



**YENİLEBİLİR MANTAR TÜRLERİNİN DERİN
ÖĞRENME İLE SINIFLANDIRILMASI**

**2024
YÜKSEK LİSANS TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ**

Hakan BAYATLI

**Tez Danışmanı
Dr. Öğr. Üyesi Kasım ÖZACAR**

**YENİLEBİLİR MANTAR TÜRLERİNİN DERİN ÖĞRENME İLE
SINIFLANDIRILMASI**

Hakan BAYATLI

**Tez Danışmanı
Dr. Öğr. Üyesi Kasım ÖZACAR**

**T.C.
Karabük Üniversitesi
Lisansüstü Eğitim Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalında
Yüksek Lisans Tezi
Olarak Hazırlanmıştır**

**KARABÜK
Ocak 2024**

Hakan BAYATLI tarafından hazırlanan “YENİLEBİLİR MANTAR TÜRLERİNİN DERİN ÖĞRENME İLE SINIFLANDIRMASI” başlıklı bu tezin Yüksek Lisans Tezi olarak uygun olduğunu onaylarım.

Dr. Öğr. Üyesi Kasım ÖZACAR
Tez Danışmanı, Bilgisayar Mühendisliği Anabilim Dalı

Bu çalışma, jürimiz tarafından Oy Çokluğu ile Bilgisayar Mühendisliği Anabilim Dalında Yüksek Lisans tezi olarak kabul edilmiştir. 15/01/2024

<u>Ünvanı, Adı SOYADI (Kurumu)</u>	<u>İmzası</u>
Başkan : Dr. Öğr. Üyesi Muhammet ÇAKMAK (SNÜ)
Üye : Dr. Öğr. Üyesi Kasım ÖZACAR (KBÜ)
Üye : Dr. Öğr. Üyesi Sait DEMİR (KBÜ)

KBÜ Lisansüstü Eğitim Enstitüsü Yönetim Kurulu, bu tez ile, Yüksek Lisans derecesini onamıştır.

Doç. Dr. Zeynep ÖZCAN
Lisansüstü Eğitim Enstitüsü Müdürü

“Bu tezdeki tüm bilgilerin akademik kurallara ve etik ilkelere uygun olarak elde edildiğini ve sunulduğunu; ayrıca bu kuralların ve ilkelerin gerektirdiği şekilde, bu çalışmadan kaynaklanmayan bütün atıfları yaptığımı beyan ederim.”

Hakan BAYATLI

ÖZET

Yüksek Lisans Tezi

YENİLEBİLİR MANTAR TÜRLERİNİN DERİN ÖĞRENME İLE SINIFLANDIRILMASI

Hakan BAYATLI

Karabük Üniversitesi

Lisansüstü Eğitim Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

Tez Danışmanı:

Dr. Öğr. Üyesi Kasım ÖZACAR

Ocak 2024, 39 sayfa

Bu çalışmada, yenilebilir mantarların sınıflandırması ve üzerindeki dokulara göre kalitesinin belirlenmesinde insan gücü olarak ayırt edilmesi meşakethli, dikkat gerektiren ve yorucu bir iştir. Ülkemizde Batı Karadeniz, Karadeniz, Ege ve Akdeniz bölgelerinde mantarın yoğun olarak bulunduğu ancak bilinmeyen değerli mantarların ekonomiye kazandırılmadan geçildiğini söylemek mümkündür. Bu çalışmada yüksek oranda verim sağlayan YoloV8 versiyonu ile derin öğrenme yöntemi kullanılarak mantar tanımlama çözümü önerilmiştir. Mantar görüntüleri toplanarak 9 tür mantar için 807 görüntü ile veri seti hazırlanmış ve derin öğrenme modelini hazırlanarak oluşan model ONNX türüne çevrilmiştir. Model geliştirme olarak mantarların kalite sınıflandırılması için geliştirmeler yapılmıştır. YoloV8 yöntemiyle geliştirilmiş mantar tanıma ve sınıflandırma modeli başarı oranı görüntü cihazı ile %99,98 olduğu gözlemlenmiştir. Yapılan çalışmalar incelendiğinde Inception-V3, VGG-16, Resnet50, Yolov4, Yolov5 ve geliştirilen CNN mimarilerindeki başarı oranı en yüksek %88,4 olarak belirlenmiş ve YoloV8 ile karşılaştırıldığında önerilen geliştirilmiş

yöntemin daha verimli kapsamlı sonuçlara sahip olduđu görülmüştür. Mantarların tanınması ve kalitesine göre sınıflara ayrılması da etkili bir şekilde uygulanabilmektedir.

Anahtar Sözcükler : Mantar, Derin Öğrenme,YOLOV8, Sınıf Belirleme, ONNX.

Bilim Kodu : 92431

ABSTRACT

Master Thesis

CLASSIFICATION OF EDIBLE MUSHROOM SPECIES WITH DEEP LEARNING

Hakan BAYATLI

Karabük University

Institute of Graduate Programs

Department of Computer Engineering

Thesis Advisor:

Dr. Lecturer Member Kasım ÖZACAR

January 2024, 39 pages

In this study, classifying edible mushrooms and determining their quality according to their components is a laborious, careful, and tiring task that requires manpower. It is possible to say that mushrooms are abundant in the Western Black Sea, Black Sea, Aegean and Mediterranean regions of our country, but unknown valuable mushrooms are passed without being brought into the economy. In this study, a mushroom identification solution was proposed using the deep learning method with the YoloV8 version, which provides good efficiency. By collecting mushroom images, a data set with 807 images for 9 species of mushrooms was prepared and the deep learning model was prepared and the resulting model was converted on ONNX type. As model development, improvements have been made for the quality classification of mushrooms. The success rate of the mushroom recognition and classification model developed with the YOLOV8 method was determined to be 99.98% with a 1080p display device. When the studies were examined, the success rate in Inception-V3, VGG-16, Resnet50, Yolov4, Yolov5 and the developed CNN architectures was

determined to be 88.4% at most, and it was seen that the proposed improved method had more efficient and comprehensive results compared to YoloV8. Recognizing mushrooms and dividing them into classes according to their quality can also be applied effectively.

Key Word : Mushroom, Deep Learning, YoloV8, Class Detection, ONNX.

Science Code : 92431

TEŐEKKÜR

Bu tez alıŐmasının planlanmasında, araŐtırılmasında, yürütülmesinde ve oluşumunda ilgi ve desteęini esirgemeyen, saygıdeęer danıŐman hocam; Dr. Öğr. Üyesi Kasım ÖZACAR'a tüm kalbimle teşekkür ederim.

İÇİNDEKİLER

	<u>Sayfa</u>
KABUL.....	ii
ÖZET.....	iv
ABSTRACT.....	vi
TEŞEKKÜR.....	viii
İÇİNDEKİLER	ix
ŞEKİLLER DİZİNİ.....	xii
ÇİZELGELER DİZİNİ	xiii
SİMGELER VE KISALTMALAR DİZİNİ	xiv
BÖLÜM 1	1
1. GİRİŞ	1
1.2. PROBLEM	2
1.2. AMAÇ	2
1.3. VARSAYIMLAR.....	2
1.4. SINIRLIKLAR	2
BÖLÜM 2	4
LİTERATÜR ARAŞTIRMASI	4
BÖLÜM 3	8
3.KAVRAMSAL MİMARİ	8
3.1. MAKİNE ÖĞRENİMİ	8
3.1.1. Denetimli Öğrenme	9
3.1.2. Denetimsiz Öğrenme	9
3.1.3. Takviyeli Öğrenme	9
3.2. DERİN ÖĞRENME	10
3.2.1. Sınır Ağı	10
3.2.2. Derin Öğrenme Algoritmaları.....	10

	<u>Sayfa</u>
3.2.2.1. Evrişimli Sinir Ağları.....	11
3.2.2.2. Tekrarlayan Sinir Ağları	11
3.2.2.3. Çok Katmanlı Algılayıcı	12
BÖLÜM 4	13
4.MATERYAL VE METOTLAR	13
4.1. MANTAR VERİ SETİ.....	13
4.2. GÖRÜNTÜDEKİ MANTARLARIN ETİKETLENMESİ	14
4.3. ML.NET MODEL ÇALIŞMASI	14
4.3.1. Model Builder Arayüz Aracı Kurulumu.....	14
4.3.2. Model Eğitim Aşamaları.....	14
4.3.3. Modelin Uygulamayla Kullanımı	15
4.4. DARKNET KÜTÜPHANESİ MODEL ÇALIŞMASI	17
4.4.1. Darknet Kütüphanesi Yazılım Gereksinimleri	17
4.4.2. CMake ile Darknet Kütüphanesi Windows Konfigirasyonu	18
4.4.3. Darknet Kütüphanesi Model Eğitimi.....	18
4.5. ULTRALUTICS YOLOV8 MODEL ÖĞRENİMİ	19
4.5.1. Anaconda Eğitim Ortamı Oluşturma ve Paket Kurulumları	19
4.5.2. Veri Seti Doğrulama	20
4.5.3. YoloV8 Model Eğitimi	20
4.5.4. Eğitilen Mantar Modeli Testi.....	20
4.5.5. Eğitilen YoloV8 Modeli Mantar Algılama Uygulaması	21
4.6. MODEL SONUÇ GRAFİKLERİ	22
4.7. TEST SONUÇLARI.....	27
4.8. YÖNTEMLERİN KARŞILAŞTIRILMASI	30
4.9. ÇALIŞMADAKİ YOLOV8 MODELİ İLE SSD MODELLERİ VE YOLOV7 KARŞILAŞTIRMASI.....	31
BÖLÜM 5	33
TARTIŞMA VE SONUÇLAR	33
5.1. ZORLUKLAR.....	34
5.2. SINIRLAMALAR.....	34

