

T.C.
PAMUKKALE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
MEKATRONİK MÜHENDİSLİĞİ ANABİLİM DALI

MISIR TARLASINDA GÖRÜNTÜ İŞLEME YÖNTEMİ İLE
YABANCI OTLARIN TESPİTİ

YÜKSEK LİSANS TEZİ

MEHMET BAĞCI

DENİZLİ, AĞUSTOS - 2024

T.C.
PAMUKKALE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
MEKATRONİK MÜHENDİSLİĞİ ANABİLİM DALI



MISIR TARLASINDA GÖRÜNTÜ İŞLEME YÖNTEMİ İLE
YABANCI OTLARIN TESPİTİ

YÜKSEK LİSANS TEZİ

MEHMET BAĞCI

DENİZLİ, AĞUSTOS - 2024

Bu tezin tasarımı, hazırlanması, yürütülmesi, arařtırmalarının yapılması ve bulgularının analizlerinde bilimsel etięe ve akademik kurallara özenle riayet edildiđini; bu alıřmanın dođrudan birincil ürünü olmayan bulguların, verilerin ve materyallerin bilimsel etięe uygun olarak kaynak gösterildiđini ve alıntı yapılan alıřmalara atfedildiđine beyan ederim.

MEHMET BAĐCI

ÖZET

**MISIR TARLASINDA GÖRÜNTÜ İŞLEME YÖNTEMİ İLE YABANCI
OTLARIN TESPİTİ
YÜKSEK LİSANS TEZİ
MEHMET BAĞCI
PAMUKKALE ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ
MEKATRONİK MÜHENDİSLİĞİ ANABİLİM DALI
(TEZ DANIŞMANI: DR. ÖĞR. ÜYESİ SADIK ÖZDEMİR)**

DENİZLİ, AĞUSTOS - 2024

Mısır, tarımsal açıdan büyük öneme sahip olan bir bitkilerin başında gelmektedir. Dünyanın en önemli tahıllarından biri mısırdır. Ancak mısır bitkisi, yabancı otlarla mücadele açısından biraz hassas bir bitkidir. Bu yabancı otlar, mısır bitkisinin büyümesini ve verimini olumsuz etkilemektedir. Bu nedenle mısır yetiştiriciliğinde yabancı ot tespiti ve kontrolü büyük önem taşır. Bu yabancı otların mısırın v5 gelişim evresine kadar olan yabancı otları tanımlamak için görüntü işlemeyi kullanmak, tarım üreticilerine büyük kolaylık sağlayıp otomatik algılama ve kontrol imkânı sağlanması hedeflenmiştir. Bu teknolojiler, tarımsal verimi artırmak ve yabancı ot kontrolünü etkinleştirmek için önemli araçlardır. Bu çalışmada, Roboflow ile makine öğrenmesinden yararlanarak kendi görüntü veri setlerimizi oluşturup, eğitimde kullanılacak görüntülerdeki yabancı otların mısırdan ayrıştırılıp, tespit edilmesi işlemi yapılarak kendi veri setimiz oluşturulmuştur. Roboflow üzerinden online oluşturduğumuz veri setini Google Colab' a eklenmesi sağlanmıştır. Yüksek doğruluk oranına sahip nesne tanımlama algoritmaların öncülerinden Yolo v9 derin öğrenme kütüphanesini de dahil edip, geliştirdiğimiz algoritma ile oluşturduğumuz veri seti üzerindeki mısır dışındaki yabancı otların tespitinin sağlanması hedeflenmiştir. Ayrıca mısır tarlası içerisindeki yabancı otların yoğunlukta olduğu kısımlar bölgeler halinde belirlenmiştir. Böylece o bölgelere lokal ilaçlama yapılarak hem ilaç maliyetinden tasarruf hem de sağlıklı mısırların daha az kimyasala maruz kalacağından dolayı aynı zamanda daha çevreci bir sistem yapılması sağlanmıştır.

**ANAHTAR KELİMELEER: GÖRÜNTÜ İŞLEME, MISIR TARLASI,
YABANI OT, YABANI OT TESPİTİ, TOHUM, MISIR**

ABSTRACT

DETECTION OF WEEDS BY IMAGE PROCESSING METHOD IN MAIZE FIELD

MSC THESIS

MEHMET BAĞCI

PAMUKKALE UNIVERSITY INSTITUTE OF SCIENCE

DEPARTMENT OF MECHATRONICS ENGINEERING

MECHANICAL ENGINEERING

(SUPERVISOR: ASSİST. PROF. DR. SADIK OZDEMİR)

DENİZLİ, AUGUST 2024

Maize is one of the plants of great agricultural importance. One of the most important cereals in the world is maize. However, maize plant is a sensitive plant in terms of weed control. These weeds negatively affect the growth and yield of the maize plant. Therefore, weed detection and control is of great importance in maize cultivation. It is aimed to use image processing to identify these weeds up to the v5 development stage of maize, providing great convenience to agricultural producers and providing automatic detection and control. These technologies are important tools to increase agricultural yield and enable weed control. In this study, we created our own image datasets using machine learning with Roboflow and created our own dataset by separating and detecting weeds from corn in the images to be used in training. The dataset we created online via Roboflow was added to Google Colab. By including the Yolo v9 deep learning library, which is one of the pioneers of high accuracy object identification algorithms, it is aimed to detect weeds other than corn on the data set we have created with the algorithm we have developed. In addition, the parts where weeds are dense in the corn field were determined as regions. Thus, by spraying those areas locally, it is ensured to save both the cost of medication and to make a more environmentally friendly system at the same time since healthy corns will be exposed to less chemicals.

KEYWORDS: IMAGE PROCESSING, MAIZE FIELD, WEED DETECTION, SEED, CORN

İÇİNDEKİLER

Sayfa

ÖZET.....	i
ABSTRACT	ii
İÇİNDEKİLER	iii
ŞEKİL LİSTESİ.....	v
TABLO LİSTESİ	vi
SEMBOL LİSTESİ	vii
ÖNSÖZ.....	viii
1. GİRİŞ.....	1
1.1 Endüstriyel Tarım ve Özellikleri	3
1.1.1 Endüstriyel Tarımda Mısırın Önemi	4
1.1.1.1 Mısır Bitkisinde Yabancı Ot Sorunu	6
1.1.1.2 Görüntü İşleme Tekniklerinin Tarımsal Uygulamadaki Rolü ..	7
1.1.1.2.1 Çalışmanın Amacı ve Kapsamı.....	9
2. GÖRÜNTÜ İŞLEME KAVRAMI.....	10
2.1 Görüntü ve Renk Kavramı.....	10
2.1.1 RGB Renk Uzayı	10
2.1.2 HSV Renk Uzayı	11
2.1.3 CMYK Renk Uzayı	11
2.1.4 Diğer Renk Uzayları	12
2.2 Görüntü Çeşitleri	12
2.2.1 Analog Görüntü	12
2.2.2 Dijital Görüntü	13
2.2.3 Dijital Görüntü İşleme Yöntemleri	13
2.2.3.1 Filtreleme İşlemi	13
2.2.3.2 Lineer Filtreleme	13
2.2.3.3 Lineer Olmayan Filtreleme	14
2.2.3.4 Filtreleme İşlemi Nasıl Yapılır?.....	14
2.3 Histogram İşleme.....	15
2.4 Morfolojik İşlemler	17
2.5 Kenar Tespiti ve Segmentasyon	17
3. YAPAY ZEKA KAVRAMI.....	19
3.1 Yapay Sinir Ağları.....	19
3.1.1 Yapay Sinir Ağlarının Temel Yapısı	19
3.1.2 Yapay Sinir Ağlarının Temel Bileşenleri	20
3.2 Yapay Zekanın Uygulama Alanları ve Sınıflandırılması	21
3.2.1 Makine Öğrenmesi (Machine Learning).....	22
3.2.2 Derin Öğrenme (Deep Learning)	23
3.2.3 Doğal Dil İşleme (Naturel Language Processing)	23
3.2.4 Bilgisayarlı Görme (Computer Vision)	24
3.2.5 Robotik ve Uzman Sistemler	25
3.2.6 Pekiştirmeli Öğrenme (Reinforcement Learning)	25
3.3 Görüntü İşlemede Derin Öğrenme Tabanlı Algoritmalar	26

3.3.1	Evriřimli Sinir Ađları (Convolutional Neural Network)	26
3.3.2	Nesne Tespiti (Object Detection)	27
3.3.3	Görüntü Segmentasyonu (Image Segmentation)	27
3.4	Tek Ařamalı Nesne Tespit Metotları.....	28
3.4.1	YOLO Metodu (You Look Only Once)	28
3.4.2	SSD Metodu (Single Shot Multibox).....	30
4.	MISIR VE YABANCI OTLARIN TESPİTİ	31
4.1	Elektriksel ve Mekanik Tasarım ve Özellikleri.....	31
4.2	Sistemin Modellenmesi ve Çalışma Prensibi	32
4.2.1	Akış Diyagramı ve Sistemin Çalışma Prensibi.....	32
4.2.2	Görüntülerin Toplanıp Veri Setinin Oluřturulması İşlemi	32
4.2.3	Google Colab ile Python Dilinde Programlanması.....	35
5.	BULGULAR VE TARTIřMALAR.....	37
6.	SONUÇ VE ÖNERİLER	41
7.	KAYNAKLAR.....	42
8.	ÖZGEÇMİř	44

ŞEKİL LİSTESİ

Sayfa

Şekil 1.1: Mısır bitkisinin kullanım alanları	6
Şekil 1.2: Tarım sektöründe görüntü işlemenin rolü	8
Şekil 1.3: Pivot sulama sistemi	9
Şekil 2.1: RGB renk havuzu	10
Şekil 2.2: Mısır bitki görüntüsünün gri tonlama yapılmış hali	16
Şekil 2.3: İncelenen mısır bitkisinin histogram grafiği	17
Şekil 3.1: YSA temel modeli	20
Şekil 3.2: YSA uygulama modeli (Funcs 2024)	21
Şekil 3.3: CNN temel çalışma prensibi (Bhatt ve diğ.2021)	26
Şekil 3.4: Süper piksel ön segmentasyonu ile hazırlanmış mısır görüntüsü (Wang ve diğ. 2020).....	28
Şekil 3.5: Yolo v9 performans karşı grafiği (Wang ve diğ. 2024)	29
Şekil 4.1: İp kameranın pivot üzerine montajı.....	31
Şekil 4.2: Uygulama akış diyagramı.....	32
Şekil 4.3: Nesne tespiti işleminden önce mısırların tespiti ve işaretlenmesi (Zhao ve diğ.2023).....	33
Şekil 4.4: Roboflow ile mısır ve yabancı otların seçilip sınıflandırılması	34
Şekil 4.5: Google Colab'a Roboflow'daki veri setimizin ve Yolo v9'un yüklenmesi	35
Şekil 5.1: Eğitim modelinin son iterasyonundaki veriler	37
Şekil 5.2: Modelimizin eğitim süreçlerindeki grafikleri.....	37
Şekil 5.3: Modelimizin karışıklık matrisi	39
Şekil 5.4: Test görüntüsündeki tespit edilen mısır ve yabancı otlar	40

