adımları kayıt altına alınarak, veri toplama sürecinin şeffaflığı ve tekrar edilebilirliği sağlanmıştır.

3.10.4. Veri ön işleme

Derin öğrenme modellerinin doğru ve verimli şekilde eğitilebilmesi için, ham görüntüler üzerinde çeşitli ön işleme adımları uygulanmıştır. Bu adımlar; görüntü boyutlarının standardize edilmesi, ceviz nesnelerinin arka plandan ayrıştırılması ve veri setinin temizlenerek model eğitime hazır hale getirilmesini kapsamaktadır. Tüm işlemler Python dili ile geliştirilmiş betikler ve OpenCV kütüphanesi kullanılarak gerçekleştirilmiştir.

Boyutlandırma: Ham görüntüler orijinal çözünürlükte olduğu için, derin öğrenme modelinin giriş katmanları ile uyumlu hale getirilmek üzere yeniden boyutlandırılmıştır. Bu işlem, OpenCV kütüphanesinin cv2.resize() fonksiyonu aracılığıyla, bilinear interpolasyon yöntemi kullanılarak yapılmış ve tüm görseller 512x512 piksel boyutuna dönüştürülmüştür. Bu yöntem, hem detay kaybını minimumda tutmakta hem de işlem süresini optimize etmektedir. Ayrıca farklı interpolasyon teknikleri (örneğin bicubic veya Lanczos) ile karşılaştırmalı analizler yapılması da mümkündür (Balovsyak ve Hnatiuk, 2024).


Kontur Kırpma ve Arka Plan Temizleme: Görüntülerde yalnızca ceviz nesnelerinin kalmasını sağlamak amacıyla, kontur tespiti ve kırpma temelli bir arka plan temizleme prosedürü uygulanmıştır. Bu süreçte OpenCV'nin findContours() ve boundingRect() gibi fonksiyonları kullanılmıştır (Wang ve ark., 2024). Aşamalar aşağıda açıklanmıştır:

- Renk Dönüşümü: cv2.cvtColor() fonksiyonu ile görüntüler gri tonlamaya (grayscale) çevrilmiştir.
- Gürültü Azaltma: Görüntüdeki parazitleri azaltmak için cv2.GaussianBlur() kullanılarak Gaussian bulanıklaştırma uygulanmıştır.
- Eşikleme: Nesne ve arka plan ayrımını sağlamak üzere cv2.threshold() fonksiyonu ile ikili (binary) eşikleme yapılmıştır. Eşik değeri olarak 190 belirlenmiş ve cv2.THRESH_BINARY_INV parametresiyle cevizler beyaz, arka plan siyah olacak şekilde işaretlenmiştir.
- Kontur Tespiti: cv2.findContours() fonksiyonu yardımıyla yalnızca dış konturlar

(RETR_EXTERNAL) ve sadeleştirilmiş kontur noktaları (CHAIN_APPROX_SIMPLE) tespit edilmiştir.

- En Büyük Konturun Seçimi: En büyük alana sahip kontur, ceviz nesnesi olarak varsayılmış ve bu kontur temel alınmıştır.
- Dikdörtgen Alan Oluşturma: cv2.boundingRect() ile seçilen konturu çevreleyen dikdörtgen belirlenmiş ve görüntü bu alana göre kırpılmıştır.
- Alt Kenar Temizliği: Görüntünün alt kısmında yer alan ve sıklıkla zemin veya tabla yüzeyi gibi istenmeyen alanları temizlemek amacıyla, her satırın piksel yoğunluğu hesaplanmış; belirli bir eşik üzerinde kalan satırlar belirlenerek görüntü bu noktadan yeniden kırpılmıştır.

Bu işlemler sonucunda, ceviz nesneleri görüntüde odaklanmış ve model eğitiminde olumsuz etkiler yaratabilecek arka plan öğeleri etkili şekilde elimine edilmiştir. Böylece veri seti, derin öğrenme modellerinin daha doğru ve genel geçer öğrenmesini destekleyecek şekilde sadeleştirilmiştir. Şekil 3.18.'de, ceviz görüntülerine uygulanan kırpma işleminin etkisi gösterilmektedir.



Şekil 3.18. Kontur kırpma ve arkaplan temizleme

Veri Seti Ayırıştırma: Veri ön işleme adımlarından geçirilmiş görüntüler, model eğitim sürecine geçmeden önce, eğitim, doğrulama ve test alt kümelerine ayırıştırılmıştır. Bu işlem, Python programlama dili içerisinde yer alan train_test_split fonksiyonu aracılığıyla gerçekleştirilmiştir. Görseller; %50 eğitim, %25 doğrulama ve %25 test oranlarında

rastgele olarak dağıtılmıştır. Bu oranlama, özellikle sınırlı sayıda örnek içeren veri setleri için denge gözetilerek belirlenmiştir. Geleneksel olarak kullanılan %70-%15-%15 gibi dağılımlara kıyasla, bu yapı hem öğrenme hem de model değerlendirme sürecinde daha eşit bir örnekleme sağlamaktadır.


Daha geniş çaplı veri setlerinde farklı oranlar tercih edilebilir (örneğin, %80 eğitim, %10 doğrulama, %10 test). Ancak bu çalışmada, veri miktarının sınırlı olması nedeniyle daha dengeli bir yaklaşım benimsenmiştir.

Ayrıştırma işlemi sırasında, her ceviz türünün tüm alt kümelerde orantılı biçimde yer alması amacıyla katmanlı örnekleme (stratified sampling) yöntemi kullanılmıştır. Bu sayede, tüm sınıfların model tarafından öğrenilme şansı eşitlenmiş ve herhangi bir cinsin eksik temsil edilmesinden kaynaklanabilecek öğrenme dengesizlikleri önlenmiştir [25].

Bu işlemde sklearn.model_selection modülünden alınan train_test_split() fonksiyonu kullanılmış; ayrıca tekrar üretilebilirlik sağlamak amacıyla random_state parametresi tanımlanmıştır. Ayrılan veriler, Python betikleri tarafından otomatik olarak oluşturulan ilgili klasörlere kaydedilmiş ve eğitim sürecine hazır hale getirilmiştir.

3.10.5. Klasör organizasyonu

Veri setinin düzenli, erişilebilir ve yeniden kullanılabilir bir yapıya sahip olması amacıyla standart bir klasör yapısı oluşturulmuştur. Bu yapı, veri setinin farklı algoritmalar ve platformlar üzerinde kolayca entegre edilmesine olanak sağlamaktadır. Tüm verileri içeren ana klasör “ceviz_veri_seti” olarak adlandırılmış ve altında eğitim, doğrulama ve test alt kümelerini barındıran klasörler yapılandırılmıştır. Şekil 3.19’da, oluşturulan ceviz veri setinin eğitim (train), doğrulama (validation) ve test kümelerine ayrılmış klasör yapısı şematik olarak gösterilmiştir.



Şekil 3.19. Veri seti oluşturmada kullanılan donanımlar

Veri ön işleme aşamalarından (bkz. 3.10.4 Veri Ön İşleme) geçirilen görüntüler; train, validation ve test adlı üç ayrı klasöre, belirlenen %50-%25-%25 oranlarına göre yerleştirilmiştir. Her bir bu küme klasörünün içerisinde, sınıflandırılması hedeflenen ceviz türlerine ait alt klasörler bulunmaktadır. Bu alt klasörlerde, her bir ceviz cinsine ait beş farklı örneğin çeşitli açılardan çekilmiş görselleri yer almaktadır. Her ceviz örneği, yatay ve dikey düzlemlerde 5°'lik açılarla 144 farklı pozdan görüntülenmiştir. Bu da her ceviz cinsi için $5 \times 144 = 720$ toplamda 3600 görüntü anlamına gelmektedir.

Bu yapılandırma sayesinde her kümede tüm ceviz türlerinden örnekler yer almakta; böylece modelin eğitim, doğrulama ve test aşamalarında her sınıf için dengeli performans ölçümü yapılabilmektedir.

Veri ayrıştırma süreci sırasında, Python diliyle geliştirilen bir betik aracılığıyla klasörler otomatik olarak oluşturulmuş ve her cins için önceden işlenmiş görüntüler uygun oranlarda ilgili dizinlere kopyalanmıştır. Bu işlem sırasında katmanlı örnekleme uygulanmış; böylece her kümede her cinsten orantılı sayıda görüntü yer alması sağlanmıştır.

