

T.C.
BANDIRMA ONYEDİ EYLÜL ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

**ZEYTİN RENK VE DOKU BOZUKLUĞUNUN YAPAY ZEKA MODELLERİ İLE TESPİT
EDİLMESİ**

Doğukan TOPALLAR

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Mühendisliği Tezli Yüksek Lisans Programı

OCAK 2025

T.C.
BANDIRMA ONYEDİ EYLÜL ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

**ZEYTİN RENK VE DOKU BOZUKLUĞUNUN YAPAY ZEKA MODELLERİ İLE
TESPİT EDİLMESİ**

Doğukan TOPALLAR

DANIŞMAN

Dr. Öğr. Üyesi Süleyman Gökhan TAŞKIN

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Mühendisliği Tezli Yüksek Lisans Programı

OCAK 2025

ONAY

Doğukan TOPALLAR tarafından hazırlanan “**Zeytin Renk ve Doku Bozukluğunun Yapay Zeka Modelleri ile Tespit Edilmesi**” adlı tez çalışması 30/06/2025 tarihinde yapılan sınavla aşağıdaki danışman tarafından Bandırma Onyedli Eylül Üniversitesi Lisansüstü Eğitim Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Dr. Öğr. Üyesi Süleyman Gökhan TAŞKIN

(Danışman)

Doç. Dr. Emrah DÖNMEZ

(Üye)

Prof. Dr. Ecir Uğur KÜÇÜKSİLLE

(Üye) (varsa)

Bu tezin kabulü, Fen Bilimleri Enstitüsü Yönetim Kurulu’nun / / gün ve / sayılı kararı ile onaylanmıştır.

Prof. Dr. Özgen KORKMAZ

Bölüm Başkanı

BANDIRMA ONYEDİ EYLÜL ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

ETİK BEYANI

Bandırma Onyedi Eylül Üniversitesi Fen Bilimleri Enstitüsü tez yazım kılavuzuna göre hazırlamış olduğum “Zeytin Renk ve Doku Bozukluğunun Yapay Zeka Modelleri ile Tespit Edilmesi” adlı tezimin özgün bir çalışma olduğunu, tez hazırlanırken tüm aşamalarda bilimsel etik ilkelerine uygun davrandığımı, tez kapsamında sunulan tüm verileri bilimsel etik ilkelerine uygun elde ettiğimi, tezde faydalandığım tüm eserlere atıf yaptığımı ve kaynaklar kısmında bu eserleri gösterdiğimi beyan ederim. 17/06/2025.

Doğukan TOPALLAR

İmza

ÖNSÖZ

Bu tez çalışması, zeytin renk ve doku bozukluğu ayırma süreçleri için gerçek zamanlı görüntü işleme ile, tarım sektöründe verimliliği artırmayı hedeflemektedir. Geleneksel yöntemlerin zaman alıcı ve hataya açık doğası göz önüne alındığında, bu çalışmanın sağladığı otomasyon sistemi ile daha tutarlı ve hızlı ayrıştırma yapılması mümkün olacaktır. Böylece hem iş gücü maliyetleri azalacak hem de ürün kalitesi artırılacaktır.

Bu çalışmayı yürütürken, özellikle teknolojik yenilikleri tarım sektörüne entegre etme motivasyonu ve görüntü işleme tekniklerini endüstriyel otomasyona uyarlama isteği beni yönlendiren temel faktörler olmuştur. Aynı zamanda bu çalışmanın, diğer tarım ürünleri için de örnek teşkil ederek geniş bir uygulama alanı yaratacağına inanıyorum.

Çalışmamı tamamlamamda ilgisini ve desteğini bir an esirgemeyen değerli danışman hocam Dr. Öğr. Üyesi Süleyman Gökhan TAŞKIN'a başta olmak üzere, Bandırma Onyedi Eylül Üniversitesi Mühendislik ve Doğa Bilimleri Fakültesi Bilgisayar Mühendisliği bölüm hocalarıma, her zaman yanımda olan sevgili aileme ve desteğini daima benimle en yakından paylaşan yol arkadaşım Elif Türkan UÇAR'a teşekkürü borç bilirim.

ÖZET

YÜKSEK LİSANS TEZİ

ZEYTİN RENK VE DOKU BOZUKLUĞUNUN YAPAY ZEKA MODELLERİ İLE TESPİT EDİLMESİ

Doğukan TOPALLAR

**Bandırma Onyedli Eylül Üniversitesi
Lisansüstü Eğitim Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı**

Danışman: Dr. Öğr. Üyesi Süleyman Gökhan TAŞKIN

Haziran 2025, 65 sayfa

Son yıllarda tarım sektöründe, verimlilik ve kalite standartlarını artırmak amacıyla görüntü işleme ve otomasyon sistemlerine yönelik ilgi hızla artmaktadır. Geleneksel zeytin ayrıştırma yöntemlerinde, insan gözüyle yapılan renk ve kalite tespiti süreci, zaman alıcı ve hataya açıktır. Bu tez çalışmasında, ham zeytinlerin renk (kırmızı, yeşil, siyah) ve kalite (sinek vuruklu) durumlarına göre gerçek zamanlı olarak ayrıştırılmasını sağlayan bir görüntü işleme sistemi geliştirilmiştir. Geliştirilen sistem, zeytinlerin renk ve doku analizlerini yaparak, yüksek doğruluk oranları ve hızlı sınıflandırma ile işçilik maliyetlerini azaltmayı ve kaliteyi tutarlı bir şekilde korumayı amaçlamaktadır.

Ayrıca, endüstriyel otomasyonla entegre edilecek bu sistem, büyük ölçekli üretimlerde verimlilik artışı sağlamakta ve zeytin tarımında iş gücüne olan bağımlılığı en aza indirmektedir. Çalışma, zeytin ayrıştırmanın yanı sıra, diğer tarım ürünlerinin kalite kontrol süreçlerinde de uygulanabilir bir altyapı sunarak, tarım sektöründe modern teknolojilerin kullanımının önemini vurgulamaktadır.

CNN mimarisi, %99,56 doğruluk oranına ulaşmış; Fly, Green ve Black sınıflarında sırasıyla 0,9973, 0,9973 ve 0,9935 F1 skorları ile en yüksek başarıyı göstermiştir. Bu sonuçlar, modelin tüm sınıflarda dengeli ve güvenilir bir şekilde çalışabildiğini ortaya koymaktadır.

Anahtar kelimeler: Görüntü İşleme, Kalite Kontrol, Renk Analizi, Zeytin Ayırıştırma.



ABSTRACT

M.Sc. THESIS

DETECTION OF OLIVE COLOR AND TEXTURE TISSUE WITH ARTIFICIAL INTELLIGENCE MODELS

Doğukan TOPALLAR

**Bandırma Onyedi Eylül University
Graduate School of Computer Sciences
Department of Computer Engineering**

Supervisor: Asst. Prof. Dr. Süleyman Gökhan TAŞKIN

June 2025, 65 pages

In recent years, there has been a rapid increase in interest towards image processing and automation systems in the agricultural sector to improve productivity and quality standards. In traditional olive sorting methods, the process of color and quality detection performed by the human eye is time-consuming and prone to errors. In this thesis, an image processing system has been developed to sort raw olives in real-time based on their color (red, green, black) and quality (fly damage) status. The developed system aims to reduce labor costs and consistently maintain quality by performing accurate color and texture analysis of the olives, providing high accuracy and fast classification.

Furthermore, this system integrated with industrial automation provides increased efficiency in large-scale production and minimizes the dependency on human labor in olive farming. The study not only focuses on olive sorting but also offers an applicable infrastructure for the quality control processes of other agricultural products, emphasizing the importance of modern technologies in the agricultural sector.

The CNN architecture achieved an accuracy of 99.56% and demonstrated the highest performance with F1 scores of 0.9973, 0.9973, and 0.9935 for the Fly, Green, and Black classes,

respectively. These results indicate that the model performs in a balanced and reliable manner across all classes.

Keywords: Color Analysis, Image Processing, Olive Sorting, Quality Control.



İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	i
ABSTRACT	iii
İÇİNDEKİLER.....	v
ŞEKİL LİSTESİ	vii
TABLO LİSTESİ.....	viii
SİMGE VE KISALTMA LİSTESİ.....	ix
1. GİRİŞ.....	1
2. ZEYTİNCİLİKTE HASAT, KULLANILAN YÖNTEM VE UYGULAMALARIN LİTERATÜRDEKİ DEĞERLENDİRMESİ	3
2.1 ELLE TOPLAMA YÖNTEMİ	3
2.2 MEKANİK HASAT YÖNTEMLERİ.....	4
2.2.1 GÖVDE SALLAYICI (TRUNK SHAKER)	4
2.2.2 DALLARIN MEKANİK OLARAK SALLANMASI	5
2.2.3 HASAT VERİMLİLİĞİ VE MEYVE HASARI	7
2.2.4 TÜRKİYE’DE MODERNİZASYONUN DURUMU	7
2.2.5 EKONOMİK VE ÇEVRESEL ANALİZ.....	8
2.2.6 VERİLER ÜZERİNDEN GENEL DEĞERLENDİRME.....	8
2.2.7 LİTERATÜRDEKİ İYİLEŞTİRME YAKLAŞIMLARI	9
2.2.8 HASAT METOTLARININ KARŞILAŞTIRMALI ANALİZİ	9
2.3 TÜRKİYEDE MEKANİK HASAT UYGULAMALARI	9
2.4 AVANTAJLAR VE DEZAVANTAJLAR	10
3. MATERYAL VE YÖNTEM	11
3.1 VERİ SETİNİN OLUŞTURULMASI VE ÖRNEK TOPLAMA SÜRECİ.....	12
3.1.1 ORJİNAL VERİ SETİNİN OLUŞTURULMASI.....	17
3.2 GÖRÜNTÜ ÖN İŞLEME	19
3.2.1 CLAHE (CONTRAST LİTED ADAPTİVE HİSTOGRAM EQUALİZATİON) İLE KONTRAST İYİLEŞTİRME	20
3.2.1.1 NEDEN CLAHE TERCİH EDİLDİ?	21
3.2.1.2 ÖN İŞLEM SONRASI GÜNCEL KARŞILAŞTIRMALAR.....	21
3.2.2 GAN İLE VERİ ARTIRIMI	24
3.2.3 VERİLERİN ÇOĞALTILMASI	28

3.3	MAKİNE ÖĞRENMESİ YÖNTEMLERİ.....	29
3.3.1	CONVOLUTIONAL NEURAL NETWORK (CNN) MİMARİSİ	30
3.3.1.1	CNN MODELİNDE MATEMATİKSEL FORMÜLASYON	31
3.3.1.2	AKTİVASYON FONKSİYONU VE KAYIPLAR	32
3.3.2	TRANSFORMER MİMARİSİ	33
3.3.2.1	TRANSFORMER MİMARİSİ VE MATEMATİKSEL FONKSİYONLARI.....	34
3.3.3	METAFORMER MİMARİSİ	35
3.3.3.1	METAFORMER MİMARİSİ VE MATEMATİKSEL FORMÜLASYONU	36
3.3.4	MODEL MİMARİLERİNİN SINIFLANDIRILMASI VE KARŞILAŞTIRILMASI	37
3.4	PERFORMANS METRİKLERİ.....	38
4.	ARAŞTIRMA BULGULARI	40
4.1.1	EĞİTİM KONFIGÜRASYONU	41
4.2	SINIFLANDIRMA SONUÇLARININ RAPORLANMASI.....	41
5.	TARTIŞMA VE SONUÇ	57
6.	KAYNAKLAR	60
	ÖZGEÇMİŞ	64

ŞEKİL LİSTESİ

<u>Şekil</u>	<u>Sayfa</u>
Şekil 1: Türkiyede hasat edilmiş zeytin	3
Şekil 2: Elle zeytin toplama.....	4
Şekil 3: Zeytin Gövde Sallayıcı.....	5
Şekil 4: Zeytin Dalı Silkeleme Tarağı	6
Şekil 5: Zeytin Dalı Silkeleme Kolu	7
Şekil 7: Kasım 2024 Erdek/Balıkesir, Ham Zeytinin Ağaçtaki Görüntüsü	13
Şekil 8: Farklı Sınıflardan Zeytin Örneklerinin Görsel Temsili (Sinek Vuruklu, Siyah, Yeşil)	15
Şekil 9: Kameralı Görüntüleme Sistemi: Endüstriyel Kamera ve Işık Kontrollü Kapsül Düzenek	16
Şekil 10: CLAHE uygulanmadan önce (sol) ve uygulandıktan sonra (sağ) bir zeytin görselinde detay kazanımı.	22
Şekil 11: GAN Modeli	25
Şekil 12: GAN Modeli Sağlıklı ve Sağlıksız Meyve Üzerindeki Çıktıları.....	27
Şekil 13: 16 Katmanlı Bir CNN Uygulaması Görselleştirmesi.....	31
Şekil 14: Transformer Mimarisi Görselleştirmesi.....	34
Şekil 15: CNN Modeline Göre Eğitim Sonuçları Grafiği.....	44
Şekil 16: CaFormer Modeline Göre Eğitim Sonuçları Grafiği	46
Şekil 17: ConvFormer Modeline Göre Eğitim Sonuçları Grafiği	48
Şekil 18: CrossVit Modeline Göre Eğitim Sonuçları Grafiği	50
Şekil 19: MobileNet Modeline Göre Eğitim Sonuçları Grafiği	52
Şekil 20: MobileVit Modeline Göre Eğitim Sonuçları Grafiği	54
Şekil 21: ResNet Modeline Göre Eğitim Sonuçları Grafiği	56

TABLO LİSTESİ

<u>Tablo</u>	<u>Sayfa</u>
Tablo 1: Ulaşılan en yüksek hücre verimler	8
Tablo 2: Hasat Yöntemleri ve Karşılaştırmalı Analizi	9
Tablo 3: Hasatta Avantajlar ve Dezavantajlar	10
Tablo 4: CNN Modeline Göre Eğitim Sonuçları	43
Tablo 5: CaFormer Modeline Göre Eğitim Sonuçları	45
Tablo 6: ConvFormer Modeline Göre Eğitim Sonuçları	47
Tablo 7: CrossVit Modeline Göre Eğitim Sonuçları	49
Tablo 8: MobileNet Modeline Göre Eğitim Sonuçları	51
Tablo 9: MobileVit Modeline Göre Eğitim Sonuçları	53
Tablo 10: ResNet Modeline Göre Eğitim Sonuçları	55

SİMGE VE KISALTMA LİSTESİ

Simgeler	Açıklama
$W^{(l)}$	: l-inci katmana ait ağırlık matrisi (filtreler)
$b^{(l)}$	: l-inci katmana ait bias (terim)
$X^{(l-1)}$	: Önceki katmandan gelen giriş (özellik haritası)
f	: Aktivasyon fonksiyonu (örneğin ReLU, Softmax)
$Z^{(l)}$	: l-inci katmandaki lineer kombinasyon (“ön aktivasyon”)
$\sigma(z_i)$	: Softmax fonksiyonunun i-inci sınıfa ait çıktısı
z_i	: i-inci sınıf için hesaplanan ham skor değeri
K	: Çıktı katmanındaki sınıf sayısı (örneğin 3)
L	: Kayıp fonksiyonu (categorical crossentropy)
$y_{\{i,c\}}$	: Gerçek etiketin one-hot kodlamadaki değeri
$\hat{y}_{\{i,c\}}$	: Modelin tahmin ettiği ilgili sınıf olasılığı
N	: Toplam örnek sayısı (batch size veya veri miktarı)
C	: Sınıf sayısı (örneğin 3: yeşil, siyah, fly-damaged)

Kısaltmalar	Açıklama
GAN	: Generative Adversarial Network
CNN	: Convolutional Neural Network
CLAHE	: Contrast Limited Adaptive Histogram Equalization
Cgan	: Conditional Generative Adversarial Network
DCGAN	: Deep Convolutional GAN
PLC	: Programmable Logic Controller

RGB	: Red Green Blue
YOffset	: RGB gibi yaygın kullanılan değilse atlanabilir, ama baskın değil
YOLO	: You Only Look Once
TinyML	: Edge cihazlar için hafif makine öğrenme modeller



1. GİRİŞ

Tarım endüstrisinde, özellikle zeytin işleme süreçlerinde, hasat sonrası yapılan sınıflandırma işlemi ürün kalitesinin ve ticari değerinin belirlenmesinde kritik bir rol oynamaktadır [1]. Geleneksel yöntemlerle yapılan zeytin ayırıştırma işlemleri büyük ölçüde manuel kontrole dayanmakta, bu da tutarsızlıklara, verimsizliklere ve yüksek düzeyde iş gücü bağımlılığına yol açmaktadır [2]. Manuel ayırıştırma yöntemleri hasat sonrası direct olarak yapılmakta ve hasat işgücü üzerine ek işi gücü eklemektedir. Literatür ve uygulamadaki bu açık ve yüksek işgücü ihtiyacı bu alandaki çalışmaları geliştirmeyi gerektirmektedir.