	<u>Sayfa</u>
5.3. SONUÇ	34
KAYNAKLAR	36
ÖZGEÇMİŞ	39

ŞEKİLLER DİZİNİ

	<u>Sayfa</u>
Şekil 3.1. Makine öğrenimi süreci.....	9
Şekil 3.2. Evreşimli sinir ağı modeli	11
Şekil 3.3. Tekrarlayan sinir ağı modeli	12
Şekil 3.4. Çok katmanlı algılayıcı modeli	12
Şekil 4.1. Vott json dosyası seçimi.....	15
Şekil 4.2. Yazılım ekran görüntüsü	16
Şekil 4.3. Resim üzerinde mantar görüntüsü ekranı.....	16
Şekil 4.4. Kamera ile mantar görüntüsü tespiti.	17
Şekil 4.5. Darknet model eğitimi ekranı.....	19
Şekil 4.6. Modelden geçirilen mantar görüntüsü	21
Şekil 4.7. Hassas geri çağırma eğrisi.....	22
Şekil 4.8. Hassas güven eğrisi	23
Şekil 4.9. Geri çağırma güven eğrisi	24
Şekil 4.10. F1 puan eğrisi	25
Şekil 4.11. Karışıklık matrisi.....	26
Şekil 4.12. Her sınıfın eğitim ve doğrulama kaybı.....	27
Şekil 4.13. Kamera ile mantar tespiti yapılması.....	28
Şekil 4.14. Sınıf mantar kalite sınıflandırması.	28
Şekil 4.15. 2.Sınıf mantar kalite sınıflandırma.....	29

ÇİZELGELER DİZİNİ

	<u>Sayfa</u>
Çizelge 2.1. Literatür çalışmalarının sonuç bilgileri	7
Çizelge 4.1. Kullanılan yöntemlerin karşılaştırılması.....	31
Çizelge 4.1. Kullanılan Yolov8 modeli ile diğer model sonuçlarının karşılaştırılması.	32

SİMGELER VE KISALTMALAR DİZİNİ

SİMGELER

Ca : kalsiyum

Na : sodyum

Fe : demir

Mn : manganez

Zn : çinko

Se : selenyum

KISALTMALAR

ONNX: Open Neural Network Exchange (Açık Sinir Ağı Değişimi)

CNN : Convolutional Neural Networks (Evrışimli Sinir Ağları)

YOLO: You Only Look Once (Sadece Bir Kez Bakmak)

SVM : Support Vector Machine (Destek Vektör Makinesi)

RNN : Recurrent Neural Network (Yinelemeli Sinir Ağı)

BÖLÜM 1

1. GİRİŞ

Ülkemizde yetişen mantarlar hem besin olarak hem de ilaç üretiminde kullanılarak önemli bir yere sahip olmaktadır. Halk tarafından bilinen mantarlar genel de besin olarak tüketilen mantarlar olduğu için mantar toplama sürecinde değerli ve bilinirliği az olan mantarlar zehirli ya da zararlı olarak ayırt edilerek mantarların ekonomimize katkısı azalmaktadır. Mantarlar dünyadaki en büyük besin kaynaklarından biri olarak kabul edilmektedir. Mantarlar yağmurun fazla olduğu veya hızlı sıcaklık değişiminden sonra organik madde, nem içeriği veya hayvan artıklarının fazla olduğu toprakta genellikle görülür. Fakat bir süre sonra kaybolur ve toprak altında kalır [1].

Mantar, besinsel ve ticari yararlarından dolayı ticari değere sahiptir [2, 3]. Farklı araştırmacılar, günümüz dünyasında 70.000'den fazla mantar türünün varlığını bildirmiş olup bunların 2000 türü yenilebilir mantarlara, 30 türün yaklaşık %10'u zehirli mantarlara ait olup, birkaç türün ise ölüme neden olduğu kabul edilmektedir [4]. Ülkemizde farklı bölgelerde yetişen mantarla beraber yaklaşık 350'den fazla yenilebilir cinsten mantar türü yer almaktadır. Tüketim için toplaması yapılan mantarların birazı pazarlarda satılırken birazı da mantar fabrikalarına verilmekte ve ihraç edilmektedir. Mantar türlerinin içinden lezzet olarak en fazla tercih edilenlerden bazıları kuzugöbeği mantarı, ayı mantarı, trüf mantarı, kanlıca mantarı, gelincik mantarıdır. Dünya genelindeki gibi ülkemizde de yiyecek ve ekonomi getirisi olarak mantarlar önemli gıda kaynaklarındandır.

Mantarlar diğer mahsullerle karşılaştırıldığında yüksek protein miktarı ile birlikte kısa sürede birim alandan yüksek miktarda üretildiğinden yetersiz beslenmeyle mücadelede kullanılmaktadır [5]. Düşük kalori, karbonhidrat, Ca (kalsiyum) ve Na (sodyum) ve yıkıcı lipidler içermeyen maksimum miktarda yağ içermektedir. Yüksek oranda vitamin içerirler. Mantarlar kuru ağırlık bazında B vitamini kompleksi C

Vitamini ve Folik asit gibi Ca, Fe, Mn, Mg, Zn ve Se gibi mineraller bakımından zengindir [6]. Et, balık, sebze ve meyvelerin yerine kullanılırlar [7].

1.2. PROBLEM

Bu çalışma da bilinirliđi az olan ancak deđerli olan trüf mantarı gibi mantar türlerinin ekonomimize kazandırmak, mantar üretici ve toplayıcılarının bilinçlendirilmesini sağlamak ve en önemlisi mantar toplayan fabrikaların ayrışım bantlarındaki işlemlerinde sadece belirli mantarları deđil deđerli mantarları da ayrışım da kazanarak katkı da bulunulması ile dünya payında ülkemizin mantar üretimi sıralaması problemi ele alınmıştır.

1.2. AMAÇ

Toplanan mantarların tanımlanması ve kalite sınıflarına göre ayrıştırılarak ülkemizin dünyadaki mantar payının yükseltilmesi amaçlanmıştır. Yapılan çalışma ile mantar tanımlamaları ve mantarların kalite sınıflandırmaları derin öğrenme ile görüntü makineleriyle tespit edilip ekran da gösterilmiştir.

1.3. VARSAYIMLAR

Toplanan mantar görüntülerinin belirlenen sınıf kalitesi belirlenirken piyasadaki fabrikanın öngürdüđü kalite seviyesi varsayılmaktadır.

1.4. SINIRLIKLAR

YoloV8 derin öğrenme algoritması mantar görüntünün kalite fazlalığı ve iterasyon sayısındaki başarıyı etkilediđi göz önüne alındığında 100 iterasyon ve 0,2 yaklaşık deđer kabul edilerek model eğitimleri tamamlanmıştır.

Bitkisel baharatlar tanınması ve sınıflandırılmasında makine öğrenmesi ve derin öğrenme yöntemleri başarıyla benimsenmektedir [8]. Farklı ülkeler yapay zeka ile ilgili projelere de fon sağlamaktadır. Hindistan hükümeti gayri safi yurt içi hasılanın

büyümesini destekleyecek yapay zeka ile ilgili projelere fon sağlamaktadır. Bu çalışmada uygulanan Darknet kütüphanesi AlexNet modeli sekiz katman içermekte; ilk beş katmanı evreşim ve diğer üç katmanı tamamen bağlantılı katman olmaktadır [9].

CNN'nin temel katmanları evreşim, maksimum havuzlama ve tam bağlı katmanları içermektedir [10, 11]. Tipik olarak ağ derinleştikçe ağ daha iyi öğrenme eğilimi gerçekleştirmektedir [11]. Ancak hesaplama süresi etkileyebilir. Bu nedenle, daha kısa hesaplama süresi gerektiren ağ mimarisini dikkatli bir şekilde tasarladık. En yüksek sınıflandırma performansı, eğitim aşamasında hassas bir şekilde ayarlanan parametrelerle elde edilmektedir.

Evreşim katmanı, bir çekirdek kullanarak giriş sinyaliyle evrilir [12, 13]. Evreşiminden sonra bir sonraki katman için bir özellik haritası oluşturulmaktadır. Bundan sonra, girdi eğitim verilerinin ara katmanlar arasında akışını normalleştirmek için toplu normalleştirme katmanı uygulamaktadır. Amaç daha hızlı öğrenmeyi ve güçlendirmeyi sağlamaktır. Daha sonra düzeltilmiş doğrusal birim giriş verilerini eşiklemek için uygulanarak verilerdeki fazlalıkları azalmaktadır. Özellik haritasının boyutunu azaltmak için maksimum katmanın her nöronu, çıkışın giriş sinyalinin sonucunu tahmin ettiği tam bağlı katmandaki her nörona bağlı olmaktadır [14, 15, 16].

BÖLÜM 2

LİTERATÜR ARAŞTIRMASI

Mantar tüketimi insanoğlunun avcılık ve toplayıcılık yaptığı zamanlara dayanmaktadır. Beslenme yönünden; esansiyel aminoasitler, karbonhidratlar, lifler, önemli vitaminler ve mineraller bakımından zengin bir içeriğe sahip olan mantarlar, düşük kalori içermekte, pek çok ülkede spesifik aromaları ve dokuları nedeniyle lezzetli bir gıda olarak tüketilmekte ve doğu ülkelerinde yüzyıllardır ilaç olarak kullanılmaktadır. İlaç sektöründe kullanılan zehirli ve zehirsiz mantarların bilinçli sınıflandırma ve tespitinin yapılması ilaç sektörü ve firma için büyük önem taşımaktadır. Mantar tanıma ve sınıflandırmaları ile alakalı farklı metodlar geliştirilmiştir.

Sajedi vd. (2019) yaptıkları çalışmada; müsinajlı taksonları otomatik olarak tanımlamak için dört katmanlı bir evreşimli sinir ağı kullanmıştır. Bu yaklaşımın ilk aşaması, bir CNN (Evrişimli sinir ağı) kullanarak görüntü özelliklerini çıkarmaktır. Bu özellikler, SVM, XGBoost ve Extreme Learning Machine (MLP) gibi makine algoritması sınıflandırıcılarına girilir. Bu aşamada doku ve şekle karşılık gelen özellikler öğrenilir. Bu fazın çıktısı ikinci kısma yönlendirilir. İkinci kısım, denetimli faz olarak da adlandırılan bir sınıflandırıcıdır. Sonraki aşamalarda özellik çıkarma ve sınıflandırma aşamaları yapılarak çalışma tamamlanmaktadır. Bu çalışma ile SVM sınıfı ile %91,7'lik doğruluk elde etmişlerdir. [17].

Zahan vd. (2021) yaptıkları çalışmada; 8190 mantar görüntüsünden oluşan bir veri kümesinde mantar türlerini belirlemek için Inception-V3, VGG-16 ve Resnet50 gibi derin öğrenme modellerini uygulamışlardır. Inceptionv3 ağı ile kontrast sınırlı uyarlanabilir histogram eşitlemeyi kullandılar ve test setinde %88,4 doğruluk elde ettiler [18].