TABLO LİSTESİ

	<u>Sayfa</u>
Tablo 3.1: YOLO ile SSD metodunun karşılaştırılması	30

SEMBOL LİSTESİ

GDO	:	Genetiği değiştirilmiş organizmalar
RGB	:	Kırmızı-Mavi-Yeşil renk uzayı
HSV	:	Ton-Doygunluk-Parlaklık renk uzayı
CMYK	:	Turkuaz-Macenta-Sarı-Siyah renk uzayı
YCbCr	:	Parlaklık-Mavi-Kırmızı renk uzayı
CIELAB	:	Algısal doğruluk renk uzayı
AHE	:	Adaptif histogram
AI	:	Yapay zeka
YSA	:	Yapay sinir ağları
ReLU	:	Yapay sinir ağlarında aktivasyon fonksiyonu
ML	:	Makine öğrenmesi
NLP	:	Doğal dil işleme
YZ	:	Yapay zeka
GPT	:	Doğal dil işleme kullanan bir dil modeli
DL	:	Derin öğrenme
GPU	:	Grafik işlem birimi
RL	:	Pekiştirmeli öğrenme
CNN	:	Evrişimli sinir ağı
R-CNN	:	Bölge tabanlı evrişimsel sinir ağı
YOLO	:	Görüntü işlemede kullanılan derin öğrenme modeli
SSD	:	Tek adımla çalışan, derin öğrenme modeli
PGI	:	Görüntü grafik ara birimi
GELAN	:	Çok yönlü grafik mimarisi
COCO	:	Görüntü veri setleri
SD	:	Harici depolama birimi
API	:	Farklı yazılım uygulamaları arasında iletişimi sağlayan arayüz
TPU	:	Görüntü grafik ara birimi
Cls_loss	:	Sınıflandırma hatası
Val	:	Yapay zekada kullanılan doğrulama
Df_loss	:	Mesafe fonksiyon kaybı
MAP	:	Modelin performansını değerlendirme birimi
IoU	:	Nesnenin konumu gösteren kutu / gerçek(doğru) kutu arasındaki örtüşme oranı

ÖNSÖZ

Bu tez, tarımsal üretimde verimliliği artırmayı amaçlayan yenilikçi tekniklerin uygulanması üzerine yapılan kapsamlı bir çalışmanın sonucudur. Tarımın temel unsurlarından biri olan mısır bitkisi üzerinde odaklanan bu araştırma, özellikle yabancı otlarla mücadelede modern teknolojilerin kullanımını incelemektedir. Çalışmalarım sırasında karşılaştığım zorluklar ve elde ettiğim başarılar hem akademik bilgi birikimime hem de tarımsal uygulamalar hakkındaki anlayışıma önemli katkılar sağlamıştır.

Öncelikle, tez dönemim boyunca bana yol gösteren ve sürekli destek sağlayan kıymetli danışmanım Sayın Dr. Öğr. Üyesi Sadık Özdemir'e en içten teşekkürlerimi sunarım. Onun rehberliği, bilgi birikimi ve sabrı, bu çalışmanın her aşamasında büyük bir ilham kaynağı olmuştur.

Ayrıca, tez çalışmam süresince bana sürekli destek olan aileme sonsuz teşekkür ederim. Onların sevgisi, sabrı ve anlayışı, bu zorlu süreci daha kolay ve anlamlı hale getirmiştir. Son olarak, iş yerimdeki değerli ekip arkadaşlarıma teşekkür ederim. Onların iş birliği, desteği ve motivasyonu, bu çalışmanın tamamlanmasında önemli bir rol oynamıştır.

1. GİRİŞ

Tarım, ilk insandan beri uygarlığın temel taşı olmuş, insan oluşumlarını ayakta tutmuş, ekonomilere yön verip onları biçimlendirmiş, var olan ve olacak tüm toplumların kültürel kimliklerini geliştirmiştir. Modern çağda yani günümüzdeki önemi ise, bir geçim kaynağı olmaktan çıkıp, global anlamda gıda güvenliği, çevresel sürdürülebilirliğin aynı zamanda sosyoekonomik kalkınmanın vazgeçilmez bir ögesi olarak karşımıza çıkmaktadır. İnsanlık; artan nüfusun getirdiği problemler olan çevresel zorluklar, tüketimin artması, farklılaşan beslenme koşulları gibi etmenler yüzünden teknolojiyi tarım uygulamalarında kullanmak ve bunu tarım uygulamalarına optimize etmek zorundadır.

Günümüz dünyası, tarım alanından hem benzeri görülmemiş fırsatlar yakalarken diğer taraftan içinden çıkılması güç zorluklara tanıklık etmektedir. Dünya nüfusun yaklaşık 2050 yılına kadar 9 milyar insanı açacağı düşünülürken gıda talebinin hiç olmadığı kadar artması beklenmektedir. Bunun beraberinde getirdiği; iklim değişikliği, su kıtlığı, var olan canlı çeşidinin daha da azalması, yer şekillerinin tahrip olması gibi etkenler tarımsal üretkenliğin ve tarımsal dayanıklılığın üzerine belirsizlik düşürmektedir. Artan nüfus ve hızlı kentleşme, teknolojik ilerlemeler, tarımsal manzaraları yeniden şekillendirip inovasyonu zorunlu kılmaktadır.

Mısır, küresel tarımdaki en önemli ve çok yönlü ürünlerden biri olarak karşımıza çıkmaktadır. Binlerce yıl önce Amerika'dan gelen mısır, ilkel uygarlıkların gıda maddesi olmaktan çıkıp global tarım sistemlerinin vazgeçilmez bir parçası haline gelmiştir. Mısır bitkisini insanlık için bu kadar önemli hale getiren şeyler; besin değeri, uyarlanabilirliği, mısır bitkisinden geliştirilen çeşitli uygulamalar... gibi nedenlerdir. İnsan popülasyonlarının devamında, ekonomik kalkınmanın desteklenmesinde ve tarımsal alanların biçimlendirilmesinde etkin rol oynamaktadır.

Mısır bitkisinin tarımdaki önemi çok yönlü ve geniş kapsamlı olarak karşımıza çıkmaktadır. Dünya çapında milyonlarca insan için birincil kalori ve besin kaynağı olarak hizmet etmektedir. Karbonhidratlar, proteinler, gerekli vitaminler ve mineraller bakımından zengin olan tahıllar, özellikle diğer temel mahsullerin yerel koşullara daha

az elverişli olduğu bölgelerde, çok sayıda topluluk için beslenmenin temelini oluşturmaktadır. Ayrıca mısır, kümes hayvanları, domuz ve sığır endüstrilerine yem sağlayarak hayvan yemi üretiminde önemli bir rol oynamaktadır. Yüksek enerji içeriği ve sindirilebilirliği, hayvansal proteine yönelik artan talebin karşılanması için gerekli olan verimli et, süt ürünleri ve yumurta üretim sistemlerini destekleyerek onu hayvan diyetlerinin vazgeçilmez bir bileşeni haline getirmektedir. Ayrıca mısır, biyoyakıt için etanol üretimi, gıda ve gıda dışı uygulamalar için nişasta ekstraksiyonu ve yenilenebilir enerji üretimi için biyokütle dahil olmak üzere çok sayıda endüstriyel proses için hammadde görevi görmektedir. Hammadde olarak çok yönlülüğü, sürdürülebilir tarım uygulamalarını teşvik etme ve fosil yakıtlara bağımlılığı azaltma konusundaki önemini vurgulamaktadır.

Mısır bitkisinin tarımdaki önemi, iklim değişikliği, nüfus artışı ve kaynak kıtlığı gibi küresel zorluklar karşısında daha da artmaktadır. Çeşitli çevre koşullarına dayanıklılığı, yetiştirme, biyoteknoloji ve tarımsal uygulamalardaki süregelen ilerlemelerle birleştiğinde, mısırın; tarımsal üretkenliği, dayanıklılığı ve sürdürülebilirliği artırmayı amaçlayan stratejilerin hayati bir bileşeni olarak konumlandırılmaktadır.

Modern dünyadaki tarım alanında karşımıza çıkan en büyük problemlerden biri de verimliliği arttırırken aynı zamanda sürdürülebilir uygulamaları benimsemekteki yetersizliktir. Nüfus artmaya devam ettikçe, küresel dünyanın gıda talebinin karşılanması, kaynak kullanımını optimize etmek, çevresel etkiyi en aza indirmek ve tarımsal faaliyetlerin verimini engelleyen faktörleri minimum seviyeye indirmek için yenilikçi, kaynak kullanımını azaltan, çevre dostu yaklaşımlar gerekmektedir. Bu alanda karşımıza yapay zeka ile birleşen görüntü işleme teknikleri umut verici olmuştur.

Görüntü işleme teknikleri, modern tarımda çok yönlü uygulamalarla birlikte kullanılabilir. Bu uygulamalar arasında en dikkat çekenlerden biri de yabancı ot tespiti ve yabancı otların kontrolü olarak karşımıza çıkmaktadır. Tarım alanlarında istenmeyen bitki örtüsü olarak tanımlanan yabancı otlar, mahsul verimi üzerinde önemli tehditler oluşturmaktadır. Geleneksel yabancı ot yönetimi yöntemlerinin çoğu zaman zahmetli, zaman alıcı ve mali açıdan külfetli olduğu kanıtlanmıştır. Bu nedenle,

otomatik yabancı ot tespiti ve kontrolünü kolaylaştıran yenilikçi metodolojilere yönelik kritik bir ihtiyaç ortaya çıkmaktadır.

