

# Tarımsal Otomasyon Sistemleri için Muz Olgunluk Seviyelerinin Derin Öğrenme Yöntemleri İle Sınıflandırılması

## Classification of Banana Ripeness Levels Using Deep Learning Methods for Agricultural Automation Systems

<sup>id</sup> Sezgin Dulkadir<sup>1</sup>, Gökhan Koray Gültekin<sup>1</sup> <sup>id</sup>

<sup>1</sup>Elektrik - Elektronik Mühendisliği  
Ankara Yıldırım Beyazıt Üniversitesi  
sezgindulkadir@aybu.edu.tr, gkgultekin@aybu.edu.tr

### Özet

Tarımsal üretimde kalite ve verimin artırılması ve maliyetlerin azaltılması için yüksek doğrulukla çalışan otonom sistemlerin kullanımı kaçınılmazdır. Ürün hasatının çok sayıda otonom robot sistemi tarafından farklı olgunluk seviyelerindeki ürünlerin toplanması şeklinde gerçekleştirilebilmesi için ürünlerin olgunluklarının yapay zeka yöntemleriyle tespit edilebilmesi gerekmektedir. Bu çalışmada, çoklu otonom robotik hasat sistemlerinde kullanılmak üzere muz olgunluk seviyelerinin otonom olarak sınıflandırılmasına yönelik üç farklı evrimsel yapay sinir ağı modeli (YOLOv5s, YOLOv8n, YOLOv8m) kullanılmıştır. Modeller, 6 sınıflı bir muz olgunluk seviyesi veri kümesi ile eğitilerek elde edilen test sonuçları yaygın kullanılan ölçütler ile karşılaştırılmıştır.

Anahtar kelimeler: tarımsal otomasyon sistemleri, muz olgunluk seviyesi, derin öğrenme, evrimsel yapay sinir ağları

### Abstract

The autonomous systems that are working with high accuracy must be utilized in agriculture in order to increase the quality and the efficiency and reduce the costs in agricultural production. For carrying out the harvesting of products with different ripeness levels by a large number of autonomous robot systems, the ripeness of the products must be determined by artificial intelligence methods. In this study, three different convolutional neural network models (YOLOv5s, YOLOv8n, YOLOv8m) were used for autonomous classification of banana ripeness levels for use in multiple autonomous robotic harvesting systems. The models were trained with a 6-class banana ripeness level dataset and the test results are compared using widely used performance metrics.


Keywords: agricultural automation systems, banana ripeness level, deep learning, convolutional neural networks

## 1. Giriş

Tropikal bir meyve olan ve 1000 civarında çeşidi olduğu bilinen muz, Güneydoğu Asya menşeli bir tarım ürünüdür. Dünyanın önemli mahsullerinden biri olarak 130'dan fazla ülkede, küçük ve büyük ölçekli birçok üretici tarafından yetiştirilmektedir [1]. Türkiye'de de muz yetiştiriciliği, ekonomik açıdan önemli bir gelir kaynağıdır. Özellikle son yıllarda gerek açık alanda gerekse örtü altı yetiştiriciliğinde üretimi gitgide artmaktadır. Ülkemizde meyveler ile içecek ve baharat bitkileri üretim

miktarı 2022 yılında bir önceki yıla göre ortalama %7,7 oranında artarken muz üretimi %12,9 oranında artmıştır [2].

Muzların olgunluk derecesi, gıda endüstrisi ve tüketiciler için önemli bir faktördür, çünkü muzlar farklı aşamalarda farklı tat, doku ve besin içeriği özelliklerine sahiptir [3,4]. Muz olgunluk tespiti, meyve endüstrisinde verimliliği artırmak ve tüketicilere daha kaliteli ürünler sunmak için önemli bir adımdır. Bu sınıflandırma işlemi çoğunlukla geleneksel olarak insan eliyle emek yoğun bir çalışma gerektirmektedir.



Şekil 1: Ürünleri olgunluklarına göre sınıflayarak koordineli olarak hasat yapan çok sayıda otonom robotun (mavi daireler) çalışması gösterilmektedir.

Ürün yetiştiriciliği çoğunlukla binlerce ağaçtan oluşan bahçelerde yapılmaktadır. Hasatın kısa sürede yapılabilmesi için çok sayıda otonom robotun eş zamanlı ve koordineli olarak çalışması gerekmektedir [5]. Robotlar üzerindeki kameralar vasıtasıyla aldıkları görüntülerinden ürünleri olgunluk seviyelerine göre sınıflandırır. Her robotun sadece aynı olgunluk sınıfındaki ürünleri toplayacağı varsayılmaktadır. Robotlar arası haberleşme ile hangi ağaçta ne olgunluk seviyesinde ürün olduğu ağ üzerinden tüm robotlarla paylaşılır. İlgili olgunluk seviyesindeki ürünleri toplamaktan sorumlu olan robot veya robotlar en uygun yol planlamasını yaparak ürünleri toplarlar. Yol planlaması, sıklıkla çalışılan gezici satıcı probleminde kullanılan yöntemler ile gerçekleştirilir.

Derin öğrenme, yapay zeka alanında son yıllarda büyük bir dönüşüm yaratmıştır ve tarımsal uygulamalarda da sıklıkla kullanılmaya başlanmıştır. Palmiye yağı meyvesinin olgunluğunu sınıflandırmak ve çeşitli meyveleri tanımak için otomatik görüntü açıklama görev tekniğini uygulananır [6]. Önerilen yaklaşım, çiftçilerin meyve yöntemlerinin sınıflandırılmasını geliştirmelerine ve üretimlerini artırmalarına

yardımcı olur. Bu çalışma, YOLO'nun çeşitli versiyonları ile derin öğrenme tabanlı basit ve etkili modeller önermektedir.