Preechasuk vd. (2019) yaptıkları çalışmada; birden çok mantar türünü sınıflandırmak için temel bir CNN mimarisi oluşturmuşlardır. Deneysel veri seti, 35'i yenilebilir mantar ve diğer 10'u zehirli olmak üzere 45 türe sınıflandırılan 8556 mantar görüntüsünü içermektedir. Önerilen yöntem %74'lük sonuç vermiştir [19].

Liu vd. (2022) yaptıkları çalışmada; shiitake mantarlarının sınıflandırılması ve işlenmesi için bir YoloX derin öğrenme yöntemi geliştirmek amacıyla kanal budama mekanizması önermişlerdir. Görüntü veri setlerini genişlettikten sonra YoloX modeli oluşturmuşlardır. İkinci aşama da kanal budama algoritması ile modeli optimize etmişlerdir. YoloX yönteminin bu çalışma da shiitake mantarlarının yüzey dokusunu etkili bir şekilde incelediğini ve ortalama hassasiyet değerlerinde %99,96 doğruluk değerine yaklaştıklarını göstermişlerdir. Çalışmalarında YoloV3, YoloV4 gibi yöntemlerle karşılaştırmışlar ve daha iyi kapsamlı performansta shiitake mantarlarının hızlı kalite sınıflandırmasına etkili bir şekilde uygulanabildiğini bildirmişlerdir [20].

Guan vd. (2022) yaptıkları çalışmada; yenilebilir mantar çeşitlerinin hızlı tespiti, kaliteli toplanması ve yetiştiriciliği açısından önem taşıdığı belirtilmiş ve çalışma bunun üzerine odaklanılarak yapılmıştır. Bu çalışmada, yakın kızılötesi spektroskopi ve derin öğrenme modeline dayalı olarak mantar çeşitlerini tanıma yöntemi önermişlerdir. İlk olarak altı çeşit mantar miselyumunun yakın kızılötesi, spektral verileri Fourier dönüşümü yakın kızılötesi spektrometresi ile elde edilmiştir. İkinci olarak, mantar miselyumunun yakın kızılötesi spektral verilerinin ön işlenmesi için dalgacık paketi eşik gürültüsü giderme yöntemi ve standart normal değişken dönüşümü yöntemi kullanılmıştır. 691 eğitim seti ve 173 test seti ile çalışılmıştır. Çalışmada 8 katmanlı bir evreşimli sinir ağı kullanılarak mantar miselyum çeşitlerinin bir tanıma modeli oluşturulmuştur. Çalışma sonucu olarak %98,27 tanıma doğruluğu gerçekleştirildiği söylenmiştir [21].

Guragain vd. (2024) yaptıkları çalışmada; gelişmekte olan olan ülkelerdeki çiftçilerin çoğunluğu hala mantar yetiştiriciliğinde geleneksel yaklaşıma güvendiği belirtilmiş yerel talebi karşılamak amacıyla verimliliği arttırmak için modern teknolojinin benimsenmesine dikkat çekilmiştir. Çiftçilerin karmaşık tedarik zinciri sorunlarıyla, tarım uzmanlarıyla doğrudan iletişim eksikliğiyle ve sık görülen hastalık salgınlarıyla

karşı karşıya kaldığı belirtilerek bu sorunlara çözüm için düşük maliyetli, merkezi bir IoT ekosistemi sunmuşlardır. Çiftçilerin şüpheli görüntüyü IoT cihazına yükleyerek ve tahmin edilen hastalığı ile ilgili alabildiği hastalık tespit modeli %98,33'lük doğruluk payına ulaşmıştır [22].

Wang vd. (2022) yaptıkları çalışmada; nesnelere interneti çiftçilere üretimden mahsul satışına kadar yardımcı olacak akıllı tarım uygulamalarının sınırlarını zorladığı ve mantarın tarımsal üretimde ekonomik açıdan en değerli ürünlerden birisi olduğu, Çin'den Amerika'ya kadar dünyanın her yerinde yaygın olarak yetiştirildiği belirtilmiştir. Devletler, shiitake mantarının yetiştirilmesi, iç mekan ortamının gerçek zamanlı olarak ayarlanmasını ve shiitake mantarlarının verimi ve türlerine ilişkin istatistikleri gerektirdiği ve geleneksel ekim yönetimi emek gerektirmekte ve verimi belirlemek için maliyetin arttığını söylemişlerdir. Bu sorunu çözmek için mantar büyümesini tanıma için geliştirilmiş Yolov5 derin öğrenme algoritması kullanılmış ve %99,24'lük bir performans sağlamışlardır [23].

Cong vd. (2023) yaptıkları çalışmada; meyve ve sebze denetimi, modern tarımsal üretimde robotik hasada yardımcı olduğu söylemişlerdir. Taze shiitake mantarlarının hızlı ve doğru bir şekilde algılanması için, toplama robotlarının yetiştirme ortamının, çeşitli morfolojinin, yoğun gölgelemenin ve değişen görüş alanının karmaşık koşullarının üstesinden gelmesi gerektiğini belirtmişlerdir. Yaptıkları çalışmada YoloV3 modelini temel alan MYolo modeli ile shiitake mantar tespiti oluşturmuşlar ve %97,03'lük bir doğruluk elde etmişlerdir [24].

Yapılan literatür çalışmaları incelendiğinde doğruluk oranlarının Yolo sürümlerinde daha performanslı olduğu ve yolo versiyonunu yükseldikçe sonuçta ulaşılan doğruluk oranının arttığını aşağıdaki tabloda gösterilmiştir.

Çizelge 2.1. Literatür çalışmalarının sonuç bilgileri.

Literatür Çalışması	Model	Veri Büyüklüğü	Doğruluk Oranı
Müsinajlı Takson [17]	CNN SVM Sınıfı	30 türde 322 Meyve Görüntüsü	%91,7
Mantar Türleri [18]	Inceptionv3 CNN	8190 Mantar Görüntüsü	%88,4
Mantar Türleri [19]	Keras TensorFlow	8556 Mantar Görüntüsü	%74
Shiitake Mantar Türü [20]	YoloX	303 Mantar Görüntüsü	%99,96
Yenilebilir Mantar Tespiti [21]	E-CNN Modeli	864 Mantar Görüntüsü	%98,27
Mantar Hastalık Tespiti[22]	DensNet201 ve NASNetMobile Birleşimi	3955 Mantar Görüntüsü	%98,33
Shiitake Mantarları Büyüme Tanıma [23]	Yolov5	300 Mantar Görüntüsü	%99,24
Shiitake Mantarı Tespiti [24]	MYolo	1416 Mantar Görüntüsü	%97,03

BÖLÜM 3


3.KAVRAMSAL MİMARİ

Bu çalışmada kullanılan yöntemler makine öğrenimi ve derin öğrenme temeli üzerine ilerlemektedir. Makine öğrenimi ve derin öğrenme örnekleri hayatımızın her yerinde bulunmaktadır. Örneğin, bu algoritmalar Tesla'nın sürücüsüz arabalar üretmesinde, aracın çevresindeki nesnelere tanınmasında kullanılmaktadır. Yapılan çalışmada mantar çeşitlerinin tanımlanması ile kalite sınıflarına göre ayrılmasında da bu modeller, yöntemler kullanılarak ilerlenmektedir. Makine öğrenimi ve derin öğrenme birlikte, yeniliğin sınırlarını zorlayan yapay zeka odaklı araçları güçlendirmektedir.

3.1. MAKİNE ÖĞRENİMİ

Makine öğrenimi, istatistiksel modeller ve algoritmalar üzere eğitilmiş, tahmin ve karar vermesini sağlayan bir yapay zeka dalı olmaktadır. Makine öğrenimi algoritmaları, eğitim ve geçmiş verileri kullanılarak zaman içinde gelişip uyum sağlayarak yeteneklerini zenginleştirmektedir. Karmaşık sorunları çözüme ve verilerdeki kalıpları tanımlayarak önemli içgörüler oluşturmada ustalaşmıştır [26].

Makine öğrenimi, bilgisayarların ve yazılımlarını eğitim verilerini kullanarak kalıpları ve ilişkileri öğrenmesini sağlayan bir algoritmadır. Bir makine öğrenimi modeli, kullanıcılarla etkileşim kurarak elde ettiği geçmiş verilerden öğrenerek zaman içinde gelişmeye devam etmektedir. Makine öğrenim süreci şekil 3.1'de gösterilmektedir.



Şekil 3.1. Makine öğrenimi süreci.

Çeşitli makine öğrenimi modelleri arasındaki temel fark, onların nasıl eğitiliğidir. Ancak denetimli öğrenme, denetimsiz öğrenme ve takviyeli öğrenme gibi modelleri kullanarak benzer sonuçlar elde edilebilmektedir.

3.1.1. Denetimli Öğrenme

Denetimli öğrenmede, bir makine öğrenimi algoritmasına eğitim verileri verilerek verilere yanıt vermek için bir model eğitimi yapılmaktadır [26]. Buradaki süreç bilgisayar etiketli verilerle eğitimi tamamlanmakta ve veri bilimcisi, bilgisayarın doğru yanıtlarını onaylayarak ve yanlış sonuçları denetleyerek süreci tamamlamaktadır.

3.1.2. Denetimsiz Öğrenme

Denetimsiz öğrenme süreci sırasında bilgisayarlar, insan müdahalesi olmadan kalıpları tanımlamakta sonucun ne olacağından emin olunmadığı durumlarda kullanılmaktadır [26]. Buradaki süreç, etiket için sınıf olarak bir bilgi olmadığı durumlarda çalışan makine öğrenmesi yöntemi sürecidir.

3.1.3. Takviyeli Öğrenme

Takviyeli öğrenme yöntemi, bir modelin geri bildirim kullanarak öğrenmesine olanak tanıyan bir deneme yanılma yaklaşımı olarak tanımlanmaktadır. Buradaki süreç model

eđitim verileriyle eđitim tamamlanmakta ve modele ince ayar yapmak iin dođru yanıtıları ödüllendirerek ve hatalı ıktıları cezalandırarak tamamlanmaktadır. Yanlıř cevap verilmesi durumunda dođru cevap modeli eđiten tarafından verilmektedir [26].