Bu tez, mısır tarlalarındaki yabancı otların görüntü işleme teknikleri aracılığıyla tespit edilmesine odaklanmayı amaçlamaktadır. Görüntü işleme ve yapay zeka algoritmalarından yararlanılarak amaç, mısır tarlalarında bulunan yabancı otları tespit etmektir. Çalışmanın tarımda teknoloji odaklı çözümlerin benimsenmesine ve tarımsal verimliliğin artırılmasına katkı sağlaması amaçlanmaktadır.

Bu giriş, çalışmanın genel amacını ve önemini açıklayarak bağlamını ve hedeflerini özetlemektedir. Sonraki bölümlerde, mısır tarlalarında yabancı ot tespiti için önerilen metodolojiler açıklanarak görüntü işleme teknikleri ve yapay zeka algoritmaları derinlemesine incelenecektir.

1.1 Endüstriyel Tarım ve Özellikleri

Endüstriyel tarım, büyük ölçekli üretim için modern tarım teknolojilerini ve yöntemlerini kullanan bir tarım sistemidir. Bu sistem, küresel gıda üretimini artırmak, maliyetleri azaltmak ve gıda güvenliğini sağlamak amacıyla geliştirilmiştir. Endüstriyel tarımın gelişimi, toplumların tarımsal üretim yöntemlerinde önemli değişikliklere neden olmuş ve tarım sektöründe devrim yaratmıştır.

Mekanizasyon: Endüstriyel tarım, tarımsal üretim süreçlerinde yaygın olarak mekanizasyon kullanır. Traktörler, hasat makineleri, ekim makineleri ve sulama sistemleri gibi tarım makineleri, iş gücü ihtiyacını azaltır ve verimliliği artırır. Mekanizasyon, büyük tarım alanlarının hızlı ve verimli bir şekilde işlenmesine olanak sağlar.

Kimyasal Kullanım: Endüstriyel tarımda gübreler, pestisitler ve herbisitler gibi kimyasallar yaygın olarak kullanılır. Bu kimyasallar, bitki büyümesini teşvik eder, zararlıları kontrol altına alır ve yabancı otları yok eder. Kimyasal kullanımı, ürün verimini artırırken, aynı zamanda çevresel etkileri de beraberinde getirir.

Monokültür: Endüstriyel tarım, genellikle tek tip mahsul yetiştirme yöntemi olan monokültürü tercih eder. Bu, tarımsal verimliliği artırır ve işleme süreçlerini

kolaylaştırır. Ancak, monokültürün biyolojik çeşitliliği azaltması ve hastalıklara karşı hassasiyeti artırması gibi dezavantajları da vardır.

Genetik Modifikasyon: GDO'lar (Genetik Olarak Değiştirilmiş Organizmalar), endüstriyel tarımın önemli bir parçasıdır. GDO'lar, daha dayanıklı, besleyici ve yüksek verimli bitkiler geliştirmek için kullanılır. Bu, ürün kayıplarını azaltır ve tarımsal verimi artırır.

Endüstriyel tarım, modern tarımın vazgeçilmez bir parçasıdır ve dünya gıda üretiminin artmasında önemli bir rol oynamaktadır. Mekanizasyon, kimyasal kullanımı ve genetik modifikasyon gibi teknolojiler, tarımsal verimliliği ve gıda güvenliğini sağlarken, aynı zamanda çevresel ve sosyal sürdürülebilirlik açısından da birçok zorluğu beraberinde getirmektedir. Bu nedenle, endüstriyel tarımın avantajlarından yararlanırken, sürdürülebilir tarım uygulamalarının teşvik edilmesi ve çevresel etkilerin minimize edilmesi büyük önem taşımaktadır.

1.1.1 Endüstriyel Tarımda Mısırın Önemi

Mısır, endüstriyel tarımın en önemli ürünlerinden biridir ve dünya çapında büyük ölçekli üretim yapılan temel tahıllardan biri olarak öne çıkar. Mısırın endüstriyel tarımdaki önemi birkaç ana başlık altında incelemek mümkündür (Steduto ve diğ. 2012).

İnsan Tüketimi: Mısır, tüm dünyada temel gıda maddesi olarak tüketilir. Özellikle Amerika, Afrika ve Asya'da mısır, ekmek, un, cips ve diğer birçok gıda ürününün ana bileşenidir.

Hayvan Yemi: Mısır, hayvancılık sektörü için önemli bir yem kaynağıdır. Sığır, domuz, tavuk gibi çiftlik hayvanlarının beslenmesinde yaygın olarak kullanılmaktadır. Yüksek enerji içeriği ve besin değeri nedeniyle tercih edilir.

Biyoetanol Üretimi: Mısır, biyoetanol üretiminde en yaygın kullanılan hammaddelerden biridir. Biyoetanol, yenilenebilir bir enerji kaynağı olarak fosil yakıtlara alternatif oluşturur. Bu, enerji güvenliğine katkı sağlar ve aynı zamanda çevresel sürdürülebilirlik açısından önemlidir.

Gıda Katkı Maddeleri: Mısır, yüksek fruktozlu mısır şurubu, mısır nişastası, mısır yağı gibi birçok sanayi ürünü için hammadde olarak kullanılır. Bu ürünler, gıda

sanayinde yaygın olarak kullanılır ve işlenmiş gıdaların üretiminde önemli bir rol oynar.

Küresel Ticaret: Mısır, dünya tarım ticaretinde önemli bir yer tutar. Amerika Birleşik Devletleri, Çin, Brezilya gibi ülkeler, mısırın en büyük üretici ve ihracatçılarıdır. Bu, küresel tarım ekonomisi için önemli bir gelir kaynağı oluşturur.

İstihdam: Mısır üretimi, iş gücü açısından önemli bir sektördür. Mısır üretim zincirinde tarım işçileri, çiftçiler, nakliyeciler ve sanayi çalışanları gibi birçok kişi istihdam edilir.

Yüksek Verim: Mısır, yüksek verimli bir üründür ve modern tarım teknikleri ile verimi daha da artırılabilir. Genetik modifikasyon ve hibrit tohum teknolojileri, mısır verimliliğini artırmada etkin rol oynar.

Arazi Kullanımı: Mısır, geniş tarım arazilerinde yetiştirilir ve toprak verimliliğini artırmak için dönüşümlü ekim sistemlerinde kullanılır. Bu, toprak sağlıklı kalmasına yardımcı olur.

Adaptasyon: Mısır, farklı iklim koşullarına uyum sağlayabilen bir bitkidir. Bu, iklim değişikliğine karşı dayanıklılığını artırır ve farklı coğrafi bölgelerde yetiştirilmesine olanak sağlar.

Karbon Ayak İzi: Biyoetanol üretiminde kullanılması, karbon emisyonlarını azaltmaya yardımcı olur. Ancak, mısır tarımında yoğun su ve kimyasallar kullanıldığı için çevresel etkilerinin de dikkatli bir şekilde yönetilmesi gerekiyor.



Şekil 1.1: Mısır bitkisinin kullanım alanları

1.1.1.1 Mısır Bitkisinde Yabancı Ot Sorunu

Tarımda önemli bir yere sahip olan mısırın, verimli ve kaliteli ürün elde edilebilmesi için yabancı otların etkin bir şekilde kontrol altına alınması gerekmektedir. Yabancı otlar, mısır bitkisinin gelişimini olumsuz etkileyerek verim kayıplarına yol açmaktadır. Bu nedenle, mısır tarlalarında yabancı otların kontrol altına alınması büyük bir önem taşır.

Yabancı otların mısır bitkisi üzerindeki olumsuz etkileri arasında besin maddeleri ve su için rekabet, ışık miktarının azalması ve hastalıkların yayılması yer alır. Bu araştırmada, geleneksel yöntemler ile görüntü işleme ile yabancı ot tespiti yöntemlerinin herbisitlerin kullanımı karşılaştırılmıştır. Herbisit kontrolünün mısır bitkisinin verim ve kalitesi üzerinde önemli etkileri olduğunu göstermiştir. Yabancı otların kontrol altına alınması, mısır bitkisinin büyümesini desteklemiş ve verim kayıplarını minimize etmiştir (Yılmaz ve diğ. 2021).

Görüntü işleme yöntemiyle lokal herbisit kullanımıyla yabancı otlarla etkin mücadele yöntemlerinin uygulanması, mısır yetiştiriciliğinde başarılı sonuçlar elde

edilmesini sağlayarak, üreticilerin ekonomik kayıplarını azaltabilir. Bu nedenle, çiftçilerin uygun herbisitler ve diğer kontrol yöntemleri hakkında bilinçlendirilmesi büyük bir öneme sahiptir.

1.1.1.2 Görüntü İşleme Tekniklerinin Tarımsal Uygulamadaki Rolü

Görüntü işleme teknikleri, tarımsal uygulamalarda önemli bir rol oynamaktadır. Bu teknikler, tarım sektöründe verimliliği artırmak, kaynak kullanımını optimize etmek ve tarımsal üretimin sürdürülebilirliğini sağlamak amacıyla kullanılmaktadır. Aşağıda görüntü işleme tekniklerinin tarımsal uygulamadaki bazı önemli rol ve kullanım alanları belirtilmiştir:

- Tarlalardaki yabancı otları tespiti ve kontrolünde görüntü işleme teknikleri kullanılır. İnsansız hava araçları veya robotlar tarafından alınan görüntüler analiz edilerek yabancı otların yerleri belirlenir ve hedefe yönelik herbisit uygulamaları yapılır. Bu sayede kimyasal kullanım miktarı azaltılır ve çevresel etkiler en aza indirilir.
- Bitkilerin sağlık durumu, yaprak rengindeki değişiklikler, yaprak yüzeyindeki lekeler veya bitki gelişimindeki düzensizlikler gibi belirtiler üzerinden izlenebilir. Görüntü işleme teknikleri, multispektral veya hiperspektral kameralar kullanarak bitki sağlığını izler ve hastalık ya da zararlı tespit edildiğinde erken müdahaleye olanak sağlar.
- Görüntü işleme, bitki büyüme aşamalarını ve biyokütle miktarını belirlemek için kullanılabilir. Bu sayede hasat öncesinde verim tahminleri yapılabilir ve üretim planlaması daha verimli bir şekilde gerçekleştirilebilir. İnsansız hava araçları veya uydulardan elde edilen görüntüler, bitki örtüsünün yoğunluğu ve sağlığı hakkında bilgi verir.
- Görüntü işleme, tarlalardaki su stresi, toprak nemi ve toprağın fiziksel özelliklerini değerlendirmek için kullanılır. Bu bilgiler, sulama sistemlerinin optimize edilmesi ve su kaynaklarının verimli kullanılması için önemlidir. Ayrıca, erozyon ve toprak bozulmasının önlenmesi için de önemli veriler sağlar.
- Görüntü işleme teknikleri, hasat robotlarının meyve ve sebzeleri tespit edip toplamasında kullanılır. Bu teknikler, ürünün olgunluk seviyesini değerlendirir

ve hasat zamanını belirler. Robotlar, yüksek hassasiyetle çalışarak ürün kayıplarını minimize eder.