Derin evrişimli sinir ağlarını kullanarak meyve tespitine yeni bir yaklaşım sunan [7], otonom bir tarım robotik platformunun hayati bir unsuru olan doğru, hızlı ve güvenilir bir meyve algılama sistemi oluşturmaktır. Meyve verimi tahmini otonom hasat için önemli bir unsurdur. Nesne tespitini gerçekleştirmek için son zamanlarda oldukça popüler olan daha hızlı R-CNN nesne dedektörünü kullanılmaktadır.

Bilgisayarlı görü ve derin öğrenme teknikleri kullanarak havadan alınan görüntülerden hasarlı mısır alanlarını tespit etmek için yapılan bir çalışmada [8], üç popüler nesne dedektörü (Daha hızlı R-CNN, YOLOv2 ve RetinaNet), bir alandaki hasarlı bölgeleri algılama yetenekleri açısından değerlendirilmiştir. Nesne dedektörlerinin performansları ortalama kesinlik ölçütü kullanılarak kıyaslanmıştır.

Derin öğrenme uygulamaları ve bunların tarımda hastalık teşhisi ve yönetimi için kullanımlarıyla ilgili eğilimler üzerine 70 araştırmaya kapsamlı bir genel bakış açısı [9]'de yer alırken, bitkilerde daha yüksek doğrulukta hasare tespiti, geliştirilmiş bir YOLOv5m tabanlı yöntemle [10]'da önerilmiştir. Önerilen yöntemin, orijinal YOLOv3, YOLOv4 ve YOLOv5m modellerinden önemli ölçüde daha iyi olduğu öne sürülmüştür.

Her geçen gün geliştirilen yöntemler ile nesne algılama ve sınıflandırma gibi birçok görsel tanıma probleminde başarılı sonuçlar elde edilebildiği gösterilmektedir. Ancak literatürde, güncel derin öğrenme yöntemleri ile muzların olgunluk derecesinin sınıflandırılması hakkında bir çalışmaya rastlanmamıştır.

Bu çalışmada, bir otonom robotik hasat sisteminde yer almak üzere, derin öğrenme yöntemlerinin kullanılmasıyla muzların olgunluk derecesinin otomatik olarak ve yüksek doğrulukla belirlenmesi amaçlanmaktadır. Yapılan çalışma ile literatürde ilk kez derin öğrenme yöntemleri içerisinde YOLOv5 ve YOLOv8 [11] evrişimsel sinir ağı yapılarının farklı büyüklükteki modelleri, 6 sınıfa ayrılmış olan geniş bir muz olgunluğu görüntü veri kümesi ile eğitilerek muz görüntülerinin olgunluklarına göre yüksek doğrulukla sınıflandırılması gerçekleştirilmiştir. Elde edilen sonuçlar literatürde kabul gören farklı ölçütler ile karşılaştırılmıştır.

## 2. Derin Öğrenme ile Nesne Sınıflandırma

Derin öğrenme, büyük miktarda veriden öğrenme yeteneğine sahip sinir ağları kullanarak karmaşık problemleri çözebilen bir yapay zeka yaklaşımıdır. Önceden etiketlenmiş büyük veri kümeleri üzerinde otomatik öğrenme yetenekleriyle bilinen derin sinir ağları kullanarak pek çok karmaşık problemin çözümünde önemli başarılar elde edilmiştir. Derin öğrenme yöntemleri, karmaşık desenleri ve ilişkileri keşfetmek için çok katmanlı yapay sinir ağları kullanır ve genellikle büyük veri kümelerine dayanarak modelin parametrelerini optimize eder. Derin öğrenme yöntemlerinin nesne sınıflandırma [12] ve otomasyon sistemlerindeki [13] uygulamaları bulunmaktadır.

### 2.1. YOLO Evrişimsel Derin Öğrenme Sinir Ağı Yapısı

YOLO (You Only Look Once) [14] evrişimsel derin öğrenme yöntemlerinden biri olup, gerçek zamanlı nesne algılama ve

sınıflandırmada önemli bir dönüm noktası olarak kabul edilmektedir. Diğer modellere kıyasla hızlı çalışır ve tek bir geçişle nesne tespiti yapar. Bu hızlı algılama yeteneği özellikle gerçek zamanlı çalışma ihtiyacı olan otonom sistemler gibi uygulamalarda büyük avantaj sağlamaktadır.

YOLO, bağlamsal ilişkileri dikkate alabilme yeteneğiyle öne çıkmaktadır. Görüntü ızgara hücrelerine bölünür ve her hücre üzerindeki nesnelere algılanır. Bu sayede nesnelere birbirleriyle olan bağlamsal ilişkileri doğrudan algılanabilir. Örneğin, bir nesnenin diğer nesnelere olan ilişkisi ve konumu kolayca tespit edilebilir. Bu özellik, nesnelere daha iyi anlaşılmasını sağlar ve nesne algılama performansını artırır. YOLOv8, sınıflandırmada sınırlayıcı kutu yitimi ve ikili çapraz entropi için Clou [15] ve DFL [16] yitim fonksiyonlarını kullanır.