Son yıllarda meyve sınıflandırma görevlerinde derin öğrenme ve evrişimli sinir ağlarının kullanımına yönelik çeşitli çalışmalar yapılmış olsa da [1,4,5], zeytine özel otomatik çözümler hala sınırlı kapsam ve uygulanabilirliğe sahiptir. Bu eksiklikleri gidermek amacıyla, bu çalışma; zeytinlerin görsel özelliklerine (renk ve yüzey bütünlüğü) göre gerçek zamanlı olarak sınıflandırılmasını sağlayan, bilgisayarlı görü tabanlı bir görüntü işleme ve endüstriyel otomasyon sistemi önermektedir. Temel hedef, insan müdahalesini azaltmak, sınıflandırma doğruluğunu artırmak ve akıllı tarım sistemlerinde ölçeklenebilir bir çözüm sunmaktır.

Kasım 2024 tarihinde, Türkiye'nin Balıkesir ili Erdek ilçesinde özel mülkiyete ait bir zeytin bahçesinden çeşitli ağaçlardan rastgele seçilen ham zeytin örnekleri manuel olarak toplanmıştır. Örnekleme sürecinde, farklı ağaç bölgelerinden toplanan zeytinlerin kalite ve olgunluk açısından doğal çeşitliliğinin yansıtılması hedeflenmiştir. Veri kümesi; siyah (sağlıklı ve tam olgunlaşmış), yeşil (olgunlaşmamış), kırmızı (kısmen olgunlaşmış ve ticari olarak daha az tercih edilen) ve sinek vuruklu (zeytin sineği istilasına uğramış) olmak üzere dört görsel kategoriye ayrılmıştır. Sinek vuruklu zeytinler, çiçeklenme döneminde meyve sineği tarafından yumurta bırakılması sonucu iç yapısında erken bozulma oluşan ve tam gelişimini tamamlamadan ağaçtan erken dökülen meyveleri ifade etmektedir.

Veri setini oluşturmak amacıyla, yaklaşık 250 adet zeytin örneği, 48 megapiksellik endüstriyel bir görüntüleme kamerası kullanılarak çoklu yüzey açılarıyla fotoğraflanmıştır. Tüm görüntüler, kontrollü bir ortamda, beyaz ve yansıtmasız bir arka plan eşliğinde, sabit ve gölgesiz bir ışıklandırma altında çekilerek görsel tutarlılık sağlanmıştır. Elde edilen örnekler manuel olarak sınıflandırılmış ve etiketlenmiştir. Bu özel veri setinin oluşturulması, makine öğrenmesi tabanlı

alıřmalar iin uygun kamuya aık, standart bir zeytin sınıflandırma veri kmesinin bulunmaması nedeniyle gerekli grlmřtr [6].

Ayrıca, bu alıřmada geliřtirilen sınıflandırma sisteminin yalnızca dijital ortamda yksek doėrulukla alıřması deėil, aynı zamanda gerek zamanlı fiziksel ayıklama srelerine entegre edilebilmesi hedeflenmektedir. Bu doėrultuda, sınıflandırma sonularına baėlı olarak zeytinleri iki farklı kanala ynlendirebilen, hava nozulları ile alıřan prototip bir mekanik ayırma dzeneėi tasarlanmıřtır. Bu mekanizmanın, sınıflandırma kararı alındıktan sonra ilgili zeytini uygun yne ynlendirerek sreci otomatikleřtirmesi amalanmaktadır. Planlanan sistem, manuel ayıklama srelerinde karřılařılan zaman kaybı ve insan kaynaklı tutarsızlıkları ortadan kaldırarak, sreci daha hızlı ve gvenilir hale getirmeyi hedeflemektedir. Hasat dneminde, bu prototip mekanizmanın saha kořullarında test edilmesi ve ayırırırma prosesine doėrudan entegre edilerek endstriyel uygulanabilirliėinin deėerlendirilmesi planlanmaktadır. Bylece, iř gcnn insan zerinden makineye aktarılması saėlanacak, operasyonel verimlilik artırılacaktır.

2. ZEYTİNCİLİKTE HASAT, KULLANILAN YÖNTEM VE UYGULAMALARIN LİTERATÜRDEKİ DEĞERLENDİRMESİ

Türkiye, dünyada yaklaşık 3,6 milyon ton zeytin üretimiyle öne çıkmakta, bunun 750.000 tonu sofralık zeytin olarak değerlendirilmekte ve 475.000 ton zeytinyağı üretimiyle global sıralamada üst sıralarda yer almaktadır [7].

Ülkemizde 200 milyonun üzerinde zeytin ağacı bulunmakta olup, bu sektör tarımsal istihdam ve bölgesel kalkınma açısından hayati önem taşımaktadır. Zeytin hasadı geleneksel olarak elle gerçekleştirilmiş, ancak artan iş gücü maliyeti ve mevsimsellik nedeniyle, mekanizasyon ihtiyacı artmış durumdadır.



Şekil 1: Türkiyede hasat edilmiş zeytin

2.1 ELLE TOPLAMA YÖNTEMİ

Sofralık zeytinlerde tercih edilen bu yöntem, dalların uzun sopalarla sallanarak zeytinlerin yere düşürülmesi esasına dayanır. Yüksek iş gücü gereksinimi ve düşük verim nedeniyle ekonomik olmadığı bilinmektedir. Ayrıca mevsimsel işçilerin yoğun talep ettiği bu yöntem, işçilik eksikliği durumlarında aksamalara yol açabilmektedir. Özellikle günümüzde pek kullanılmamak ile birlikte endüstriyel aletlerin ağaçlara daha az zarar vererek verimi artırdığı düşünülmektedir.



Şekil 2: Elle zeytin toplama

2.2 MEKANİK HASAT YÖNTEMLERİ

2.2.1 GÖVDE SALLAYICI (TRUNK SHAKER)

Zeytin gövdesine sıkıştırılan titreşim aparatı sayesinde zeytinler hızlıca düşürülür. Ünliversal kullanım imkânı sunar. Verim, 20–50 ağaç/saat aralığında olup, iş gücü ihtiyacını elle toplamaya kıyasla 5–6 kat azaltır [9].

Ayrıca, ters şemsiye (umbrella) toplama sistemiyle birlikte uygulandığında %97'ye yakın verim elde edilmiştir. Titreşim frekansı 18–24 Hz civarındadır ve çalışma verimi, İtalya'da 20 - 133 kg/işçi-saat aralığında raporlanmıştır [10].



Şekil 3: Zeytin Gövde Sallayıcı

2.2.2 DALLARIN MEKANİK OLARAK SALLANMASI

Bu uygulamada elektrikli veya benzinli endüstriyel iş makinelerinin insan vasıtasıyla taşınarak hasat edilmesi yöntemidir. Bu uygulamada zeytin ağacına uzun kol mesafesine sahip parmak/tarak benzeri dallar arasında hareket kabiliyeti yüksek parça kullanılarak, motor hareketi ile zeytinlerin dallardan sıyrılmasını sağlar. Bu yöntem az miktarda yaprağa zarar verse de işgücü ve zaman açısından yüksek avantaj sağlar. Ağacın yüksek dallarına erişim zorlaşır. Uygun tarım alanlarında kullanımı avantajlıdır.



Şekil 4: Zeytin Dalı Silkeleme Tarağı

Ayrıca bu yönteme ek ve birlikte kullanımı yaygın olan bir diğer yöntem. Ağacın ana dallarının içerisine girebilecek “U” şeklindeki bir boyun mekanizmasının lineer hareket sağlayan uzun kollu motora bağlanarak yüksek frekanslı ileri geri hareket sağlanması ve dalların silkeleme yöntemi ile zeytinlerin yere düşürülmesini sağlar. Bu hareket yüksek verimlilik sağlayarak, zamandan tasarruf ettirir de ağaç dallarına hasar verebilir ve bunu değerlendirerek uygun kalınlıkta ve mukavemetteki dallara uygulanmalıdır.



Şekil 5: Zeytin Dalı Silkeleme Kolu

2.2.3 HASAT VERİMLİLİĞİ VE MEYVE HASARI

Mekanik sistemlerin %90+ verimlilikle hasat sağlaması mümkünken (özellikle trunk shaker), meyvedeki fiziksel hasar, serbest yağ asitliği (FFA) ve polifenol içeriğinde azalmaya neden olur [11, 12].

Örneğin, trunk shaker ile hasat edilen zeytinlerde polifenol azalışı %10–20, meyve hasarı %15–20 oranında gerçekleşir. Elle hasatta meyve hasarı %5–8, over-the-row harvester ile %10–15, trunk shaker ile %15–20 olarak ölçülmüştür.

2.2.4 TÜRKİYE’DE MODERNİZASYONUN DURUMU

Hatay, Aydın, İzmir ve Balıkesir’de: %43–78 oranında elle toplama, %15–27 sıra ile sıvık/tarak kullanımı bulunmakta ve makineyle hasat yalnızca %1–2 oranındadır [13, 14].

Bursa’da Uludağ Üniversitesi verileri gösteriyor ki; elle hasat maliyeti 0,15 \$/kg; makineyle 0,023 \$/kg olmaktadır – bu, %80–85 işgücü azaltımı anlamına gelir [15].

Milas örneğinde: “Gemlik” zeytini elle toplandıktan sonra, hemen temizlenip sınıflandırılarak salamura sürecine aktarılır, bekleme süresi genellikle 1–5 saattir [18].

2.2.5 EKONOMİK VE ÇEVRESEL ANALİZ

Türkiye’de mekanik hasat; ortalama %60 makine kullanım oranıyla maliyetleri düşürür, Ergonomik riskleri azaltır, ancak yüksek yatırım (makine + bakım) gerektirir. Elle hasat sürekli işgücü talep ederken – makine kullanımı gürültü, titreşim ve kabuk/çamur kalıntısını arttırabilir [17].

Mekanik hasat sonrası zeytinin işlem süresi 4–6 saat içinde başlatılmazsa kalite düşüşü hızla gerçekleşir.

2.2.6 VERİLER ÜZERİNDEN GENEL DEĞERLENDİRME

Tablo 1’de hasat yöntemlerine göre ulaşılan en yüksek verilerden bahsedilmiştir.

Tablo 1: Ulaşılan en yüksek hücre verimler

Kriter	Elle Hasat	Mekanik Hasat	Gövde Shaker
Verim (kg/sa)	~22 kg/sa	~148 kg/sa	~148 kg/sa
Maliyet (\$/kg)	0,150	0,023	~0,010–0,020
Hasar Riski (%)	5–8	10–15	15–20

Elle hasat kalite açısından avantajlıdır ancak ekonomik olarak verimsizdir. Mekanik sistemler verim sağlar ama kalite/işçi sağlığı riskleri taşır. Makineler ideal kalite-verim dengesi sunar ancak yatırım ihtiyacı yüksektir. Özellikle bazı alanlarda coğrafi kriterlerin uygun olması durumunda kabinli silkeleme makineleri de yüksek yatırım ihtiyacı doğurur.

2.2.7 LİTERATÜRDEKİ İYİLEŞTİRME YAKLAŞIMLARI

Titreşim frekansı optimizasyonu: Ağaç, trunk shaker'in merkezine yakın tutulmalı ve titreşim frekansı 18–24 Hz optimal aralıktadır. Ters şemsiye entegrasyonu: Mekanik shaker ile birlikte kullanıldığında hem verimi artırır hem iş gücü ihtiyacını azaltır. Zeytin kalite etkisi: Mekanik titreşim süreçlerinde soğuk atmosferde işlem yapılması (4-6 °C) ve 2 saat içinde işlenmesi, oksidasyonu azaltarak kalitesini korur.

2.2.8 HASAT METOTLARININ KARŞILAŞTIRMALI ANALİZİ

Tablo 2'de tüm hasat metotları ve araştırmalarca değerlendirilmiş veriler sunulmuştur.

Tablo 2: Hasat Yöntemleri ve Karşılaştırmalı Analizi

Yöntem	Detaylar
Elle Hasat	Uludağ Üniversitesi verilerine göre elle hasat kapasitesi sadece 21,9 kg/adam-sa olup maliyet yaklaşık 0,15 \$/kg'dır. Ergonomik olarak zorlayıcı ve iş güvenliği riski yüksektir [18].
Sırık/Tarakla Hasat	Basit işçilik gerektirir ancak dal kırılmasına ve periyodisitenin artmasına neden olduğu tespit edilmiştir. Operatör yorgunluğu ve mekanizasyon eksikliği, ekonomik verimi düşürür. [18].
Dal Sarsıcı (Hand-held)	Hafif el tipi cihazlar ~147,9 kg/sa kapasiteye ulaşabilir; maliyeti ~0,023 \$/kg'dır (%85 verim artışı sağlar). Ancak titreşim ve gürültü, operörde HAV riskine yol açabilir [17].
Gövde Shaker (Trunk Shaker)	Ortalama 147–148 kg/sa verim sağlar. Net gelir: trunk shaker 713 TL/sa, dal sarsıcı 411 TL/sa, elle hasat 27 TL/sa. Verimlilik oranı %90–97 arasındadır. Meyve zedelenme oranı %15–20 olup, buna bağlı olarak antioksidan kaybı %10–20 olarak belirlenmiştir [18].
Tam Mekanize Kabinli Makineler	Örnek: PMC 6430, Gregoire 140. Dakikada 10–15 ağaç hasat kapasitesine sahiptir. Meyve hasarı %7–15 aralığındadır. Yatırım maliyeti ve mekanizasyon gereksinimleri yüksektir.

2.3 TÜRKİYEDE MEKANİK HASAT UYGULAMALARI

Türkiye'de mekanik hasat oranı sınırlı kalmakla birlikte, balıkesir, İzmir, Aydın gibi yörelerde pilot uygulamalar ve tractor-mounted shaker (Traktöre Montajlı Silkeleme) sistemleri yaygınlaşmaya başlamıştır. Ancak altyapı eksiklikleri, makinelerin yüksek maliyeti ve çiftçilerin eğitimsizliği gibi faktörler uygulama oranını sınırlandırmaktadır [17].

Özellikle Güney Marmara, Ege ve kıyı kesimlerde dağların yerleşimi, zeytin bahçelerinin coğrafi özellikleri ve zeminler dikkate alındığında genellikle yokuş, dar ve araziler traktör kullanımını zorlaştırabiliyor. Özellikle silkeleme mekanizması buna eklendiğinde kullanımın zorlaşması göz önünde bulundurulmalıdır.

2.4 AVANTAJLAR VE DEZAVANTAJLAR

Bu çalışmada genel olarak hasat yöntemleri arasında el ile toplama ve makine gücü ile toplama ele alınarak tablo 3’de karşılaştırılmıştır.