- Görüntü işleme, aynı zamanda hasat sonrası ürünlerin kalite kontrolü ve sınıflandırılmasında da önemli bir rol oynar. Ürünlerin boyut, şekil, renk ve olgunluk gibi kriterlere göre ayrılması sağlanır. Bu, pazara sunulan ürünlerin kalitesini artırır ve tüketici memnuniyetini sağlar.



Şekil 1.2: Tarım sektöründe görüntü işlemenin rolü

Görüntü işleme teknikleri, tarımda verimliliği artırmak ve sürdürülebilirliği sağlamak için çeşitli uygulamalarda kullanılmaktadır. Bu teknolojiler, tarımın dijitalleşmesi ve modernleşmesi sürecinde önemli bir yer tutmaktadır. İlerleyen zamanlarda, yapay zeka ve makine öğrenimi ile entegrasyonu sayesinde bu tekniklerin daha da gelişeceği ve tarımsal üretimde daha geniş bir yelpazede kullanılacağı tahmin edilmektedir.

1.1.1.2.1 Çalışmanın Amacı ve Kapsamı

Mısır tarlasının içerisinde çıkan yabancı otlar mısırı v5 dönemine kadar olumsuz etkileyip gelişimini yavaşlatmaktadır. Bu nedenle bu otların arazinin hangi bölgelerinde olduğu tespit edilmesi, hem arazinin durumu hakkında veri almamıza hem de ilaçlamada zaman, maliyet ve herbisit(kimyasal) kullanımını düşüreceğinden dolayı çevreye verilen zararın minimuma düşürülmesine olanak tanınır.

Bu çalışmada Mısır ekilmiş olan arazi içerisindeki, pivot sulama sistemi üzerine sabitlenen kamera ile alınan görüntülerin 7.5dBi Anten yardımıyla 5 Ghz radio frekansıyla görüntünün, işletmedeki bilgisayara aktarılıp, Google colab üzerinden mısırın gelişimini etkileyen yabancı otların varlıklarını görüntü işleme ile tespit edilmesi amaçlanmaktadır.



Şekil 1.3: Pivot sulama sistemi

Üsteki fotoğrafta görünen hareketli pivot sulama sistemine bağlanacak olan kamera ile mısırın görüntüsü elde edilip, bu görüntü içerisindeki mısır dışındaki önceden belirlenen yabancı otların tespiti sağlanarak, bu veri pivotun konum bilgisiyle birleştirilip, mısır tarlasının hangi bölgelerinde yabancı ot bulunduğunu görsel olarak işaretlemesini yapıp, bu işaretlemelere göre o bölgelerin lokal olarak ilaçlanması amaçlanmaktadır.

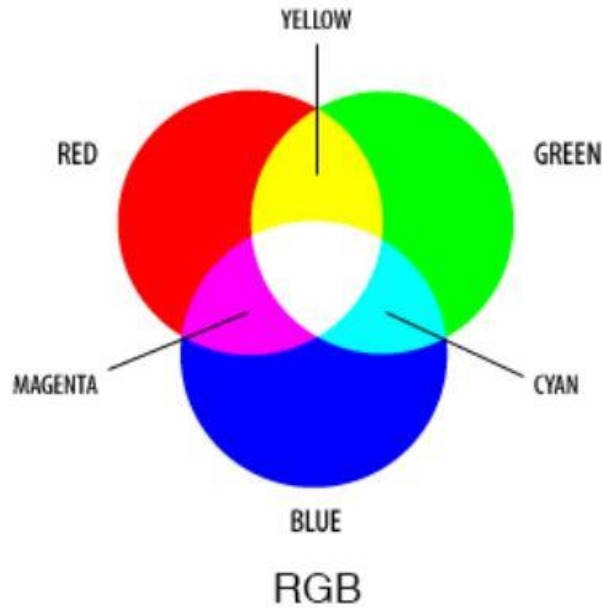
2. GÖRÜNTÜ İŞLEME KAVRAMI

2.1 Görüntü ve Renk Kavramı

Görüntü renk kavramı, dijital görüntülerdeki renklerin temsil edilmesi, algılanması ve işlenmesiyle ilgili bir terimdir. Bu kavram, genellikle dijital görüntüleme sistemlerinde renklerin nasıl depolandığı, görüntülendiği ve manipüle edildiğini ifade eder

2.1.1 RGB Renk Uzayı

RGB renk uzayı, Kırmızı (Red), Yeşil (Green) ve Mavi (Blue) olmak üzere üç temel renk bileşeninden oluşur ve bu renk uzayına eklemeli renk uzayı da denilmektedir. Bu isimlendirme, RGB renk uzayının, CMYK gibi diğer renk uzaylarındaki ana renklerin birleştirilmesiyle oluşmasından kaynaklanmaktadır. RGB renk modeli, bu üç ana rengin birleşimi ile elde edilen renkleri tanımlar. Kırmızı, Yeşil ve Mavi ışık, ışıksal renklerin birincil kümesini oluşturur ve bu tür renk uzayı, ışıksal renkler olarak da adlandırılır (Kısa ve diğ. 2019).



Şekil 2.1: RGB renk havuzu

Doğada bulunan tüm renkler, bu üç ana renk bileşeninin farklı oranlarda karıştırılmasıyla elde edilir. RGB renk bileşenleri, her biri için 0 ile 255 arasında değişen sayısal değerler alır ve farklı değerlerde birleştirildiklerinde yeni renk tonlarını oluştururlar. Kırmızı, Yeşil ve Mavi renklerinin maksimum değer olan 255'te karışımı beyaz rengi oluştururken, %0 oranında yani tüm değerlerin sıfır olduğu durumda ise siyah renk elde edilir.

2.1.2 HSV Renk Uzayı

HSV renk uzayı insan gözünün renkleri algılama şekline en yakın olan modeldir. HSV renkleri üç temel bileşenden oluşur:

Ton: Bu bileşen renklerin tümünü kırmızı mavi ve yeşil olarak temsil eder .0° kırmızıyı, 120° yeşili ve 240° maviyi temsil ederken, 360° ile tekrar kırmızıya dönüş yapar.

Doygunluk: Renk yoğunluğunu ifade eder. Doygunluk yüzde olarak ölçülür; %0 tamamen grileşmiş renk anlamına gelirken, %100 tamamen doygun renk demektir.

Değer: Parlaklık (Brightness) olarak adlandırılır. Renklerin ışık şiddetini belirtir. Değer yüzde olarak ölçülür; %0 tamamen karanlık (siyah), %100 ise en parlak ve renklerin en açık hali demektir.

2.1.3 CMYK Renk Uzayı

CMYK renk uzayı, özellikle baskı endüstrisinde kullanılan bir renk modelidir. Cyan (Turkuaz), Magenta (Macenta), Yellow (Sarı) ve Key (Black, Siyah) olmak üzere dört temel renkten oluşur. Bu renk uzayının adı, bu dört ana renk bileşeninin baş harflerinden meydana gelir. CMYK, baskı teknolojilerindeki sınırlamaları ve malzeme özelliklerini göz önünde bulundurarak en iyi renk doğruluğunu ve kalitesini elde etmek amacıyla kullanılır. Bu, dijital ortamda kullanılan RGB renk modelinden farklı olarak, daha teknik ve özelleşmiş bir renk yönetimi gerektirir. Yani her mürekkepten ne kadar kullanılacağına karar verilecek baskıdaki istenilen renkler oluşturulur.

2.1.4 Diğer Renk Uzayları

YCbCr renk uzayı, video bilgilerini işlemek için dijital algoritmalara yönelik artan taleplere yanıt olarak tanımlanmış ve dijital videoda yaygın olarak kullanılan bir model haline gelmiştir. Y, parlaklığı temsil eden parlaklık bileşenidir ve doğrusal olmayan RGB'den hesaplanır. RGB değerlerinin ağırlıklı toplamı olarak elde edilir. Cb, mavi ile parlaklık bileşeni arasındaki farkı, Cr ise kırmızı ile parlaklık bileşeni arasındaki farkı temsil eder (Kaur ve diğ. 2012).

CIELAB algısal olarak tekdüze bir renk uzayıdır. Algısal tekdüzelik, iki rengin insanlar tarafından gözlemlendiğinde ne kadar farklı görüldüğü anlamına gelir. Bu nedenle, tüm renklerin algısal farklılıklara göre düzenlendiği her durumda renk uzayları tanımlanmıştır. Ancak, bu renk uzaylarında algısalılık, yoğun hesaplama gerektiren dönüşümler pahasına elde edilmektedir (Kaur ve diğ. 2012).

2.2 Görüntü Çeşitleri

Görüntü, bir nesnenin, ortamın veya olayın görsel olarak temsilidir. Fiziksel bir nesnenin, ışık ve yansıma gibi etkenlerle gözle veya teknolojik araçlarla (kamera, ekran, ayna vb.) algılanabilir hale gelmiş hali olarak tanımlanabilir. Görüntü, fotoğraf, video, dijital grafikler, yansımalar ya da insan gözünün algıladığı herhangi bir görsel bilgi olabilir. Görüntü türleri iki başlık altında değerlendirilir.

2.2.1 Analog Görüntü

Analog görüntü, fiziksel dünyadaki sürekli bir sinyalin kesintisiz bir biçimde kaydedildiği veya iletildiği görsel bir temsildir. Analog görüntüler, dijital görüntülerden farklı olarak belirli bir çözünürlüğe veya piksellere bölünmezler; aksine, sonsuz sayıda ayrıntıyı temsil edebilecek şekilde sürekli bir sinyal biçiminde oluşturulurlar.

Örneğin, eski tip analog televizyonlarda ve video kameralarında üretilen görüntüler, fiziksel sinyallerin doğrudan elektriksel sinyallere dönüştürülmesiyle

oluşur. Analog görüntülerde bilgi, genellikle voltaj veya frekans gibi sürekli değişen fiziksel parametrelerle taşınır.