2015 yılında çıkan ilk versiyonundan, 2023 yılında çıkan YOLOv8'e kadar akıllı tarım uygulamalarında yapılan birçok akademik çalışmada oldukça başarılı sonuçlar elde edilebildiği gösterilmiştir. Tarlalardaki yabancı otlar ve zararlıların tespit ve sınıflandırmasında [17], bitkilerdeki hastalıkların tespit ve sınıflandırmasında [18], ananas, elma çilek gibi meyvelerin olgunluk seviyelerinin sınıflandırmasında yüksek performans elde edilmiştir [19].

YOLOv5 ve YOLOv8 Tablo 1'de görüldüğü gibi farklı büyüklüklerde model yapılarına sahiptir. YOLOv5; küçükten büyüğe doğru s, m, l ve x takılarıyla adlandırılan 4 farklı modele sahipken, YOLOv8; küçükten büyüğe doğru n, s, m, l ve x takılarıyla adlandırılan 5 farklı modele sahiptir. Özellikle daha düşük donanım performansına sahip olan uygulamalarda küçük modeller daha hızlı sonuç vermeleri nedeniyle gerçek zamanlı uygulamalarda tercih edilirler. Bununla birlikte küçük modellerin doğruluk performansı ise büyük modellere kıyasla bir miktar daha düşük olabilmektedir.

Tablo 1: YOLOv5 ve YOLOv8 modellerinin parametre sayıları.

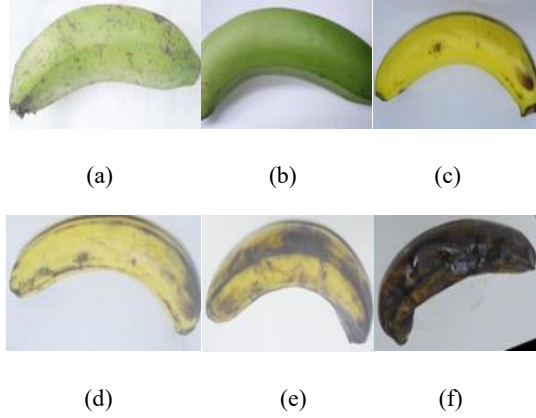
Model	Parametre Sayısı	Model	Parametre Sayısı
YOLOv5s	7,5M	YOLOv8n	3,2M
YOLOv5m	21,8M	YOLOv8s	11,2M
YOLOv5l	47,8M	YOLOv8m	25,9M
YOLOv5x	89,0M	YOLOv8l	43,7M
		YOLOv8x	68,2M

Bu çalışmada, YOLO'nun son sürümlerinden olan YOLOv5s, YOLOv8n ve YOLOv8m modellerinin muzların olgunluk seviyelerine göre sınıflandırılması amacıyla eğitilmesi ve testler sonucu elde edilen çalışma performanslarının karşılaştırılması gerçekleştirilmiştir.

### 2.2. Muz Olgunluğu Veri Kümesi

Bu çalışmada kullanılan veri kümesi [20], 18257 muz meyvesi görüntüsünden oluşmaktadır. Veri kümesi, 16000 eğitim kümesi, 1500 geçirme kümesi ve 757 test görüntüsünden oluşmaktadır. Görüntülerin %87'si eğitim kümesine aitken,

görüntülerin %8 geçerleme kümesine, %4'ü de test görüntülerine aittir. Görüntüler 6 olgunluk sınıfına ayrıldı: taze olgun, taze olgunlaşmamış, olgunlaşmış, olgun, çürük ve olgunlaşmamış. Şekil 2, farklı sınıflar içeren muz görüntülerinin görselleştirmesini göstermektedir.



Şekil 2: Olgunlaşmamış (a), taze olgunlaşmamış (b), taze olgunlaşmış (c), olgunlaşmış (d), fazla olgunlaşmış (e) ve çürük muz görüntüleri (f).

Eğitim sürecinde kullanılan çeşitli veri kümesi bölmelerindeki (eğitim, geçerleme, test kümeleri) görüntü sayısı Tablo 2'de gösterilmiştir. Tablo 3, eğitim sürecinde kullanılan farklı muz olgunluk sınıflarında yer alan görüntü sayıları verilmektedir.

Tablo 2: Eğitim sürecinde kullanılan çeşitli veri kümesi bölmelerindeki görüntü sayıları

	Eğitim Kümesi	Geçerleme Kümesi	Test Kümesi	Toplam
Görüntü Sayısı	16000	1500	757	18257

Tablo 3: Eğitim sürecinde kullanılan farklı muz olgunluk sınıflarındaki görüntü sayıları

Sınıf	Görüntü Sayısı
S1. Taze Olgun	1321
S2. Taze	940
S3. Fazla Olgunlaşmış	1657
S4. Olgun	2146
S5. Çürük	2656
S6. Olgunlaşmamış	768

### 2.3. Performans Ölçütleri

Eğitim aşamasında, genelleme yeteneğini değerlendirmek ve modeli kademeli olarak optimize etmek için, değerlendirme

indeksleri olarak kesinlik, duyarlılık, F1 puanı ve ortalama kesinlik değerleri kullanılmıştır.

Ortalama kesinlik, nesne algılama ve segmentasyon sistemlerinin performansını analiz etmek için yaygın olarak kullanılmaktadır. Ortalama kesinlik, daha hızlı R-CNN, YOLO, Mask R-CNN vb. nesne algılama modellerini değerlendirmek için kullanılan bir ölçüttür. Ortalama kesinlik değerlerinin ortalaması, 0 ile 1 arasındaki duyarlılık değerleri üzerinden hesaplanır.