Tablo 3: Hasatta Avantajlar ve Dezavantajlar

Kriter	Elle Hasat	Mekanik Hasat
İş Gücü Gereksinimi	Yüksek; toplam maliyetin %40–50’sini oluşturur.	Düşük; uzun vadeli iş gücü masraflarını azaltır.
Verim / Hız	Yavaş; büyük arazilerde dakikada tek ağaç bile uzun sürede toplanabilir.	Hızlı; trunk shaker ile 20–50 ağaç/saat arası verim mümkündür.
Kalite Etkisi	Meyve hasarı çok düşük; ideal kaliteye uygun.	Hafif meyve zedelenmesi (%7–20); polifenol içeriğinde azalma olabilir.
Yatırım / Operasyon Maliyeti	Düşük ekipman maliyeti; işçilik yükü yüksek olduğu için sürekli maliyetlidir.	Makine yatırımı yüksek (8–17 kW güç); başlangıç maliyeti ciddi.
Arazi Uygunluğu	Tüm arazi tiplerine uygun; eğimli ve küçük bahçelerde rahatlıkla kullanılır.	Düz ve düzenli dikim alanlarında ideal; dağınık veya dikim sistemine bağlı sahalarda sınırlıdır.
Ağaç ve Meyve Etkisi	Ağaç sağlığı korunur; mekanik etki riski yoktur.	Bazı durumlarda gövde/asma zararları ortaya çıkabilir; titreşim riskleri.

3. MATERYAL VE YÖNTEM

Bu çalışma kapsamında geliştirilen zeytin sınıflandırma sistemi, bilgisayarla görme ve derin öğrenme teknolojilerinin tarımsal otomasyon süreçlerine entegrasyonunu amaçlamaktadır. Sistem, hem görüntü işleme algoritmalarıyla elde edilen sayısal verilerin makine öğrenmesi modellerine uygun şekilde yapılandırılmasını hem de fiziksel bir ayıklama mekanizmasıyla sınıflandırılan ürünlerin gerçek zamanlı olarak ayrıştırılmasını kapsamaktadır. Bu çerçevede yürütülen çalışmalar, dört temel aşamada ele alınmıştır: Zeytin örneklerinin temin edilmesi ve yüksek çözünürlüklü görüntülerinin elde edilmesi, görüntülerin ön işleme teknikleriyle iyileştirilmesi ve etiketlenmesi, konvolüsyonel sinir ağı, transformer ve metaformer mimarileri ile sınıflandırma modelinin eğitilmesi ve değerlendirilmesi, modelin fiziksel ayırma sistemine entegre edilerek saha testlerinin gerçekleştirilmesi.

Transformer mimarisi, 2017 yılında Vaswani ve arkadaşları tarafından önerilen "Attention is All You Need" adlı çalışma ile tanıtılmış ve özellikle doğal dil işleme (NLP) alanında önemli başarılar elde etmiştir. Bu mimarinin temel yapı taşları arasında self-attention mekanizması, çok başlı dikkat (multi-head attention), pozisyonel kodlama (positional encoding) ve ileri beslemeli (feedforward) katmanlar yer almaktadır. Transformer, giriş verileri arasındaki uzun menzilli ilişkileri modelleyebilmesi sayesinde NLP dışında görsel işlemlerde de kullanılabilir hâle gelmiştir. Görüntü sınıflandırma gibi görevlerde Vision Transformer (ViT) gibi türev yapılar geliştirilmiş ve bu mimari, görüntüleri sabit boyutlu yamalara (patch) bölerek her birini kelime gibi işleyerek sıraya dizmektedir. Böylece geleneksel konvolüsyon işlemleri yerine global dikkat mekanizması ile öğrenme gerçekleştirilir.

Ancak Transformer mimarisinin en büyük dezavantajlarından biri yüksek hesaplama maliyetidir. Özellikle self-attention katmanları, görüntü boyutu büyüdükçe katlanarak artan bellek ve işlem yüküne neden olmaktadır. Bu durum, gömülü sistemler veya gerçek zamanlı çalışması gereken sistemlerde verimliliği azaltmaktadır. Ayrıca Transformer'ın mimari olarak "attention" mekanizmasına bağımlı olması, daha esnek tasarımlar geliştirilmesinin önüne geçmektedir.

Bu bağlamda ortaya çıkan Metaformer mimarisi, Transformer yapısının dikkat (attention) katmanına olan bağımlılığını ortadan kaldırmayı amaçlayan yeni bir yaklaşımdır. Metaformer, temel olarak Transformer'ın iskeletini (normalizasyon, katmanlaştırma, ileri besleme gibi) korurken, self-attention yerine alternatif yapılar kullanılmasına imkân tanır. Bu alternatif yapılar arasında konvolüsyonel katmanlar (CNN), çok katmanlı algılayıcılar (MLP) veya diğer hafif

bloklar yer alabilir. Metaformer yaklaşımı, özellikle görsel görevlerde dikkat mekanizması olmadan da benzer veya daha iyi performansın elde edilebileceğini göstermiştir.

Metaformer mimarisine dayalı modellerden bazıları CaFormer, ConvFormer, CrossViT ve MobileViT gibi yapılardır. Örneğin ConvFormer, self-attention yerine CNN tabanlı bloklar kullanarak bilgi akışını sağlamaktadır. MobileViT ise mobil cihazlara uygun hafif bir yapıda Vision Transformer prensiplerini uygularken, CNN ve Transformer hibriti bir yapı sunmaktadır. Bu tür modeller, hesaplama maliyetini azaltmakla kalmayıp aynı zamanda gömülü sistemlere ve edge cihazlara uygulanabilirliği ile ön plana çıkmaktadır.

Sonuç olarak, Transformer tabanlı mimariler yüksek performanslı ve doğruluk odaklı sistemler için tercih edilmekte iken, Metaformer tabanlı yapılar esneklik, hız ve donanım verimliliği açısından avantaj sağlamaktadır. Bu çalışmada test edilen CaFormer, ConvFormer, MobileViT ve CrossViT gibi mimariler, Metaformer yaklaşımının görüntü sınıflandırma gibi görevlerde güçlü alternatifler sunduğunu göstermektedir. Özellikle sınırlı veri ve sınırlı donanım koşullarında Metaformer tabanlı modeller, düşük hesaplama maliyetiyle yüksek doğruluk sağlayarak etkili çözümler ortaya koymaktadır.

Çalışmanın her aşamasında hem yazılım hem de donanım bileşenlerinin birbirini destekleyecek şekilde tasarlanması sağlanmış; özellikle endüstriyel ortamlarda çalışmaya uygun, yüksek hızda ve temassız ayırım yapabilecek bir prototip mekanizma üzerinde odaklanılmıştır. Görüntü verilerinin elde edilmesinde kullanılan donanım, sınıflandırma modeline en doğru bilgiyi sağlayacak şekilde optimize edilmiş, verilerin tutarlılığı adına ışık koşulları, arka plan ve çekim açısı gibi faktörler standart hale getirilmiştir. Verisetinin oluşturulmasından modelin uygulanmasına kadar tüm süreç, gelecekte farklı meyve/sebze türlerine uyarlanabilecek modüler bir yapıda planlanmıştır. Böylece, hem bilimsel araştırmalara kaynak sağlayabilecek bir model geliştirilmiş hem de gerçek zamanlı çalışabilecek pratik bir sınıflandırma sisteminin altyapısı oluşturulmuştur.

3.1 VERİ SETİNİN OLUŞTURULMASI VE ÖRNEK TOPLAMA SÜRECİ

Bu çalışmada kullanılan veri seti, Kasım 2024 hasat sezonu sırasında araştırmacının Balıkesir'in Erdek ilçesinde bulunan özel zeytin bahçesinden özenle toplanan ham zeytin örneklerinden oluşturulmuştur. Veri setinin amacı, zeytinlerin görsel niteliklerine göre

sınıflandırılmasına olanak tanıyacak çeşitli renk ve yüzey durumlarını temsil eden örnekleri içermesini sağlamaktır. Bu doğrultuda, farklı ağaçlardan rastgele ve elle seçilen zeytin örnekleri, renk farklılıkları (yeşil, kırmızı, siyah) ve yüzey kusurları (sağlam ya da sinek vuruklu) açısından çeşitliliği maksimize edecek şekilde toplanmıştır.



Şekil 6: Kasım 2024 Erdek/Balıkesir, Ham Zeytinin Ağaçtaki Görüntüsü

Toplanan örneklerin büyük çoğunluğu sağlıklı ve tamamen olgunlaşmış siyah zeytinlerden oluşurken; yeşil (henüz olgunlaşmamış), kırmızı (kısmen olgunlaşmış ve ticari değeri daha düşük)

ve sinek vuruklu (hasar görmüş) zeytinler de sınıflandırma için dahil edilmiştir. Özellikle sinek vuruklu zeytinler, zeytin sineği olarak bilinen *Bactrocera oleae* türünün erken aşamada meyveye yumurta bırakması sonucu oluşmaktadır. Bu larvalar, zeytinin normal gelişimini engelleyerek meyvenin ağaçtan zamanından önce dökülmesine neden olur. Bu tür zeytinler genellikle yüzey deformasyonları, renk bozuklukları ve yumuşamış doku gibi ayırt edici fiziksel özellikler gösterdiğinden, yüzey kusurlarının tespiti için yapılan görüntü işleme çalışmalarında oldukça uygun örnekler olarak değerlendirilmektedir [1, 4].

Veri seti oluşturma sürecinde toplamda 250 adet yüksek çözünürlüklü zeytin görüntüsü elde edilmiştir. Görüntüler, 48 megapiksel çözünürlüğe sahip endüstriyel bir kamera yardımıyla kaydedilmiştir. Çekimler, yansımaları minimize eden özel bir ışıklandırma kutusu içerisinde gerçekleştirilmiştir. Bu kutuda zeytinler beyaz bir arka plan üzerine yerleştirilmiş ve ortam, doğrudan ışık kaynaklarından uzak tutulmuştur. Bu sayede, tüm örneklerin tutarlı ve karşılaştırılabilir bir şekilde görüntülenmesi sağlanmıştır. Her zeytin örneği, birden fazla açıdan çekilerek yüzeyindeki potansiyel bozuklukların, renk geçişlerinin ve dokusal farklılıkların detaylı şekilde yakalanması hedeflenmiştir.

Bu manuel kurulum, endüstriyel otomasyon sistemlerinde kullanılan gerçek zamanlı görüntüleme altyapısının kontrollü bir simülasyonu niteliğindedir. Böylece, eğilecek derin öğrenme modeline girdi sağlayacak verilerde yüksek kalite ve homojenlik elde edilmiştir. Veri toplama sürecinin bu şekilde titizlikle gerçekleştirilmesi, makine öğrenimi ve görüntü işleme tabanlı sınıflandırma algoritmalarının güvenilirlik ve doğruluğunu doğrudan etkilemektedir [2, 6].




Şekil 7: Farklı Sınıflardan Zeytin Örneklerinin Görsel Temsili (Sinek Vuruklu, Siyah, Yeşil)

Zeytinlerin sınıflandırılmasında kullanılacak görsel verilerin doğruluğu ve çeşitliliği, geliştirilecek modelin başarısını doğrudan etkilemektedir. Bu nedenle sistemin temelini oluşturan görüntüleme altyapısı, dikkatle seçilmiş ekipmanlar ve kontrollü bir ortamda kurgulanmıştır. Görüntülerin toplanmasında 48 megapiksel çözünürlüğe sahip endüstriyel bir kamera kullanılmıştır. Bu kamera, yüzey detaylarını en ince ayrıntısına kadar algılayabilecek nitelikte olup renk farklılıkları, dokusal bozulmalar ve sinek zararları gibi sınıflandırma için kritik olan özelliklerin tespitini kolaylaştırmaktadır.

Görüntüleme işlemi, yansıma ve gölge oluşumunu en aza indirmek amacıyla homojen ışıktandırmaya sahip kapalı bir ışık tüneli içerisinde gerçekleştirilmiştir. Bu ortam, beyaz zeminli ve yansıtıcı olmayan malzemelerle kaplanarak sabit renk dengesi ve kontrast sağlanmıştır. Bu

şekilde, dış etkenlerin model öğrenimine olumsuz etkide bulunabilecek varyansları ortadan kaldırılmış ve standart bir veri toplama protokolü geliştirilmiştir. Kamera, sabit bir tripod üzerine yerleştirilmiş ve her bir zeytin örneği için farklı açılardan birden fazla fotoğraf alınarak sınıflandırma için gerekli çeşitlilik sağlanmıştır.



Şekil 8: Kameralı Görüntüleme Sistemi: Endüstriyel Kamera ve Işık Kontrollü Kapsül Düzenek

Ayrıca, zeytinlerin sistematik olarak yerleştirilebilmesi için üzerinde ızgara desenli ölçü işaretleri bulunan kontrast referans tabanlı bir yerleştirme yüzeyi geliştirilmiştir. Bu yüzey hem ölçekleme hem de otomatik etiketleme sürecini kolaylaştırmış, veri bütünlüğünün korunmasına katkı sağlamıştır.

Toplanan görüntüler daha sonra, işleme öncesinde kalite kontrol aşamasından geçirilmiş ve bulanık, eksik alan içeren veya yansıma barındıran kareler elenmiştir. Kalan görüntüler, model

eğitiminde kullanılacak olan veri kümesine dâhil edilmeden önce bir ön işleme algoritmasına (data augmentation) tabi tutulmuştur.

3.1.1 ORJİNAL VERİ SETİNİN OLUŞTURULMASI

Bu bölümde, geliştirilen derin öğrenme tabanlı sınıflandırma sisteminin başarımını artırmak amacıyla uygulanan veri artırımı (data augmentation) teknikleri, eğitim ve doğrulama veri kümelerinin oluşturulma stratejileri, model mimarisinde tercih edilen katman yapıları ve hiperparametre ayarları, eğitim sürecinin adımları ile bu sürecin performansını doğrudan etkileyen donanımsal altyapıya ilişkin tüm teknik ayrıntılar ayrıntılı biçimde ele alınacaktır. Bu kapsamda; verilerin sınıflandırma modeline uygun hale getirilmesi için gerçekleştirilen ön işleme ve normalizasyon adımları, veri setinin dengeli ve temsili bir şekilde eğitim/doğrulama alt kümelerine bölünme yöntemi, mimarilerin katman derinliği, filtre boyutları, aktivasyon fonksiyonları gibi yapısal özellikleri, eğitim süresince kullanılan optimizasyon algoritmaları ve öğrenme oranı gibi hiperparametre ayarları ile eğitim süreci boyunca kullanılan veri jeneratörü ve eğitim döngüleri ayrıntılı olarak açıklanacaktır. Ayrıca, modelin eğitildiği donanım ortamı, işlemci, grafik işlem birimi (GPU), bellek kullanımı ve eğitim süresine etkisi gibi uygulama detaylarına da yer verilerek sistemin gerçek zamanlı çalışabilirliği değerlendirilecektir.

Derin öğrenme modelinin sağlıklı biçimde eğitilebilmesi için veri seti öncelikle eğitim ve doğrulama (validation) olmak üzere ikiye ayrılmıştır. Sınıflandırma problemlerinde modelin sadece eğitim verisi üzerinde değil, görmediği yeni veriler üzerinde de başarı sağlaması hedeflendiğinden, eğitim ve doğrulama ayrımı kritik öneme sahiptir. Bu bağlamda veri setinin %80'i eğitim için, %20'si ise doğrulama (validasyon) için ayrılmıştır. Söz konusu oran, literatürde yaygın olarak tercih edilen ve eğitim başarısı ile genelleme performansı arasında dengeli sonuçlar veren bir dağılımdır.

Veri klasörleri, sınıflara göre isimlendirilmiş alt dizinlerde organize edilmiştir. Örneğin; dataset/siyah, dataset/yesil, dataset/sinek_vuruklu gibi yapılar kullanılarak, her sınıfa ait görseller kendi klasöründe depolanmıştır. Bu yöntem, ImageDataGenerator gibi veri jeneratörlerinin otomatik etiketleme yapabilmesi açısından önemlidir.

Verilerin eğitim ve doğrulama için ayrılması süreci Python'da Keras kütüphanesinin ImageDataGenerator sınıfı üzerinden gerçekleştirilmiştir. Bu yapı sayesinde hem veri artırımı

yapılabilmekte hem de aynı anda validation_split parametresi ile doğrulama verisi ayrılabilir.

Veri seti, zeytinlerin renk ve yüzey durumlarına göre alt klasörlerde organize edilmiştir (örneğin dataset/siyah/, dataset/yesil/, dataset/sinek_vuruklu/). Bu düzen, Keras'ın flow_from_directory() fonksiyonunun otomatik etiketleme yapmasını sağlar ve sınıf etiketlerinin doğru ve güvenilir şekilde oluşturulmasına olanak tanır [32, 33]. Ayrıca, modüler yapı sayesinde yeni sınıflar (örneğin "kırmızı", "hasarlı") kolayca eklenerek genişletilebilir [36].