Örneğin, eğer Bilecik türüne ait 720 adet işlenmiş görüntü mevcutsa, yaklaşık olarak 360 adet train/Bilecik/, 180 adet validation/Bilecik/, 180 adet test/Bilecik/ klasörlerine


yerleştirilmiştir. Sayılar küsurat içerdiğinde en yakın tam sayıya yuvarlama yapılmıştır. Bu organizasyonel yapı, veri yönetimini kolaylaştırmakta; model eğitimi, değerlendirme ve yeniden üretilebilirlik açısından önemli bir standartlaşma sunmaktadır. Tablo 3.1.'de, her bir ceviz cinsi için eğitim, doğrulama ve test kümelerine ait görüntü sayıları verilmiştir.

Tablo 3.1. Eğitim, doğrulama ve test kümelerine ait görüntü sayıları

Ceviz Cinsi	Eğitim	Doğrulama	Test
Bilecik	360	180	180
Chandler	360	180	180
Fernette	360	180	180
Yavuz	360	180	180
Niksar	360	180	180

4. BULGULAR ve TARTIŞMA

Bu bölümde, önerilen ESA mimarisi ve beş farklı önceden eğitilmiş derin öğrenme modelleri (ResNet50, Xception, InceptionV3, MobileNet ve DenseNet121) kullanılarak elde edilen sınıflandırma performansları sunulmuştur. Tüm modeller, aynı hiperparametrelerle ve aynı veri seti üzerinde eğitilmiş olup, eğitim süreci ve sonuçlar görsellerle desteklenerek analiz edilmiştir.



Şekil 3.10.5. Ceviz sınıflandırma sürecine ait genel iş akışı


Şekil 4.1, ceviz cinsi sınıflandırma sürecine ait genel metodolojiyi akış diyagramı biçiminde sunmaktadır. Veri toplama sürecinden başlayarak ön işleme, veri bölme, artırma, model eğitimi ve sınıflandırma aşamaları sıralı olarak gösterilmiştir. Geliştirilen özel modelin yanı sıra transfer öğrenme tabanlı beş farklı ESA mimarisi de bu süreçte değerlendirilmiştir.

4.1. Önerilen ESA Mimarisi

Bu tez çalışmasında geliştirilen önerilen ESA mimarisi, ceviz cinslerinin sınıflandırılması için sıfırdan tasarlanmış ve optimize edilmiş bir evrişimli sinir ağı (ESA) mimarisidir. Bu model, karmaşıklığı düşük tutarken yüksek doğruluk oranlarına ulaşmayı hedefleyen, dengeli bir derin öğrenme yapısı sunmaktadır.

Önerilen ESA mimarisi, 6 ardışık evrişim bloğu (*Conv2D* + *BatchNormalization* + *MaxPooling2D*), ardından gelen *GlobalAveragePooling2D* katmanı ve son olarak tam

bağlantılı (*dense*) katmanlardan oluşmaktadır. Bu yapı, hem düşük seviye kenar ve doku özelliklerini hem de yüksek seviyeli soyut temsilleri öğrenmeye olanak tanımaktadır.



Şekil 3.10.5. Önerilen ESA mimarisine ait ağ tasarımı

Yukarıdaki Şekil 4.2.'de önerilen ESA mimarisinin temel yapı taşları olan evrişim (*Conv2D*), normalizasyon (*BatchNormalization*), havuzlama (*MaxPooling2D*) ve tam bağlantılı katmanlar katman bazında renklerle ayrıştırılarak gösterilmiştir. Modelin ilk katmanlarında düşük seviyeli özellikler (kenar, renk, doku) öğrenilirken, katman derinliği arttıkça daha soyut ve anlamlı temsiller oluşturulmaktadır. *GlobalAveragePooling2D* ile çıkarılan özellikler, tam bağlantılı katmanlar aracılığıyla sınıflandırmaya dönüştürülmektedir. Son katmanda yer alan *Softmax* aktivasyon fonksiyonu ile model, 5 farklı ceviz cinsine ilişkin olasılık değerlerini hesaplamaktadır.

Bu mimari, hem derin hem de geniş katman yapısıyla farklı seviye özellikleri başarıyla yakalayabilmekte ve 5 farklı ceviz türünü yüksek doğruluk oranıyla sınıflandırabilmektedir. Aşırı öğrenmeyi önlemek için *Dropout* ve *BatchNormalization* teknikleri stratejik olarak yerleştirilmiştir. Bu yapı, özelleştirilmiş ve optimize edilmiş bir tasarım olarak literatürdeki benzer ESA mimarilerine kıyasla daha az parametre ile benzer doğruluk performansı sunmaktadır. Önerilen ESA Mimarisine ait parametre özet ve katman çıktıları Tablo 4.2'de sunulmuştur.

Tablo 4.2. Önerilen ESA mimarisinin katman çıktıları ve parametre özeti

Katman Adı	Çıkış Boyutu	Parametre Sayısı
Conv2D (16 filtre)	(224, 224, 16)	448
BatchNormalization	(224, 224, 16)	64
MaxPooling2D	(112, 112, 16)	0
Conv2D (32 filtre)	(112, 112, 32)	4640
BatchNormalization	(112, 112, 32)	128
MaxPooling2D	(56, 56, 32)	0
Conv2D (64 filtre)	(56, 56, 64)	18496
BatchNormalization	(56, 56, 64)	256
MaxPooling2D	(28, 28, 64)	0
Conv2D (128 filtre)	(28, 28, 128)	73856
BatchNormalization	(28, 28, 128)	512
MaxPooling2D	(14, 14, 128)	0
Conv2D (256 filtre)	(14, 14, 256)	295168
BatchNormalization	(14, 14, 256)	1024
MaxPooling2D	(7, 7, 256)	0
Conv2D (512 filtre)	(7, 7, 512)	1180160
BatchNormalization	(7, 7, 512)	2048
MaxPooling2D	(3, 3, 512)	0
GlobalAvgPooling2D	(512)	0
Dense (64 nöron)	(64)	32832
BatchNormalization	(64)	256
Dropout (0.5)	(64)	0
Dense (5 nöron)	(5)	325
Toplam parametre sayısı		1 610 213
Eğitilebilir parametre sayısı		1 608 069
Eğitilemez parametre sayısı		2.144

4.2. Deneysel Ortam ve Eğitim Yapılandırması

Bu çalışmada kullanılan derin öğrenme modellerinin eğitimi, yüksek performanslı bir donanım ortamında gerçekleştirilmiştir. Eğitim ve test işlemlerinin verimli ve hızlı yürütülebilmesi amacıyla Tablo 4.3.'te belirtilen yazılım ve donanım bileşenleri tercih edilmiştir.

Tablo 4.3. Eğitimde kullanılan yazılım ve donanım bileşenleri

Bileşen	Özellik
İşlemci	Intel Core i7-13700H (5.00 GHz Max Turbo, 14 çekirdek)
RAM	32 GB DDR4 (3200 MHz)
Grafik Kartı (GPU)	NVIDIA GeForce RTX 4060 (8 GB GDDR6)
İşletim Sistemi	Windows 11 x64
Yazılım	Python 3.10.9, TensorFlow ve Keras kütüphaneleri

Tüm modeller, aynı hiperparametreler ve veri seti yapısı kullanılarak eğitilmiş ve böylece modellerin performans karşılaştırmasının adil bir şekilde yapılması sağlanmıştır. Eğitim süreci boyunca Tablo 4.4.'te eğitim parametreleri sabit tutulmuştur:

Tablo 4.4. Modellerde kullanılan eğitim parametreleri

Parametre	Değer
Görüntü Boyutu	224x224
Batch Size	20
Epoch Sayısı	60
Öğrenme Oranı	1e-4
Optimizasyon Yöntemi	Adam
Kayıp Fonksiyonu	Categorical Crossentropy
Aktivasyon Fonksiyonu	ReLU (Ara Katmanlar), Softmax (Çıkış Katmanı)
Katman Normalizasyonu	BatchNormalization
Aşırı Öğrenmeyi Önleme	Dropout (0.5)

Eğitim süreci boyunca eğitim, doğrulama ve test veri kümeleri sırasıyla %50, %25 ve %25 oranında ayrılarak kullanılmıştır. Her model aynı veri artırma (augmentation) stratejileriyle eğitilmiş olup, bu sayede modelin genel geçerliliği artırılmıştır.