Ortalama kesinlik, her sınıf için ortalama kesinlik bulunarak ve ardından birkaç sınıf üzerinden ortalama alınarak hesaplanır. Ortalama kesinlik, duyarlılık ve kesinlik arasındaki değiş tokuşu içerir ve hem yanlış pozitifleri hem de yanlış negatifleri dikkate alır. Bu özellik, ortalama kesinlikleri çoğu algılama uygulaması için uygun bir ölçüt yapar [21].

*Kesinlik*, gerçekte doğru olan tahmin edilen pozitiflerin oranını ölçer. Gerçek pozitif değerinin, gerçek pozitif ve yanlış pozitif değerlerinin toplamına bölünerek bulunur. Matematiksel olarak ifadesi aşağıdaki gibi tanımlanır.

$$Kesinlik = \frac{Gerçek Pozitif}{Gerçek Pozitif + Yanlış Pozitif} \quad (1)$$

*Duyarlılık*, doğru tahmin edilen gerçek pozitiflerin oranını ölçer. Tüm Temel Gerçeklerden Gerçek Pozitiflerdir. Matematiksel olarak ifadesi aşağıdaki gibi tanımlanır.

$$Duyarlılık = \frac{Gerçek Pozitif}{Gerçek Pozitif + Yanlış Negatif} \quad (2)$$

*F1 puanı*, kesinlik ve duyarlılık değerlerinin harmonik ortalamasını ifade etmektedir. Matematiksel olarak ifadesi aşağıdaki gibi tanımlanır.

$$F1 Puanı = 2 * \frac{kesinlik * duyarlılık}{kesinlik + duyarlılık} \quad (3)$$

*Ortalama kesinlik*, gerçek referans değerinin sınırlayıcı kutusunu algılanan kutuyla karşılaştırır ve bir puan verir. Puan ne kadar yüksek olursa, model tespitlerinde o kadar doğru olur. Matematiksel olarak ifadesi aşağıdaki gibi tanımlanır.

$$Ortalama Kesinlik(mAP) = \frac{1}{n} \sum_{k=1}^n AP_k \quad (4)$$


(4)'te yer alan denklemde,  $n$  sınıf sayısını temsil ederken,  $AP_k$  ise  $k$  sınıfının ortalama kesinliğini temsil etmektedir. Matematiksel açıdan, ortalama kesinlik hesaplama, tüm

sınıflardaki ortalama kesinlik puanlarının toplanmasını ve sonucun toplam sınıf sayısına bölünmesini gerektirir.


*Ağırlıklı kesinlik*, sınıf bazında elde edilen sonuçların örnek ağırlık ortalamasını alır. Matematiksel olarak ifadesi aşağıdaki gibi tanımlanır.

$$\text{Ağırlıklı Kesinlik} = \sum_{i=1}^n w_i \times \text{Precision}_i \quad (5)$$

$$w_i = \frac{\text{Sınıf } i \text{ 'deki örnek sayısı}}{\text{Toplam örnek sayısı}}$$



Şekil 3: YOLOv8n ile yapılan çalışmanın F1-GD grafiği

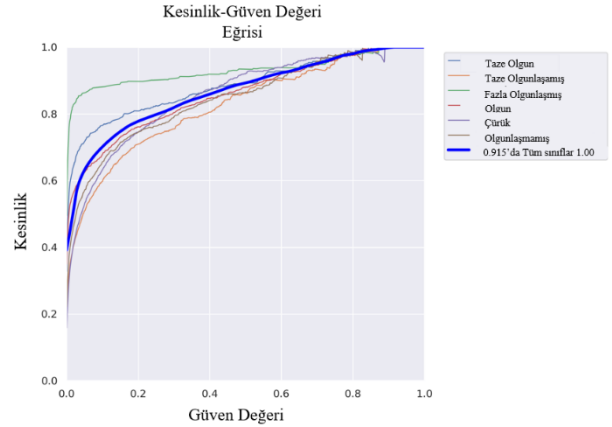


Şekil 4: YOLOv5s ile yapılan çalışmanın F1-GD grafiği

### 3. Deneysel Sonuçlar

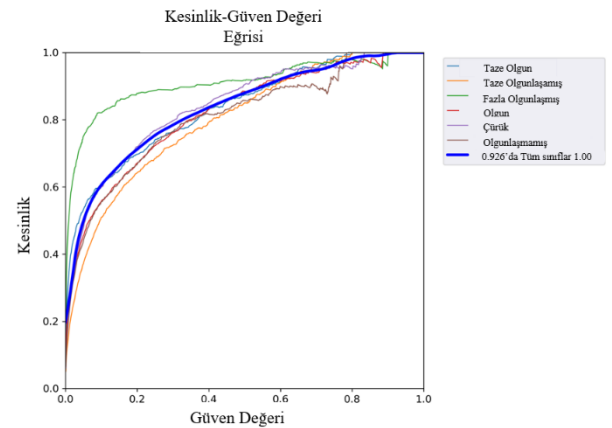
Taze muz meyvesinin kalitesi, tüketiciler ve meyve endüstrisi şirketleri için temel bir endişe kaynağıdır. Muzun olgunluk aşamasının etkinliği ve hızlı sınıflandırılması, kalitesinin belirlenmesinde en belirleyici faktörlerdir. Gelen farklı taze muz salkımlarının olgunlaşma evrelerinin doğru sınıflandırılması için görüntü işleme araçlarının tasarlanması ve uygulanması gerekmektedir. Muz meyvesinde olgunluk genel olarak meyvenin kullanım amacını, yeme kalitesini ve piyasa fiyatını etkiler. Bu bölümde, muzların olgunlaşma aşamalarını belirlemek için uygulanan en son derin öğrenme

algoritmalarına dayalı yöntemin sonuçları test edilmektedir. Farklı sahnelerdeki değerlendirme indeksleri, eğitim parametreleri ve nesne bulma etkileri açıklanmıştır.