2.2.2 Dijital Görüntü

Dijital görüntü, görsel bilgilerin sayısal olarak (0 ve 1'ler) temsil edildiği bir görüntü türüdür. Bu görüntüler, küçük kare birimlerden, yani piksellerden oluşur. Her piksel belirli bir renk veya parlaklık değerine sahiptir ve tüm pikseller bir araya gelerek görüntünün tamamını oluşturur. Dijital görüntüler bilgisayarlar, telefonlar ve dijital kameralar gibi elektronik cihazlar tarafından işlenebilir, saklanabilir ve görüntülenebilir. Kısacası, dijital görüntü, görsel verinin dijital dünyada saklanabilir ve işlenebilir hale getirilmiş halidir.

2.2.3 Dijital Görüntü İşleme Yöntemleri

2.2.3.1 Filtreleme İşlemi

Filtreleme, dijital görüntü işlemede kullanılan temel bir tekniktir ve görüntülerdeki belirli özellikleri vurgulamak veya istenmeyen parazitleri azaltmak için kullanılır. Filtreleme işlemi, genellikle bir görüntü üzerinde bir dizi matematiksel işlem gerçekleştirilerek yapılır. İşlemler, genellikle bir filtre çekirdeği (kernel) kullanılarak uygulanır ve bu çekirdek, görüntünün üzerinde dolaştırılarak piksellerin değerlerini değiştirir. Filtreleme işleme lineer ve lineer olmayan olarak iki kısımda yer alır.

2.2.3.2 Lineer Filtreleme

Ortalama Filtre (Mean Filter): Gürültüyü azaltmak ve görüntüyü yumuşatmak için kullanılır. Her bir pikselin değeri, kendisi ve çevresindeki piksellerin ortalama değeri ile değiştirilir.

Gaussian Filtre: Ortalama filtreye benzer şekilde görüntüyü yumuşatır, ancak piksellerin ağırlıkları Gaussian dağılımına göre ayarlanır, bu da merkezdeki piksellere daha fazla ağırlık verir.

Kenar Tespiti Filtreleri: Görüntünün kenarlarını belirginleştirmek için kullanılır. Bu filtreler, yatay ve dikey yönlere duyarlıdır ve görüntüdeki keskin geçişleri tespit eder. Kenar tespiti filtrelerin başında Sobel, Prewitt ve Roberts filtreleri gelmektedir.

2.2.3.3 Lineer Olmayan Filtreleme

Medyan Filtre: Her bir piksel değerini, o piksel ve çevresindeki piksellerin medyan değeri ile değiştirir. Özellikle tuz-biber gürültüsü gibi rastgele gürültüyü azaltmak için etkilidir.

Mod Filtre: Çevresindeki pikseller arasında en sık rastlanan değeri kullanır.

2.2.3.4 Filtreleme İşlemi Nasıl Yapılır?

Filtreleme, gürültü azaltma, kenar tespiti, görüntü keskinleştirme gibi birçok görüntü işleme uygulamasında temel bir yöntemdir ve görüntü işlemede önemli rol oynar. Filtreleme, en basit görüntü düzenleme işlemlerinden, en karmaşık görüntü işleme uygulamalarına kadar tercih edilen yöntemlerin başında gelir. Filtreleme işlemi 3 adımdan oluşmaktadır.

Filtre Çekirdeğinin Belirlenmesi: İlk aşama, kullanılacak filtrenin çekirdeğini belirlemektir. Bu çekirdek, çoğunlukla küçük bir matris şeklinde olup, uygulanacak matematiksel işlemi ifade eder.

Konvolüsyon (Evrışim) İşlemi: Filtre çekirdeği, görüntünün üzerinde piksel piksel kaydırılarak uygulanır. Her bir konumda, çekirdeğin kapsadığı piksellerle çekirdeğin kendisindeki değerler çarpılır ve elde edilen değerler toplanarak yeni görüntünün ilgili piksel değeri hesaplanır.

Kenar İşleme: Görüntünün kenarlarındaki pikseller için, çekirdeğin tamamı görüntü üzerinde olmayabilir. Bu durumda kenar pikselleri için çeşitli teknikler uygulanabilir. Örneğin; kenarları sıfırlama, kenarları yansıtma uygulamaları vb. işlemler yapılabilir.

2.3 Histogram İşleme

Histogram işleme, dijital görüntülerin yoğunluk değerlerinin dağılımını görselleştiren bir tekniktir. Bu işlemle, görüntünün tonal dağılımı belirlenerek, görüntü kalitesi üzerinde çeşitli iyileştirmeler yapılabilir. Histogram, genellikle bir grafik formunda sunulur ve bu grafikte yatay eksen piksel yoğunluklarını (genellikle 0 ile 255 arasında), dikey eksen ise bu yoğunluk değerlerinin görüntüde ne kadar tekrarlandığını gösterir. Histogram işleme teknikleri, görüntüdeki kontrastı artırma, detayları belirginleştirmek ve gürültüyü azaltma gibi amaçlar için kullanılır. Histogram İşleme Teknikleri aşağıda verilmiştir.

Histogram Eşitleme: Görüntünün histogramını daha geniş bir yoğunluk aralığına yayarak kontrastı artırır. Yoğunluk değerleri, görüntüdeki tonların eşit şekilde dağılmasını sağlayacak biçimde ayarlanır. Böylece, daha düz bir histogram elde edilir ve görüntünün genel aydınlığı ve kontrastı iyileştirilir.

Histogram Germe: Yoğunluk değerlerini belirli bir aralıkta (genelde 0 ile 255 arası) maksimize ederek görüntünün kontrastını iyileştirir. Düşük yoğunluklu pikseller daha koyu, yüksek yoğunluklu pikseller ise daha açık hale getirilir. Bu işlem, genelde düşük kontrastlı görüntülerde uygulanır.

Adaptif Histogram Eşitleme (AHE): Adaptif histogram eşitleme, görüntünün belli bölgelerinde lokal kontrastı artırmak için kullanılır. Görüntü küçük bölümlere ayrılır ve her bir bölüm için histogram eşitleme işlemi uygulanır. Bu yöntem, özellikle yerel detayların daha belirgin hale gelmesini sağlar ve standart histogram eşitlemeye göre daha fazla detay sunar.

Kırpma (Clipping) ve Sınırlama: Histogramdaki piksel yoğunluklarının belirli bir limit üzerinde yoğunlaşması durumunda, bu yoğunluk değerlerinin tekrar sayısı

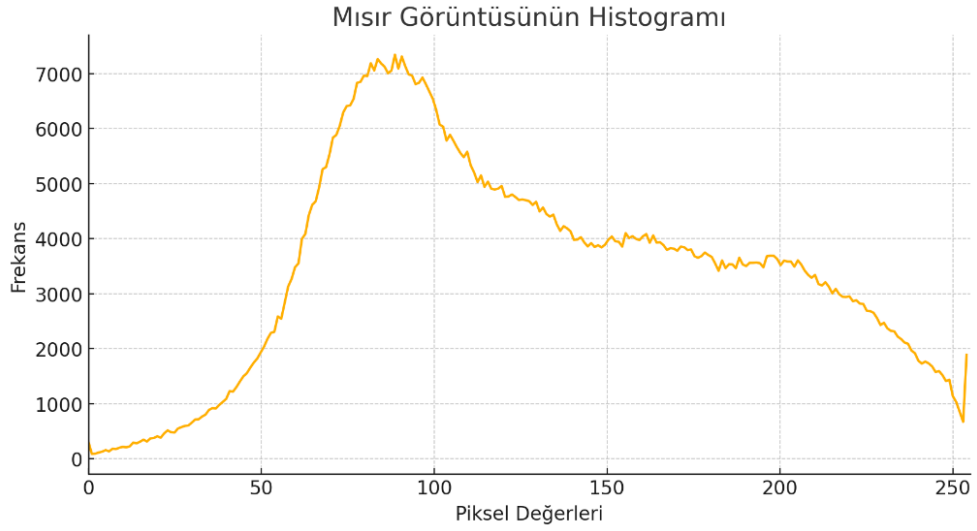
sınırlandırılabilir. Bu işlemle, görüntüdeki gürültülerin azaltılması ve daha dengeli bir histogram elde edilmesi hedeflenir.

Histogram işleme, görüntüler üzerinde önemli iyileştirmeler yapılmasına olanak tanıyan ve özellikle dijital görüntü analizi ve işleme alanlarında yaygın olarak kullanılan bir yöntemdir. Bu teknikler, görüntü kalitesini artırma, kontrastı düzenleme ve daha net görüntüler elde etme gibi çeşitli avantajlar sağlar.



Şekil 2.2: Mısır bitki görüntüsünün gri tonlama yapılmış hali

Şekil 2.2'teki görüntü pycharm derleyici ile python dilinde istenilen kod yazılarak orijinal görüntüden siyah beyaz gri tonlama görüntüsü haline dönüştürülmüştür. Bu dönüşüm, görüntünün görsel bilgisini korurken renk bilgisini kaldırır, böylece analiz ve işleme için daha basit bir hale gelir. Ayrıca gri tonlama, renk bilgisinin yoğunluk bilgisine dönüştürülmesi anlamına gelir ve histogram çıkarımı ise bu yoğunluk değerlerinin görüntüde ne sıklıkla yer aldığını gösterir. Yapılan bu işlem kontrast analizi, görüntü iyileştirme, gürültü azaltma, görsel analiz gibi çeşitli amaçlar için kullanılır.



Şekil 2.3: İncelenen mısır bitkisinin histogram grafiği

2.4 Morfolojik İşlemler

Morfolojik işlemler, dijital görüntü işleme ve analizinde kullanılan, görüntüler üzerinde yapısal dönüşümler gerçekleştirerek görüntülerin şekillerini işlemek için kullanılan bir yöntemler bütünüdür. Bu işlemler, genellikle ikili (siyah-beyaz) veya gri tonlamalı görüntüler üzerinde uygulanır ve görüntülerdeki yapıları, şekilleri veya doku özelliklerini vurgulamak, düzeltmek veya çıkarmak için kullanılır. Morfolojik işlemler, bir yapılandırıcı eleman kullanarak tanımlanır, bu eleman görüntü üzerinde bir çeşit şablon veya filtre görevi görür.

Morfolojik işlemler, sayısal baskı hatalarını düzeltmek, parmak izi ve diğer biyometrik tanıma sistemlerinde nesne ayırt etmek, tıbbi görüntülerdeki şekilleri analiz etmek ve makine görüşü uygulamalarında önemli rol oynar. Bu işlemler, görüntülerdeki önemli morfolojik yapıları belirginleştirerek analizi ve işlemeyi kolaylaştırır.