3.2. DERİN ÖĐRENME

Derin öđrenme uygulamaları, katmanlı bir algoritma yapısı olan yapay sinir ađlarını kullanarak alıřmaktadır. Derin öđrenme modelini kullanmak iin kullanıcının bir giriř (etiketlenmemiř veri) girmesi gerekmektedir. Daha sonra sinir ađının gizli katmanları aracılıđıyla gönderilmekte ve burada kalıpları tanımlamak nihai bir ıktı geliřtirmek iin matematiksel olarak kullanılmaktadır [27].

Algoritmanın tasarımı, insan beyninden ve mesajlar yoluyla bilgi ileten nöron ađından ilham almaktadır. Bu nedenle derin öđrenme, standart makine öđrenimi modellerinden daha geliřmiř olmaktadır.

3.2.1. Sinir Ađı


Yapay sinir ađları olarak adlandırılan sinir ađları, yapay zekayı, insan beyninin yaptığına benzer řekilde iřlemesi iin eđitmenin bir yolu olmaktadır. Sinir ađları, bir giriř yoluyla bilgi olarak alıřmaktadır. Bu bilginin düđümler arasındaki derin, gizli katmanlara akmasına izin vermektedir. Burada algoritma, ıkıř katmanı aracılıđıyla son bir yanıtı geri göndermeden önce öđrenilmektedir. Sinir ađları olmasaydı derin öđrenme diye bir řey büyük ihtimalle olmayacaktı. Algoritmanın öđrenmesinin derinliđi tamamen sinir ađının derinliđine bađlanmaktadır [27].

3.2.2. Derin Öđrenme Algoritmaları

Makine öđrenimi, bilgisayarların etkileyici görevleri yerine getirmesini sađlamaktadır. Ancak model insan düşünce süreçlerini taklit ederken yetersiz kalmaktadır. Derin öđrenmenin üstün olduđu nokta tam olarak burası olmaktadır [27].

3.2.2.1. Evrişimli Sinir Ağları


Evrişimli sinir ağları, beynin görsel işleme sistemi gibi çalışan algoritmalar olmaktadır. Görsel bir uyarıyı filteleyerek ve desen, doku, şekil ve renk gibi bileşenleri değerlendirerek görüntüleri işleyebilmekte ve nesneleri algılayabilmektedir. CNN'ler genellikle makinelere görsel dünyayı nasıl işleyeceklerini öğreten yapay zeka alanları olan bilgisayarlı görme ve görüntü tanımayı desteklemektedir [27]. Tam bağlantı katmanda bütün giriş nöronlarına bağlı olarak giriş üzerinde çalışması şekil 3.2'de gösterilmektedir.



Şekil 3.2. Evreşimli sinir ağı modeli [25].

3.2.2.2. Tekrarlayan Sinir Ağları


Tekrarlayan sinir ağları, geçmiş veri noktalarını hatırlamak için yerleşik geri bildirim döngülerini kullanan yapay zeka algoritmalarıdır. RNN'ler geçmiş olayların bu hafızasını mevcut olaylara ilişkin anlayışlarını bilgilendirmek ve hatta geleceği tahmin etmek için kullanılmaktadır. Özellikle veri sıralaması ve her seferinde bir veri noktasının işlenmesi için kullanılmaktadır. Derin bir sinir ağı, bu düzeyde bir bağlama sahip olduğunda daha iyi düşünebilmektedir. RNN yapısı şekil 3.3'de gösterilmektedir.



Şekil 3.3. Tekrarlayan sinir ağı modeli [28].

3.2.2.3. Çok Katmanlı Algılayıcı

Çok katmanlı algılayıcılar, öncelikle derin öğrenmede kullanılan bir algoritma türüdür. MLP'ler ileri beslemeli bir sinir ağı olarak sınıflandırılmaktadır. Bu kullanıcının girdiği bilgilerin geri bildirim döngüleri kullanmadan yalnızca bir yönde aktığı anlamına gelmektedir. Bu da onu öngürülmeyen verileri ve kalıpları diğer algoritmalara göre daha iyi işleyebilir hale gelmektedir [27]. MLP genellikle sınıflandırma işlemlerinde etkin olarak kullanılmaktadır. Çok katmanlı ağ yapısı şekil 3.4'de gösterilmektedir.



Şekil 3.4. Çok katmanlı algılayıcı modeli [29].

BÖLÜM 4

4.MATERYAL VE METOTLAR

Mantar tespiti ve kalite sınıflandırması model eğitimi 3 platform üzerinde çalışmalar yapılarak ilerlenmektedir. Çalışmanın yapıldığı yapılar .Net model eğitimi, Darknet kütüphanesi model eğitimi, Ultralytics model eğitimi olmak üzere 3 farklı alanda yapılmaktadır. Eğitilen modeller yapılarına ve kullanım zorluklarına göre karşılaştırılmış Ultralytics model eğitimi ile çalışma modeli eğitilerek tamamlanmaktadır. Eğitilen modellerin uygulama ile test işlemleri için .Net modeli için WPF uygulaması geliştirilerek çalışmalardan bahsedilmektedir. Darknet kütüphanesi ve Ultralytics YoloV8 model çalışmaları için python dilinde geliştirilen yazılım ile kamera tespit sistemi yapılarak yine çalışmalarından bahsedilmektedir. Bu çalışmada model eğitimi için kullanılan bilgisayar donanım konfigürasyonu şu şekildedir: CPU: Inter-Xeon E5-2665 Çift İşlemci, 4.80 GHz; GPU: NVIDIA GeForce GTX 1060 6GB; RAM: 32GB; SSD: 512GB. Model Windows 10 Pro 64 bit işletim sistemi ile Visual Studio 2017, Anaconda 2.5, CMake, Python 3.9, CUDA yazılımları ile OpenCV görüntü işleme ve görüntüleme için kullanılmıştır.

4.1. MANTAR VERİ SETİ

Derin öğrenmeye dayalı olarak mantarların kalitesini sınıflandırmak için yeterli sayıda mantar görüntüsü elde etmek gerekmektedir. Bu çalışma da ülkemizdeki mantar görüntüleri belirli platformlardan toplanmış, toplanan görüntüler üzerine bölgeden mantar görüntüleri ile zenginleştirilmiş ve kalitesine göre sınıflandırma işlemi yapılmaktadır. Üzerine çalışılacak mantar türleri borazan mantarı, gelincik mantarı, istiridye mantarı, kültür mantarı, trüf mantarı, ayı mantarı, kuzu göbeği mantarı, kanlıca mantarı ve tirit mantarıdır.

4.2. GÖRÜNTÜDEKİ MANTARLARIN ETİKETLENMESİ

Mantar tanıma ve sınıflandırma veri kümesi bağlamında etiketleme işlemi modelimizin algoritmasını istediğimiz nesnenin etrafına dikgörtgen sınırlayıcı kutular çizmek anlamına gelmektedir. Etiketleme sınırlandırma kutusu çizme işlemi, etiketleme veri açıklaması olarak bilinmektedir. Mantar veri kümesini etiketlemek için bu çalışma da visual studio model eğitimi için VoTT yazılımı, darknet kütüphanesi ve ultralytics çalışmaları için LabelImg adlı araç kullanılmaktadır. Görüntülerdeki mantarları etiketleme işlemi tamamlandıktan VoTT yazılımı için json türünde dışa aktarma, LabelImg için txt dosyaları oluşturulmaktadır. Bu değerlerin anlamı ilk sayı olan 0 sayısı belirlenen sınıf sayısına göre ilkini temsil etmektedir. İkinci sayı görüntü genişliğinin bir kesri olarak sınırlandırma kutusunun merkezi x koordinatını temsil etmektedir. Üçüncü sayı görüntü yüksekliğinin bir kesri olarak sınırlayıcı kutunun merkez y koordinatını temsil etmektedir. Dördüncü sayı sınırlayıcı kutunun genişliğini görüntü genişliğinin bir kesri olarak temsil etmektedir. Beşinci sayı sınırlayıcı kutunun yükseliğini görüntü yükseliğinin bir kesri olarak temsil etmektedir.

4.3. ML.NET MODEL ÇALIŞMASI

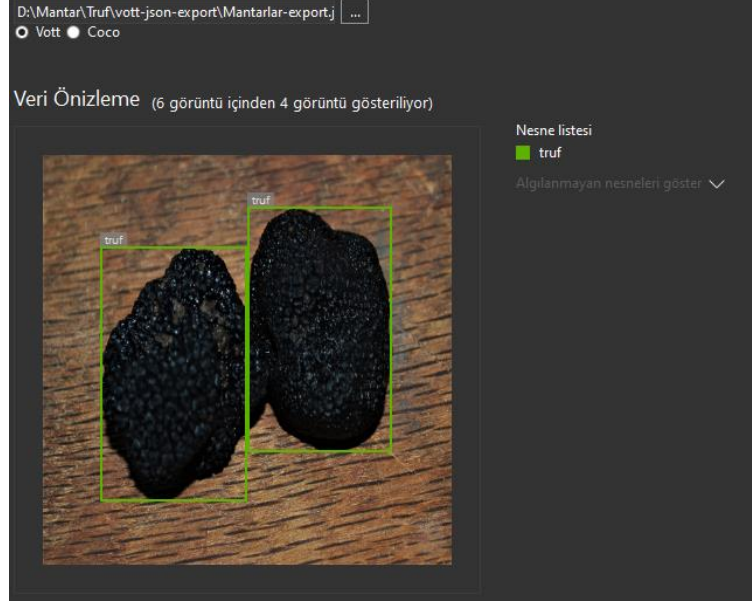
4.3.1. Model Builder Arayüz Aracı Kurulumu

Model Builder, geliştiricilerin .NET uygulamalarında özel makine öğrenimi modellerini oluşturmasına, eğitmesine ve göndermesine yönelik basit bir kullanıcı arayüzü aracıdır. Bu arayüz aracı Visual Studio araçlar kısmından yüklenmektedir.

4.3.2. Model Eğitim Aşamaları

Visual studio üzerinden makine öğrenimi modeli projeye eklenmektedir. İlk aşaması senaryo seçim ekranıdır. Senaryo ekranından görüntü işleme bölümünden nesne algılama seçilerek model eğitiminin ortamı belirlenmelidir. Model builder eklentisi Azure dışında yerel GPU ile çalışılmasını sağlamaktadır. Azure sınırlı ücretsiz kredi sunmaktadır. Modelin eğitiminin uzaması ya da büyüklüğü Azure üzerindeki sanal makinenin kullanımına bağlı olarak yetersiz kalmaktadır. Bu durumda ücretli hale

getireceğinden model eğitim çalışmasının maliyeti yükselmektedir. Model builder ile yerel GPU seçilerek Vott yazılımı ile etiketleme ve dışarı aktarımı yapılan json dosyası seçilerek ilerlenmektedir. Json dosyası seçimi yapıldıktan sonra etiketlenmiş mantar görüntüleri şekil 4.1’de gösterildiği gibi etiketli şekilde gelmektedir.