Şekil 5: YOLOv8n ile yapılan çalışmanın K-GD grafiği

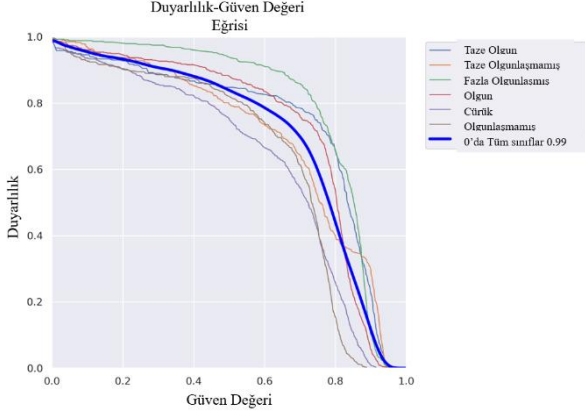
Yapay zekâ ve derin öğrenme projeleri üzerinde çalışanlar için etkileşimli, tamamen bulut tabanlı, kullanımı kolay ve ortak çalışmaya dayalı bir programlama ortamı olan Google Colaboratory ile YOLOv5s, YOLOv8n ve YOLOv8m algoritmaları kullanılarak eğitim süreci gerçekleştirildi. Eğitim süreci boyunca Dell marka bilgisayar, işletim sistemi olarak Windows 10 kullanılmıştır. Kullanılan bilgisayar 16 GB Ram ve Core i7 CPU modeline sahiptir. Eğitim süreci boyunca her üç model için epok sayısı 30, görüntü boyutu 800x800 piksel olarak belirlendi. Eğitim YOLOv5s için 5 saat 10 dakika 12 saniye sürerken YOLOv8n için 6 saat 25 dakika 16 saniye ve YOLOv8m 6 saat 54 dakika 48 saniye sürmüştür. Eğitimde parti büyüklüğü 8 olarak belirlenmiştir. Her iterasyonda 8 adet görüntü alınmıştır. Her epokun ağırlık sonuçları geçeri kümesinde doğrulandı.



Şekil 6: YOLOv5s ile yapılan çalışmanın K-GD grafiği

Derin öğrenme modeli her bir görüntüdeki tespit edilen nesnelere için bir güven değeri hesaplar. Bu güven değeri, görüntünün algoritma tarafından doğru algılanma olasılığını gösterir ve yüzde olarak verilir. Puanlar, farklı IoU (Birleşim Üzerinden Kesişme) eşiklerinde ortalama kesinlik üzerinden alınır [19]. Şekil 3,4,5,6 ve 7 güven değerine karşılık farklı ölçütlerin değişimini göstermektedir. Bir eşığe bağlı olarak, bir


grup kesinlik ve modelin duyarlılığı elde edilebilir. Model için farklı eşikler ayarlandığında, çoklu kesinlik, duyarlılık ve F1 puanı grupları elde edilir böylece K-G, D-G ve F1-G eğrisi çizilebilir.



Şekil 7: YOLOv8n ile yapılan çalışmanın D-G grafiği

Şekil 3, YOLOv8n ile yapılan eğitim sırasında artan güven değeri ile F1 puanının nasıl değiştiğini göstermektedir. Model, %84'lik genel bir F1 puanına ulaştı ve bu ölçüt altında iyi bir doğruluk gösteriyor. Şekil 4, YOLOv5s ile yapılan eğitim sırasında artan güven değeri ile F1 puanının nasıl değiştiğini göstermektedir. Model, %81'lik genel bir F1 puanına ulaştı ve bu ölçüt altında iyi bir doğruluk göstermekle birlikte YOLOv8n'den daha düşük bir performans göstermektedir.

YOLOv8n ile yapılan çalışmanın, tüm muz olgunluk sınıfları için kesinlik ve güven değerleri Şekil 5'te gösterilmektedir. Şekil 5'te görüldüğü gibi, 0,915'in üzerindeki bir güven değeri için kesinlik değeri 1 elde edilmektedir.