2.5 Kenar Tespiti ve Segmentasyon

Segmentasyon modellerinde sıklıkla karşılaşılan bir zorluk, sınıf sınırları etrafındaki bulanıklıklar ve belirsizliklerdir. Bu sorunun temel sebebi, kenar

piksellerinin görüntüdeki toplam piksel sayısına oranla oldukça az olması ve dolayısıyla standart piksel bazlı çapraz entropi kaybı tarafından yeterince dikkate alınmamasıdır. Görüntülerde kenarların az olması, bu piksellerin model tarafından ihmal edilme olasılığını artırır, bu da kenar bölgelerde segmentasyonun doğruluğunu düşürür (Heidler ve diğ. 2021). Bu nedenle, kenar bilgilerini anlamsal segmentasyon sürecine dahil etme fikri, bu sorunu çözmek için önemli bir yaklaşım olarak öne çıkar. Kenarları özellikle vurgulayarak, modellerin sınıf sınırlarını daha net bir şekilde tanımlaması ve daha keskin segmentasyonlar yapması sağlanabilir. Bu yaklaşım, segmentasyonun genel doğruluğunu artırarak daha detaylı ve doğru sonuçlar elde edilmesine olanak tanır.

Bir görüntüdeki kenarların farkında olan bir segmentasyon modeli oluşturmanın bir yolu, keskin kenarların tahmin edilmesini teşvik eden yardımcı bir kayıp terimi eklemektir (Cheng ve diğ. 2017). Şaşırtıcı bir şekilde, segmentasyon modeline sadece kenar tespit görevini yardımcı bir çıktı olarak eklemek, modele başka değişiklikler yapmadan bile segmentasyon sonuçlarını oldukça iyileştirebilir (Jiang ve diğ. 2020).

3. YAPAY ZEKA KAVRAMI

Yapay zeka, makinelerin, özellikle bilgisayar sistemlerinin insan zekâsı gerektiren görevleri yerine getirebilme kabiliyetini ifade eder. Bu görevler; dil işleme, mantık yürütme, öğrenme, algılama ve problem çözme gibi insan zekasıyla özdeşleştirilen işlevleri içerir.

Yapay zeka, 1950'lerde modern bilgisayar biliminin doğuşuyla birlikte şekillenmeye başladı (McCarthy ve diğ. 2006). 1956'da John McCarthy tarafından düzenlenen Dartmouth Konferansı, bu alandaki ilk büyük adım olarak kabul edilir. O dönemde, araştırmacılar genel zeka yeteneklerine sahip makineler geliştirmeye odaklandı.

3.1 Yapay Sinir Ağları

Yapay sinir ağları, insan beynindeki biyolojik sinir ağlarının işleyişinden esinlenen ve bilgisayarlar tarafından öğrenme, sınıflandırma, tahmin ve karar verme gibi görevleri gerçekleştirmek için kullanılan bir yapay zeka (AI) modelidir. Yapay sinir ağları, verileri işlemek ve modellemek için birçok katmandan oluşan bir yapıya sahiptir ve özellikle makine öğrenmesi ve derin öğrenme alanlarında önemli bir rol oynar.


3.1.1 Yapay Sinir Ağlarının Temel Yapısı

Yapay sinir ağları, nöronlar (veya düğümler) adı verilen birimlerden oluşur ve bu nöronlar, insan beynindeki sinir hücrelerine benzer bir şekilde çalışır. Nöronlar üç ana katman halinde düzenlenir:

Giriş Katmanı (Input Layer): Bu katman, ham veriyi (örneğin bir resim, bir metin veya bir dizi sayı) alır ve bu bilgiyi ağın içine iletir. Giriş katmanındaki her nöron, bir girdi özelliğine karşılık gelir.

Gizli Katmanlar (Hidden Layers): Giriş katmanından gelen bilgiyi işler ve nöronlar arasındaki bağlantılar aracılığıyla bilgi aktarımı sağlar. Bu katmanlar, modelin karmaşık ilişkileri öğrenmesi için önemlidir. Derin sinir ağları, birçok gizli katman içerir ve bu katmanlar arasındaki bağlantılar modelin öğrenme kapasitesini artırır.

Çıkış Katmanı (Output Layer): Sonuçları üretir ve tahminleri yapar. Bu katman, bir sınıflandırma probleminde sınıf etiketlerini, bir regresyon probleminde ise sayısal tahminleri sağlar.



Şekil 3.1: YSA temel modeli

3.1.2 Yapay Sinir Ağlarının Temel Bileşenleri

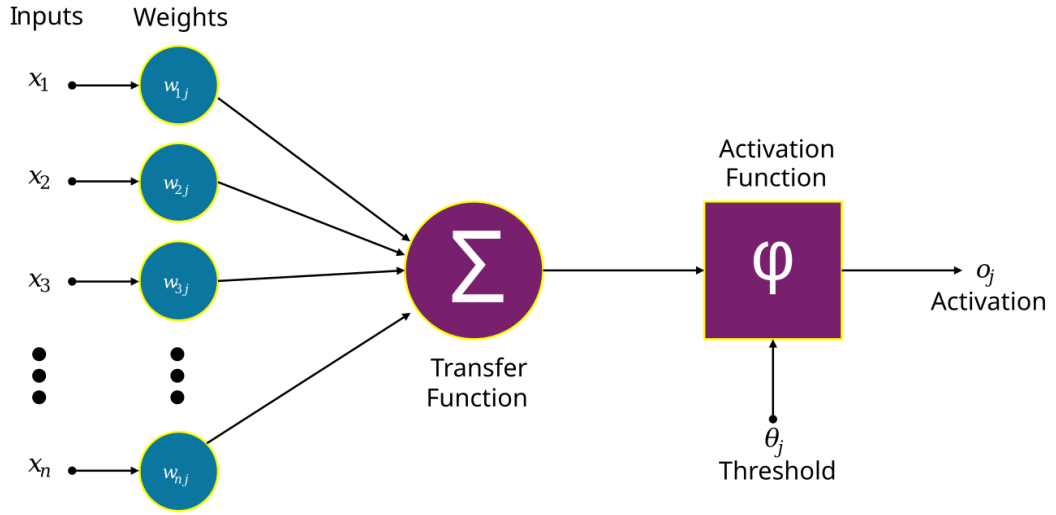
Ağırlıklar ve Önyargılar (Weights and Biases): Nöronlar arasındaki bağlantılar, ağırlık adı verilen değerlerle ifade edilir. Bu ağırlıklar, modelin öğrenme sürecinde güncellenir ve öğrenilen ilişkileri temsil eder. Önyargı ise her nörona eklenen sabit bir değerdir ve modelin esnekliğini artırır.

Aktivasyon Fonksiyonu: Her nöron, aldığı girdiyi işledikten sonra bir aktivasyon fonksiyonu uygular. Diğer adıyla transfer fonksiyonu olarak da bilinir. Bu fonksiyon, nöronun çıktısını belirler. Yaygın olarak kullanılan aktivasyon fonksiyonları şunlardır:

Sigmoid: Çıktıları 0 ile 1 arasında sınırlayan bir fonksiyondur.

ReLU (Rectified Linear Unit): Pozitif değerleri olduğu gibi alır, negatif değerleri sıfır yapar.

Hiperbolik Tanjant Fonksiyonu (Tanh): -1 ile 1 arasında çıktı verir.



Şekil 3.2: YSA uygulama modeli (Funcs 2024)

Öğrenme Süreci: Yapay sinir ağları, geriye yayılım algoritmasıyla öğrenir. Geriye yayılım, modelin yaptığı hataları hesaplayarak ağırlıkları ve önyargıları günceller. Bu süreç, ağın hata miktarını (kayıbı) minimize etmek için tekrar tekrar uygulanır. Öğrenme süreci şu adımlarla işler: Giriş verisi nöronlara iletilir ve her katman sırasıyla hesaplanır. Daha sonra çıkış katmanında elde edilen sonuçlar, gerçek sonuçlarla karşılaştırılır ve bir hata hesaplanır. Son olarak geriye yayılım ile bu hata, ağın içindeki ağırlıklara yansıtılır ve güncellemeler yapılır.

3.2 Yapay Zekanın Uygulama Alanları ve Sınıflandırılması

Yapay zeka günümüzde neredeyse her alanda kullanılabilir. En çok kullanılan alanlar:

- Sağlık Hizmetleri (hastalık teşhisi ve tedavi, tıbbi görüntüleme, cerrahi robotlar, kişisel sağlık asistanları)

- Eğitim (öğrenme yönetim sistemleri, otomatik notlandırma, eğitim danışmanlığı)
- Finans ve Bankacılık (algoritmik ticaret, dolandırıcılık tespiti, müşteri hizmetleri, kredi risk analizi)
- Ulaşım (otonom araçlar, trafik yönetim sistemi, rota optimizasyonu)
- İmalat ve Endüstri (robotik otomasyon, öngörücü bakım, kalite kontrol)
- Tarım (akıllı tarım, dron tabanlı tarım, mahsul tahmini, stres analizi)
- Güvenlik (yüz tanıma, güvenlik kameraları, siber güvenlik)
- Eğlence ve Medya (içerik öneri sistemleri, oyun endüstrisi, medya ve içerik üretimi)

3.2.1 Makine Öğrenmesi (Machine Learning)

Makine öğrenmesi (ML), bilgisayarların açıkça programlanmadan, verilerden öğrenmesini sağlayan bir yapay zeka alt alanıdır. ML, algoritmaların ve istatistiksel modellerin büyük veri kümeleri üzerinde çalışarak, kalıpları tanıması ve bu verilerle tahminlerde bulunmasını içerir. Başlıca amacı, bilgisayarların geçmiş verilerden elde edilen bilgi ile gelecekteki verilerle daha iyi tahminler yapabilmesidir.

Benzer şekilde, bilgiyi bilgisayarlara kodlamak yerine, makine öğrenimi (ML), anlamlı ilişkileri ve desenleri örneklerden ve gözlemlerden otomatik olarak öğrenmeyi amaçlar (Bishop ve diğ. 2006). Makine öğrenimindeki ilerlemeler, iş dünyamıza ve kişisel yaşamımıza nüfuz eden, insan benzeri bilişsel kapasiteye sahip zeki sistemlerin yükselişini sağlamıştır ve bu sistemler, elektronik pazarlardaki ağ etkileşimlerini her açıdan şekillendirmektedir. Şirketler, karar verme süreçlerini üretkenlik, etkileşim ve çalışanların elde tutulması için desteklerken, eğitilmiş asistan sistemleri bireysel kullanıcı tercihlerine uyum sağlamakta (Fischer ve diğ. 2020) ve ticaret ajanları geleneksel finansal ticaret piyasalarını sarsmaktadır. Makine Öğrenmesinin Ana Bileşenleri aşağıda verilmiştir (Shrestha ve diğ. 2021).