Keras'ın ImageDataGenerator, hem gerçek zamanlı veri artırımı (augmentation) hem de validation_split parametresi ile eğitim-doğrulama ayrımı yapmayı mümkün kılar [34]. Bu sayede aynı dizin yapısı kullanılarak hem augment edilmiş hem de ayrılmış veri seti elde edilir. Örnek kod bloğu şu şekildedir:

```
datagen = ImageDataGenerator(
    rescale=1./255,
    validation_split=0.2,
    rotation_range=20,
    width_shift_range=0.1,
    height_shift_range=0.1,
    zoom_range=0.2,
    horizontal_flip=True,
    brightness_range=[0.8, 1.2],
    fill_mode='nearest'
)

train_gen = datagen.flow_from_directory(
    'dataset/',
    target_size=(128,128),
    batch_size=16,
```

```
class_mode='categorical',  
subset='training',  
shuffle=True,  
seed=42  
)  
  
val_gen = datagen.flow_from_directory(  
'dataset/',  
target_size=(128,128),  
batch_size=16,  
class_mode='categorical',  
subset='validation',  
shuffle=False,  
seed=42  
)
```

Validation_split parametresi ile en son %20 oranındaki örnekler validation seti olarak ayrılır community.deeplearning.ai. shuffle=True ile eğitim setindeki veriler her epoch başında karıştırılırken, validation seti sabitlenir [34]. Böylece validation aşamasında veri artırımı uygulanmaz, model gerçek (augment edilmemiş) görsellerle değerlendirilir.

3.2 GÖRÜNTÜ ÖN İŞLEME

Zeytin sınıflandırma sisteminin doğruluğunu ve kararlılığını artırmak amacıyla, ham görüntüler üzerinde uygulanan ön işleme adımları, derin öğrenme modelinin başarısını doğrudan etkilemektedir. Görüntü işleme süreci yalnızca verilerin görsel kalitesini artırmakla kalmaz, aynı zamanda modelin öğrenmesini kolaylaştıracak yapısal özniteliklerin vurgulanmasını sağlar. Bu bağlamda, çalışmada uygulanan ön işleme adımları, görüntü boyutlarının normalize edilmesi, renk uzayı dönüşümleri, kontrast artırma işlemleri ve nihayetinde modelle uyumlu hale getirme süreçlerini kapsamaktadır.

İlk olarak, elde edilen tüm zeytin görselleri, 128×128 piksel boyutuna yeniden boyutlandırılmıştır. Bu işlem, derin öğrenme modeline sabit boyutta giriş sağlamak amacıyla yapılmış olup, aynı zamanda bellek kullanımı ve işlem süresi açısından da verimlilik kazandırmaktadır. Görsellerin boyutları tek tip hale getirilmeden bir CNN mimarisine sokulması, filtre boyutlarının ve katman çıkışlarının tutarsızlığına neden olabileceğinden bu adım zorunlu olarak uygulanmıştır.

Ek olarak, piksellerin yoğunluk değerleri 0-255 aralığından 0-1 aralığına indirgenmiş ve böylece tüm görüntüler normalize edilmiştir. Bu işlem hem eğitim sürecinin daha hızlı yakınsamasına katkı sağlar hem de ağırlıkların dengesiz güncellenmesini önler. Literatürde de benzer uygulamalarda giriş verilerinin normalize edilmesinin model başarımına katkı sağladığı rapor edilmiştir [19].

3.2.1 CLAHE (CONTRAST LİMITED ADAPTİVE HİSTOGRAM EQUALİZATİON) İLE KONTRAST İYİLEŞTİRME

Zeytinlerin yüzey dokularını ve renk farklılıklarını daha belirgin hale getirmek amacıyla CLAHE (Sınırlı Kontrast Uyarlanabilir Histogram Eşitleme) yöntemi kullanılmıştır. Klasik histogram eşitleme, tüm görüntü üzerinde aynı kontrast iyileştirme uygularken; CLAHE yöntemi, görüntüyü lokal bölgelere ayırarak her bölgeye özel histogram eşitleme uygular. Bu sayede hem aşırı parlaklık hem de gölgeli bölgelerde detaylar korunmuş olur.

CLAHE'nin “clip limit” değeri 3.0, “tileGridSize” parametresi ise 8x8 olarak seçilmiştir. Bu ayarlar, yüzey kusurlarının, renk geçişlerinin ve dokusal farklılıkların daha iyi vurgulanmasına yardımcı olmuş, özellikle sinek vuruklu zeytinlerdeki ince yüzey bozulmalarının CNN tarafından ayırt edilebilmesini kolaylaştırmıştır. Görsel iyileştirme adımları aşağıdaki şekilde uygulanmıştır:

```
lab = cv2.cvtColor(image, cv2.COLOR_BGR2LAB)
l, a, b = cv2.split(lab)
clahe = cv2.createCLAHE(clipLimit=3.0, tileGridSize=(8,8))
cl = clahe.apply(l)
merged = cv2.merge((cl, a, b))
```

```
image = cv2.cvtColor(merged, cv2.COLOR_LAB2BGR)
```

Bu işlemde kullanılan LAB renk uzayı, insan gözünün parlaklığa verdiği duyarlılığı temel alan bir renk uzayıdır. L kanalı parlaklığı, A ve B kanalları ise renk bileşenlerini temsil eder. CLAHE, yalnızca L kanalına uygulanarak parlaklık iyileştirilmiş; renk dengesine ise müdahale edilmemiştir. Bu da renk sınıflandırmasının doğruluğunu korumaya katkı sağlamıştır.

3.2.1.1 NEDEN CLAHE TERCİH EDİLDİ?

CLAHE, özellikle yüzey detaylarının belirginleştirilmesi gereken uygulamalarda yaygın olarak tercih edilmektedir. Bu çalışmada da sinek zararları gibi mikro düzeydeki deformasyonların tespiti büyük önem taşıdığı için, klasik histogram eşitleme yerine CLAHE algoritması kullanılmıştır. CLAHE yöntemi, hem ışık değişimlerine karşı daha toleranslıdır hem de fazla kontrast artışını sınırlandırarak görüntüdeki yapaylıkları önler.

Benzer şekilde, literatürde de CLAHE'nin meyve ve yaprak hastalıklarının sınıflandırılmasında etkili sonuçlar verdiği belirtilmiştir. Özellikle Uğuz ve Uysal (2021) tarafından yapılan bir çalışmada, CLAHE'nin yaprak dokusu sınıflandırmalarında doğruluk oranlarını %7'ye kadar artırdığı rapor edilmiştir. Bu nedenle bu tezde de CLAHE algoritması veri işleme sürecine entegre edilmiştir.

3.2.1.2 ÖN İŞLEM SONRASI GÜNCEL KARŞILAŞTIRMALAR

Görsellerin işlenmeden önceki ve CLAHE uygulandıktan sonraki halleri karşılaştırıldığında, özellikle zeytin yüzeyindeki kabuk kıvrımları, renk geçişleri ve kusurlar çok daha belirgin hale gelmiştir. Aşağıda bu dönüşüme ait görsel ve kod parçaları sunulmuştur.



Şekil 9: CLAHE uygulanmadan önce (sol) ve uygulandıktan sonra (sağ) bir zeytin görselinde detay kazanımı.

Gerekli kütüphanelerin kurulumu için gerekli kod parçası aşağıdaki gibidir.

```
import cv2
import numpy as np
from matplotlib import pyplot as plt
from google.colab.patches import cv2_imshow
```

OpenCV cv2 kütüphanesi görüntü işleme fonksiyonlarını sağlar. Görseli yüklemek için “cv2.imread()”, renk uzayı dönüşümü fonksiyonu için “cv2.cvtColor()”, CLAHE uygulaması için “cv2.createCLAHE()”, görsel göstermek veya kaydetmek için “cv2.imshow()” ve “cv2.imwrite()” komutları kullanılmaktadır. [20].

“numpy” isimli kütüphane sayısal işlemler ve dizilerle çalışma amacıyla kullanılmaktadır. Python programlama dilinde yüksek frekans ile kullanılmaktadır ve temel kütüphanelerden biridir. CHALE için bu kod parçasında görsel birleştirme amacı ile kullanılmıştır. Türkçe manası ile “side by side” yan yana oluşturma amacı için “np.hstack()” komutu kullanılmıştır. Aynı zamanda numpy kütüphanesi piksel verisi işleme için de bu çalışmada kullanılmıştır [21].

“matplotlib.pyplot” kütüphanesi, Python diliyle oluşturulan grafiksel görselleştirme işlemlerinde yaygın olarak kullanılmaktadır. Özellikle yapay zekâ, makine öğrenmesi ve sinyal

işleme uygulamalarında doğruluk, kayıp ve karışıklık matrislerinin görsel olarak ifade edilmesinde kritik rol oynar. Bu çalışmada eğitim süreci boyunca model doğruluklarının karşılaştırmalı olarak gösterilmesi amacıyla kullanılacak olan “plt.plot()”, “plt.title()”, “plt.xlabel()”, “plt.ylabel()”, ve “plt.grid()” gibi komutlar matplotlib.pyplot modülü altında yer almaktadır [22].

“google.colab.patches.cv2_imshow” fonksiyonu, Google Colaboratory platformu üzerinde OpenCV ile işlenen görsellerin doğru şekilde görüntülenmesini sağlar. Çünkü klasik “cv2.imshow()” fonksiyonu Colab üzerinde doğrudan çalışmadığı için Google tarafından özel olarak geliştirilmiş bu modül kullanılmaktadır. Görsel karşılaştırmalar (örneğin CLAHE öncesi ve sonrası) bu sayede interaktif bir ortamda akademik olarak sunulabilir hale gelir.

Şekil 10’de yer alan kolaj halindeki zeytin fotoğraflarının CHALE uygulamasına tabi tutulması Google Colaboratory platformunda hazırlanmıştır.

```
image_path = "/content/zeytin.png"
original = cv2.imread(image_path)
lab = cv2.cvtColor(original, cv2.COLOR_BGR2LAB)
l, a, b = cv2.split(lab)

# CLAHE uygulaması
clahe = cv2.createCLAHE(clipLimit=3.0, tileGridSize=(8,8))
cl = clahe.apply(l)
merged = cv2.merge((cl, a, b))
enhanced = cv2.cvtColor(merged, cv2.COLOR_LAB2BGR)

# Karşılaştırma için birleştirme
combined = np.hstack((original, enhanced))

# Göster
cv2_imshow(combined)
```

Bu çalışmada `cv2.imread()`: Görüntü dosyasını OpenCV ile okur. Bu aşamada görsel, varsayılan olarak BGR (Blue-Green-Red) formatında yüklenir. `cv2.cvtColor(..., cv2.COLOR_BGR2LAB)`: Görüntü, LAB renk uzayına dönüştürülür. LAB, özellikle kontrast artırma ve parlaklık düzenleme işlemleri için uygun bir renk uzayıdır çünkü “L” bileşeni parlaklık (lightness) bilgisini tek başına içerir. Bu durum, CLAHE işlemini uygulamak için idealdir [23]. `cv2.split(lab)`: LAB uzayı üç ayrı kanalına (L, A, B) ayrılır. Yalnızca L kanalı işlenir çünkü bu kanal görüntünün parlaklık verisini taşır.

CHALE uygulaması için “`cv2.createCHALE()`” komutu ile `climpLimit = 3.0` kontrast sınırlamasını tanımlar. Yüksek bir değer verildiğinde daha yüksek ayrıntı verebilir fakat gürültü artabilir. Bu da yanılgıya neden olabilir. `tileGridSize = (8,8)` komutu ile görüntüyü 8x8 parçaya böler. Her bölgeye ayrı histogram eşitlemesi uygular. `Chale.apply(1)` sadece L (parlaklık) kanalına CHALE uygular. Dataylar güçlendirilmiş olur. Karanlık bölgeler aydınlatılır. Ancak resimin dengesini ve renk düzenini bozmadan işlem yapılır [23].

Görselin görüntülenmesi için, “`np.hstack(...)`”, Orijinal ve CLAHE uygulanmış görseller yan yana birleştirilir. Böylece karşılaştırmalı bir çıktı elde edilir.

Bu ön işleme adımı sayesinde modelin giriş verileri yüksek kontrastlı, eşit aydınlatmalı ve öğrenmeye uygun hale getirilmiştir. Bu da modelin eğitim sürecinde daha kararlı bir öğrenme eğrisi oluşturmasını sağlamıştır.

3.2.2 GAN İLE VERİ ARTIRIMI

Görüntü sınıflandırma modellerinde veri miktarı ve çeşitliliği, modelin genelleme gücünü doğrudan etkiler. Basit dönüşüm teknikleri (döndürme, kırpma, parlaklık değişimi) sınırlı çeşitlilik sağlar. Buna karşılık Generative Adversarial Networks (GAN) gibi derin öğrenme tabanlı yöntemler, daha gerçekçi ve çeşitlik içeren örnekler üretebilir [24, 41].


GAN’ler, birbirine karşı yarışan iki sinir ağı (generator ve discriminator) kullanarak, eğitim verilerine benzer yapay görüntüler üretir. Generator, sahte görüntüleri oluştururken Discriminator bu görüntüleri ayırt etmeye çalışır; bu iteratif süreç, zamanla gerçekmiş gibi görünen görüntüler üretimini sağlar [25].

Son yıllarda tarım alanında GAN tabanlı veri artırımı; bitki hastalığı tespiti, meyve kalite sınıflandırması, ürün hasar analizleri gibi görevlerde etkin olarak uygulanmaktadır. Sistemik

incelemeler, 2018 sonrası bu yöntemlerin tarımsal görüntü projelerinde hızla yaygınlaştığını ortaya koymaktadır.

GAN'lerin meyve sınıflandırmada uygulanmasına örnek olarak, 2021'de sunulan bir çalışmada Conditional GAN (cGAN) kullanılarak meyve hastalığı görüntüleri çoğaltılmış, sınıflandırma doğruluğu %83,8'den %88,8'e yükseltilmiş; bu, GAN destekli artırmanın etkili olduğunu göstermiştir.

Tarım uygulaması verileri genellikle dengesiz ve çeşitlilik açısından zayıftır; GAN tabanlı artırımlar, bu sorunları hafifletir ve modelin nadir sınıflardaki örnekler odaklanmasını sağlar. Örneğin, tarla bitkisi görüntülerinde GAN'ler sayesinde az sayıdaki etiketlenmiş örnek yapay çoğaltılarak sınıflandırma başarı oranı anlamlı ölçüde artırılmıştır.




Şekil 10: GAN Modeli

Bu çalışmada, klasik augmentasyon yöntemlerine ek olarak GAN ile üretilecek yapay zeytin görüntüleri planlanmaktadır. Bu sayede: Sınıf dengesizliği giderilecek, Modelin uç örneklerle (örneğin az sayıda fly-damaged zeytin) tanıma gücü artacak, Gerçekleştirilecek sınıflandırmanın doğruluk ve genelleme başarısı yükseltilecektir.

Bu yaklaşım, özellikle fly-damaged gibi düşük sayıda örneği olan sınıflar için dengeleme sağlar ve model performansını optimize eder.