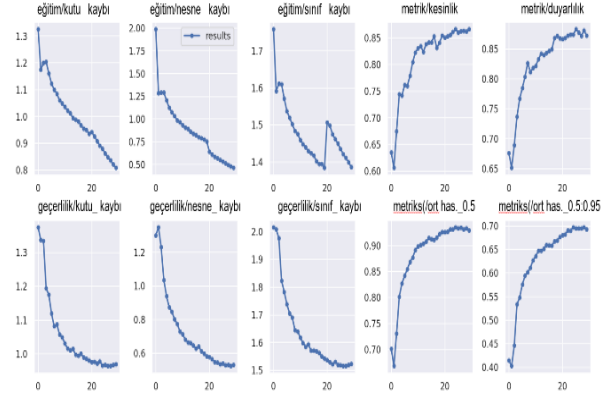


Şekil 8: YOLOv5s ile yapılan çalışmanın K-D grafiği

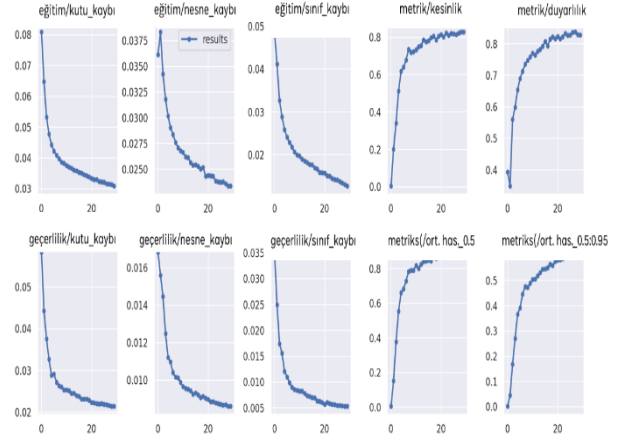
YOLOv5s ile yapılan çalışmanın, tüm muz olgunluk sınıfları için kesinlik ve güven değerleri gösterilmektedir. Şekil 6'da, 0,926'nın üzerindeki bir güven değeri için kesinlik değeri 1 elde edilmektedir.

Şekil 7 Duyarlılık-Güven eğrisinin sonuçlarını göstermektedir. Görselde yer alan sonuçlara göre, 0 güven değerinde tüm muz

olgunluk sınıflarının 0.99 duyarlılık değerine ulaştığı gösterilmektedir.



Şekil 9: YOLOv8n modeline sahip evrimsel sinir ağının performans eğitimi analizi çizim grafikleri.



Şekil 10: YOLOv5s modeline sahip evrimsel sinir ağının performans eğitimi analizi çizim grafikleri

Kesinlik-Duyarlılık eğrileri, farklı olasılık eşikleri kullanan bir tahmine dayalı model için gerçek pozitif oran ile pozitif tahmin değeri arasındaki değiş tokuşu özetler. Şekil 8'de yer alan sonuçlara göre, en yüksek skor fazla olgunlaşmış sınıfa aittir, en düşük skor 0.864 ile çürük sınıfa aittir. Tüm sınıflar 0.895 değerinde, 0.5 ortalama hassasiyet değerine sahiptir.

Şekil 9 muz olgunluk seviyeleri veri kümesi için YOLOv8n algoritmasının nesne dedektörünün ve 30 epok sınıflandırmanın hem eğitim hem de geçerleme kayıplarını gösterir. Eğitim ve geçerleme aşamasındaki kesinlik ve duyarlılık ölçütleri en yüksek %97,4 doğrulukta birleşirken, ortalama hassasiyet 0,5 eşik ile %95'te birleşir.

Şekil 10 muz olgunluk seviyeleri veri kümesi için YOLOv5s algoritmasının nesne dedektörünün ve 30 epok sınıflandırmanın hem eğitim hem de geçerleme kayıplarını gösterir. Eğitim ve geçerleme aşamasındaki kesinlik ve duyarlılık ölçütleri en yüksek %94,8 doğrulukta birleşirken, ortalama hassasiyet 0,5 eşik ile %95'te birleşir.

Tablo 4: YOLOv5s algoritması ile elde edilen değerlendirme sonuçları

Sınıf	Kesinlik	Duyarlılık	F1	Ort. Kesinlik 50
S1	0.82	0.84	0.83	0.93
S2	0.78	0.87	0.82	0.90
S3	0.90	0.89	0.89	0.95
S4	0.65	0.88	0.75	0.90
S5	0.75	0.83	0.79	0.86
S6	0.76	0.79	0.77	0.83

Tablo 4 YOLOv5s algoritması ile elde edilen değerlendirme sonuçlarını göstermektedir. En yüksek kesinlik, duyarlılık, F1 ve ortalama kesinlik değeri S3 sınıfında kaydedilmiştir. En düşük kesinlik, duyarlılık, F1 ve ortalama kesinlik değerleri sırasıyla S4,S6,S4 ve S6 sınıflarında kaydedilmiştir.

Tablo 5: YOLOv8n algoritması ile elde edilen değerlendirme sonuçları

Sınıf	Kesinlik	Duyarlılık	F1	Ort. Kesinlik 50
S1	0.88	0.88	0.88	0.95
S2	0.76	0.91	0.83	0.92
S3	0.91	0.95	0.93	0.97
S4	0.71	0.90	0.79	0.95
S5	0.73	0.89	0.80	0.91
S6	0.78	0.85	0.81	0.92

Tablo 5 YOLOv5s algoritması ile elde edilen değerlendirme sonuçlarını göstermektedir. Değerlendirme metriklerinin her biri için en yüksek değer S3 sınıfında kaydedilmiştir. En düşük kesinlik, duyarlılık, F1 ve ortalama kesinlik değerleri sırasıyla S2,S1,S4 ve S5 sınıflarında kaydedilmiştir.

Tablo 6 YOLOv8m algoritması ile elde edilen değerlendirme sonuçlarını göstermektedir. Eğitim YOLOv8n için 6 saat 25 dakika 16 saniye sürerken, YOLOv8m için 6 saat 54 dakika 48 saniye sürmüştür. YOLOv8m modeli, YOLOv8n algoritmasına göre daha uzun bir eğitim sürecine sahipken, elde edilen değerlendirme sonuçlarında belirgin bir değişiklik gözlemlenmemiştir. Çalışmamızda, YOLOv8n modeli zaman ve performans açısından bazı sınıflarda YOLOv8m modeline göre daha başarılı bir sonuç elde etmiştir.