4.3. Derin Öğrenme Modellerinin Performansı


Bu bölümde, önerilen ESA mimarisi ile birlikte literatürde sıkça kullanılan önceden eğitilmiş modellerden ResNet50, Xception, InceptionV3, MobileNet ve DenseNet121'in performansları detaylı olarak analiz edilmiştir. Tüm modeller, aynı veri seti, hiperparametreler ve eğitim stratejileri kullanılarak eğitilmiş, böylece karşılaştırmanın

nesnel ve tutarlı olması sağlanmıştır. Her bir modelin eğitim süresi, doğruluk ve kayıp grafikleri, karışıklık matrisleri ile birlikte başarı oranları ayrı ayrı değerlendirilmiş ve tartışılmıştır. Bu kapsamda; modellerin ceviz cinsi sınıflandırma görevindeki genel başarımları, doğruluk (*accuracy*), kesinlik (*precision*), duyarlılık (*recall*) ve F1 skoru gibi metrikler çerçevesinde ayrıntılı olarak sunulmaktadır.

4.3.1. ResNet50 modelinin performans değerlendirmesi

ResNet50 modeli, literatürde yaygın olarak kullanılan ve transfer öğrenmeye uygunluğu ile bilinen güçlü bir derin öğrenme mimarisidir (Firat ve Hanbay, 2022). Bu çalışmada ResNet50 modeli, ceviz cinsi sınıflandırma problemine uyarlanmış ve 60 epoch boyunca eğitilmiştir. Eğitim sonucunda model, yüksek doğruluk oranlarına ulaşmış ve başarılı sonuçlar elde etmiştir.


ResNet50 modeline ait Şekil 4.3. ResNet50 doğruluk grafiği incelendiğinde, eğitim doğruluğunun oldukça istikrarlı bir şekilde arttığı ve erken epoch'lardan itibaren yüksek doğruluk değerlerine ulaştığı gözlemlenmiştir. Doğrulama doğruluğunda ise bazı dalgalanmalar olmakla birlikte, genel seyir yüksek başarıyı korumuştur. Bu durum, veri setinin boyutuna bağlı olarak *overfitting* eğiliminin sınırlı düzeyde kaldığını göstermektedir.



Şekil 4.3. Resnet50 doğruluk grafiği


Şekil 4.4. Resnet50 kayıp grafiği incelendiğinde doğruluk grafiğini desteklemekte; eğitim

kaybının hızlı bir şekilde azaldığı ve düşük seviyelerde seyrettiği görülmektedir. Doğrulama kaybında ise zaman zaman ani sıçramalar gözlemlense de genel eğilim, başarılı bir eğitim süreci yaşandığını göstermektedir.



Şekil 4.4. Resnet50 kayıp grafiği

Modelin test verisi üzerinde oluşturduğu karışıklık matrisi Şekil 4.5 incelendiğinde, en çok hata yapılan sınıfın "fennette" olduğu ve bu sınıfın diğer sınıflarla karıştırıldığı anlaşılmaktadır (örneğin 12 örnek "bilecik" ve 4 örnek "yavuz" olarak sınıflanmış). Diğer sınıflarda ise oldukça yüksek başarı sağlanmış, özellikle "bilecik", "chandler" ve "yavuz" sınıflarında %100'e yakın sınıflandırma doğruluğu elde edilmiştir. Bu durum, modelin genel sınıflandırma başarımının oldukça yüksek olduğunu ortaya koymaktadır.



Şekil 4.5. Resnet50 karışıklık matrisi

Modelin eğitim, doğrulama ve test doğrulukları, eğitim süresi ve parametre boyutları Tablo 4.5’de verilmiştir. Modelin toplam parametre sayısı 23 597 957 olup, eğitim süresi yaklaşık 1104 saniyedir. Eğitim doğruluğu 0.9983, doğrulama doğruluğu ve test doğruluğu ise her ikisi de 0.9811 olarak ölçülmüştür. Bu sonuçlar, modelin hem eğitim hem de test verilerinde yüksek başarıyla çalıştığını göstermektedir.

Tablo 4.5. Resnet50 parametre sayısı, eğitim süresi ve doğruluk değerleri

Parametre Sayısı	Eğitim Süresi (sn)	Eğitim Doğruluğu	Doğrulama Doğruluğu	Test Doğruluğu
23 597 957	1104.53	0.9983	0.9811	0.9811

Modelin test kümesi üzerindeki performans metrikleri (Accuracy, Precision, Recall ve F1-Score) Tablo 4.6’de verilmiştir. Bu metrikler doğrultusunda ResNet50 modeli, hem genel hem de sınıf bazlı sınıflandırma başarısı açısından güçlü bir performans sergilemiştir. Özellikle yüksek F1 skoru, modelin hem hatalı pozitifleri hem de hatalı negatifleri başarılı şekilde dengelediğini göstermektedir.


Tablo 4.6. Resnet50 performans metrikleri

Doğruluk (Accuracy)	Kesinlik (Precision)	Duyarlılık (Recall)	F1 Skoru (F1-Score)
0.9811	0.9821	0.9811	0.9809

4.3.2. Xception modelinin performans değerlendirmesi


Xception modeli, derin öğrenme mimarileri arasında hem derinliği hem de ayrık evrişim (depthwise separable convolution) mantığı ile dikkat çeken güçlü bir yapıdır (Chollet, 2017). Bu model, ceviz cinslerinin sınıflandırılmasında olağanüstü bir başarı göstermiştir. Eğitim süreci boyunca oldukça stabil bir öğrenme eğrisi sergilemiş ve hem eğitim hem de test verilerinde %100 başarıya ulaşmıştır.

Xception modeline ait Şekil 4.6. Xception doğruluk grafiği incelendiğinde, hem eğitim hem de doğrulama eğrilerinin çok kısa sürede maksimum seviyelere ulaştığı ve eğitim süresi boyunca bu yüksek başarıyı koruduğu gözlemlenmektedir. Bu durum, modelin eğitim sürecinde istikrarlı bir şekilde genelleme yaptığını göstermektedir.




Şekil 4.6. Xception doğruluk grafiği

Şekil 4.7. Xception kayıp grafiği incelendiğinde eğitim ve doğrulama kayıplarının her iki grafikte de hızla düştüğü ve sonraki epoch'larda çok düşük değerlerde seyrettiği görülmektedir. Bu, modelin aşırı öğrenme eğiliminde olmadığını ve tüm veri dağılımı üzerinde etkili bir öğrenme gerçekleştirdiğini kanıtlamaktadır.



Şekil 4.3.27. Xception kayıp grafiği

Xception modeline ait test verisi üzerinde oluşturduğu karışıklık matrisi Şekil 4.8. incelendiğinde, tüm sınıflarda %100 doğru sınıflandırma sağlandığını göstermektedir. Beş farklı ceviz türü için her bir sınıfa ait 180 test örneğinin tamamı doğru sınıflandırılmıştır. Bu sonuç, modelin sınıflar arasındaki ayrımı son derece etkili biçimde öğrendiğini ortaya koymaktadır.



Şekil 4.3.28. Xception karışıklık matrisi

Modelin eğitim, doğrulama ve test doğrulukları, eğitim süresi ve parametre boyutları Tablo 4.7’de verilmiştir. Modelin toplam parametre sayısı 20 871 725 olup, eğitim süresi yaklaşık 1123 saniye olarak kaydedilmiştir. Eğitim doğruluğu 0.9933, doğrulama ve test doğruluğu ise 1.0000 gibi maksimum değerlere ulaşmıştır. Bu durum, modelin tüm sınıfları çok yüksek doğrulukla ayırt edebildiğini göstermektedir.