Generative Adversarial Networks (GAN), sınırlı sayıda gerçek görüntüye sahip durumlarda, gerçekçi sentetik görüntüler üretmek amacıyla sıklıkla kullanılan derin öğrenme tabanlı bir yöntemdir. GAN, bir “üreteç” (generator) ve bir “ayırt edici” (discriminator) ağıdan oluşur. Üreteç, rastgele gürültüyü gerçekçi görsellere dönüştürmeye çalışırken, ayırt edici bu sentez görüntülerin gerçek mi yoksa sentetik mi olduğunu tahmin etmeye çalışır. Eğitim süreci “sıfır toplamli oyun” yaklaşımıyla yürütülür ve her iki ağı da birbirini geliştirir. GAN tabanlı veri artırımı, özellikle sınıflar arasında dengesizlik olan durumlarda büyük avantaj sağlar. Örneğin, nadir gözlemlenen “fly-damaged” sınıfı için sentez veri üretmek hem genel doğruluğu hem de azınlık sınıf performansını yükseltir. Tarım görüntüleme uygulamalarına örnekler: Tarımsal görüntülerde GAN’ler kullanılarak yaprak hastalığı verisi artırımı uygulanmıştır; bu yöntemde üretilen yaprak görselleri sınıflandırma doğruluğunu önemli ölçüde yükseltmiştir. Meyve kalitesinde conditional GAN (“Fruit Quality and Defect Image Classification with Conditional GAN”) modeli ise sentetik meyve görüntüleri ile sınıflandırma doğruluğunu %5–8 artırarak %88,75 seviyesine çıkarmıştır [26].

Sistemimizde uygulanma metodu: Gerçek veri setimizde sınıf dağılımı dengesizdir (örneğin “fly-damaged” az sayıda, nitekim bu dağılım gerçekte de bu şekildedir.). Conditional GAN kullanarak her sınıfa özgü görüntüler üretiriz. Bu sayede hem renk hem doku özellikleri modellenir. Üretilen sentetik görüntüler eğitim setine eklenir. Model yeniden eğitilir ve performans farkı değerlendirilir.



Şekil 11: GAN Modeli Sağlıklı ve Sağlıksız Meyve Üzerindeki Çıktıları

Beklenen avantajlar: Azınlık sınıf temsili artışı: Fly-damaged sınıf örnek sayısı artar. Aynı mevcut dağılım özellikleri korunur: Doku, ışık gibi unsurlar gerçek veriyle uyumlu sentezlerde yansıtılır. Modellerin genelleme gücü yükselir: Özellikle sınıf dengesizliği olan veri setlerinde model başarısı artar.

Örnek GAN eğitim akışı (Şekil 12): Görseldeki gibi, gerçek örnekler ve üretilmiş verilerle diskriminatör eğitilir; üreteç ise bu ayrımı aşmayı öğrenir. Bu şekilde GAN ile veri çoğaltma hem modelin doğruluğunu hem de “fly-damaged” gibi nadir sınıflar için tanıma yeteneğini artırmada etkili bir yöntem sunar.

Geleneksel veri artırımı teknikleri (döndürme, kırpma, parlaklık değişimi) sınırlı çeşitlilik sunar. GAN’lar ise orijinal veri dağılımını öğrenerek gerçekçi ve yeni görüntüler üretebilir, veri seti çeşitliliğini artırarak model genellemesini ve performansını yükseltir [26, 27, 28].

GAN, iki destekleyici sinir ağından oluşur: Generator (G): Rastgele latent vektörden gerçekçi görüntüler üretir. Discriminator (D): Gerçek ve sahte görüntüleri ayırt eder. Bu iki ağ arasında bir “oyun” kuruludur: Generator sahte görüntülerle D'yi kandırmaya çalışır, D ise doğru sınıflandırma yapmak ister [29].

DCGAN, hem G hem de D içinde evrişimli katmanlar, batch normalization ve ReLU/Leaky ReLU/ Tanh aktivasyonları kullanarak stabilite ve görüntü kalitesini artırır [29, 31]. cGAN'lar, sınıf etiketiyle birlikte görüntü üretimini sağlar. Örneğin farklı zeytin tür ve durumlarını label bilgisi ile üretebiliriz. Bu sayede sınıflardan bağımsız üretim engellenir [29, 30]. cGAN'lar, sınıf etiketiyle birlikte görüntü üretimini sağlar. Örneğin farklı zeytin tür ve durumlarını label bilgisi ile üretebiliriz. Bu sayede sınıflardan bağımsız üretim engellenir [29, 30].

3.2.3 VERİLERİN ÇOĞALTILMASI

Bu çalışmada model performanslarını karşılaştırmak amacıyla, farklı veri çeşitlendirme stratejileriyle oluşturulmuş yedi temel veri seti kullanılmıştır. İlki olan original++, yalnızca temel verilerden oluşan, herhangi bir dönüşüm uygulanmamış versiyondur ve referans veri seti olarak değerlendirilmiştir. original-flip veri seti, yatay ekseninde döndürülmüş (horizontal flip) görüntülerden oluşmakta olup modelin simetrik varyasyonlara olan duyarlılığını ölçmek için kullanılmıştır. original-horizontal180 veri seti, görüntülerin 180 derece döndürülmesiyle oluşturulmuş olup özellikle ışık ve yön değişimlerine karşı modelin dayanıklılığını test etmede önemli rol oynamıştır. original-horizontal180-flip ise hem 180 derece döndürülmüş hem de yatay çevrilmiş görüntüleri içermekte, böylece daha karmaşık dönüşümlere karşı modelin genelleme yeteneğini analiz etmeye olanak sağlamaktadır.

Ayrıca, styleGAN ile üretilmiş yapay görüntülerin çeşitli dönüşümleri de ayrı veri setleri olarak tanımlanmıştır. original-stylegan-flip, GAN ile üretilmiş görüntülerin yatay çevrilmiş versiyonlarını, original-stylegan-horizontal180 ise bu yapay görüntülerin 180 derece döndürülmüş halini içermektedir. Bu tür veriler, gerçek verilerle modelin yapay veri üzerindeki tutarlılığını karşılaştırmak amacıyla kullanılmıştır. original-stylegan-horizontal180-flip ise hem 180 derece döndürülmüş hem de yatay çevrilmiş GAN türevli görselleri barındırmaktadır.

Bu veri setleri, hem gerçek hem de sentetik görüntülerin farklı dönüşüm kombinasyonlarıyla zenginleştirilerek, modelin hem doğruluğunu hem de genelleme kapasitesini ölçmek için kapsamlı bir değerlendirme zemini oluşturmuştur.

Veri Seti 1 – original++: Orijinal yüksek çözünürlüklü görüntülerden oluşur. CLAHE kontrast iyileştirmesi uygulanmamış, ham ve saf veri kümesidir. Referans veri seti olarak değerlendirilmiştir.

Veri Seti 2 – original-flip: Orijinal görüntüler yatay ekseninde çevrilerek (flip) artırılmıştır. Bu sayede veri çeşitliliği sağlanmış ve simetrik bozulmalar test edilmiştir.

Veri Seti 3 – original-horizontal180: Görüntüler 180 derece döndürülerek modelin yönelime duyarlılığı değerlendirilmiştir.

Veri Seti 4 – original-horizontal180-flip: 180 derece döndürülmüş ve ardından yatay ekseninde çevrilmiş görüntülerden oluşur. Bu set, yön ve pozisyon varyasyonlarının birlikte ele alındığı bir yapıya sahiptir.

Veri Seti 5 – original-stylegan-flip: StyleGAN ile yapay olarak üretilen sinek vuruklu görüntüler ve gerçek veriler birleştirilmiş; ardından flip işlemi uygulanmıştır. GAN tabanlı veri artırmanın etkisi bu veri setiyle test edilmiştir.

Veri Seti 6 – original-stylegan-horizontal180: Yapay sinek vuruklu örnekler, 180 derece döndürülmüş olarak eğitime dahil edilmiştir.

Veri Seti 7 – original-stylegan-horizontal180-flip: GAN tabanlı görüntüler hem döndürülüp hem de flip işlemine tabi tutularak en fazla çeşitliliğe sahip artırılmış veri seti elde edilmiştir.

3.3 MAKİNE ÖĞRENMESİ YÖNTEMLERİ


Makine öğrenmesi tabanlı görsel sınıflandırma sistemlerinde, verinin yapısına ve çözülmesi istenen problemin doğasına göre farklı mimari yaklaşımlar tercih edilmektedir. Bu çalışmada, zeytinlerin renk ve yüzey kusurlarına göre sınıflandırılması problemi için hem geleneksel hem de modern derin öğrenme yöntemleri kullanılmıştır. Uygulanan başlıca yöntemler; Convolutional Neural Network (CNN), Transformer tabanlı görsel modeller ve MetaFormer mimarileri olmuştur.

3.3.1 CONVOLUTIONAL NEURAL NETWORK (CNN) MİMARİSİ

Convolutional Neural Network (CNN), görüntü sınıflandırma ve nesne tanıma gibi görevlerde yaygın olarak kullanılan, derin öğrenmeye dayalı bir yapay sinir ağı mimarisidir. Özellikle görsel verilerden öznitelik çıkarımı ve sınıflandırma işlemlerinde yüksek doğruluk sağlaması nedeniyle tercih edilmektedir. CNN'ler, evrişim (convolution) katmanları sayesinde görüntü üzerinde kayan filtreler aracılığıyla kenar, renk, doku gibi düşük seviyeli öznitelikleri çıkarır. Bu öznitelikler, katmanlar arasında hiyerarşik olarak işlenerek daha soyut özellikler haline gelir ve nihayetinde tam bağlantılı (fully connected) katmanlar aracılığıyla sınıflandırma yapılır.

CNN mimarisinin tipik bileşenleri arasında; evrişim katmanları, aktivasyon fonksiyonları (ReLU), havuzlama (pooling) katmanları, dropout ve tam bağlantılı katmanlar (Dense) yer almaktadır. Evrişim katmanları, giriş görüntüsü üzerinde öğrenilebilir filtreler kullanarak öznitelik haritaları oluşturur. Havuzlama katmanları, bu haritaların boyutunu azaltarak hesaplama yükünü düşürürken aynı zamanda özniteliklerin konumsal değişimlere karşı daha dayanıklı hale gelmesini sağlar. Dropout işlemi ise overfitting (aşırı öğrenme) riskini azaltmak için bazı nöronların geçici olarak devre dışı bırakılmasını sağlar. Tam bağlantılı katmanlarda ise, bu öznitelikler sınıflandırma amacıyla kullanılır.

Bu çalışmada uygulanan CNN modeli; 128×128 piksel boyutundaki RGB giriş görüntüleri ile başlamakta ve sırasıyla 32, 64 ve 128 filtre içeren üç evrişim bloğu içermektedir. Her blok, ReLU aktivasyon fonksiyonu ve MaxPooling katmanı ile desteklenmiştir. Ağın sonunda, %50 dropout içeren bir ara katman ve üç sınıflı (yeşil, siyah, sinek vuruklu) Softmax çıkış katmanı yer almaktadır. Modelin eğitimi sırasında, optimizasyon algoritması olarak Adam seçilmiş; öğrenme oranı 0.001 olarak belirlenmiştir. Eğitim süreci, 50 epoch üzerinden early stopping uygulanarak gerçekleştirilmiştir. Şekil 13'de CNN mimarisine ait 16 katmanlı bir eğitim modelinin görselleştirilmesi bulunmaktadır.



Şekil 12: 16 Katmanlı Bir CNN Uygulaması Görselleştirilmesi

3.3.1.1 CNN MODELİNDE MATEMATİKSEL FORMÜLASYON

Bu çalışmada sınıflandırma modeli olarak bir evrişimsel sinir ağı (CNN) kullanılmıştır. CNN, giriş görüntüsünü öğrenilebilir filtreler ve doğrusal olmayan işlemler aracılığıyla işler. Her konvolüsyon katmanında Eşitlik 1'deki matematiksel işlem uygulanır.

$$Z^{\{1\}} = f(W^{\{1\}} * X^{\{1-1\}} + b^{\{1\}}) \quad (1)$$

$W^{\{1\}}$: 1-inci katmana ait filtre ağırlıklarıdır; konvolüsyon aracılığıyla görüntüdeki kenar, doku gibi öznitelikleri öğrenir. Şekil 14'de Transformer mimarisine ait görselleştirilmesi verilmiştir.

$X^{\{1-1\}}$: Bir önceki katmandan gelen giriş (özellik haritası) olur.

$b^{\{1\}}$: Bias terimi olup her katmanda öğrenilir. f : Kullanılan doğrusal olmayan aktivasyon fonksiyonudur; bu çalışmada ReLU tercih edilmiştir. ReLU, negatif değerleri sıfırlayarak modelin derinleşmesine yardımcı olur.

Eşitlik 2'de doğrusal olmayan aktivasyon fonksiyonunun denklemi verilmiştir.

$$\sigma(z_i) = e^{z_i} / \sum_{j=1}^K e^{z_j} \quad (2)$$

Z_i : Z nin i 'inci sınıfa ait ham skor değerini ifade eder, $K=3$ olarak belirlenmiştir; yani sınıflar yeşil, siyah ve böcek hasarlı (sinek-vuruklu) zeytinlerdir. Model, eğitim sırasında kategorik çapraz entropi (categorical crossentropy) kayıp fonksiyonu kullanılarak optimize edilmiştir.

Eşitlik 3'de kayıplar fonksiyonunun denklemi verilmiştir.

$$L = - \sum_{i=1}^N \sum_{c=1}^C y_{i,c} \log(\hat{y}_{i,c}) \quad (3)$$

Burada;

$y_{i,c}$, **one-hot kodlamalı gerçek etiketi** (gerçek sınıf bilgisi),

$\hat{y}_{i,c}$, modelin tahmini olasılığını,

N , toplam örnek sayısını,

C , çıktı sınıf sayısını (örneğin 3 sınıf) ifade eder.

Bu çalışmada kategorik çapraz entropi (categorical crossentropy) kayıp fonksiyonu ile optimal performans sağlanmıştır. Araştırmalar göstermiştir ki, sınıflandırma problemlerinde Softmax aktivasyonunun ardından kategorik çapraz entropi kullanımı yaygın ve başarılı bir yöntemdir; ReLU ve Softmax kombinasyonları CNN tabanlı meyve sınıflandırmalarında sıkça görülmektedir.

Bu denklemler, modelin ileri besleme (forward pass) ve kayıp hesaplama süreçlerini tanımlayarak sistemin zeytin sınıflandırması için ayırt edici öznelilikler öğrenmesine olanak sağlar.

3.3.1.2 AKTİVASYON FONKSİYONU VE KAYIPLAR

ReLU (Rectified Linear Unit) basit yapısı ve yoğun derin sinir ağlarında karşılaşılan vanishing gradient (kaybolan gradyan) problemlerine karşı etkili olması nedeniyle tercih edilmiştir. Softmax aktivasyonu ise çıktı katmanında sınıflar arasında normalize edilmiş bir olasılık dağılımı sağlar ve çok sınıflı sınıflandırma problemlerine uygun bir sonuç sunar. Eğitimin yönetilmesi ve modelin başarısızlık ölçümü için kullanılan categorical crossentropy kayıp

fonksiyonu, gerçek etiket ile modelin tahmin ettiği olasılıklar arasındaki farkı ölçerek ağırlık öğrenmesine sağlam bir temel sağlar [4, 6].


3.3.2 TRANSFORMER MİMARİSİ

Transformer mimarisi, temel olarak dizisel (sequence-based) verilerde bağlamsal ilişkileri paralel olarak öğrenebilen bir yapıdır. Geleneksel olarak kullanılan RNN ve LSTM mimarilerinin sıralı işleme kısıtlarını ortadan kaldırarak daha hızlı ve daha derin modellerin eğitilmesini mümkün kılmıştır. Transformer'ın en temel yapı taşları, çok başlı dikkat mekanizması (multi-head self-attention) ve konum (position) kodlamalarıdır.

Bu mimaride her bir giriş birimi (token), modelin diğer tüm giriş birimleriyle ilişkisini öğrenir. Self-attention mekanizması, her token'ın diğer token'larla olan ilişkisini öğrenerek bağlamsal ağırlıkları belirler. Bu sayede, her bir birim, yalnızca kendi komşuları ile değil, tüm veri dizisiyle etkileşim kurabilir. Görüntü işleme uygulamalarında bu durum, her bir piksel bölgesinin tüm görüntüyle olan bağlamının öğrenilmesini sağlar ve geleneksel CNN mimarilerinin yerel filtre sınırlamalarını aşar.

Görüntü işleme için adapte edilmiş Transformer mimarileri (örneğin Vision Transformer – ViT), görüntüleri küçük yamalara (patch) bölerek her birini birer token olarak işler. Bu yamalar, bir dizi pozisyonel kodlama ile zenginleştirilerek Transformer katmanlarına aktarılır. Böylece model hem mekânsal hem de anlamsal bağıntıları öğrenebilir. Bu yöntem, özellikle karmaşık desen tanıma, renk ayrımı, yüzey deformasyonu tespiti gibi görevlerde etkili sonuçlar vermektedir.