Şekil 4.1. Vott json dosyası seçimi.

Eğitim aşamasına geçilerek eğitimi başlatılmakta ve eğitim sonucunda değerlendirme ekranlarında modelin doğruluk ölçülerine bakılarak eğitim görüntüleri ya da eğitim tekrarlama gerçekleştirilmektedir.


4.3.3. Modelin Uygulamayla Kullanımı

Visual studio WPF projesi ile geliştirilen projeye eğitilen mantar tanıma modeli seçilerek mevcut görüntü üzerinde ya da kamera ile anlık görüntü ile tespit yapılacağı seçilmektedir. Görüntü ya da kamera ile ilerleme seçimi yapılması gereken ekran şekil 4.2’de gösterilmektedir.




Şekil 4.2. Yazılım ekran görüntüsü.

Geliştirilen mantar modellerinden seçim yapıldıktan sonra dosya seçimi ile ilerlenmesi durumunda görüntü resmi dosya konumu seçilerek mantar model eğitimi görüntü üzerinde uygulanmakta ve ekran görüntüsü şekil 4.3’de gösterilmektedir.



Şekil 4.3. Resim üzerinde mantar görüntüsü ekranı.

Uygulama üzerinden kamera seçilmesi durumunda sisteme bağlı olan dahili ya da harici kamera üzerinden mantar tarama etkilenleştirildiği anda kamera görüntüsü üzerine mantar tespit eğitimi uygulanmaya başlanmakta ve mantar tespitleri şekil 4.4’da gösterilmektedir.



Şekil 4.4. Kamera ile mantar görüntüsü tespiti.

4.4. DARKNET KÜTÜPHANESİ MODEL ÇALIŞMASI

Darknet kütüphanesi açık kaynaklı yapay sinir ağı kütüphanesidir. Gerçek zamanlı olarak en hızlı şekilde nesne tespiti yapabilen YOLO algoritmasının önceden eğitilmiş modelini kullanarak model eğitimi yapılmaktadır.

4.4.1. Darknet Kütüphanesi Yazılım Gereksinimleri


Darknet kütüphanesinin Windows işletim sisteminde çalışabilmesi için darknet kütüphanesinin derlenmesi gerekmektedir. Derleme işlemi için CMake yazılımı birçok IDE için gereken dosyalar da meydana getirme betikleri oluşturmaktadır. CMake yazılımı ile derleme işlemi tamamlanmaktadır. Web kamerasından görüntü almak işlemi için OpenCV kütüphanesi, GPU'ya ait olan hafıza ve işlemci birimlerini yönetmek için CUDA yazılımı ve GPU üzerinde derin öğrenme işlemlerini hızlandırmak için cuDNN yazılımı kurulmaktadır.

4.4.2. CMake ile Darknet Kütüphanesi Windows Konfigürasyonu

Visual Studio 2017 versiyonu C++ özelliđi ile kurulmaktadır. CMake kurulumu işletim sistemi özelliđine göre seçilerek tamamlanmaktadır. Darknet kütüphanesinin GPU ile çalışabilmesi için sistemde CUDA, cuDNN ve OpenCV yazılımları kurulması gerekmektedir. OpenCV kurulumu tamamlandıktan sonra kurulan dizin yolu sistem deđişkenlerinde deđişken olarak tanımlanmaktadır. Cuda 12.3 kurulumu ile beraber cuDNN kitaplığı Cuda dizinin içine kopyalanmakta ve sistem deđişkenleri bölümüne Cuda dizini deđişken olarak eklenmektedir.

4.4.3. Darknet Kütüphanesi Model Eğitimi

Kurulum ve çalışma ortamı hazırlandıktan sonra obj.data içeriđi eğitim ve doğrulama seti dosyalarının ne olduđunu ve tespit etmek istediđimiz kategorilerin adlarını hangi dosyanın içeriđini belirtilerek doldurulmaktadır. Obj.names içeriđi mantar sınıflarının isimlerini yazılmaktadır. Buradaki en önemli nokta mantar kategori numaraları oluşturulan satır numaraları ile eşlemesi gerekmektedir. Çalışılacak yolo versiyonu düzenlemesi yapılarak model öğrenmesi öncesinde daha önce eğitilen model seçimiyle beraber eğitim başlatılmaktadır. Mantar model eğitimi tekrarlama sayısı darknet kütüphanesi için ne kadar fazla yapılırsa sonuç olarak o kadar yüksek deđerler alınabilmektedir. Model eğitiminde ortalama kayıp deđer için 0.2 deđer yeterli görülmektedir. Bu deđere ulaşmak darknet kütüphanesi için büyük veri setlerinde GPU performansına göre ortalama 2 ile 3 gün sürmektedir. Bu süre sonrasında bir ekleme yapılmakta veya deđişiklik olur ise eğitimin baştan yapılması süreci baştan başlatılmaktadır. Eğitim başlamasıyla birlikte ekrana gelen grafiksel görüntü ile iterasyon sayısı ve yaklaşık ortama deđer hesaplanmaya başlamakta iterasyon sayısı arttıkça deđerde ki düşme gerçekleşmekte belirli iterasyon sayısından sonra modeli otomatik kayıt etmektedir. Eğitim başlaması sonrası şekil 4.5'de gösterildiđi gibi iterasyon ve ortalama hassasiyet deđer takip edilmekte ve en iyi sonuç veren model kayıt edilmektedir.



Şekil 4.5. Darknet model eğitimi ekranı.

4.5. ULTRALYTICS YOLOV8 MODEL ÖĞRENİMİ

Ultralytics YoloV8 eğitim modu, modern donanım özelliklerinden tam olarak yararlanarak nesne algılama modellerinin etkili ve verimli eğitimi için kullanılmaktadır.

4.5.1. Anaconda Eğitim Ortamı Oluşturma ve Paket Kurulumları

Anaconda kurulumu tamamlandıktan sonra model eğitimi için ortam oluşturulmaktadır. Yeni ortam için aşağıdaki komut kullanılmalıdır. Ortam oluşturulduktan sonra aşağıdaki komut ile etkinleştirilmesi gerekmektedir. Ortam etkinleştirildikten sonra yolu projemizde kullanmak için yolo dosyaları indirilip kullanılmakta ya da ultralytics üzerinden de kullanılmaktadır. Ultralytics, bu sınır açısından faydalanmak için bize yöntemler sunmakta ve kullanmamızı sağlamaktadır. Bu işlem için aşağıdaki komut ile kurulumu tamamlamaktadır. Bu komut ile beraber sistemimizde Yolo kullanılabilir hale gelmektedir.

4.5.2. Veri Seti Doğrulama

Etiketleme işlemleri tamamlandıktan sonra nesne algılama modeli için performanslı olduğundan emin olmak için önce içerde sonrasında dışarda test işlemleri yapılması gerekmektedir. Mantar veri kümesini 2 parçaya bölüp birinci kısmı train ve ikinci kısmı val olarak iki parçaya bölmek gerekmektedir. Doğrulama mantar setimizi bölerken yapıya göre dizin yapısını yapılandırmak gerekmektedir.


Eğitime başlamadan önce Yolo parçalanmış veri setlerinin hangi konum olduğu belirtmemiz gerekmektedir. Bu gereksinim için data_custom.yaml adında bir dosya oluşturup içeriğine train, val klasörlerinin konumlarını ve sınıf adeti ve isimlerini yazmamız gerekmektedir.

4.5.3. YoloV8 Model Eğitimi

Model eğitimi için kullanılacak platform jupyter notebook, anaconda vb. uygulama açıldıktan sonra eğitim için klasör konumuna gidilir ve model eğitimi başlatılmaktadır. YoloV8 için önemli noktalardan biri imgsiz değeri olan görüntü boyutunu belirtmektedir. YoloV8 dikgörtgen görüntüler üzerinde çalışır ve daha sağlam sonuçlar vermektedir. Görüntülerin büyümesi eğitim süresini de arttırmaktadır. Ancak potansiyel olarak doğruluk anlamında daha fazla sonuç vermektedir. Yolo mimarilerinde s – küçük, m – orta, l – large, x – ekstra büyüklük gibi çeşitli boyutları mevcuttur.

4.5.4. Eğitilen Mantar Modeli Testi

Model eğitimi tamamlandıktan sonra, Yolo tarafından otomatik olarak runs/train/weights yolunda best.pt adıyla en iyi ağırlıklar olarak model kaydedilecektir. Eğitilen mantar modeli yükleyip görüntüyü modelden geçirerek bir mantar algılama yapılmaktadır. Görüntü eğitilen mantar modelinden geçirilmektedir. Görüntünün eğitilen modelden geçildikten sonra runs/detect/predict yoluna otomatik olarak kayıt edilmektedir. Oluşan görüntü aşağıdaki şekilde gösterilmektedir.




Şekil 4.6. Modelden geçirilen mantar görüntüsü.

4.5.5. Eğitilen YoloV8 Modeli Mantar Algılama Uygulaması


Mantar model eğitimi ve testler tamamlandıktan sonra kamera ile tespit yazılımı için python dili kullanılmaktadır. Eğitilen model ONNX formatına dönüştürülmektedir. ONNX, açık sinir ağı değişiminin kısaltmasıdır. Derin öğrenme modelleri için özel olarak tasarlanmış ve ücretsiz olarak kullanılabilen bir format olmaktadır. Temel amacı, PyTorch ile birlikte kullanıldığında TensorFlow gibi farklı derin öğrenme çerçeveleri genelinde modellerin sorunsuz alışverişini ve paylaşımını kolaylaştırmaktır. Bu çerçevelerin her biri, farklı formatlarda eğitilmiş modeller oluşturarak onları çeşitli yazılım ortamlarında kullanım için taşınabilir hale getirmektedir. Eğitilmiş modellerin farklı yazılım platformlarında kolayca kullanılmasını olanak tanımaktadır. Model dönüşüm işlemi ile beraber model yazılım ile kullanılabilir hale gelmektedir.

4.6. MODEL SONUÇ GRAFİKLERİ




Şekil 4.7. Hassas geri çağırma eğrisi.