Veri: Makine öğrenmesi modelleri, büyük miktarda yığıntıya dayanarak öğrenir. Bu veriler genellikle yapılandırılmış (tablo) veya yapılandırılmamış (metin, görüntü, ses) olabilir.

Model: Veriler üzerinde eğitilen matematiksel yapı veya algoritma. Bu model, veriler arasındaki ilişkileri ve kalıpları öğrenir.

Eğitim (Training): Model, verilen veriler üzerinde çalışarak bu kalıpları öğrenir ve tahminler yapmaya hazırlanır.

Tahmin (Prediction): Eğitim tamamlandıktan sonra model, yeni verilere dayalı olarak tahminler yapar.

3.2.2 Derin Öğrenme (Deep Learning)

Derin öğrenme, yapay sinir ağlarına dayalı bir makine öğrenimi kavramıdır. Birçok uygulamada, derin öğrenme modelleri, yüzeysel makine öğrenme modellerini ve geleneksel veri analiz yaklaşımlarını geride bırakmaktadır. Bu makalede, günümüz zeki sistemlerinin yöntemsel temellerini daha geniş bir anlayış oluşturmak amacıyla makine öğrenimi ve derin öğrenmenin temel prensiplerini özetliyoruz (Janiesch ve diğ. 2021). Özellikle, ilgili terimler ve kavramlar arasında kavramsal bir ayrım yaparak, makine öğrenimi ve derin öğrenme yoluyla otomatik analitik model oluşturma sürecini açıklıyoruz ve bu tür zeki sistemlerin elektronik pazarlar ve ağ tabanlı iş alanında uygulanması sırasında karşılaşılan zorlukları tartışıyoruz. Bu zorluklar doğal olarak teknolojik unsurların ötesine geçmekte olup insan-makine etkileşimi ve yapay zeka konularına dikkat çekmektedir.

Derin öğrenme, karmaşık veri kümeleri ve problemler üzerinde çalışarak son derece başarılı sonuçlar elde eden güçlü bir makine öğrenmesi yöntemidir. Bu yöntem, özellikle büyük veri ve yüksek hesaplama gücü gerektiren alanlarda tercih edilir.

3.2.3 Doğal Dil İşleme (Natural Language Processing)

Doğal Dil İşleme (NLP) bilgisayarların insan dilini anlaması, yorumlaması ve üretmesi için geliştirilmiş bir yapay zeka (YZ) alanıdır. NLP, dilbilimsel kurallar ve makine öğrenmesi tekniklerini kullanarak yazılı ve sözlü dili analiz eder. Amaç, bilgisayarların insanlarla doğal bir dilde etkileşimde bulunabilmesini sağlamaktır

(Ofer ve diğ. 2021). Doğal dil işleme (NLP), otomatik metin ve dil analiziyle ilgilenen bir bilgisayar bilimi alanıdır. Son yıllarda, derin öğrenme ve makine öğrenimindeki bir dizi atılımın ardından, NLP yöntemleri büyük ilerlemeler kaydetmiştir.

Doğal dil işleme de kullanılan tekniklerin başında; kelime parçalama, bilgisayar etiketleme, duygu analizi, adlandırılmış varlık tanıma gibi metodlar kullanılır. Kullanım alanları ise; makine çevirisi, sesli asistanlar, otomatik metin özetleme, sohbet botlar gelmektedir. Günümüzde verilecek en büyük örnek ise Chat GPT olmuştur.

3.2.4 Bilgisayarlı Görme (Computer Vision)

Bilgisayarlı Görme (Computer Vision), bilgisayarların görsel verileri (resimler, videolar) algılamasını, yorumlamasını ve anlamasını sağlayan bir yapay zeka alanıdır. Amacı, insan gözünün yaptığı gibi görsel dünyayı analiz etmek ve anlamaktır. Bilgisayarla görme, nesne tanıma, yüz tanıma, görüntü sınıflandırma, hareket takibi ve sahne analizi gibi birçok görevi yerine getirir.

Bilgisayarlı görme bilgisayarların görsel uyarınları anlamlı bir şekilde algılamasını sağlamaya yönelik on yıllardır süregelen çalışmalarla zengin bir geçmişe sahiptir. Makine algılaması, kenarların tanımlanması gibi düşük seviyeli görevlerden, tam sahnelerin anlaşılması gibi yüksek seviyeli görevlere kadar çeşitli düzeylerde işlevleri kapsar. Son on yıldaki ilerlemeler büyük ölçüde üç faktöre bağlı olmuştur. Derin öğrenmenin (DL) olgunlaşması ham verilerden çok karmaşık fonksiyonların uçtan uca öğrenilmesini sağlayan bir makine öğrenimi türü ve GPU'lar aracılığıyla yerleşmiş hesaplama gücünde atılan adımlar ve bu algoritmaları eğitmek için kullanılan büyük etiketli veri kümelerinin açık kaynaklı hale getirilmesidir. Bu üç unsurun birleşimi, bireysel araştırmacılara alanı ileriye taşımak için gerekli kaynak erişimini sağlamıştır. Araştırma topluluğu katlanarak büyüdükçe, ilerleme de aynı şekilde artmıştır (Esteva ve diğ. 2021).

3.2.5 Robotik ve Uzman Sistemler

Robotik, fiziksel görevleri yerine getirebilen otomatik makinelerin tasarımı, geliştirilmesi ve kullanımı ile ilgilenen bir mühendislik ve bilim dalıdır. Robotlar, genellikle sensörler, işlemciler ve aktüatörler kullanarak çevrelerini algılayabilir, analiz edebilir ve belirli görevleri yerine getirebilirler. Uzman sistemler ise belirli bir alanda uzmanlık bilgisine sahip bir insan uzman gibi karar verme yeteneğine sahip olan bilgisayar programlarıdır. Genellikle bir dizi kurallar ve bilgi tabanı kullanarak çalışırlar. Bu sistemler, belirli bir alanda uzmanlardan toplanan bilgileri kullanarak karmaşık sorunlara çözüm bulur. Robotik, fiziksel dünyada otomasyon ve görevleri gerçekleştiren makinelerle ilgilenirken, uzman sistemler, belirli bilgi alanlarında uzman gibi kararlar veren yazılım sistemleridir.

Her iki alan da insan hayatını kolaylaştırmak ve iş süreçlerini daha verimli hale getirmek için yaygın olarak kullanılmaktadır.

3.2.6 Pekiştirmeli Öğrenme (Reinforcement Learning)

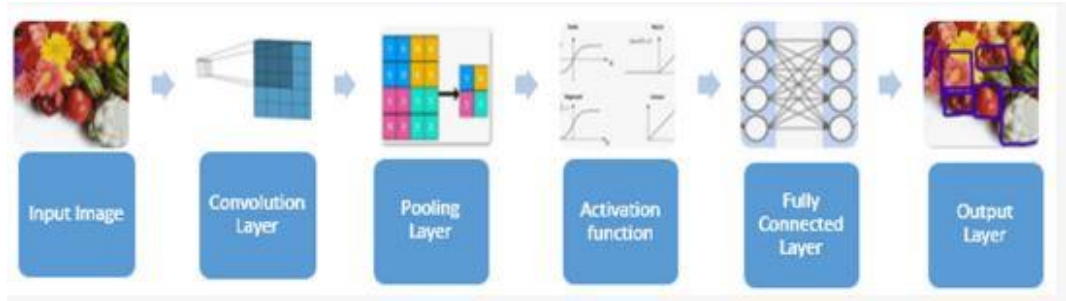
Pekiştirmeli öğrenme (RL), yapay zekanın bir türüdür ve bir ajan (karar verici) ile çevresi arasındaki etkileşimi temel alır. Ajan, bir hedefe ulaşmak veya bir görevi yerine getirmek için, çevresiyle sürekli olarak etkileşimde bulunur ve bu süreçte aldığı ödüller veya cezalar doğrultusunda davranışlarını öğrenir.

Model tabanlı ve model bağımsız RL olmak üzere iki çeşit öğrenme türü vardır. Model tabanlı RL de ajan, çevrenin nasıl çalıştığına dair bir model öğrenir ve bu modeli kullanarak gelecekteki durumları tahmin eder. Model bağımsız RL de ajan, çevrenin nasıl çalıştığına dair bir bilgiye sahip olmadan, deneme-yanılma yoluyla öğrenir. Ajan, doğrudan eylemlerinin sonuçlarından öğrenir.

3.3 Görüntü İşlemede Derin Öğrenme Tabanlı Algoritmalar

3.3.1 Evrişimli Sinir Ağları (Convolutional Neural Network)

Evrişimli sinir ağı (CNN), görüntü ve video tanıma, sınıflandırma ve işleme gibi görevler için yaygın olarak kullanılan bir yapay sinir ağı türüdür. CNN, bilgisayarlı görme algoritmalarının çoğunu oluşturmak için kullanılır. Evrişimli sinir ağı, bir giriş görüntüsünü alan ve görüntüdeki çeşitli nesnelere önem (öğrenilebilir önyargılar ve ağırlıklar) atayan ve birini diğerinden ayıran bir derin öğrenme yöntemidir (Bhatt ve diğ.2021).



Şekil 3.3: CNN temel çalışma prensibi (Bhatt ve diğ.2021)

Şekil 3.3'te Evrişimli Sinir Ağı (CNN) modelinin temel bileşenlerini ve iş akışını gösteren bir şema içermektedir. Şemada, bir görüntü işleme süreci adım adım anlatılmaktadır ve bu süreçte kullanılan CNN bileşenleri şu şekilde sıralanmıştır:

Giriş Resmi (Input Image): İşlenmek üzere olan ham resim burada yer alır.

Evrişim Katmanı (Convolution Layer): Görüntü üzerinde çeşitli filtreler uygulanarak özellik haritaları oluşturulur. Bu katmanda, görüntünün özellikleri (kenarlar, renk blokları, doku vb.) tespit edilir.