Tablo 4.7. Xception parametre sayısı, eğitim süresi ve doğruluk değerleri

Parametre Sayısı	Eğitim Süresi (sn)	Eğitim Doğruluğu	Doğrulama Doğruluğu	Test Doğruluğu
20 871 725	1123.49	0.9933	1.0000	1.0000

Modelin test kümesi üzerindeki performans metrikleri (Accuracy, Precision, Recall ve F1-Score) Tablo 4.8’de verilmiştir. Bu metriklerin tamamında maksimum değerlere ulaşılmış olması, Xception modelinin bu problem özelinde mükemmel bir sınıflandırıcı olarak görev yaptığını göstermektedir. Eğitim sürecindeki stabilite, düşük kayıplar ve sıfır hata ile sınıflandırma yapabilmesi açısından, Xception bu tez çalışmasındaki en güçlü adaylardan biridir.


Tablo 4.8. Xception performans metrikleri

Doğruluk (Accuracy)	Kesinlik (Precision)	Duyarlılık (Recall)	F1 Skoru (F1-Score)
1.0000	1.0000	1.0000	1.0000

4.3.3. InceptionV3 modelinin performans değerlendirmesi


InceptionV3 modeli, çok ölçekli evrişim filtreleriyle hem detay hem de genel yapısal bilgileri öğrenmeye olanak sağlayan derin ve geniş bir mimariye sahiptir (Özdemir, 2023). Bu model, ceviz cinsi sınıflandırması görevinde yüksek bir performans ortaya koymuştur.

InceptionV3 modeline ait Şekil 4.9. InceptionV3 doğruluk grafiği incelendiğinde, eğitim ve doğrulama doğruluklarının başlangıçta hızlı bir yükseliş gösterdiği, ardından küçük dalgalanmalarla birlikte yaklaşık %98 doğruluk seviyelerinde sabitlendiği görülmektedir. Bu durum, modelin dengeli bir öğrenme süreci geçirdiğini ve overfitting eğiliminde olmadığını göstermektedir.




Şekil 4.3.39. InceptionV3 doğruluk grafiği

Şekil 4.10. InceptionV3 kayıp grafiği incelendiğinde eğitim ve doğrulama kayıplarının başlangıçta keskin bir şekilde düştüğü, sonrasında ise düşük seviyelerde dalgalanarak istikrarlı bir performans sergilediği görülmektedir. Bu da modelin veriye adapte olduğunu ve stabil bir öğrenme sağladığını göstermektedir.



Şekil 4.3.310. InceptionV3 kayıp grafiği

InceptionV3 modeline ait test verisi üzerinde oluşturduğu karışıklık matrisi Şekil 4.11. incelendiğinde,, tüm sınıflar için yüksek doğrulukla tahmin yapabildiği görülmektedir. Özellikle Fernette cinsi için 16 adet yanlış sınıflandırma ve Yerli cinsi için 3 adet karışıklık tespit edilmiştir. Diğer sınıflarda neredeyse %100 doğru sınıflandırma sağlanmıştır.



Şekil 4.3.311. InceptionV3 karışıklık matrisi

Modelin eğitim, doğrulama ve test doğrulukları, eğitim süresi ve parametre boyutları Tablo 4.9’de verilmiştir. Modelin toplam parametre sayısı 21 813 029 olup, yaklaşık 1054 saniyede eğitilmiştir. Eğitim doğruluğu 0.9900, doğrulama doğruluğu 0.9744 ve test

doğruluğu 0.9789 olarak elde edilmiştir. Bu sonuçlar, modelin yüksek bir genelleme kabiliyeti sergilediğini göstermektedir.

Tablo 4.9. InceptionV3 parametre sayısı, eğitim süresi ve doğruluk değerleri

Parametre Sayısı	Eğitim Süresi (sn)	Eğitim Doğruluğu	Doğrulama Doğruluğu	Test Doğruluğu
21 813 029	1054.53	0.9900	0.9744	0.9789

Modelin test kümesi üzerindeki performans metrikleri (Accuracy, Precision, Recall ve F1-Score) Tablo 4.10’de verilmiştir. Bu metrikler, modelin genel başarımının oldukça yüksek olduğunu ortaya koymaktadır. Xception modeline kıyasla biraz daha düşük sonuçlar elde edilmesine rağmen, InceptionV3 modeli genel performans, hız ve doğruluk açısından tatmin edici bir denge sunmaktadır.


Tablo 4.10. InceptionV3 performans metrikleri

Doğruluk (Accuracy)	Kesinlik (Precision)	Duyarlılık (Recall)	F1 Skoru (F1-Score)
0.9789	0.9802	0.9789	0.9788

4.3.4. MobileNet modelinin performans değerlendirmesi


MobileNet, hafif yapısı ve düşük parametre sayısı ile taşınabilir cihazlar için tasarlanmış verimli bir ESA mimarisidir (Howard ve ark., 2017). Ceviz sınıflandırma problemi için yapılan deneylerde oldukça yüksek doğruluk seviyelerine ulaşmıştır.

MobileNet modeline ait Şekil 4.12. MobileNet doğruluk grafiği incelendiğinde, eğitim ve doğrulama doğruluklarının çok hızlı bir şekilde yükselip 10 epoch’tan sonra %99 üzerinde stabil kaldığı görülmektedir. Eğitim ve doğrulama doğruluklarının birbirine çok yakın olması, modelin dengeli bir şekilde öğrendiğini ve overfitting eğiliminin olmadığını göstermektedir.




Şekil 4.3.4 MobileNet doğruluk grafiği

Şekil 4.13. MobileNet kayıp grafiği incelendiğinde benzer şekilde eğitim ve doğrulama kayıplarının hızlı bir şekilde azaldığı ve minimum seviyelerde sabitlendiği gözlemlenmiştir. Bu durum, modelin tutarlı ve güvenilir sonuçlar verdiğini desteklemektedir.



Şekil 4.3.4 MobileNet kayıp grafiği

MobilNet modeline ait test verisi üzerinde oluşturduğu karışıklık matrisi Şekil 4.14 incelendiğinde, beş ceviz türü arasında neredeyse hatasız sınıflandırma gerçekleştirmiştir. Yavuz sınıfında yalnızca 2 örnek yanlış sınıflandırılmıştır (1'i Fernette, 1'i Yerli olarak tahmin edilmiştir). Diğer tüm sınıflarda doğruluk oranı %100'dür.



Şekil 4.3.4. MobileNet karışıklık matrisi

Modelin eğitim, doğrulama ve test doğrulukları, eğitim süresi ve parametre boyutları Tablo 4.11’de verilmiştir. Modelin toplam parametre sayısı 3 233 989 olup, eğitim süresi yaklaşık 1004 saniyedir. Eğitim doğruluğu 0.9967, doğrulama doğruluğu 1.0000, test doğruluğu ise 0.9978 olarak hesaplanmıştır. Bu değerler, modelin hem öğrenme hem de genelleme yeteneğinin güçlü olduğunu göstermektedir.

Tablo 4.11. MobileNet parametre sayısı, eğitim süresi ve doğruluk değerleri

Parametre Sayısı	Eğitim Süresi (sn)	Eğitim Doğruluğu	Doğrulama Doğruluğu	Test Doğruluğu
3 233 989	1004.95	0.9967	1.0000	0.9978

Modelin test kümesi üzerindeki performans metrikleri (Accuracy, Precision, Recall ve F1-Score) Tablo 4.12’de verilmiştir. Bu metrikler, MobileNet’in sınıflandırma görevinde yüksek doğruluk ve tutarlılık gösterdiğini ortaya koymaktadır. Ayrıca düşük eğitim süresi ve parametre sayısıyla kaynak verimliliği açısından da avantajlıdır.


Tablo 4.12. MobileNet performans metrikleri

Doğruluk (Accuracy)	Kesinlik (Precision)	Duyarlılık (Recall)	F1 Skoru (F1-Score)
0.9978	0.9979	0.9978	0.9975

4.3.5. DenseNet121 modelinin performans deęerlendirmesi


DenseNet121 modeli, katmanlar arasında yoğun baęlantılar kurarak bilgi akışını artırmayı ve gradyanların kaybolma problemini azaltmayı amaçlayan bir ESA mimarisidir. Bu yönüyle daha az parametreyle yüksek performans elde etmeyi mümkün kılar (Kılıçarslan ve Pacal, 2023).

DenseNet121 modeline ait Şekil 4.15. DenseNet121 doğruluk grafięi incelendięinde, eğitim ve doğrulama doğruluklarının birbirine çok yakın seyretmesi modelin öğrenme sürecinde dengeli bir yapı sergilediğini göstermektedir. Doğruluk %97 üzerinde başlayıp hızla %99 seviyesine yaklaşarak stabil hale gelmiştir.