Transformer tabanlı modellerin en büyük avantajlarından biri, çok büyük veri kümeleri üzerinde yüksek genelleme kabiliyeti sunmalarıdır. Ancak bu mimariler yüksek hesaplama gücü gerektirdiğinden, pratikte optimize edilmiş versiyonları (örneğin Swin Transformer, MobileViT, Compact Convolutional Transformers gibi) daha yaygın şekilde kullanılmaktadır.



Şekil 13: Transformer Mimarisi Görselleştirmesi

3.3.2.1 TRANSFORMER MİMARİSİ VE MATEMATİKSEL FONKSİYONLARI

Transformer mimarisi, ilk olarak Vaswani ve arkadaşları tarafından tanıtılmış olup özellikle doğal dil işleme (NLP) görevlerinde dikkat mekanizmasına dayalı olarak yüksek başarı sağlamıştır. Görsel sınıflandırma görevlerinde de Vision Transformer (ViT) gibi varyantlar sayesinde etkili şekilde kullanılmaya başlanmıştır. Bu mimari, evrişim işlemlerine ihtiyaç duymadan tüm girdi dizisi üzerinde öğrenme gerçekleştirir ve sıralı veriler arasındaki ilişkileri modelleyebilir.

Transformer, temel olarak girdi vektörlerinin lineer dönüşümle sorgu (Query), anahtar (Key) ve değer (Value) vektörlerine dönüştürülmesiyle çalışır. Bu vektörler kullanılarak hesaplanan dikkat (attention) matrisi, bilgi akışını yönlendirir. Eşitlik 4’de ilgili formül verilmiştir.

$$\text{Attention}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right) * V \quad (4)$$

Burada:

Q, K, V : Giriş vektörlerinden türetilen Query, Key ve Value matrisleridir.

d_k : Anahtar vektörlerinin boyutudur, ölçekleme amacıyla karekökü alınır.

Softmax fonksiyonu, dikkat skorlarını normalize eder ve hangi girdiye ne kadar dikkat edileceğini belirler.

Transformer’da çok başlı dikkat (multi-head attention) kullanılarak farklı temsil uzaylarında öğrenme gerçekleştirilir. Bu mekanizma aşağıdaki Eşitlik 5’de özetlenir:

$$\text{MultiHead}(Q, K, V) = \text{Concat}(\text{head}^1, \dots, \text{head}_h) * W^o \quad (5)$$

Her bir head, kendi ağırlık matrisleriyle öğrenim sağlar ve sonunda tüm head’ler birleştirilip çıkışa aktarılır. Eğitim sürecinde Adam optimizasyonu, ReLU aktivasyonu ve sınıflandırma için Softmax çıkış katmanı kullanılmıştır. Kayıp fonksiyonu olarak CNN’de olduğu gibi categorical cross-entropy tercih edilmiştir.

3.3.3 METAFORMER MİMARİSİ

MetaFormer, 2022 yılında Meta AI araştırmacıları tarafından tanıtılan ve Transformer mimarisine alternatif olarak geliştirilen, daha modüler ve dikkat (attention) bağımlılığı olmayan bir derin öğrenme iskeletidir. Transformer mimarilerinde başarıyı sağlayan temel yapıların, yalnızca self-attention mekanizmasından değil, daha genel bir veri işleme şablonu (data processing framework) olan “form”dan kaynaklandığını savunur. Bu yaklaşıma göre, attention yerine başka işlemler kullanılarak da güçlü performanslar elde edilebilir.

MetaFormer mimarisi, temel olarak üç yapı bloğundan oluşur:

Normalizasyon katmanı (örneğin LayerNorm),

Token mixer (veriler arası etkileşim sağlayan işlemci – attention yerine konulabilir),

MLP (Multi-Layer Perceptron) katmanı.

Transformer’da “token mixer” olarak self-attention yer alırken, MetaFormer’da bu katman yerine Convolution, MLP, Fourier transform gibi farklı yapılar kullanılabilir. Örneğin ConvFormer modelinde bu katmanda konvolüsyon uygulanırken, PoolFormer’da basit pooling işlemi tercih edilmiştir.

MetaFormer yapısı, “attention is all you need” görüşüne karşıt olarak, başarıyı asıl getirenin dikkat değil genel mimari şablonun kendisi olduğunu savunur. Yapılan deneyler, dikkat mekanizması içermeyen MetaFormer türevlerinin, çeşitli görüntü sınıflandırma görevlerinde Vision Transformer (ViT) ve Swin Transformer gibi modellere yakın veya daha iyi performans sergileyebildiğini göstermiştir.

Zeytin sınıflandırma probleminde MetaFormer mimarisine dayalı ConvFormer ve CaFormer gibi türev modeller kullanılarak, hem parametre verimliliği sağlanmış hem de sınıflar arası dengesizliğe rağmen yüksek genel doğruluk elde edilmiştir. Bu yapılar, hem detaylı yüzey desenlerini ayırt edebilmiş hem de sinek vuruklu zeytinlerdeki mikroskobik deformasyonları öğrenme konusunda başarılı sonuçlar vermiştir.

3.3.3.1 METAFORMER MİMARİSİ VE MATEMATİKSEL FORMÜLASYONU

Metaformer mimarisi, temel Transformer yapısının “Attention = Transformer” kavramını sorgulayarak, dikkat (attention) yerine başka bilgi birleştirme (token mixer) yöntemlerinin de kullanılabileceğini ortaya koyan bir yaklaşımdır. Metaformer, genel bir çatı olup içerisinde hem attention’lı hem attention’sız modüller barındırabilir. Bu yönüyle hem Transformer’a genelleme sunar hem de konvolüsyonel yapılarla entegre edilerek daha hesaplamalı verimli modellerin geliştirilmesine olanak tanır.

Metaformer mimarisinde giriş, üç ana bileşenle işlenir:

Token Mixer: Girdi özelliklerinin birbirine karıştırılması. Bu işlem dikkat mekanizması (attention), konvolüsyon, MLP-Mixer gibi farklı yaklaşımlarla gerçekleştirilebilir.

Normalization: Layer Normalization veya RMSNorm gibi teknikler kullanılarak girdilerin dağılımı düzenlenir.

Feed-Forward Network (FFN): Her token’a ayrı ayrı uygulanan iki katmanlı bir tam bağlı yapıdır. ReLU gibi aktivasyon fonksiyonları içerir.

Metaformer’ın genel formülü Eşitlik 6 ve Eşitlik 7’de özetlenebilir:

$$x' = x + \text{TokenMixer}(\text{Norm}(x)) \quad (6)$$

$$x' = x + \text{TokenMixer}(\text{Norm}(x)) \quad (7)$$

Bu yapı, katman bazlı ardışık bir işlem zinciri sunar. CNN’de olduğu gibi burada da ReLU aktivasyonu, çıktı katmanında Softmax fonksiyonu ve categorical crossentropy kaybı kullanılarak eğitim gerçekleştirilir. Bu çalışmada kullanılan Metaformer varyantları, görsel sınıflandırmada minimum parametre sayısı ile yüksek doğruluk sağlamayı hedeflemektedir.

3.3.4 MODEL MİMARİLERİNİN SINIFLANDIRILMASI VE KARŞILAŞTIRILMASI

Bu çalışmada zeytin sınıflandırma görevi için toplam yedi farklı derin öğrenme mimarisi kullanılmış olup, bu modeller mimari yapılarına göre üç temel gruba ayrılmıştır: CNN tabanlı mimariler, Transformer tabanlı mimariler ve Metaformer tabanlı mimariler. Bu ayrım, her mimarinin görüntü verisini işleme ve öznitelik çıkarma stratejilerine dayalı olarak yapılmıştır. Her bir grubun hem yapısal özellikleri hem de sınıflandırma görevine katkıları aşağıda açıklanmıştır.

CNN (Convolutional Neural Network) tabanlı mimariler, görüntü üzerinde kayan filtrelerle yerel özellikleri (kenar, doku, renk geçişleri vb.) çıkararak sınıflandırma işlemini gerçekleştiren klasik derin öğrenme yapılarıdır. Bu çalışmada kullanılan üç CNN tabanlı model şunlardır: özel olarak geliştirilen temel CNN mimarisi, MobileNet ve ResNet. Geliştirilen özel CNN yapısı, 3 konvolüsyon katmanı, ReLU aktivasyonları, MaxPooling ve Dropout katmanları ile birlikte düşük parametrelili ve yorumlanabilir bir yapı sunmaktadır. MobileNet, derinlik ayırık evrişim (depthwise separable convolution) mimarisiyle çalışarak mobil cihazlar için optimize edilmiş hafif bir çözüm sunarken, ResNet modeli residual blokları sayesinde çok daha derin yapıları etkin biçimde eğitebilmekte ve gradyan kaybını önleyerek soyut özniteliklerin çıkarımını kolaylaştırmaktadır.

Transformer tabanlı mimariler, görüntü içindeki tüm pikseller veya patch’ler arasında dikkat (self-attention) mekanizması kurarak küresel (global) ilişkileri öğrenebilen yapılardır. Bu çalışma kapsamında iki adet Transformer temelli mimari kullanılmıştır: CrossViT ve MobileViT. CrossViT, farklı boyutlardaki görüntü patch’lerini aynı anda işleyerek hem yerel hem de global bağlamı yakalamayı amaçlayan çift ölçekli bir Vision Transformer (ViT) mimarisidir. MobileViT ise, CNN ile Transformer bloklarının birleşiminden oluşan hibrit bir yapı sunar; konvolüsyonel katmanlarla yerel özellik çıkarımı yapılırken, self-attention bloklarıyla küresel bağıntılar

öğrenilmektedir. Bu sayede hem mobil uyumluluk sağlanmakta hem de dikkat mekanizmalarının avantajları elde edilmektedir.

Metaformer tabanlı mimariler, Transformer mimarisinin genel iskeletini (normalizasyon, MLP, residual bağlantılar) korurken dikkat (attention) modülünü farklı öznitelik karıştırıcı (token mixer) bloklarla değiştirmektedir. Bu çalışma kapsamında ConvFormer ve CaFormer olmak üzere iki Metaformer mimarisi test edilmiştir. ConvFormer, attention yerine konvolüsyon tabanlı öznitelik karıştırıcılar kullanarak daha verimli ve hızlı çalışan bir yapı sunar. Bu durum, özellikle sınırlı veri içeren senaryolarda hesaplama avantajı sağlar. CaFormer ise kanal (channel-wise) düzeyinde dikkat mekanizmalarıyla çalışmakta, renk ve kanal bilgisi üzerinden sınıflandırma başarımını artırmayı hedeflemektedir. Metaformer yapılar, Transformer'a kıyasla daha az parametre ile benzer düzeyde başarı sağlayabilme potansiyeli taşımaktadır.

Bu üç grup arasında en temel fark, öznitelik çıkarma yaklaşımıdır: CNN mimarilerinde yerel filtrelerle bilgi çıkarımı yapılırken; Transformer mimarileri global dikkat öğrenmesiyle tüm veriler arasındaki ilişkiyi göz önünde bulundurur; Metaformer yapıları ise bu iki yaklaşım arasında bir köprü kurarak farklı öznitelik karıştırma modülleri ile esnek, modüler ve hesaplama dostu çözümler sunar. Tez kapsamında yapılan deneylerde bu mimarilerin her biri belirli veri setlerinde yüksek performans göstermiştir ve bu durum detaylı şekilde ileriki bölümlerde raporlanmıştır.

3.4 PERFORMANS METRİKLERİ

Çalışmada geliştirilen zeytin sınıflandırma sistemlerinin başarımını değerlendirmek amacıyla dört temel performans metriği kullanılmıştır: Accuracy (Doğruluk), Precision (Kesinlik), Recall (Duyarlılık) ve F1-Score (F1 Skoru). Bu metrikler, her bir sınıf (Yeşil, Siyah, Sinek Vuruklu) için ayrı ayrı hesaplanarak modelin yalnızca genel doğruluğu değil, aynı zamanda sınıflar arasındaki dengeyi sağlama yeteneği de incelenmiştir.

Accuracy (Doğruluk): Modelin tüm doğru tahminlerinin (hem pozitif hem negatif) toplam tahmin sayısına oranıdır. Ancak sınıflar arasında dengesizlik olduğunda yanıltıcı olabilir. Doğruluk hesaplama formülü Eşitlik 8'de verilmiştir.

$$ACC = \frac{(TP + TN)}{TP + TN + FP + FN} \quad (8)$$

Precision (Kesinlik): Belirli bir sınıfa ait olarak tahmin edilen örneklerin, gerçekten o sınıfa ait olma oranıdır. Yanlış pozitif sonuçların azaltılmasına odaklanır. Kesinlik hesaplama formülü Eşitlik 9’da verilmiştir.

$$PRECISION = \frac{TP}{TP + FP} \quad (9)$$

Recall (Duyarlılık): Gerçekten belirli bir sınıfa ait olan örneklerin, model tarafından doğru tahmin edilen oranıdır. Yanlış negatifleri azaltmayı hedefler. Duyarlılık hesaplama formülü Eşitlik 10’da verilmiştir.

$$RECALL = \frac{TP}{TP + FN} \quad (10)$$

F1-Score: Precision ve Recall değerlerinin harmonik ortalamasıdır. Özellikle dengesiz sınıf dağılımlarında daha dengeli ve anlamlı bir ölçüm sağlar. F1 hesaplama formülü Eşitlik 11’de verilmiştir.

$$F1\ SCORE = 2 * \frac{PRECISION * RECALL}{PRECISION + RECALL} \quad (11)$$

Her bir sınıf için bu metrikler ayrı ayrı hesaplanmış, ayrıca ortalama değerleri de raporlanarak sınıflar arası performans tutarlılığı değerlendirilmiştir. Böylece modelin belirli sınıflara aşırı duyarlılık göstermesi ya da bazı sınıfları ihmal etmesi gibi olasılıklar tespit edilebilmiştir.

4. ARAŞTIRMA BULGULARI

Bu çalışmada, zeytinlerin yüzey özelliklerine ve renk farklarına göre sınıflandırılmasını gerçekleştirmek amacıyla, farklı derin öğrenme mimarileri geliştirilmiş ve karşılaştırmalı olarak test edilmiştir. Kullanılan modeller hem geleneksel CNN yaklaşımını hem de dikkat (attention) mekanizmalarına dayalı modern mimarileri içermektedir. Çalışmada uygulanan modeller şunlardır:

CNN (Convolutional Neural Network): Üç adet konvolüsyon katmanı, ardından gelen max-pooling, dropout ve tam bağlı katmanlar ile yapılandırılmıştır. Ara katmanlarda ReLU aktivasyonu, son katmanda ise sınıflandırma için softmax aktivasyonu kullanılmıştır. Hesaplama verimliliği yüksek olan bu yapı, referans model olarak değerlendirilmiştir.

CaFormer: Kanal dikkat (channel attention) mekanizması ile zeytin yüzeylerinde öne çıkan bölgeleri vurgulayarak sınıflandırma başarısını artırmayı hedefleyen modern bir mimaridir.

ConvFormer: Konvolüsyonel işlemler ile dikkat (attention) mekanizmasını birleştiren bu model, görsel özniteliklerin etkin şekilde çıkarılmasını sağlar ve yüksek sınıflandırma doğruluğu sunar.

MobileViT: Mobil cihazlar için optimize edilmiş bu hibrit mimari, CNN ve Transformer bloklarını birleştirerek hem yerel hem de global görsel bağlamı işler. Hafif yapısına rağmen yüksek performans sergiler.

CrossViT: Çoklu ölçekli görüntü özniteliklerini işlemek için paralel ViT (Vision Transformer) blokları kullanan bu model, farklı boyutlardaki bilgi kümelerini entegre ederek daha kapsamlı bir temsil oluşturur.

MobileNet: Derinlik ayrıştırılabilir evrişimler (depthwise separable convolutions) ile yapılandırılmış, hesaplama açısından son derece verimli ve mobil sistemlerde yaygın kullanılan bir mimaridir.