Tablo 6: YOLOv8m algoritması ile elde edilen değerlendirme sonuçları

Sınıf	Kesinlik	Duyarlılık	F1	Ort. Kesinlik 50
S1	0.88	0.90	0.89	0.94
S2	0.79	0.88	0.83	0.93
S3	0.91	0.96	0.93	0.97
S4	0.71	0.89	0.79	0.94
S5	0.74	0.92	0.82	0.91
S6	0.78	0.87	0.82	0.91

Tablo 7: YOLOv5s, YOLOv8n ve YOLOv8m algoritmaları ile elde edilen ağırlıklı kesinlik sonuçları

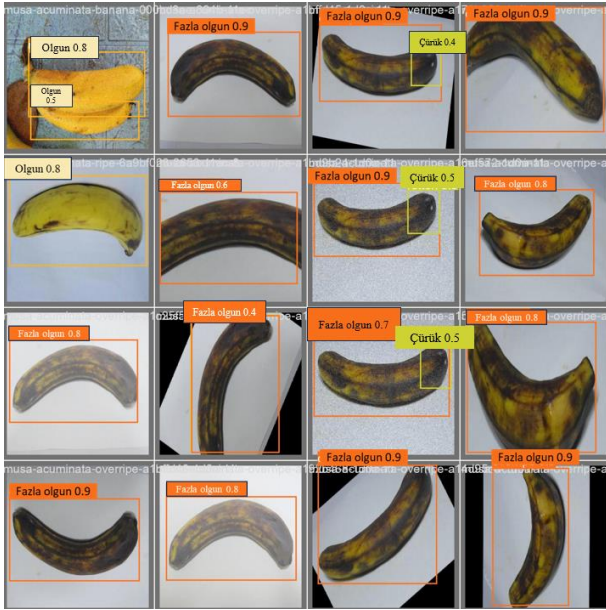
Model	Ağırlıklı Kesinlik
YOLOv5s	0.77
YOLOv8n	0.78
YOLOv8m	0.79

Tablo 7 YOLOv5s, YOLOv8n ve YOLOv8m algoritmaları ile elde edilen ağırlıklı kesinlik sonuçlarını göstermektedir. 3 farklı model kullanılarak elde edilen ağırlıklı kesinlik değerleri, birbirine oldukça yakındır.



Şekil 11: YOLOv8n modeli ile eğitilen muz olgunluk seviyelerini içeren veri kümesindeki fazla olgunlaşmış

muzların tespitini göstermektedir. 0.9 güven skoru ile algoritmanın başarılı bir sonuç elde ettiğini göstermektedir.



Şekil 12: YOLOv5s modeli ile eğitilen muz olgunluk seviyelerini içeren veri kümesindeki farklı sınıflardaki muzların tespitini göstermektedir. Fazla olgun ve olgun sınıftaki güven skoru 0.8 üzerinde sonuç vermektedir.

#### 4. Sonuç


Bu çalışmada, çok robotlu otonom tarımsal hasat sistemlerinde kullanılmak üzere yenilikçi derin öğrenme temelli yöntemler kullanılarak muz olgunluk seviyesi sınıflandırması gerçekleştirilmiştir. Özellikle robotik sistemlerdeki kısıtlı işlem kaynakları nedeniyle gerçek zamanlı sınıflandırma yapılabilmesi için küçük modellerin kıyaslaması yapılmıştır. İki farklı evrimsel yapay sinir ağı temelli yöntemin üç farklı büyüklükteki modeli (YOLOv5s, YOLOv8n, YOLOv8m) altı sınıflı bir veri kümesi ile eğitilmiş ve her bir sınıf için 0.9 üzerinde bir ortalama kesinlik değeri ile sınıflandırma performansı elde edilmiştir. Elde edilen sonuçlar, daha küçük bir model olan YOLOv8n modeliyle daha eski bir model olan YOLOv5s'den daha yüksek ortalama kesinlik değerlerine ulaşılabildiğini göstermiştir. Gerçekleştirilen otonom muz olgunluk seviyesi sınıflandırma sisteminin, kurgulanan otonom robotik hasat sisteminde kullanılması ile fire ve hasat maliyetlerinde önemli bir düşüş ile muz tarımında verim artışı elde edilmesi beklenmektedir.

#### 5. Kaynaklar

[1] Boz, F. ve Hüseyinli, N. "Türkiye'de Muz Üretimi ve İthalatına Yönelik Bir Tahmin Modellemesi." Uygulamalı Bilimler Fakültesi Dergisi 1.1-2 2019: 63-82.  
[2] <https://data.tuik.gov.tr/Bulten/Index?p=Bitkisel-Uretim-Istatistikleri-2022-45504>, 30.12.2022, Erişim tarihi: 06.07.2023.  
[3] Phillips, K. M. et al. "Dietary fiber, starch, and sugars in bananas at different stages of ripeness in the retail market." *PLOS ONE*, vol. 16, no. 7, 2021.