Şekil 4.3.5. DenseNet121 doğruluk grafięi

Şekil 4.16. DenseNet121 kayıp grafięi incelendięinde doğrulama kayıplarında bazı sıçramalar (örneğin epoch 42-48 arası) gözlemlense de genel eğilim oldukça düşüktür ve model genel olarak düşük kayıp deęerleriyle başarılı bir öğrenme gerçekleştirmiştir.



Şekil 4.3.516. DenseNet121 kayıp grafiği

DenseNet121 modeline ait test verisi üzerinde oluşturduğu karışıklık matrisi Şekil 4.17 incelendiğinde, 5 ceviz sınıfı arasında oldukça yüksek doğruluk oranlarına ulaşmıştır. Sadece Fernette sınıfında 1 örnek yanlış sınıflandırılmıştır (Bilecik olarak tahmin edilmiştir). Diğer tüm sınıflarda %100 sınıflandırma başarısı elde edilmiştir.



Şekil 4.3.57. DenseNet121 karışıklık matrisi

Modelin eğitim, doğrulama ve test doğrulukları, eğitim süresi ve parametre boyutları Tablo 4.13’de verilmiştir. Modelin parametre sayısı 7 042 629 olarak belirlenmiş, eğitim süresi yaklaşık 1116 saniye sürmüştür. Eğitim doğruluğu 0.9944, doğrulama doğruluğu 0.9989 ve test doğruluğu 0.9989 değerlerine ulaşmıştır. Bu değerler modelin hem öğrenme hem de genelleme performansının yüksek olduğunu göstermektedir.

Tablo 4.13. DenseNet121 parametre sayısı, eğitim süresi ve doğruluk değerleri

Parametre Sayısı	Eğitim Süresi (sn)	Eğitim Doğruluğu	Doğrulama Doğruluğu	Test Doğruluğu
7 042 629	1116.29	0.9944	0.9989	0.9989

Modelin test kümesi üzerindeki performans metrikleri (Accuracy, Precision, Recall ve F1-Score) Tablo 4.14.'de verilmiştir. Bu değerler, DenseNet121 modelinin sınıflandırma görevinde neredeyse kusursuz performans sergilediğini ortaya koymaktadır. Kayıp değerlerinde görülen kısa süreli dalgalanmalara rağmen genel doğruluk oranları oldukça yüksektir.


Tablo 4.14. DenseNet121 performans metrikleri

Doğruluk (Accuracy)	Kesinlik (Precision)	Duyarlılık (Recall)	F1 Skoru (F1-Score)
0.9989	0.9989	0.9989	0.9989

4.3.6. Önerilen ESA mimarisi performans değerlendirmesi


Önerilen ESA mimarisine ait doğruluk grafiği Şekil 4.18. incelendiğinde, ilk birkaç epoch boyunca doğrulama doğruluğunda dalgalanmalar görülmüş; özellikle ilk 10 turda val_accuracy değeri %20-50 arasında değişmiştir. Bu durum, modelin veriye uyum sürecini gösterirken öğrenme oranı ve ağırlık güncellemelerinin etkisini yansıtmaktadır. 9. epoch itibarıyla doğrulama doğruluğu %87'nin üzerine çıkmış ve sonraki turlarda kararlı şekilde yükselmiştir. Özellikle 30. epoch'tan sonra hem doğruluk hem de kayıp grafikleri önemli düzeyde iyileşmiş ve modelin eğitimi daha stabil hale gelmiştir. 60. epoch sonunda doğrulama kaybı 0.0078'e, doğrulama doğruluğu ise %99.89'a ulaşmıştır.

Eğitim doğruluğu zamanla istikrarlı bir şekilde artarken doğrulama doğruluğunda bazı dalgalanmalar gözlemlenmiştir.




Şekil 4.3.618. Önerilen ESA mimarisi doğruluk grafiği

Önerilen ESA mimarisine ait kayıp grafiği Şekil 4.19. incelendiğinde ise doğrulama kaybının zaman zaman yükseldiği, ancak genel eğilimin azalma yönünde olduğu görülmektedir. Bu durum modelin öğrenme sürecinde bazı dönemsel adaptasyonlar geçirdiğini göstermektedir.



Şekil 4.3.619. Önerilen ESA mimarisi kayıp grafiği

Önerilen ESA mimarisine ait test verisi üzerinde oluşturduğu karışıklık matrisi Şekil 4.20 incelendiğinde, beş ceviz sınıfı arasında yüksek doğruluk göstermiştir. Yalnızca Yavuz sınıfında 2 örnek yanlış sınıflandırılmıştır. Diğer tüm sınıflarda %100 başarı elde edilmiştir.



Şekil 4.3.620. Önerilen ESA mimarisi karışıklık matrisi

Modelin eğitim, doğrulama ve test doğrulukları, eğitim süresi ve parametre boyutları Tablo 4.15’de verilmiştir. Önerilen ESA mimarisi, doğruluk açısından oldukça başarılı sonuçlar elde etmiştir. Eğitim doğruluğu 0.9789, doğrulama doğruluğu 0.9989 ve test doğruluğu 0.9978 olarak gerçekleşmiştir. Bu sonuçlar, modelin yüksek genelleme yeteneğine sahip olduğunu göstermektedir. Ayrıca toplam 1 610 213 parametreye sahip olan bu model, yalnızca 1125 saniyelik bir eğitim süresi ile oldukça kısa sürede eğitilmiştir. Bu da modeli hem doğruluk hem de verimlilik açısından avantajlı kılmaktadır.

Tablo 4.15. Önerilen ESA mimarisi parametre sayısı, eğitim süresi ve doğruluk değerleri

Parametre Sayısı	Eğitim Süresi (sn)	Eğitim Doğruluğu	Doğrulama Doğruluğu	Test Doğruluğu
1 610 213	1125.20	0.9789	0.9989	0.9978

Modelin test kümesi üzerindeki performans metrikleri (Accuracy, Precision, Recall ve F1-Score) Tablo 4.16.’da verilmiştir. Bu sonuçlar, önerilen ESA mimarisinin sınıflandırma görevinde yüksek doğruluk, hassasiyet ve tutarlılık sağladığını göstermektedir. Ayrıca düşük parametre sayısı ve kısa eğitim süresi sayesinde model, hem güçlü hem de pratik bir çözüm olarak öne çıkmaktadır.

Tablo 4.16. Önerilen ESA mimarisi performans metrikleri

Doğruluk (Accuracy)	Kesinlik (Precision)	Duyarlılık (Recall)	F1 Skoru (F1-Score)
0.9978	0.9978	0.9978	0.9978

4.4. Genel Tartışma

Bu tez çalışmasında karşılaştırmalı olarak değerlendirilen altı derin öğrenme modeli arasında, doğruluk ve genelleme başarısı açısından öne çıkan modeller sırasıyla önerilen ESA mimari, ResNet50 ve Xception olmuştur. Özellikle önerilen ESA mimarisinin düşük parametre sayısı ile ulaştığı yüksek doğruluk oranı (%99.78 test doğruluğu), modelin hem mimari açıdan verimli hem de pratik uygulamalara uygun olduğunu göstermektedir.

Transfer öğrenme tabanlı modellerin (ResNet50, Xception, vb.) eğitim süreleri daha kısa olmakla birlikte, önerilen ESA mimarisi bu modellerle rekabet edebilecek düzeyde sonuçlar üretmiştir. Bununla birlikte, bazı modellerin belirli sınıflarda karışıklık yaşadığı karışıklık matrisi analizlerinde gözlemlenmiştir. Önerilen ESA mimarisi, genel başarı düzeyi ve dengeli sınıflandırma performansı ile dikkat çekmektedir.