Mantar türlerinin hepsinin kesinlik ve geri çağırma değerleri tüm mantar türlerinin genel performansı ile birlikte Şekil 4.7’de gösterilmektedir. Şekil 4.7’de görüldüğü gibi kesinlik değeri 0.5 ile 0.999 değerleri arasında gerçekleşmektedir. Bu da mantar türlerinin %50 ile %99,9’unda mantar sınıflarının doğru şekilde tanımlandığı göstermektedir. Mantar türlerinin yaklaşık %83,3 ile %99,9’unda mantar türünün doğru şekilde tanımlandığı göstermektedir. Bu aşamada sonuçlar modelin mantar tanıma noktasında gayet iyi performans ancak borazan mantarının diğer mantarlara göre yapısının farklı olmasından kaynaklı veri setinde iyileştirme gerektiği görülmektedir.




Şekil 4.8. Hassas güven eğrisi.

Mantar türlerinin sınıflandırılmasında şekil 4.7’de 0.999 ile ayı mantarı en yüksek hassasiyet değerine sahip olmaktadır. Sırayla 0.995 ile istiridye mantarı, 0.976 ile gelincik mantarı, 0.956 ile tirit, 0.934 ile kanlıca mantarı, 0.927 ile kuzugobegi mantarı, 0.889 ile trüf mantarı, 0.860 ile kültür mantarı ve son olarak 0.833 ile borazan mantarı gelmektedir. Şekil 4.8’deki grafikte görüldüğü gibi 0.977’lik yüksek güven eşğinde mükemmel hassasiyet gösterilmektedir. Bu durum aşırı uyumlu olduğu göstermektedir.



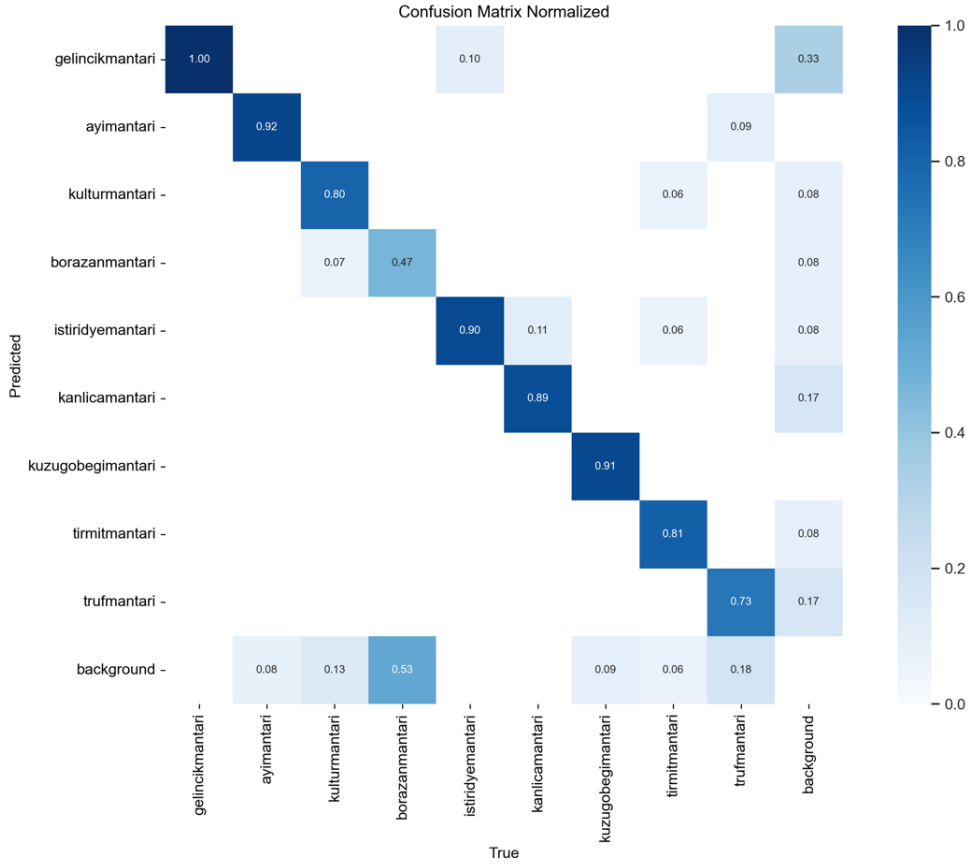
Şekil 4.9. Geri çağırma güven eğrisi.

Geri çağırma güven grafiği, modelin tahminlerinin geri çağırma ile güven arasındaki ilişkiyi göstermektedir. Şekil 4.9'da görüldüğü gibi modelin 0,0 güven eşliğinde 0,90 geri çağırma oranıyla tüm sınıfları yüksek güven seviyelerinde tespit etmede iyi performans gösterdiğini belirtmektedir. Modelin tüm mantar türlerinin tanımlanmasında büyük bir kısmını yüksek güvenle doğru şekilde tanımladığını göstermektedir. Eğride görüldüğü gibi borazan mantarına kıyasla diğer mantarların algılanması biraz daha iyi performans gösterdiğini göstermektedir.



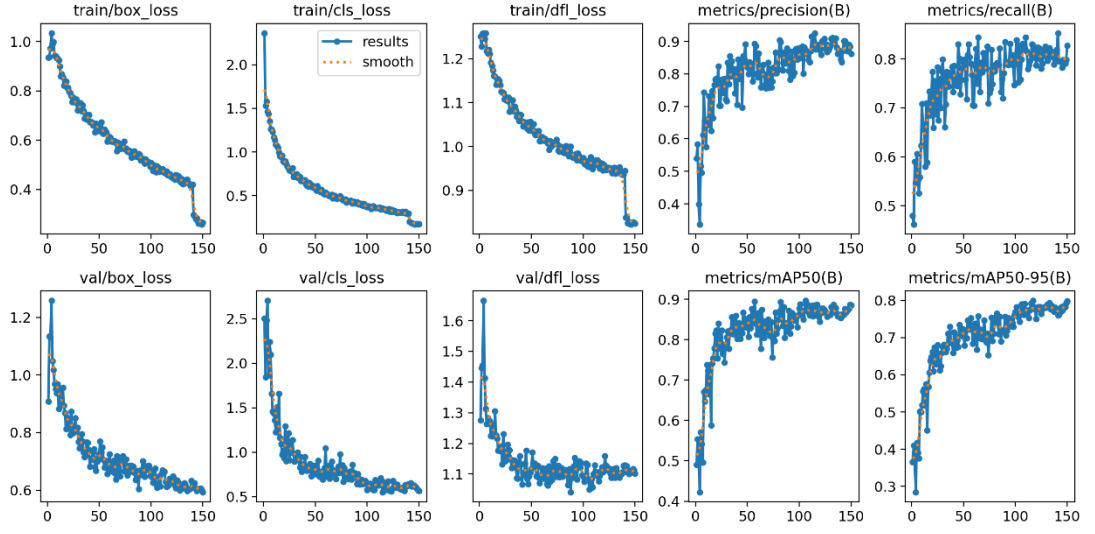
Şekil 4.10. F1 puan eğrisi.

F1 puan eğrisi grafiği şekil 4.10'da görüldüğü gibi mantar modelin ortalama olarak tüm sınıfları için 0.699 güven eşliğinde %85 hassasiyete sahip olduğunu göstermektedir.



Şekil 4.11. Karışıklık matrisi.

Şekil 4.11'deki karışıklık metrisinde on satır ve on sütun bulunmaktadır. İlk satır dokuz mantar türünden herhangi birine ait olmayan tüm very noktalarını içeren sınıfa karşılık gelmektedir. Diğer satır ve sütunlar karşılık gelen mantar türüne karşılık gelmektedir. Matris görüldüğü gibi borazan mantarı ortalamanın altında performans sergileyerek %47'lik bir doğruluk oranına ulaşmaktadır.

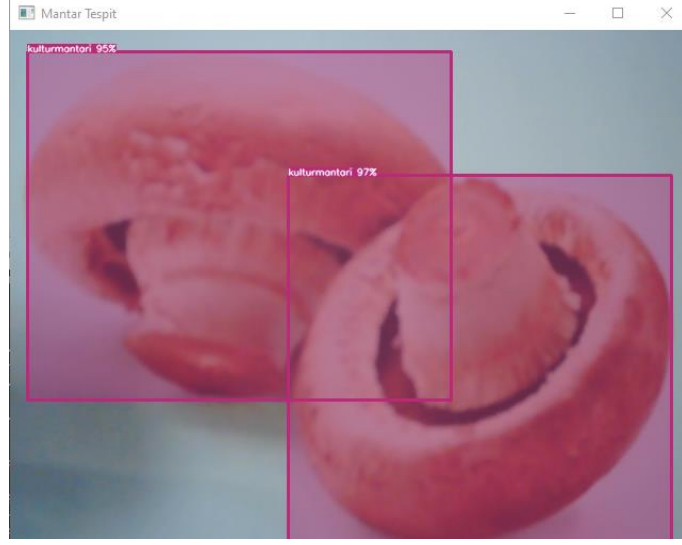


Şekil 4.12. Her sınıfın eğitim ve doğrulama kaybı.

Şekil 4.12’de hem eğitim hem de doğrulama veri setleri için YoloV8 eğitim sürecinin kayıplarını çeşitli aşamalarına ait kayıp değerlerini göstermektedir. X eksenini, 150 yenileme sayısını temsil etmektedir. Y eksenini, eğitim ve doğrulama kümeleri için kayıp matrislerinin değerlerini göstermektedir. Şekil 4.12’deki grafiklerde ayrıca mAP50 gibi YoloV8 modeli için bazı performans ölçümlerini de göstermektedir. Şekil 4.12’deki grafiklerde görüldüğü gibi box_loss, cls_loss ve dfl_loss grafikleri 150 iterasyonluk bir çalışmada sıfıra hızlı bir şekilde ulaştıkları göstermektedir. Bu durumda ölçeklendirmeyi doğru tahmin etme ve nesnelerin kategorisinin ne olduğu iyi tahmin ettiğini göstermektedir.


4.7. TEST SONUÇLARI

Mantar tanıma ve kalite sınıflandırması sisteminin sonuçlarını test etmek için tanıma olarak kültür mantarı görüntüsü ve kalite sınıflandırma için trüf mantarı görüntüsü kullanılarak doğruluk seviyelerine bakılmış ve aşağıdaki görüntülerde şekil 4.13’de mantar tanıma noktasında %97, şekil 4.14 ve şekil 4.15’de sınıflandırma noktasında %99’luk değerlere ulaşılmaktadır.