[4] Yap, M. et al. "The effects of banana ripeness on quality indices for puree production," *LWT*, vol. 80, pp. 10–18, 2017.  
[5] Gul, O.M. ve Erkmén, A. M. "Energy-Aware UAV-Driven Data Collection With Priority in Robotic Wireless Sensor Network," in *IEEE Sensors Journal*, vol. 23, no. 15, 2023.  
[6] Mamat, N., Othman, M. F., Abdulghafor, R., Alwan A. A., ve Gulzar Y., "Enhancing image annotation technique of fruit classification using a deep learning approach," *Sustainability*, vol. 15, no. 2, 2023.  
[7] Sa, I., Ge. Z., Dayoub, F., Upcroft, B., Perez, T. ve McCool, C. "DeepFruits: A Fruit Detection System Using Deep Neural Networks," *Sensors*, vol. 16, no. 8, 2016.  
[8] Hamidisepehr, A., Mirnezami, S. V. ve Ward, J. K., "Comparison of Object Detection Methods for Corn Damage Assessment Using Deep Learning," *Transactions of the ASABE*, vol. 63, no. 6, 2020.  
[9] Ahmad, A., Saraswat, D. ve Gamal, A. E. "A survey on using deep learning techniques for plant disease diagnosis and recommendations for development of appropriate tools," *Smart Agricultural Technology*, vol. 3, 2023.  
[10] Dai, M., Dorjoy, M. M. H., Miao, H. ve Zhang, S. "A new pest detection method based on improved YOLOv5M," *Insects*, vol. 14, no. 1, 2023.  
[11] Jocher, G., Chaurasia, A., ve Qiu, J. "YOLO by Ultralytics" <https://github.com/ultralytics/>, 2023.  
[12] Uysal, F. ve Erkan, M. "Evrimsel Sinir Ağları Temelli Derin Öğrenme Modelleri Kullanılarak Beyin Tümörü Manyetik Rezonans Görüntülerinin Sınıflandırılması" *EMO Bilimsel Dergi* 13.2: 19-27 2022.  
[13] Koç, İ. et al. "Raylı Sistemlerde Peron Ayırıcı Kapı Sistemi İçin Yapay Sinir Ağı Tabanlı Hata Teşhis Yaklaşımı." *EMO Bilimsel Dergi* 13.1: 13-22 2022.  
[14] Redmon, J., Divvala S., Girshick, R. ve Farhadi A., "You Only Look Once: Unified, Real-Time Object Detection" *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, USA, 2016.  
[15] Zheng, Z., Wang, P., Liu, W., Li, J., Ye, R. ve Ren, D. "Distance-IoU Loss: Faster and Better Learning for Bounding Box Regression," *Proceedings of the AAAI Conference on Artificial Intelligence*, vol. 34, no. 07, 2020.  
[16] Li, X. et al., "Generalized Focal Loss: Learning Qualified and Distributed Bounding Boxes for Dense Object Detection," *Neural Information Processing Systems*, vol. 33, 2020.  
[17] Liu, B. ve Bruch, R. "Weed Detection for Selective Spraying: a Review," *Current Robotics Reports*, vol. 1, no. 1, 2020.  
[18] Liu, J. ve Wang, X. "Tomato Diseases and Pests Detection Based on Improved Yolo V3 Convolutional Neural Network," *Frontiers in Plant Science*, vol. 11, 2020.  
[19] Sharma, A. K., Nguyen, H. H. C., Bui, T. X., Bhardwa, S. ve Thang, D. V. "An Approach to Ripening of Pineapple Fruit with Model Yolo v5," *2022 IEEE 7th International conference for Convergence in Technology (I2CT)*, 2022.  
[20] <https://universe.roboflow.com/fruit-ripening/banana-ripening-process/dataset/2>, 15.03.2022, Erişim tarihi: 05.07.2023.  
[21] Ren, S., He, K., Girshick, R. ve Sun, J. "Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks," *arXiv (Cornell University)*, 2015.

## Özgeçmişler



**Sezgin Dulkadir**, Lisans ve yüksek lisans eğitimini Ankara Yıldırım Beyazıt Üniversitesi Elektrik Elektronik Mühendisliği Bölümü'nde sırasıyla 2017 ve 2020 yıllarında tamamladı. Şu anda 2020 yılında başladığı Ankara Yıldırım Beyazıt Üniversitesi Elektrik Elektronik Mühendisliği Bölümü'nde doktora eğitimine devam etmektedir. Halen Ankara Yıldırım Beyazıt Üniversitesi'nde Elektrik Elektronik Mühendisliği Bölümü'nde Araştırma Görevlisi olarak görev yapmaktadır. Araştırma alanları arasında görüntü işleme, yapay zeka ve makine öğrenmesi yer almaktadır.



**Gökhan Koray Gültekin**, Ankara Yıldırım Beyazıt Üniversitesi Elektrik Elektronik Mühendisliği Bölümünde tam zamanlı öğretim üyesi olarak görev yapmaktadır. Orta Doğu Teknik Üniversitesi Elektrik Elektronik Mühendisliği Bölümünde 7 yıl araştırma görevlisi olarak çalışmış ve aynı zamanda doktora ve yüksek lisans eğitimlerini aynı bölümde sırasıyla 2016 ve 2010 yıllarında tamamlamıştır. Doktora sonrasında 3 yıl süresince ODTÜ Görüntü Analiz Merkezinde (OGAM), Aselsan ve Roketsan firmaları ile ortak olarak gerçekleştirilen görüntü işleme odaklı çeşitli savunma sanayi projelerinde tam zamanlı bilimsel proje uzmanı olarak çalışmış ve aynı zamanda ODTÜ Bilgisayar Mühendisliği Bölümü Ankara ve Kuzey Kıbrıs Türk Cumhuriyeti kampüslerinde yarı zamanlı öğretim üyesi olarak çeşitli dersler vermiştir. Robotik sistemler, FPGA, GPU vb. yüksek hızlı sinyal işleme donanımları, görüntü ve video işleme, makine öğrenmesi ve yeni nesil olay tabanlı görüntüleme sistemleri alanlarında araştırmalar yapmaktadır.