Literatür ile karşılaştırıldığında, önerilen ESA mimarisinin başarımı, Aktaş (2022)'nin %98.44 doğruluk oranıyla geliştirdiği Antep fıstığı sınıflandırma modeliyle benzer düzeyde olup, sahaya uygulanabilirlik açısından dikkat çekicidir. Benzer şekilde Karadeniz ve ark. (2023) tarafından ceviz yaprakları ile gerçekleştirilen çalışmada %90.55 doğruluk elde edilirken, doğrudan ceviz tanelerine yönelik geliştirilen bu çalışmada daha yüksek başarı sağlanmıştır. Ayrıca Wang ve ark. (2024)'nin ceviz kabuğu kusurlarına yönelik %98.52 doğruluk oranına sahip sistemine karşılık, bu tezde sınıflandırma başarısı %99.78 olarak gerçekleşmiştir. Anagnostis ve ark. (2021) ile Rong ve ark. (2019) gibi çalışmalarda, sınıflandırma doğrulukları %87–%95 civarında kalırken; önerilen ESA mimarisi, düşük parametre sayısına rağmen daha yüksek doğruluk ve işlem güvenilirliği sunmaktadır.

Tablo 4.17’de, kullanılan derin öğrenme modellerinin doğruluk, kayıp, eğitim süresi ve parametre sayısı gibi temel kriterlere göre karşılaştırması sunulmuştur. Bu veriler,

önerilen ESA mimarisinin daha az parametreye rağmen rekabetçi performans gösterdiğini açıkça ortaya koymaktadır.

Tablo 4.17. Derin öğrenme modellerinin karşılaştırmalı performans özeti

Model Adı	Test Doğruluğu (%)	Test Kaybı	Eğitim Süresi (sn)	Parametre Sayısı	Açıklama
Önerilen ESA Mimari	99.78	0.0130	1125.20	1 610 213	Özgün model, düşük parametre, yüksek başarı
ResNet50	98.11	0.0372	1104.53	23 597 957	Transfer öğrenme ile güçlü performans
Xception	1.000	0.0121	1123.49	20 871 725	Derin mimari, iyi genelleme
InceptionV3	97.89	0.0223	1054.53	21 813 023	Karmaşık yapı, başarılı performans
MobileNet	99.78	0.0127	1004.95	3 233 989	Hafif yapı, hızlı eğitim süresi
DenseNet121	99.89	0.0398	1116.29	7 042 629	Orta parametre, stabil performans

Sonuç olarak, önerilen ESA mimarisi, ceviz sınıflandırma görevinde yüksek doğruluk ve istikrar göstermiştir. Bu da, tarım ürünlerinin sınıflandırılmasında özel olarak tasarlanmış modellerin, geliştirilmiş transfer öğrenme yaklaşımlarına karşı güçlü bir alternatif olabileceğini ortaya koymaktadır.

5. SONUÇ ve ÖNERİLER

Bu tez çalışmasında, beş farklı ceviz cinsinin sınıflandırılması amacıyla derin öğrenme tabanlı bir görüntü işleme yaklaşımı geliştirilmiştir. Tokat ili Niksar ilçesi Sorhun Köyü yerel üreticilerinden temin edilen örnekler ile oluşturulan özgün veri seti, kontrollü koşullarda, özel bir düzenek kullanılarak toplanmış ve çeşitli ön işleme tekniklerinden geçirilmiştir. Ardından, önerilen ESA mimarisi ile birlikte, yaygın olarak kullanılan ResNet50, Xception, InceptionV3, MobileNet ve DenseNet121 gibi transfer öğrenme tabanlı modeller eğitim ve test aşamalarında karşılaştırmalı olarak değerlendirilmiştir.

Model karşılaştırmaları sonucunda, önerilen ESA mimarisi; düşük parametre sayısı, kısa eğitim süresi ve yüksek sınıflandırma doğruluğu (%99.78 test doğruluğu) ile dikkat çekici bir performans sergilemiştir. Ayrıca, karışıklık matrisleri, doğruluk-kayıp grafik analizleri ve değerlendirme metrikleri incelendiğinde, önerilen ESA mimarisinin daha istikrarlı sonuçlar verdiği gözlemlenmiştir. Bu durum, literatürde yer alan benzer çalışmalara kıyasla daha yüksek doğruluk oranlarının yakalanması açısından önemli bir katkı sağlamaktadır.

Elde edilen bulgular ışığında aşağıdaki öneriler sunulabilir:

- Uygulama Potansiyeli: Önerilen ESA mimarisi, gerçek zamanlı sınıflandırma uygulamalarına uygun olacak şekilde düşük parametrelili ve hızlı çalışabilen bir yapıya sahiptir. Bu yönüyle, ceviz üretiminde sınıflandırma süreçlerinin otomatikleştirilmesi için bir mobil uygulama ya da gömülü sistem üzerine entegre edilmesi mümkündür.
- Veri Seti Genişletilmesi: Veri seti çeşitliliği artırılarak (farklı ışık koşulları, farklı arka planlar, farklı ceviz boyutları vb.), modelin genelleme kapasitesi daha da geliştirilebilir.
- Model Geliştirme: Gelecekteki çalışmalarda, model mimarisi üzerine dikkat mekanizmaları veya hibrit yapılar entegre edilerek performansın daha da artırılması hedeflenebilir.
- Sistem Prototipleme: Geliştirilen model, ileri aşamada sınıflandırma donanımı

ile entegre edilerek yerel üreticilere yönelik düşük maliyetli bir prototip makineye dönüştürülebilir. Bu sayede, yerel ceviz üreticileri için verimliliği artıran bir otomasyon çözümü sunulabilir.

- *Yayın Potansiyeli:* Bu tez çalışması, içerdiği özgün veri seti, özelleştirilmiş ESA mimarisi ve model karşılaştırmaları ile hem ulusal hem de uluslararası hakemli dergilerde yayınlanmaya uygun niteliktedir. Özellikle tarım teknolojileri, yapay zeka ve akıllı sistemler alanlarında akademik değer taşımaktadır.

Sonuç olarak, bu çalışma ceviz sınıflandırma problemini çözmeye yönelik olarak hem literatüre özgün katkılar sunmuş hem de pratik uygulamalara dönük güçlü bir temel oluşturmuştur. Elde edilen bulgular, derin öğrenme tabanlı yaklaşımların tarım alanında etkili ve uygulanabilir çözümler sunduğunu net biçimde ortaya koymaktadır.

6. KAYNAKÇA

- Akın, E., & Şahin, M. E. (2024). Derin öğrenme ve yapay sinir ağı modelleri üzerine bir inceleme. *EMO Bilimsel Dergi*, 14(1), 27-38.
- Akman M. (2022), Derin Öğrenme Tabanlı Beyin Tümörü Segmentasyonu, Afyon Kocatepe Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi
- Aktaş, H. (2022). Antep fıstığının derin öğrenme ile dış kabuk rengine göre sınıflandırılması. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 1-1.
- Aktürk, S., & Serbest, K. (2022). Nesne Tespiti İçin Derin Öğrenme Kütüphanelerinin İncelenmesi. *Journal of Smart Systems Research*, 3(2), 97-119.
- Albelwi, S. A. (2022). Deep architecture based on DenseNet-121 model for weather image recognition. *International Journal of Advanced Computer Science and Applications*, 13(10).
- Altun, S., & Talu, M. F. (2021). Derin sinir ağıları için hiperparametre metodlarının ve kitlerinin incelenmesi. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 12(2), 187-199.
- Al-Doori, S. K. S. (2022). Dikkatsiz sürücü davranışlarının derin öğrenme yöntemleri ile tespiti.
- Anagnostis, A., Tagarakis, A. C., Asiminari, G., Papageorgiou, E., Kateris, D., Moshou, D., & Bochtis, D. (2021). A deep learning approach for anthracnose infected trees classification in walnut orchards. *Computers and Electronics in Agriculture*, 182, 105998.
- Android Developers. (t.y.). Android Debug Bridge (ADB). <https://developer.android.com/tools/adb?hl=tr>
- Atban, F., & İlhan, H. O. (2022). Öz nitelik seviyesinde Füzyon Yaklaşımının Kuruyemiş Tür Sınıflandırılmasında Performans Değerlendirmesi. *Avrupa Bilim ve Teknoloji Dergisi*, (45), 48-52.
- Balcı, M., Altun, A. A., & Taşdemir, Ş. (2016). Görüntü İşleme Teknikleri Kullanılarak Napolyon Tipi Kirazların Sınıflandırılması. *Selçuk-Teknik Dergisi*, 15(3), 221-237.
- Balovskyak, S., & Hnatiuk, Y. (2024). Analysis of Results of Scaling Digital Images by Interpolation Algorithms. *Security of Infocommunication Systems and Internet of Things*, 2(1), 01007-01007, <https://doi.org/10.31861/sisiot2024.1.01007>.
- Basri, H., Syarif, I., & Sukaridhoto, S. (2018, October). Faster R-CNN implementation method for multi-fruit detection using tensorflow platform. In *2018 international electronics symposium on knowledge creation and intelligent computing (IES-KCIC)* (pp. 337-340). IEEE.
- Bayazit, S., Tefek, H., & Çalışkan, O. (2016). Türkiye’de ceviz (*Juglans regia* L.) araştırmaları. *Ziraat Fakültesi Dergisi*, 11(1), 169-179.
- Bayazit, S., Çalışkan, O., & Kılıc, D. (2019). Pomological and chemical properties of some walnut genotypes in central Anatolia. *Journal of Agricultural Faculty of Gaziosmanpaşa University (JAFAG)*, 36(3), 243-249.
- Bakır, H., & Eker, S. B. (2023). A comprehensive experimental study for evaluating the performance of well-known cnn pre-trained models in noisy environments. *Politeknik Dergisi*, 1-1.
- Başçıftçı, F., & Gündüz, K. A. (2019). NESNELERİN İNTERNETİ UYUMLU MİKRODENETLEYİCİLER ÜZERİNE BİR ARAŞTIRMA. *Selçuk Üniversitesi*