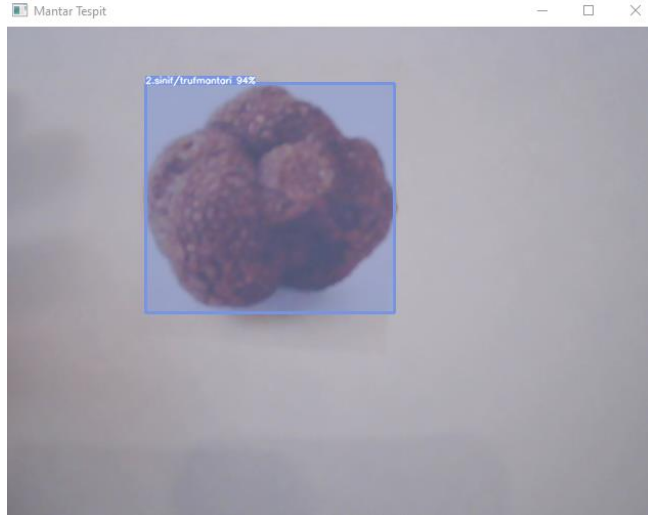


Şekil 4.13. Kamera ile mantar tespiti yapılması.

Yazılım ile beraber kullanılan eğitilen model ile mantar tespit sistemi yanı sıra kalite sınıflandırma işlemi için mantar üzerindeki oluşan görüntüler, değişen renk yapısı gibi özellikler karşılaştırılarak sınıf belirlemesi yapılmaktadır. Kalite sınıflandırması özellikle mantar tüketimi için fabrikalar için önemli bir durum olmaktadır. Kalite sınıfı yüksek olanların tüketim biraz daha düşük olanların ilaç sektörü gibi alanlarda kullanılmasını amaçlamaktadır. Mantar kalite sınıflandırması örnek olarak aşağıdaki şekillerde gösterilmiştir.



Şekil 4.14. Sınıf mantar kalite sınıflandırması.



Şekil 4.15. 2.Sınıf mantar kalite sınıflandırma.

4.8. YÖNTEMLERİN KARŞILAŞTIRILMASI

Bu çalışmada, gerçekleştirilen Net, Darknet kütüphanesi, ultralytics Yolov8 gerçek zamanlı nesne algılama ve görüntü segmentasyonu modelleri kullanılarak derin öğrenme modelleri eğitilmektedir. Eğitimi tamamlanan modeller hazırlanan yazılımlar ile çalıştırılarak değerlendirilmektedir. Bu çalışmada eğitilen mantar YoloV8 modeli tanıma ve sınıflandırma noktasında yüksek performanslı sonuçlar vermektedir. Kullanılan platform ve modeller değerlendirilmesinin yapıldığı bu çalışma sonucunda yöntem karşılaştırmaları anlatılmaktadır.

Mantar görüntüleri için .Net model eğitimi lokal ekran kartı için eğitim süresi olarak uzun sürdüğü gözlenmektedir. Belirli bir görüntü yükünün kaldırması için Azure platformuna yönlendirmekte ve ücretli hale gelmektedir. Görüntü verisinin fazlalığı ve eğitim tekrarlamasına göre maliyeti fazla arttığı görülmektedir. Kullanıcı model geliştirme platformu olarak basit ve kullanışlı olduğu küçük eğitim modelleri için kullanılabilir olduğu belirlenmektedir. WPF arayüzünde yazılan yazılım ile değerlendirilmiş ve mantar tanıma işlemleri güzel sonuç vermekte ancak maliyet bakımından sınırlı sayı da görüntü eğitimi olduğu için değerlendirme noktasındaki başarı düşük olarak belirlenmektedir.

Darknet kütüphanesi Windows işletim sisteminde çalışabilmesi için cMake yazılımı ile derleme gerekliliği bilgisayar bazlı sorunlara yer vermektedir. Derleme işleminin zorluğu Darknet'in C ve CUDA ile yazılmış açık kaynaklı bir sinir ağı olmasından kaynaklandığı belirlenmektedir. CUDA versiyonu ve C dili alt kütüphane kurulumları tam olmakta ve versiyonlar olarak alınacak hatalarda işletim sistemi güncelleme paketlerine göre düzenlemeler yapılarak ilerlenmektedir. Mantar model eğitimi olarak iterasyon sayısının yüksek tutulması mantar tanıma ortalama değerine ulaşmak için gerekmektedir. İterasyon sayısının yüksek tutularak ortalama hassasiyet 0.2 değerine yaklaşmak görüntü veri boyutuna göre değişiklik gösterse de bu çalışmadaki veri büyüklüğü ile 1 - 2 gün aralıklarında sürmektedir. Bu durum yeni bir görüntü eklenmesi ya da herhangi bir özellik değişiminde sürecin tekrarlanmasını yol açmaktadır. Darknet, nesne algılama ve görüntü sınıflandırma'yı çok yüksek doğrulukla gerçekleştirmektedir.

Ultralytics YoloV8 modeli paket kurulumları ve kullanımları bakımından kolaylıklar sağlamaktadır. Çalışmamızda 807 mantar veri kümesinin 711 adeti eğitim verisi, 96 adeti test veri seti olarak 150 iterasyonluk bir eğitim modeli ortalama 120 dakika sürmekte ve mantar tanıma oranı %99,98 olduğu gözlenmektedir. Model doğrulama setinde ortalama hassasiyet değeri 0.230'luk bir doğrulukla tespit edilmektedir. Ultralytics YoloV8 ile ister tek GPU ister birden fazla GPU'da ölçeklendirme yapıyor olmakta ve donanımızdan en iyi şekilde yararlanmak en önemli avantajların biri olduğu belirlenmektedir. COCO, VOC ve ImageNet gibi veri kümelerini yanı sıra LabelImg gibi etiketleme yazılımları ile mantar veri görüntüleri etiketlenerek eğitimi yapılabilmektedir. Mantar model performanslarında özelleştirilebilir bir hiperparametre yapısı sunmaktadır.

Çizelge 4.1. Kullanılan yöntemlerin karşılaştırılması.

Yöntem	Süre (Saat)	Ortalama Hassasiyet	İterasyon
Darknet Kütüphanesi	67.53	0.220	1036
Ultralytics YoloV8	2	0.230	150

4.9. ÇALIŞMADAKİ YOLOV8 MODELİ İLE SSD MODELLERİ VE YOLOV7 KARŞILAŞTIRMASI

SSD MobileNet, SSD Inception ve Darknet Yolov7 ile 807 mantar görüntüsü ile yapılan çalışmaların model sonuçları ile bu çalışmada yapılan Yolov8 model sonuçları aşağıdaki tabloda karşılaştırılmaktadır. Değerler karşılaştırıldığında Yolo dışındaki modellerin ortalama hassasiyet değeri performansının düşük olduğu görülmektedir. Yolo modelinin versiyonu yükseldikçe ulaşılan ortalama hassasiyet değerinin yükseldiği görülmektedir. Çalışmada kullanılan yolo modeli, son versiyon olan 8 versiyonu olmaktadır.

Çizelge 4.2. Kullanılan Yolov8 modeli ile diğer model sonuçlarının karşılaştırılması.

Model	Ortalama Hassasiyet	Kesinlik	Duyarlılık
SSD MobileNet	%97,75	0.95	0.88
SSD Inception	%97,60	0.95	0.87
Darknet Yolov7	%98,87	0,98	0,89
Çalışmadaki Yolov8	%99,98	0.97	0.90

Tabloda görüldüğü gibi ortalama hassasiyet olarak çalışmadaki Yolov8 modeli en yüksek performans değerine ulaşmaktadır. Kesinlik ve duyarlılık değerleri veri setindeki türlerin 1 değerine yakın olması modelin tahminlerinin başarı oranını belirtmektedir. SSD modellerinin kesinlik ve duyarlılık değerleri yüksek olması rağmen ortalama hassasiyet değeri Yolov8 çalışmasından düşük olduğu görülmektedir. Bu çalışmadaki Yolov8 modelinin 0.97 ile 0.90 değerlerinde olması genel anlamda güzel bir performans ancak çalışmadaki borazan mantarı diğer mantar türlerinden farklı yapıya sahip olması ile mevcut değerlerin birazcık düşmesinde rol oynamaktadır. Ortalama hassasiyet değerlerine bakıldığında Yolov8 modeli performans olarak gözle görülür daha performanslı değere sahip olmaktadır. Yolo modellerinin karşılaştırılmasına bakıldığında çalışmadaki YoloV8 çalışması YoloV7 modelinden daha iyi bir ortalama hassasiyet değerine ulaşmaktadır.

BÖLÜM 5

TARTIŞMA VE SONUÇLAR

Mantar modeli, yamll uzantılı dosyada belirtilen özel görüntü verileri ile sınıfların yer aldığı veri kümesi yollarının gösterildiği yollar üzerinde eğitilmektedir. Mantar tür sınıfları olarak 9 tür sınıfa ayrılmaktadır. Eğitilen mantar modeli 150 iterasyonluk bir eğitim döngüsü ile eğitilmektedir. Model eğitimi ortalama hassasiyet değerinin en yüksek performansına yaklaşmak için son teknoloji nesne algılama modeli olan YoloV8 mimarisi kullanılmaktadır. Bu çalışmadaki ml.net, darknet ve yolo'nun önceki sürümleriyle karşılaştırıldığında YoloV8 modelin doğruluğunu ve verimliliğini yüksek tutmaya yarayan, geliştirilebilir model sunmaktadır.

YoloV8 sınırlamalarına bakıldığında değerlendirilmesi gereken sorunlar vardır. YoloV8 modelinde küçük nesnelerin doğru şekilde algılama noktasında zorlanmaktadır. Model ince ayrıntıları temsil etme noktasında zorluklar yaşamakta bu da tanımlamaya veya çok küçük mantar türlerinde tanıma noktasında düşük güven puanına yol açabilmektedir. Yazılım uygulama tarafına da bağlı olarak YoloV8'in yüksek performans göstermesi için ince ayarlar ve uyarlamalar yapılması diğer modellerden en önemli avantajlarından biri olmaktadır.