Bu modellerin tamamı, aynı veri seti kümeleri üzerinde eğitilmiş ve 5-fold cross-validation, holdout test verisi ve overfitting/underfitting analizleri gibi farklı değerlendirme stratejileriyle test edilmiştir. Böylece, her bir mimarinin farklı sınıflar (Yeşil, Siyah, Sinek Vuruklu) üzerindeki başarıyı karşılaştırmalı olarak analiz edilmiştir.

4.1.1 EĞİTİM KONFIGÜRASYONU

Model, $\text{learning_rate}=0.001$ ile yapılandırılan Adam optimizasyon algoritmasıyla derlenmiştir. Adam, her bir parametre için adaptif öğrenme oranları hesaplayarak derin sinir ağlarında hızlı öğrenme ve etkin yakınsama sağlar [35]. Öğrenme süreci, 20 epoch boyunca, her birinde 16 örnek içeren minibatch'ler kullanılarak yürütülmüştür.

Eğitim ve doğrulama doğruluğu ile kayıp değerleri düzenli olarak izlenerek overfitting-in oluşup oluşmadığı kontrol edilmiştir. Gerekli durumlarda eğitim süreci durdurularak, modelin genelleme performansı iyileştirilebilir.

Veri çeşitliliğini artırmak ve modelin genelleme kabiliyetini yükseltmek amacıyla, Keras'ın ImageDataGenerator sınıfı kullanılarak “on-the-fly” veri artırımı yapılmıştır. Bu teknik; dönüşüm, çeviri, döndürme, zoom ve parlaklık modülasyonu gibi işlemleri gerçekleştirebilir. Böylece model her epoch'ta yeni varyantlar üzerinde eğitilerek overfitting riski azaltılır.

4.2 SINIFLANDIRMA SONUÇLARININ RAPORLANMASI

Bu bölümde, geliştirilen sınıflandırma modellerinin farklı veri setleri üzerindeki başarımları detaylı biçimde raporlanmıştır. Sınıflandırma performansı değerlendirmelerinde doğruluk (Accuracy), kesinlik (Precision), duyarlılık (Recall) ve F1-Skoru (F1-Score) olmak üzere dört temel metrik esas alınmıştır. Her bir model için oluşturulan tablolar, bu metriklerin üç farklı sınıf (Yeşil, Siyah ve Sinek Vuruklu) bazında ayrı ayrı hesaplanmasıyla elde edilmiştir.

Her bir model (CNN, CaFormer, ConvFormer, MobileViT, CrossViT, MobileNet) için yapılan eğitimlerde, veri setleri Veri Seti 1'den Veri Seti 7'ye kadar numaralandırılmıştır. Bu veri setleri, farklı görüntü artırma (augmentation) stratejilerinin uygulanmış versiyonlarıdır. Böylece hem modelin genelleme kapasitesi hem de veri seti çeşitliliğine karşı duyarlılığı test edilmiştir.


Grafikler, her bir veri setine karşılık gelen doğruluk ve sınıfa özel F1-skorlarını karşılaştırmalı şekilde sunarak görsel analiz imkânı sağlamaktadır. İlgili tablolar ise daha ayrıntılı performans değerlerini içermektedir. Bu yapı sayesinde modellerin sınıflar arası dengeyi ne ölçüde koruduğu ve hangi veri setlerinde daha başarılı olduğu açık bir şekilde gözlemlenebilmektedir. Tablo 4 ve Şekil 15'te CNN, Tablo 5 ve Şekil 16'da CaFormer, Tablo 6 ve Şekil 17'de Convformer, Tablo 7 ve Şekil 18'de CrossVit, Tablo 8 ve Şekil 19'da MobileNet, Tablo 9 ve Şekil

20’de MobileVit, Tablo 10 ve Şekil 21’de Resnet algoritmalarına ait sınıflandırma sonuçları yer almaktadır.



Tablo 4: CNN Modeline Göre Eğitim Sonuçları


DataSet	Accuracy	Green_Prec	Green_Rec	Green_F1	Black_Prec	Black_Rec	Black_F1	Fly_Prec	Fly_Rec	Fly_F1
Veri Seti 1	0,9913	0,9916	0,9916	0,9916	0,9914	0,9911	0,9914	0,9909	0,9909	0,9909
Veri Seti 2	0,9893	0,9953	0,9855	0,9873	0,9855	0,9855	0,9855	0,9873	0,9873	0,9873
Veri Seti 3	0,9888	0,9944	0,9884	0,9835	0,9884	0,9884	0,9884	0,9835	0,9835	0,9835
Veri Seti 4	0,991	0,9937	0,9894	0,9909	0,9894	0,9894	0,9894	0,9909	0,9909	0,9909
Veri Seti 5	0,9916	0,9918	0,9877	0,9947	0,9877	0,9877	0,9877	0,9947	0,9947	0,9947
Veri Seti 6	0,9956	0,9955	0,9935	0,9973	0,9935	0,9935	0,9935	0,9973	0,9973	0,9973
Veri Seti 7	0,9883	0,9962	0,9828	0,9857	0,9828	0,9828	0,9828	0,9857	0,9857	0,9857



Şekil 14: CNN Modeline Göre Eğitim Sonuçları Grafiği

Tablo 5: CaFormer Modeline Göre Eğitim Sonuçları


DataSet	Accuracy	Green_Prec	Green_Rec	Green_F1	Black_Prec	Black_Rec	Black_F1	Fly_Prec	Fly_Rec	Fly_F1
Veri Seti 1	0,9933	0,9831	0,9867	0,9849	0,9982	0,9934	0,9958	1	1	0,9933
Veri Seti 2	0,9633	0,9541	0,8963	0,9243	0,9835	0,9874	0,9855	0,9524	1	0,9633
Veri Seti 3	0,97	0,9739	0,9368	0,955	0,97	0,9802	0,9751	0,9839	1	0,97
Veri Seti 4	0,94	0,875	0,9211	0,8974	0,974	0,9672	0,9706	0,9712	0,9314	0,94
Veri Seti 5	0,9567	0,9639	0,9235	0,9432	0,9608	0,9722	0,9664	0,959	0,9748	0,9567
Veri Seti 6	0,9967	0,9965	0,9936	0,995	0,9948	1	0,9974	0,9984	0,9964	0,9967
Veri Seti 7	0,91	0,7963	0,795	0,7956	0,9958	0,9471	0,9676	0,8834	0,9963	0,91



Şekil 15: CaFormer Modeline Göre Eğitim Sonuçları Grafiği

Tablo 6: ConvFormer Modeline Göre Eğitim Sonuçları


DataSet	Accuracy	Green_Prec	Green_Rec	Green_F1	Black_Prec	Black_Rec	Black_F1	Fly_Prec	Fly_Rec	Fly_F1
Veri Seti 1	0,8989	0,9322	0,8714	0,8986	0,8571	0,8925	0,8722	0,9114	0,9277	0,9187
Veri Seti 2	0,8767	0,9346	0,7983	0,8596	0,8176	0,9217	0,8647	0,881	0,903	0,8904
Veri Seti 3	0,8722	0,9313	0,7727	0,8443	0,8476	0,9242	0,8818	0,858	0,9207	0,8865
Veri Seti 4	0,8233	0,8105	0,7572	0,7828	0,8416	0,8562	0,8452	0,8406	0,8596	0,8484
Veri Seti 5	0,8344	0,8931	0,7355	0,8051	0,7606	0,825	0,7913	0,8617	0,9018	0,8806
Veri Seti 6	0,9056	0,9244	0,9092	0,9128	0,8798	0,8409	0,8542	0,9313	0,9649	0,9433
Veri Seti 7	0,6567	0,4923	0,593	0,5248	0,5819	0,6056	0,5168	0,6629	0,7781	0,6866



Şekil 16: ConvFormer Modeline Göre Eğitim Sonuçları Grafiği

Tablo 7: CrossVit Modeline Göre Eğitim Sonuçları


DataSet	Accuracy	Green_Prec	Green_Rec	Green_F1	Black_Prec	Black_Rec	Black_F1	Fly_Prec	Fly_Rec	Fly_F1
Veri Seti 1	0,9923	1	0,9864	0,9931	0,9842	1	0,992	1	0,9912	0,9956
Veri Seti 2	0,9946	0,9988	0,9864	0,9926	0,9842	1	0,992	1	1	1
Veri Seti 3	0,9946	1	0,9864	0,9931	0,9842	1	0,992	1	1	1
Veri Seti 4	0,9985	1	0,9973	0,9986	0,9921	1	0,996	1	1	1
Veri Seti 5	0,9969	1	0,991	0,9955	0,9921	1	0,996	1	1	1
Veri Seti 6	1	1	1	1	1	1	1	1	1	1
Veri Seti 7	0,9996	0,9988	1	0,9994	1	1	1	1	0,9988	0,9994



Şekil 17: CrossVit Modeline Göre Eğitim Sonuçları Grafiği

Tablo 8: MobileNet Modeline Göre Eğitim Sonuçları


DataSet	Accuracy	Green_Prec	Green_Rec	Green_F1	Black_Prec	Black_Rec	Black_F1	Fly_Prec	Fly_Rec	Fly_F1
Veri Seti 1	0,9915	0,9839	1	0,9919	1	1	1	1	0,9574	0,9784
Veri Seti 2	0,9944	0,9934	1	0,9967	1	1	1	1	0,9739	0,9868
Veri Seti 3	0,9972	0,9973	0,9973	0,9973	1	1	1	1	0,9855	0,9927
Veri Seti 4	0,9989	1	0,9973	0,9987	1	1	1	1	0,992	0,9959
Veri Seti 5	0,9989	0,9973	1	0,9987	1	1	1	1	0,992	0,9959
Veri Seti 6	0,9994	1	0,9986	0,9993	1	1	1	0,9982	1	0,9991
Veri Seti 7	1	1	1	1	1	1	1	1	1	1



Şekil 18: MobileNet Modeline Göre Eğitim Sonuçları Grafiği

Tablo 9: MobileVit Modeline Göre Eğitim Sonuçları


DataSet	Accuracy	Green_Prec	Green_Rec	Green_F1	Black_Prec	Black_Rec	Black_F1	Fly_Prec	Fly_Rec	Fly_F1
Veri Seti 1	0,9994	1	0,9983	0,9991	1	1	1	0	0	0
Veri Seti 2	0,9991	1	0,9975	0,9987	1	1	1	0	0	0
Veri Seti 3	0,9988	1	0,9968	0,9984	1	1	1	0	0	0
Veri Seti 4	0,9977	0,9985	0,9946	0,9965	0,9981	0,9981	0,9981	0	0	0
Veri Seti 5	0,9862	0,9857	0,9885	0,9867	0,9878	1	0,9937	0	0	0
Veri Seti 6	0,9804	0,9894	0,9552	0,9707	0,9975	1	0,9987	0	0	0
Veri Seti 7	0,9625	0,9613	0,9425	0,9450	0,9551	1	0,9755	0	0	0



Şekil 19: MobileVit Modeline Göre Eğitim Sonuçları Grafiği

Tablo 10: ResNet Modeline Göre Eğitim Sonuçları

DataSet	Accuracy	Green_Prec	Green_Rec	Green_F1	Black_Prec	Black_Rec	Black_F1	Fly_Prec	Fly_Rec	Fly_F1
Veri Seti 1	0,9737	0,9842	1	0,9917	1	1	1	1	0,9833	0,9913
Veri Seti 2	1	0,9863	1	0,9930	1	1	1	1	0,9852	0,9923
Veri Seti 3	1	1	1	1	1	1	1	1	1	1
Veri Seti 4	1	0,9921	0,9697	0,9796	0,9929	1	0,9964	0,9736	0,9917	0,9816
Veri Seti 5	1	0,9896	1	0,9947	1	0,9926	0,9962	1	0,9950	0,9974
Veri Seti 6	0,9910	0,9983	1	0,9991	1	0,9983	0,9991	1	1	1
Veri Seti 7	0,9932	1	1	1	1	1	1	1	1	1



Şekil 20: ResNet Modeline Göre Eğitim Sonuçları Grafiği

5. TARTIŞMA VE SONUÇ

Bu çalışmada geliştirilen gerçek zamanlı zeytin sınıflandırma sisteminde, farklı derin öğrenme mimarileri (CNN, CaFormer, ConvFormer) ve veri artırma stratejileri kullanılarak kapsamlı bir karşılaştırma yapılmıştır. Yapılan deneysel analizlerde, her modelin farklı veri artırma yöntemleriyle nasıl performans gösterdiği; doğruluk (accuracy), hassasiyet (precision), duyarlılık (recall) ve F1 skorları üzerinden detaylı şekilde değerlendirilmiştir.

Genellenebilir Sonuçlar ve En Başarılı Modeller:

CNN mimarisi, özellikle original-stylegan-horizontal180 veri setinde en yüksek başarıyı göstermiştir. Bu konfigürasyonda doğruluk %99,56'ya ulaşırken, Fly sınıfı için F1 skoru 0.9973, Green ve Black sınıflarında ise sırasıyla 0,9973 ve 0,9935 değerlerine ulaşılmıştır. Bu durum, CNN mimarisinin hem doğruluk hem de tüm sınıflarda denge sağlayabildiğini göstermektedir.

CaFormer mimarisi, original-stylegan-flip veri seti ile %95,67 doğruluk ve Fly sınıfında 0.9668 F1 skoru ile en iyi sonucu elde etmiştir. Diğer sınıflarda da 0.94+ seviyelerinde F1 skorlarına ulaşarak tutarlı bir performans göstermiştir.

ConvFormer mimarisi, genelde daha düşük performans gösterse de original-stylegan-horizontal180 veri setinde %90,56 doğruluk ve 0,9433 Fly_F1 ile dikkat çekici sonuçlar vermiştir.

Overfitting ve Underfitting Gözlemleri:

Değerlendirme sürecinde bazı konfigürasyonlarda F1 skoru = 1,0 veya F1 skoru = 0,0 olarak raporlanmıştır. Bu durumlar aşağıdaki şekilde yorumlanmıştır:

Overfitting (Aşırı öğrenme): Bir sınıfta F1 skorunun 1.0 olması, modelin ilgili sınıfa ait örnekleri %100 doğrulukla sınıflandırdığını göstermektedir. Ancak bu durum, çoğunlukla modelin eğitildiği veriye fazla bağımlı hale gelmesiyle ilgilidir ve gerçek dünya verisine karşı genelleme kabiliyeti zayıf olabilir. Bu nedenle 1.0 olan skorlar analiz dışında bırakılmıştır.

Underfitting (Yetersiz öğrenme): F1 skorunun 0,0 olması, modelin o sınıfa ait hiçbir örneği doğru sınıflandıramadığını gösterir. Bu durum genellikle yetersiz öğrenme, yetersiz veri temsili veya model karmaşıklığının düşük olmasıyla ilişkilidir. Bu tür sonuçlar da genel analiz dışında tutulmuştur.

Bu filtreleme sonucunda yalnızca genellenebilir ve gerçekçi sonuçlar üzerinden model karşılaştırmaları yapılmış, her bir modelin doğru genelleme yapabildiği veri setleri ve sınıflar belirlenmiştir.

Zeytin sınıflandırma sistemi, farklı derin öğrenme mimarileri (CNN, CaFormer, ConvFormer) ve çeşitli veri artırma teknikleriyle detaylı biçimde test edilmiştir. Gerçek zamanlı ayırıştırma hedefiyle tasarlanan sistem, <200 ms tahmin süresi ve güçlü sınıflandırma performansı ile endüstriyel otomasyona uygunluk göstermektedir. Bulgular, yalnızca genellenebilirliği temsil eden yani overfitting (1,000) ve underfitting (0,000) gözlemleri ayıklanarak değerlendirilmiştir.