- Sosyal ve Teknik Araştırmalar Dergisi, (18), 66-76.
- Bilgin, S. (2015). Bazı yerli ve yabancı ceviz çeşitlerinin menemen koşullarında ağaç ve meyve özelliklerinin incelenmesi (Master's thesis, Fen Bilimleri Enstitüsü).
- Buchanan, B. G. (2019). Artificial intelligence in finance.
- Bulut, N. (2023). Derin öğrenme ve makine öğrenmesi yöntemleri ile hidroponik tarım (Master's thesis, Necmettin Erbakan University (Turkey)).
- Büyükarık, B., & Ülker, E. (2020). AYDINLATMA ÖZNİTELİĞİ KULLANILARAK EVRİŞİMSEL SİNİR AĞI MODELLERİ İLE MEYVE SINIFLANDIRMA. Uludağ Üniversitesi Mühendislik Fakültesi Dergisi, 25(1), 81-100.
- Camkıran, C. (2023). Derin Öğrenme algoritmaları ile hisse senetlerinin fiyat hareketliliği öngörüsü (Doctoral dissertation, Marmara Üniversitesi (Turkey)).
- 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).
- Çam, M. (2023). İnsan Merkezli Toplumda İnovatif Tarım Uygulamaları: Kasaplar Köyü Örneği (Master's thesis, Dokuz Eylül Üniversitesi (Turkey)).
- Çetinkaya, T. S., & Sertbaş, A. (2022). Derin Öğrenme Algoritmalarının GPU ve CPU Donanım Mimarileri Üzerinde Uygulanması ve Performans Analizi: Deneysel Araştırma. Avrupa Bilim ve Teknoloji Dergisi, (33), 10-19.
- Çiftci, S. M. (2025). El yazısı rakamlarından cinsiyet tahmini: Derin öğrenme yaklaşımlarının karşılaştırılması ve analizi.
- Çukur, T., Kızılaslan, N., Çukur, F., & Kızılaslan, H. (2020). Tüketicilerin coğrafi işaretli ürünler için ödeme istekliliğine etki eden faktörler: Niksar Cevizi örneği. Turkish Journal of Agriculture-Food Science and Technology, 8(11), 2476-2481.
- Dağlı, İ., & Öztürk, A. (2021). GÖRÜNTÜ SINIFLANDIRMADA DERİN ÖĞRENME YÖNTEMLERİNİN KARŞILAŞTIRILMASI. Konya Journal of Engineering Sciences, 9(4), 872-888.
- Dikici, B., Bekçioğulları, M. F., Açıkgöz, H., & Korkmaz, D. (2022). ZEYTİN YAPRAĞINDAKİ HASTALIKLARIN SINIFLANDIRILMASINDA ÖN EĞİTİMLİ EVRİŞİMLİ SİNİR AĞLARININ PERFORMANSLARININ İNCELENMESİ. Konya Journal of Engineering Sciences, 10(3), 535-547.
- Erkol, M., Altuntaş, E., & Tokbaş, H. (2008). Bilecik ve Yalova-3 Ceviz Çeşitlerinin Bazı Fiziksel Özelliklerine Nem İçeriğinin Etkisi. Tarım Bilimleri Araştırma Dergisi, (2), 37-43.
- Ersöz, F., & Çınar, Y. (2021). Veri madenciliği ve makine öğrenimi yaklaşımlarının karşılaştırılması: Tekstil sektöründe bir uygulama. Avrupa Bilim ve Teknoloji Dergisi, (29), 397-414.
- Farahmand, M. (2022). Bal peteğindeki hücrelerin tespit edilmesi için derin öğrenme yaklaşımlarının kullanılması.
- Firat, H., & Hanbay, D. (2022). Comparison of 3D CNN based deep learning architectures using hyperspectral images. Journal of the Faculty of Engineering and Architecture of Gazi University, 38(1).
- Gamauf, M. (2025). Durum İzleme Uygulamaları için BLE tabanlı Ses Platformu.
- Gerdan, D. (2020). Görüntü işleme teknikleri kullanılarak bazı meyvelerin sınıflandırılması (Master's thesis, Ankara Üniversitesi (Turkey)).
- Gill, H. S., Murugesan, G., Khehra, B. S., Sajja, G. S., Gupta, G., & Bhatt, A. (2022). Fruit recognition from images using deep learning applications. Multimedia Tools and Applications, 81(23), 33269-33290.

- Gökalp, Ö. M. (2022). Makine öğrenmesi. Gazi Üniversitesi, Gazi BilişimEnstitüsü, Adli Bilişim Bölümü, 1-14.
- Gülem, E. Y., Dursun, B., & Toylan, H. (2025). Tomato Sorting System Based on Type Using Deep Learning. *Duzce University Journal of Science and Technology*, 13(2), 857-867.
- Güler, E. (2018). Fındık zarı uygunluğunun opencv ile belirlenmesi için yazılım ve donanım geliştirilmesi (Doctoral dissertation, Selçuk Üniversitesi).
- Gülle, K., Özdemir, D., & Temurtaş, H. Derin Öğrenme Yöntemleri Kullanılarak Böbrek Hastalıklarının Tespiti ve Çoklu Sınıflandırma. *Eskişehir Türk Dünyası Uygulama ve Araştırma Merkezi Bilişim Dergisi*, 5(1), 19-28.
- Güneş, E. (2022). Derin öğrenme yaklaşımı ile fındık meyvesinin sınıflandırılması (Master's thesis, Marmara Üniversitesi (Turkey)).
- Gürbüz, Ö., & Yılmaz, T. (2023). Evrişimli Sinir Ağları Kullanarak Yüz Belirleme ve Tanıma Uygulaması. *Journal of Investigations on Engineering and Technology*, 6(2), 45-60.
- Hassan, G. M., Hussien, N. M., & Mohialden, Y. M. (2023). Python tcp/ip libraries: A review. *International Journal Papier Advance and Scientific Review*, 4(2), 10-15.
- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., ... & Adam, H. (2017). Mobilenets: Efficient convolutional neural networks for mobile vision applications. *arXiv preprint arXiv:1704.04861*.
- İnce, H., İmamoğlu, S. E., & İmamoğlu, S. Z. (2021). Yapay Zeka Uygulamalarının Karar Verme Üzerine Etkileri: Kavramsal Bir Çalışma. *International Review of Economics and Management*, 9(1), 50-63.
- İncemen, S., & Öztürk, G. (2024). Farklı eğitim alanlarında yapay zekâ: uygulama örnekleri. *International Journal of Computers in Education*, 7(1), 27-49.
- İnik, Ö., & Ülker, E. (2017). Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3), 85-104.
- Kacır, Ü., Çelik, S., & Kacır, Y. T. (2025). Kurumsal Yönetimde Dijital Dönüşüm: Python ile Veri Bilimi Uygulamaları.
- Kahya, E., & Özdüven, F. F. (2023). Robotik hasat sistemlerinde kullanılmak amacıyla lahana ve brokolinin derin öğrenme metodu ile sınıflandırılması. *Turkish Journal of Agriculture-Food Science and Technology*, 11(9), 1639-1647.
- Karaali, I., & Eminağaoğlu, M. (2021). A convolutional neural network model for marble quality classification. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 36(1).
- Karadeniz, A. T., Başaran, E., & Celik, Y. (2023). Identification of walnut variety from the leaves using deep learning algorithms. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 12(2), 531-543.
- Karadeniz, A. T. (2024). Tarımda AI kullanımı. *AgriTR Science*, 6(2), 138-145.
- Kayaalp, K., & Altınalan, A. (2023). CEVİZ SÜRGÜN GÖRÜNTÜLERİ KULLANILARAK CEVİZ ÇEŞİTLERİNİN SINIFLANDIRILMASI. *Uluborlu Mesleki Bilimler Dergisi*, 6(2), 42-52.
- Kayalı, N. Z., & Omurca, S. İ. (2021). Konvolüsyonel Sinir Ağları (CNN) ile Çin Sayı Örüntülerinin Sınıflandırması. *Computer Science, (Special)*, 184-191.
- Kılıçarslan, S., & Pacal, I. (2023). Domates Yapraklarında Hastalık Tespiti İçin Transfer Öğrenme Metotlarının Kullanılması. *Mühendislik Bilimleri ve Araştırmaları Dergisi*, 5(2), 215-222.
- Kilif, H., Cinar, I., & Dogan, N. (2025). Automatic classification of walnut (*Juglans Regia*