YoloV8 nesne algılama alanında önemli ilerlemeyi temsil etmektedir. YoloV8 modeli önceki yolo modelleri ile karşılaştırıldığında özellikle küçük nesneler ve zorlu koşullar için önceli sürümlerden daha iyi performans vermektedir. Büyük görüntülerde daha hızlı çalışmaktadır. Ölçek değişikliklerini ve diğer zorlukları daha etkili bir şekilde ele almaktadır. Ayrılmış sınıflandırma işlevi ile eğitilmesi kolay ve etkili bir eğitim süreci sunmaktadır. Bu avantajlar bir araya geldiğinde verimlilik ve doğruluk olarak artan bir mimariye sahip olmaktadır.

5.1. ZORLUKLAR

Bu çalışmadaki zorluklar mantar veri setlerinin bölgesel görüntü değişikliğine uğramaktadır. Mantar görüntüleri dünya genelinde veriler ile beraber Kastamonu’da yetişen mantar görüntüleri ile zenginleştirilmiştir. Buradaki bölgesel faktörlere ve toprağa göre değişkenlik göstermesi farklı bölgeler de geliştirilen uygulamanın kullanılması noktasında mantar sınıflarının belirlenmesinde performans düşüklüğüne neden olabilmektedir.

5.2. SINIRLAMALAR

Bu çalışmanın ana sınırlarından birisi geliştirilmiş çalışmalarda mantar sınıflandırmaları tanıma noktasında %90 altında düşük tanıma oranlarına sahip olmasıydı. Geliştirilen mantar tanıma ve sınıflandırma modeli bölgesel koşulların değişmesiyle mantarların normalden farklılık göstererek oluşması durumlarında performans olarak farklılıklar olmaktadır.

5.3. SONUÇ

Sonuç olarak, bu çalışmada eğitilen YoloV8 mantar modeli, yenilebilir mantar türlerinin tanımlanması ve kalite sınıflandırmasında iyi performans sonuçları vermektedir. Model mantar türlerinde %99,98’lik bir tanıma noktasına ulaştığı görülmektedir. Çalışmada ele alınması gereken bazı sınırlamalar ve zorluklar olmaktadır. Borazan mantarının mevcut mantar çeşitlerine göre şapkasız yapısı ve farklı bitki gibi görünmesi borazan mantarı için performans düşüklüğüne neden olmaktadır. Bu sorunu çözmek için daha fazla borazan mantar görüntüsünün toplanması ve kullanılması önerilmektedir. Diğer bir durum ise bölgesel farklılık ve mevsimine göre oluşabilecek mantarlardaki görüntüsel değişiklikler mevcut model performansının düşmesine neden olabilmektedir. Genel olarak bu çalışmanın sonuçları mantar türlerinin tanımlanması ve kalite sınıflandırılmasında derin öğrenme modellerinin kullanılma potansiyeli ile birlikte mevcutta yapılan çalışmalarda geliştirilen evrişimli sinir ağlarına yerine Yolo’nun son versiyonu olan v8 ile

ilerlenmesi çalışmaların daha yüksek performans ile sonuçlanmasını göstermektedir. Bu çalışma ile geliştirilen model ve yazılım yenilebilir olarak yetişen ve bilinmeyen mantarların ekonomiye kazandırılması, fabrika ortamına gelen mantarların ayrışım kısmında banttın geçiş sırasında kalite sınıflandırılmalarının yapılması, bu kalite sınıflandırmasına göre ilaç üretiminde ve tüketiminde kullanılanların belirlenmesi, ülkemizde yetişen bilinirliği az olan değerli mantarların değerlendirilmesi sağlamaktır.

KAYNAKLAR

1. Zeid, DC., Savoie, JM. And pardo-Gime, A., “Soybean the main nitrogen source in cultivation substrates of Edible and medicinal mushrooms”, *Soybean and nutrition*, (2011).
- 2 Peng, P. and Xianofang, P.,”Classification using deep convolution neural networks”, *Sensors*, 18(157) (2018).
- 3 Ward, J., Stromberg, E., Nowell, D., Nutter, F., “Gray leaf spot: a disease of global importance in maize production”, *Plan Disease*, 884-895 (1999).
- 4 Yenealem T., Muleta D. & Woyessa D., Mushroom Consumption Habits of Wacha Kebele residents, *Southwestern Ethiopia*, 4(1): 6-16 (2013).
- 5 Gupta RS., “Mushroom cultivation”, *Indian Horticulture*, 31(1) (1986).
- 6 Alam, N., Khan, A. Hossain, M. S., Amin, S. M. R., and Khan, L. A., “Nutritional Analysis of Dietary Mushroom- Pleurotus florida Eger and Pleurotus sajur-caju (Fr) Singer”, *Bangladesh Journal of Mushroom*, 1(2), 1-7 (2008).
- 7 Kakon A. J., Choudhury M. D. B. K and Saha, S., “Mushroom is an Ideal Food Supplement”, *Journal of Dhaka National Medical College & Hospital*, 18 (01), 58-62 (2012).
- 8 Behnke, S., Karayiannis, N., “CNet competitive neuraltrees for pattern classification”, *IEEE Transaction Son Neural Network*, 9(6) (1996).
- 9 Tongcham, P., Supa, P., Pornwongthong, P., Prasitmeeboon P., “Mushroom spawn quality classification with machine learning”, *Computers and Electronics in Agriculture*, 1680 – 1699 (2020).
- 10 Rahnemoonfar, M. and Sheppard C., “Deep count: fruit counting based on deep simulated learning”, *Sensors*, 17-905 (2017).
- 11 Chen, SW., Shivakumar, SS., Dcunha, S., Das, J., Okon, E., Qu, C., Taylor, CJ. And Kumar, V., “Couting apples and oranges with deep learning: a datadriven approach.”, *IEEE Robotics and Automation Letters*, 2: 781-788 (2017).
- 12 Bargeti, S. and Underwood, J., “Deep fruit detection in orchards”, *IEEE International Conference on Robotics and Automation*, 3626-3633 (2017).

- 13 Santoni, MM., Sensuse, DI., Artmurthy, AM. And Fanany, MI., “Cattle race classification using gray level co-occurrence matrix convolutional neural network.”, *Procedia Computer Science*, 493-502 (2015).
- 14 Ratchapra, P. and Chantrapornchai, C., “Expert system for rice disease diagnosis”, *E-Journal SU*, 6 (1) (2013).
- 15 Kononenko, “Machine learning for medical diagnosis: history, state of the art and prespective”, *Artificial Intelligence is medicine*, 23 (1): 89-109 (2001).
- 16 Hamonangan, R., Saputro, M., Atmaja, B., “Accuracy of classification poisonous or edible of mushroom using naïve bayes and K-nearest neighbors.”, *J. Soft. Comp. Explor.*, 2 (1): 53-60 (2022).
- 17 Sajedi, H., Mohammadipanah, F. And Pashaei, A., "Automated Identification of Myxobacterial Genera Using Convolutional Neural Network", *Scientific Reports* , 9 (1), 1-15 (2019).
- 18 Zahan, N., Hasan, Z., Malek, A. And Reya, S., "A Deep Learning-Based Approach for Edible, Inedible and Poisonous Mushroom Classification", *International Conference on Information and Communication Technology for Sustainable Development* , Dhaka , Bangladeş, 2021.
- 19 Preechasuk, J., Chaowalit, O., Pensiri , F. And Visutsak, P., "Image Analysis of Mushroom Types Classification by Convolution Neural Networks", *2nd Artificial Intelligence and Cloud Computing Conference* , Kobe, Japonya, 2019.
- 20 Liu, Q., Fang, M., Li, Y., and Gao, M., “Deep Learning Based Research On Quality Classification Of Shiitake Mushrooms”, *Science Direct*, 1-9 (2022).
- 21 Guan, H., Yu, M., Ma, X., Li, L., Yang, C. and Yang, J., “A Recognition Method Of Mushroom Mycelium Varieties Based On Near-Infrared Spectroscopy And Deep Learning Model”, *Science Direct*, 2022.
- 22 Guragin, P., Shrestha, B. and Bajracharya I., “A Low-cost Centralized IoT Ecosystem For Enhancing Oyster Mushroom Cultivation”, *Science Direct*, 2024.
- 23 Wang, Y., Yang, L., Chen, H. and Hussain, A., “Mushroom-YOLO: A Deep Learning Algorithm For Mushroom Growth Recognition Based On Improved Yolov5 in Agriculture 4.0”, *Research Gate*, 2022.
- 24 Cong, P., Feng, H., Kunfeng, L. and Zhou, J., “MYolo: A Lightweight Fresh Shiitake Mushroom Detection Model Based on Yolov3”, *Research Gate*, 2023.

- 25 İnternet : Stanford, “Evriřimli Sinir Ađları El Kitabı”, <https://stanford.edu/~shervine/1/tr/teaching/cs-230/cheatsheet-convolutional-neural-networks>
- 26 İnternet : Etiya, “Makine Öğrenmesi ve Derin Öğrenme Nedir ?”, <https://www.etiya.com/tr/blog/makine-ogrenmesimachine-learning-ve-derin-ogrenme-nedir>
- 27 İnternet : Medium, “Derin Öğrenme Algoritmaları”, <https://medium.com/yapay-zeka-makine-%C3%B6%C4%9Frenmesi-derin-%C3%B6%C4%9Frenme/derin-%C3%B6%C4%9Frenme-algoritmalar%C4%B1-8dea99d9b41f>
- 28 İnternet : Teknoloji, “Derin Öğrenme Nedir ? Yapay Sinir Ađları Ne İře Yarar ?”, <https://teknoloji.org/derin-ogrenme-nedir-yapay-sinir-aglari-ne-ise-yarar/>
- 29 İnternet : Isikhanelif, “Multi Layer Perceptron (MLP) Nedir ?”, <https://isikhanelif.medium.com/multi-layer-perceptron-mlp-nedir-4758285a7f15>

ÖZGEÇMİŞ

2017 yılında Kastamonu Üniversitesi Bilgisayar Programcılığı bölümünden 3.93/4 okul birinciliği ile tamamlamış. Mezuniyet sonrası Beyoğlu Belediyesi Bilgi İşlem Müdürlüğünde 2017 ağustos ayında çalışmaya başlamış ve halen görevini memur olarak sürdürmektedir. 2020 yılında Yönetim Bilişim Sistemleri bölümünü tamamladıktan sonra Karabük Üniversitesi Bilgisayar Mühendisliği Yüksek Lisans Tezsiz bölümünü 2023 yılında tamamlamıştır.