Elde edilen sonuçlara göre en başarılı yapı, CNN mimarisi ile original-stylegan-horizontal180 veri setinin kullanıldığı konfigürasyon olmuştur. Bu yapı, %99,56 doğruluk oranı ile en yüksek genel başarıyı göstermiştir. Sınıf bazlı incelendiğinde, yeşil zeytin sınıfı için 0,9973, siyah zeytin için 0,9935 ve sinek vuruklu zeytin sınıfı için yine 0,9973 F1 skoru elde edilmiştir. Bu sonuçlar, modelin her üç sınıfı da dengeli şekilde ayırt edebildiğini ve sınıflar arası ayırma yüksek başarımla gösterdiğini ortaya koymaktadır. Aynı zamanda bu yapı hem doğruluk hem de sınıf bazlı F1 skorları açısından kararlı bir yapı sergilemiş ve overfitting belirtisi göstermemiştir.

CaFormer mimarisi ise özellikle original-stylegan-flip veri artırımı ile %95,67 doğruluk ve fly sınıfında 0,9668 F1 skoru ile dikkat çekmiştir. Yeşil ve siyah sınıflarda da sırasıyla 0,9432 ve 0,9664 gibi yüksek F1 skorları kaydedilmiştir. Bu yapı, genel başarıda CNN kadar yüksek olmamakla birlikte sinek vuruklu sınıfı gibi sınıflandırılması zor gruplarda etkili performans göstermiştir. Bu nedenle CaFormer, sınıf dengesizliği olan veri setleri için tercih edilebilir mimariler arasında değerlendirilebilir.

ConvFormer mimarisi ise genellikle daha dalgalı sonuçlar üretmiştir. Ancak original-stylegan-horizontal180 veri seti ile birlikte %90,56 doğruluk ve fly sınıfında 0,9433 F1 skoru elde ederek diğer ConvFormer konfigürasyonlarına kıyasla anlamlı bir performans sergilemiştir. Bu yapı dışında kalan diğer ConvFormer varyasyonları, genellikle %90 doğruluğun altında kalarak sistemin genelleme kabiliyetini zayıflatmıştır. Özellikle original-stylegan-horizontal180-flip veri setiyle eğitilen model %65,67 doğruluk ile sistemin sınıflar arasında ayırma konusunda yetersiz kaldığını göstermiştir. Bu durum underfitting belirtisi olarak değerlendirilmiş ve çalışma dışı bırakılmıştır.

Overfitting ve underfitting durumları incelendiğinde, bazı modellerin belirli sınıflarda 1,0000 F1 skoruna ulaşması dikkat çekmiştir. Bu durum, modelin veriyi ezberlediğini ve test verisinde yapay olarak yüksek performans gösterdiğini işaret etmektedir. Öte yandan, bazı yapıların F1 skorlarının 0,0000 olması ise bu modellerin o sınıfı öğrenemediğini ve sınıflar arasında ayırım yapamadığını göstermektedir. Bu tür sonuçlar, aşırı veri azlığı, veri dengesizliği veya mimari uyumsuzluk gibi nedenlerle oluşabilmekte ve sistemin üretim ortamında başarısız olmasına yol açabilmektedir. Bu nedenle, bu tür ekstrem sonuçlar değerlendirme dışında bırakılmış ve yalnızca anlamlı ve genellenebilir sonuçlar çalışmaya dahil edilmiştir.

Sonuç olarak, önerilen sistem CLAHE tabanlı ön işleme, uygun veri artırma stratejileri ve özellikle CNN mimarisiyle birlikte yüksek doğruluk sağlayarak endüstriyel seviyede sınıflandırma potansiyeli taşımaktadır. Modelin hızlı ve güvenilir tahmin performansı ile birlikte, farklı sınıflar arasında dengeli başarı sunması, gerçek zamanlı sınıflandırma ve kalite kontrol süreçlerinde kullanılabilirliğini doğrulamaktadır. Gelecek çalışmalar için bu mimarilerin YOLO veya TinyML gibi yapılarla genişletilerek daha kompakt, daha az enerji tüketen ve daha çeşitli kalite kriterlerini kapsayan sistemlerin geliştirilmesi planlanmaktadır.

6. KAYNAKLAR

- [1] A. Hossain et al., “Deep learning in agriculture: a survey,” *Computers and Electronics in Agriculture*, vol. 165, 2019.
- [2] J. M. Ponce, A. Aquino, J. M. Andújar, “Olive-fruit variety classification by means of image processing and convolutional neural networks,” *IEEE Access*, vol. 7, pp. 147629–147641, 2019. DOI:10.1109/ACCESS.2019.2947160
- [3] D. M. Ibrahim and N. M. Elshennawy, “Improving Date Fruit Classification Using CycleGAN-Generated Dataset,” **Comput. Model. Eng. Sci.**, vol. 131, no. 1, pp. 331–348, 2022, doi:10.32604/cmesci.2022.016419.
- [4] H. Miho et al., “OliVaR: Improving olive variety recognition using deep neural networks,” *Computers and Electronics in Agriculture*, vol. 216, art. no. 108530, 2024.
- [5] A. M. Hayajneh, S. Batayneh, E. Alzoubi, M. Alwedyan, “TinyML Olive Fruit Variety Classification by Means of Convolutional Neural Networks on IoT Edge Devices,” *AgriEngineering*, vol. 5, no. 4, pp. 2266–2283, 2023. DOI:10.3390/agriengineering5040139
- [6] A. Beyaz and R. Öztürk, “Identification of olive cultivars using image processing techniques,” *Turkish Journal of Agriculture and Forestry*, vol. 40, pp. 671–683, 2016.
- [7] F. Erdem, “Turkey is expected to lead global production of table olives in the 2022/23 season,” *Tridge Sourcing Hub*, Nov. 4, 2022. [Online]. Available: <https://www.tridge.com/insights/turkey-is-expected-to-lead-global-production-of-table-olives-in-the-20222023-season>
- [8] F. Özdemir, “Türkiye’nin zeytin üretimi 2024’te rekora ulaştı,” *Anadolu Ajansı*, Jan. 9, 2025. [Online]. Available: <https://www.aa.com.tr/tr/ekonomi/turkiyenin-zeytin-uretimi-2024te-rekora-ulasi-3445476>
- [9] G. Messina, M. Sbaglia, and B. Bernardi, “Mechanical harvesting of olive orchards: An overview on trunk shakers,” **AgriEngineering**, vol. 7, no. 3, art. no. 52, Feb. 2025. doi: 10.3390/agriengineering7030052
- [10] C. Di Vaio, N. Marallo, S. Nocerino, and F. Famiani, “Mechanical harvesting of oil olives by trunk shaker with a reversed umbrella interceptor,” **Advances in Horticultural Science**, vol. 26, no. 3–4, pp. 176–179, Dec. 2012, doi:10.13128/ahs-22675.
- [11] U. Gökovalı and M. Terzioğlu, “Yerel ekonomi için dönüşüm fırsatı: Milas’ta zeytincilik,” *350 Türkiye ve Climate Action Network Europe*, Nisan 2022. [Online]. Available: https://350turkiye.org/files/2022/04/Milasta_Zeytincilik_Nisan2022.pdf
- [12] G. Çiçek, S. K. Sümer, and H. Kocabıyık, “Effect of different harvest methods on olive yield and work capacity: two-year results,” **African Journal of Agricultural Research**, vol. 5, no. 14, pp. 3246–3250, Dec. 2010.

- [13] İ. Sezer, S. Deviren, İ. Yaman, E. Dağıstan ve C. Toplu, “Hatay ilinde zeytin yetiştiriciliğinin sosyo-kültürel analizi,” **Mustafa Kemal Üniversitesi Tarım Bilimleri Dergisi**, cilt 28, no. 1, ss. 185–202, 2023. [Online]. Available: <https://dergipark.org.tr/tr/download/article-file/2792266>
- [14] E. Işık and H. Ünal, “Mekanik titreşimli zeytin hasat makinasının performans değerlerinin belirlenmesi,” **Uludağ Üniversitesi Ziraat Fakültesi Dergisi**, cilt 17, no. 2, ss. 103–110, 2003. [Online]. Available: <https://acikerisim.uludag.edu.tr/bitstreams/dac9af47-55ba-4f56-acbe-4b1d4ce25493/download>
- [15] İ. Sezer, S. Deviren, İ. Yaman, E. Dağıstan ve C. Toplu, “Hatay ilinde zeytin yetiştiriciliğinin sosyo-kültürel analizi,” **Mustafa Kemal Üniversitesi Tarım Bilimleri Dergisi**, cilt 28, no. 1, ss. 185–202, 2023. [Online]. Available: <https://dergipark.org.tr/tr/download/article-file/2792266>
- [16] E. Işık and H. Ünal, “Mekanik titreşimli zeytin hasat makinasının performans değerlerinin belirlenmesi,” **Uludağ Üniversitesi Ziraat Fakültesi Dergisi**, cilt 17, no. 2, ss. 103–110, 2003. [Online]. Available: <https://acikerisim.uludag.edu.tr/bitstreams/dac9af47-55ba-4f56-acbe-4b1d4ce25493/download>
- [17] T.C. Tarım ve Orman Bakanlığı, “2024 Temmuz Sofralık Zeytin Tarım Ürünleri Piyasaları Raporu,” **Tarım Ürünleri Piyasaları**, vol. —, Temmuz 2024. [Online]. Available: [https://arastirma.tarimorman.gov.tr/tepge/Belgeler/PDF Tarım Ürünleri Piyasaları/2024-Temmuz Tarım Ürünleri Piyasaları Raporu/Sofralık Zeytin Tarım Ürünleri Piyasaları Raporu Temmuz-2024-v4.pdf](https://arastirma.tarimorman.gov.tr/tepge/Belgeler/PDF%20Tarim%20Urunleri%20Piyasaları/2024-Temmuz%20Tarım%20Ürünleri%20Piyasaları%20Raporu/Sofralık%20Zeytin%20Tarım%20Ürünleri%20Piyasaları%20Raporu%20Temmuz-2024-v4.pdf)
- [18] M. Yalçın and F. N. Alayunt, “Siyah sofralık Gemlik çeşidi zeytinde farklı hasat yöntemlerinin ekonomik ve ergonomik yönden incelenmesi,” **Tarım Makinaları Bilimi Dergisi**, vol. 11, no. 4, pp. 285–293, Aug. 2015. *, vol. 32, no. 2, pp. 225–232, Mar. 2016. doi:10.13031/aea.32.11322.
- [19] 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.
- [20] G. Bradski, “The OpenCV Library,” **Dr. Dobb’s Journal of Software Tools**, vol. 25, no. 11, pp. 120–125, Nov. 2000.
- [21] T. E. Oliphant, **Guide to NumPy**, 1st ed. USA: Trelgol Publishing, 2006.
- [22] J. D. Hunter, “Matplotlib: A 2D graphics environment,” **Computing in Science & Engineering**, vol. 9, no. 3, pp. 90–95, May/Jun. 2007, doi:10.1109/MCSE.2007.55.
- [23] K. J. Zuiderveld, “Contrast limited adaptive histogram equalization,” in **Graphics Gems IV**, P. S. Heckbert, Ed. San Diego, CA, USA: Academic Press, Aug. 1994, pp. 474–485.
- [24] I. Goodfellow *et al*, “Generative adversarial networks,” **Wikipedia, The Free Encyclopedia**.
- [25] EasyChair Preprints, “EasyChair preprint mechanics,” **EasyChair Preprint Series**, preprint no. QQHP, accessed Jun. 17, 2025.

- [26] E. Olaniyi, D. Chen, Y. Lu ve Y. Huang, “Generative adversarial networks for image augmentation in agriculture: A systematic review,” **Computers and Electronics in Agriculture**, vol. 200, Art. no. 107208, Aug. 2022. doi:10.1016/j.compag.2022.107208.
- [27] J. J. Bird, C. M. Barnes, L. J. Manso ve A. Ekárt, “Fruit quality and defect image classification with conditional GAN data augmentation,” **arXiv Preprint**, Apr. 13, 2021.
- [28] Y. Lu, D. Chen, E. Olaniyi ve Y. Huang, “Generative adversarial networks for image augmentation/synthesis in agriculture,” **arXiv Preprint**, 2022
- [29] F. Omarzai, “Generative Adversarial Network (GAN) In Depth,” **Medium**, Feb. 2024.
- [30] “Generative adversarial network,” **Wikipedia, The Free Encyclopedia**, 2025.
- [31] **Conditional Generative Adversarial Networks and Deep Learning...**, MDPI, 2024.
- [32] A. Amidi ve S. Amidi, “A detailed example of data generators with Keras,” Stanford.edu blog, blog yazısı, 2020. [Online]. Available: <https://stanford.edu/~shervine/blog/keras-how-to-generate-data-on-the-fly> (accessed Jun. 17, 2025)
- [33] M. Taha, “Keras - understanding ImageDataGenerator dimensions,” DataScience.StackExchange.com, Jul. 4, 2019. [Online]. Available: <https://datascience.stackexchange.com/questions/55054/keras-understanding-imagedatagenerator-dimensions>
- [34] “Image Data Generators in Keras,” ExpoundAI blog, Apr. 24, 2019. [Online]. Available: <https://expoundai.wordpress.com/2019/04/24/image-data-generators-in-keras/>
- [35] “Keras ImageDataGenerator and Data Augmentation,” PyImageSearch blog, Jul. 8, 2019. [Online]. Available: <https://pyimagesearch.com/2019/07/08/keras-imagedatagenerator-and-data-augmentation/>
- [36] “Albumentations: fast and flexible image augmentations,” arXiv preprint, Sep. 18, 2018. [Online]. Available: <https://arxiv.org/abs/1809.06839>
- [37] E. Kahya and Y. Aslan, “Derin Öğrenme Destekli Gerçek Zamanlı Zeytin Tespiti Uygulaması”, *Osmaniye Korkut Ata University Journal of The Institute of Science and Techno*, vol. 7, no. 4, pp. 1438–1454, 2024, doi: 10.47495/okufbed.1392386.
- [38] Adrian Rosebrock, “Keras ImageDataGenerator and Data Augmentation,” PyImageSearch, Jul. 8, 2019. [Online]. Available: <https://pyimagesearch.com/2019/07/08/keras-imagedatagenerator-and-data-augmentation/>
- [39] S. Figorilli, S. Violino, L. Moscovini, L. Ortenzi, F. Pallottino ve arkadaşları, “Olive Fruit Selection through AI Algorithms and RGB Imaging,” *Foods*, cilt 11, no 21, makale no 3391, 2022.
- [40] J. Redmon, S. Divvala, R. Girshick ve A. Farhadi, “You Only Look Once: Unified, Real-Time Object Detection,” *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016, s. 779-788, doi: 10.1109/CVPR.2016.91 .

- [41] Z. Ur Rahman, M. S. Mohd Asaari, H. Ibrahim, I. S. Z. Abidin, and M. K. Ishak, "Generative Adversarial Networks for Image Augmentation in Farming: A Review," IEEE Access, early access, Jan. 2024, doi: 10.1109/ACCESS.2024.3505989 .



ÖZGEÇMİŞ

Kişisel Bilgiler		Fotoğraf
Adı	Doğukan TOPALLAR	
Soyadı		
Doğum Yeri		
Doğum Tarihi		
Uyruğu	Türk	
Telefon		
E-Posta Adresi		
Web Adresi	-	

	Eğitim Bilgileri
	Lisans
Üniversite	Bandırma Onyedi Eylül Üniversitesi
Fakülte	Mühendislik ve Doğa Bilimleri Fakültesi
Bölümü	Elektrik – Elektronik Mühendisliği
Mezuniyet Yılı	2022

	Eğitim Bilgileri
	Lisans
Üniversite	Bandırma Onyedi Eylül Üniversitesi
Fakülte	Mühendislik ve Doğa Bilimleri Fakültesi
Bölümü	Bilgisayar Mühendisliği
Mezuniyet Yılı	2023

	Yüksek Lisans
Üniversite	Bandırma Onyedi Eylül
Enstitü Adı	Lisansüstü Eğitim Enstitüsü
Anabilim Dalı	Bilgisayar Mühendisliği
Programı	Bilgisayar Mühendisliği

Makale ve Bildiriler
Topallar, D.; TASKIN, S.G. (2025). <i>Real-Time image processing and industrial automation for olive color and tissue disorder sorting processes</i> [Tam Metin Bildiri]. Bandırma Onyedi Eylül Üniversitesi, Bilgisayar Mühendisliği.