- L.) species using deep learning methods. *Journal of Food Measurement and Characterization*, 1-22.
- Knott, M., Pérez-Cruz, F., & Defraeye, T. (2022). Facilitated machine learning for image-based fruit quality assessment in developing countries. *CoRR*.
- Li, Y., Feng, X., Liu, Y., & Han, X. (2021). Apple quality identification and classification by image processing based on convolutional neural networks. *Scientific Reports*, 11(1), 16618.
- Medium. (2019). Python Os Modülü. <https://medium.com/@aykutuludag/python-os-mod%C3%BCI%C3%BC-1e6eced93069>.
- Naranjo-Torres, J., Mora, M., Hernández-García, R., Barrientos, R. J., Fredes, C., & Valenzuela, A. (2020). A review of convolutional neural network applied to fruit image processing. *Applied Sciences*, 10(10), 3443.
- Nogueira, A. F. R., Oliveira, H. S., Machado, J. J., & Tavares, J. M. R. (2022). Transformers for urban sound classification—A comprehensive performance evaluation. *Sensors*, 22(22), 8874.
- Olut, M. B. (2018). Chandler x Kaplan-86 F1 ceviz populasyonunun meyvelerinde yağ asidi ve tokoferol içeriklerinin karakterizasyonu (Master's thesis, Fen Bilimleri Enstitüsü).
- Özdemir, C. (2023). Derin Öğrenme Modelleri ve Veri Ön İşleme Yöntemleri ile Çeltik Yaprak Hastalıklarının Erken Teşhisi. *Çukurova Üniversitesi Mühendislik Fakültesi Dergisi*, 38(3), 807-817.
- Özil, C., & Onder, M. Derin öğrenme için otomatik görüntü veri seti oluşturma düzeneği tasarımı ve ceviz cinslerine uygulanması. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 14(3), 1-1.
- Öztürk, K., & Şahin, M. E. (2018). Yapay sinir ağları ve yapay zekâ'ya genel bir bakış. *Takvim-i Vekayi*, 6(2), 25-36.
- Prathiba, D. S. G. R. (2025). ADB Debugging—Security Risks and Investigations.
- Rahman, M. M., & Barua, P. (2021, December). A CNN Model-based ensemble approach for Fruit identification using seed. In *2021 5th International Conference on Electrical Information and Communication Technology (EICT)* (pp. 1-6). IEEE.
- Rong, D., Xie, L., & Ying, Y. (2019). Computer vision detection of foreign objects in walnuts using deep learning. *Computers and Electronics in Agriculture*, 162, 1001-1010.
- Sadaiyandi, J., Arumugam, P., Sangaiah, A. K., & Zhang, C. (2023). Stratified sampling-based deep learning approach to increase prediction accuracy of unbalanced dataset. *Electronics*, 12(21), 4423, <https://doi.org/10.3390/electronics12214423>.
- Saini, K., & Devi, R. (2023). A systematic scoping review of the analysis of COVID-19 disease using chest X-ray images with deep learning models. *J. Auton. Intell*, 7(10.32629).
- Selamet, F. (2023). Derin öğrenme yöntemleri ile metalik yüzeylerde kusur tespiti ve sınıflandırılması= Defect detection and classification on metallic surfaces using deep learning methods.
- Seyyarer, E., Ayata, F., Uçkan, T., & Karci, A. (2020). Derin öğrenmede kullanılan optimizasyon algoritmalarının uygulanması ve kıyaslanması. *Computer Science*, 5(2), 90-98.
- Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on Image Data Augmentation for Deep Learning. *Journal of Big Data*, 6(1), 1–48. <https://doi.org/10.1186/S40537-019-0197-0/FIGURES/33>

- Şeker, A., Diri, B., & Balık, H. H. (2017). Derin öğrenme yöntemleri ve uygulamaları hakkında bir inceleme. *Gazi Mühendislik Bilimleri Dergisi*, 3(3), 47-64.
- Şen, F., Bilgin, S., Özeke, E., & Bilgin, N. A. (2018). Bazı ceviz çeşitlerinin Menemen ekolojisinde morfolojik ve pomolojik özelliklerinin belirlenmesi. *ÇOMÜ Ziraat Fakültesi Dergisi*, 6(1), 31-39.
- Veziroglu, E., Pacal, I., & Coşkunçay, A. (2023). Derin evrişimli sinir ağları kullanılarak pirinç hastalıklarının sınıflandırılması. *Journal of the Institute of Science and Technology*, 13(2), 792-814.
- Vidarthi, S. K., Singh, S. K., Xiao, H. W., & Tiwari, R. (2021). Deep learnt grading of almond kernels. *Journal of Food Process Engineering*, 44(4), e13662.
- Yılmaz, S., & Ustun, A. B. (2023). APP INVENTOR İLE BLUTOOTH KONTROLLÜ ARDUİNO UNO HABERLEŞMESİ AKILLI KURUTMA SİSTEMİ. *Bilgi ve İletişim Teknolojileri Dergisi*, 5(2), 158-171.
- Yılmaz, B. (2025). Exploring Deep Learning Approaches for Walnut Phenotype Variety Classification. *International Journal of Food Science*, 2025(1), 9677985.
- Wang, F., Lv, C., Pan, Y., Zhou, L., & Zhao, B. (2023). Efficient Non-Destructive Detection for External Defects of Kiwifruit. *Applied Sciences*, 13(21), 11971.
- Wang, Q., Bi, Y., Xue, B., & Zhang, M. (2024). Genetic Programming With Flexible Region Detection for Fine-Grained Image Classification. *IEEE Transactions on Evolutionary Computation*, <https://doi.org/10.1109/TEVC.2024.3379257>.
- Wang, J., Bai, X., Xu, D., Li, W., Tong, S., & Zhang, J. (2024). Online sorting of surface defective walnuts based on deep learning. *Journal of Food Engineering*, 379, 112133.
- Westphal, E., & Seitz, H. (2021). A machine learning method for defect detection and visualization in selective laser sintering based on convolutional neural networks. *Additive Manufacturing*, 41, 101965.
- Wu, R., Yan, S., Shan, Y., Dang, Q., & Sun, G. (2015). Deep image: Scaling up image recognition. *arXiv preprint arXiv:1501.02876*.
- Xiao, F., Wang, H., Xu, Y., & Zhang, R. (2023). Fruit detection and recognition based on deep learning for automatic harvesting: An overview and review. *Agronomy*, 13(6), 1625.
- Xiaomi. (t.y.). Xiaomi 13 Pro teknik özellikler. Xiaomi Türkiye. <https://www.mi.com/tr/product/xiaomi-13-pro/specs/>.

7. ÖZGEÇMİŞ