Havuzlama Katmanı (Pooling Layer): Oluşturulan özellik haritalarının boyutu küçültülür (örneğin maksimum havuzlama ile). Bu işlem, modelin odaklanması gereken özellikleri belirginleştirirken hesaplama maliyetini azaltır.

Aktivasyon Fonksiyonu (Activation Function): Genellikle ReLU (Düzeltilmiş Doğrusal Birim) gibi bir aktivasyon fonksiyonu kullanılır. Bu fonksiyon, modelin doğrusal olmayan özellikler öğrenmesini sağlar.

Tam Bağlantılı Katman (Fully Connected Layer): Tüm özellikler tek bir vektöre dönüştürülür ve bu vektör, sınıflandırma gibi daha karmaşık işlemler için kullanılır.

Çıkış Katmanı (Output Layer): Modelin sonucu burada üretilir. Örneğin, görüntüdeki nesnelerin hangi kategorilere ait olduğu bu katmanda belirlenir.

Bu şematik gösterim, CNN'in nasıl çalıştığını ve görüntülerden otomatik olarak özellik çıkarmak ve sınıflandırmak için nasıl kullanıldığını basit bir şekilde anlatır. Görüntü işleme, otonom sürüş sistemleri, yüz tanıma ve daha birçok alanda kullanılan bu yapay zeka modeli, karmaşık görsel verileri etkili bir şekilde işleyebilir.


3.3.2 Nesne Tespiti (Object Detection)

Nesne tespiti (object dedection), görüntüler veya videolar içindeki nesnelere tanımlamak ve sınıflandırmak için kullanılan bir teknolojidir. Bu teknoloji, güvenlik sistemlerinden sağlık hizmetlerine, perakende sektöründen otomotiv sanayine kadar pek çok farklı alanda uygulama bulmaktadır. Nesne tespiti, yapay zeka modellerinin, görüntü içindeki nesnelere saptayarak bunları çeşitli kategorilere ayırma kabiliyetine dayanır. Nesne tespiti modellerinin başında; R-CNN (Regions with Convolutional Neural Networks) ile her bölgeyi ayrı ayrı sınıflandırarak nesne tespiti yapar. YOLO (You Only Look Once) ise görüntüyü tek bir işlemde analiz ederek nesnelere saptar ve sınıflandırır. SSD (Single Shot MultiBox Detector): YOLO gibi tek bir seferde nesne tespiti ve sınıflandırma yapar, ancak farklı ölçeklerdeki nesnelere tespit etme konusunda daha iyidir.

3.3.3 Görüntü Segmentasyonu (Image Segmentation)

Görüntü segmentasyonu, dijital bir görüntüyü anlamak ve analiz etmek için kullanılan bir görüntü işleme tekniğidir. Bu teknik, bir görüntüyü oluşturan farklı

nesne veya bölgeleri ayırt edebilmek için görüntüyü birden fazla parçaya (segmentlere) böler. Her segment, belirli bir özelliği, nesneyi veya bölgeyi temsil eder ve genellikle benzer özellikler (renk, doku, yoğunluk, parlaklık vb.) paylaşır. Görüntü segmentasyonunun amacı, görüntü içindeki anlamlı yapıları izole etmek ve daha sonraki analiz veya görsel tanıma görevleri için kullanılabilir hale getirmektir.



Şekil 3.4: Süper piksel ön segmentasyonu ile hazırlanmış mısır görüntüsü (Wang ve diğ. 2020)

3.4 Tek Aşamalı Nesne Tespit Metotları

Tek aşamalı nesne tespit metotları; görüntülerde nesnelerin konumlarını ve sınıflarını hızlı ve verimli bir şekilde belirlemeye yönelik algoritmalarıdır. Bu metotlar, bir görüntüyü doğrudan bir kerede işleyerek nesnelerin tespiti ve sınıflandırmasını gerçekleştirir. Tek aşamalı yöntemler, genellikle yüksek hızları sayesinde gerçek zamanlı uygulamalar için tercih edilir.

3.4.1 YOLO Metodu (You Look Only Once)

Nesne algılama alanında, YOLO her zaman en popüler derin öğrenme modellerinden biri olmuştur. YOLO, tüm görüntüyü birden fazla ızgaraya bölen ve her

Şekil 3.5 Coco'nun hazır veri setiyle hazırlanmış karşılaştırmalı performans grafiğinden de anlaşılacağı üzere YOLO her geçen güncellemede kendini daha da geliştirip daha iyi sonuçlar verdiğini görebiliriz.

3.4.2 SSD Metodu (Single Shot Multibox)

SSD (Single Shot Multibox) görüntülerdeki nesnelerin hem konumlarını hem de sınıflarını hızlı ve verimli bir şekilde tespit etmek için kullanılan tek aşamalı nesne tespit algoritmasıdır. SSD, hem yüksek hız hem de makul doğruluk sağlayarak nesne tespiti için ideal bir yöntemdir. YOLO gibi tek aşamalı bir yöntemdir, ancak farklı ölçeklerde özellik haritalarını kullanarak daha geniş bir nesne boyutu aralığını tespit edebilme yeteneğine sahiptir. SSD, görüntüyü tek bir aşamada işleyerek her bir nesne için sınır kutusu (bounding box) ve sınıf tahmini yapar. SSD, farklı özellik haritaları üzerinde çalışarak hem küçük hem de büyük nesnelere tespit eder.

Tablo 3.1: YOLO ile SSD metodunun karşılaştırılması

KRİTER	YOLO	SSD
Hız	Çok hızlı	Hızlı
Doğruluk	Yüksek	Yüksek
Küçük Nesne Tespiti	Düşük	Yüksek
Ölçeklenebilirlik	Tek ölçekli çalışır	Farklı ölçek kullanılabilir
Mimari	Basit ve kompakt	Çok katmanlı, karmaşık
Gerçek Zamanlı Kullanım	Çok uygun	Uygun
Kullanım Alanları	Otonom araçlar, görüntü işleme	Dronlar, mobil cihazlar

4. MISIR VE YABANCI OTLARIN TESPİTİ

4.1 Elektriksel ve Mekanik Tasarım ve Özellikleri



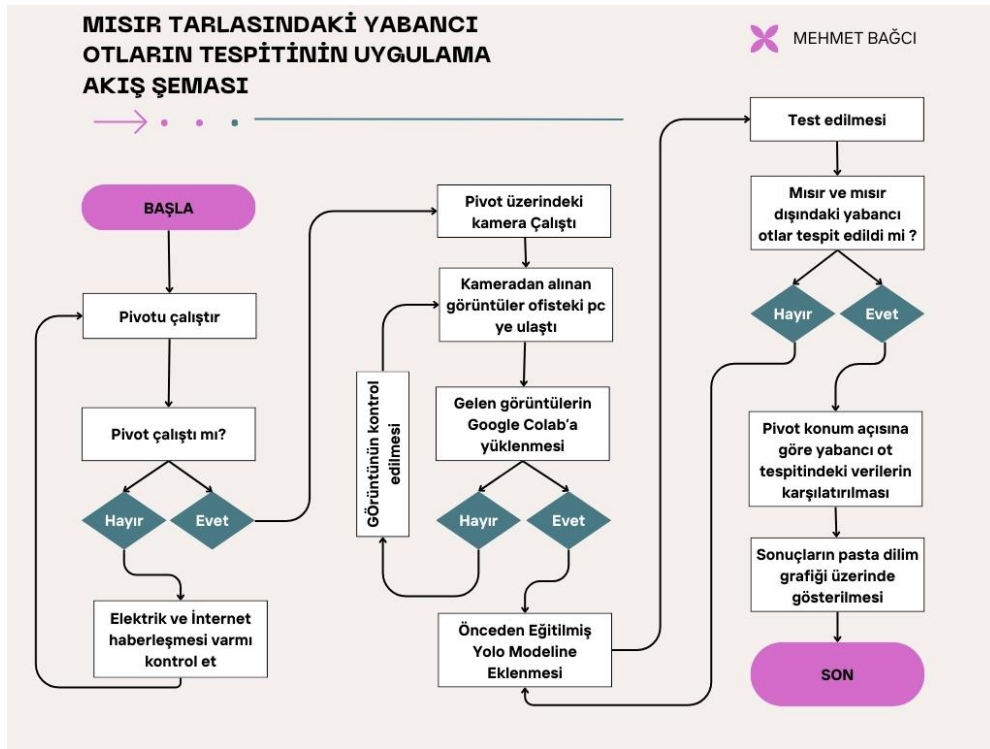
Şekil 4.1: İp kameranın pivot üzerine montajı

Pivot üzerine montajı yapılan kameranın enerji bağlantısı, pivot üzerinde bulunan enerji panosundaki 220/12V dönüştürücü ile sağlanmaktadır. Pivot her çalıştığında pano enerjilenecek ve dolayısıyla kamera ve haberleşme sistemi de çalışacaktır. Kamera üzerinde 64gb'lık mini sd kart bulunmaktadır. Buradaki görüntülerin bu sd kart üzerine kaydedilmesi sağlanmıştır. Kaydedilen bu görüntüler router görevi gören Mikrotik marka 5Ghz 16dbi lık anten yardımıyla, şirketti internet bağlantısı kablosuz olarak pivota aktarılır. Menzili yaklaşık olarak 10km civarındadır. Bu anten yardımıyla kameranın sd kartındaki görüntülere erişim ofisteki pc den kolaylıkla erişile bilinmektedir. Böylece sahadan alınan görüntüler birkaç saniye gecikme ile görüntü işlemeye dahil edilir.

4.2 Sistemin Modellenmesi ve Çalışma Prensibi

4.2.1 Akış Diyagramı ve Sistemin Çalışma Prensibi

Bu çalışmada iki adet akış diyagramı mevcuttur. Elde edilen görüntüler ile görüntü işleme adımlarının model oluşturulup sistem eğitilerek görüntü işlemeye hazır hale gelmiştir. Ardından şekil 4.2’teki akış diyagramındaki gibi uygulama adımları izlenerek araziden elde edilen görüntülerden mısır dışındaki yabancı otların tespitini yapmak hedeflenmiştir.



Şekil 4.2: Uygulama akış diyagramı

4.2.2 Görüntülerin Toplanıp Veri Setinin Oluşturulması İşlemi

Arazideki şekil 4.1’deki pivot üzerindeki kamera ile mısır ve yabancı ot görüntüleri toplanır. Bu çalışmada mısır tarlasından alınan 540 adet görüntü ile veri seti oluşturulmuştur. Bu görüntülerdeki mısır ve yabancı ot tanımlamalarını yapmak için mısırlar ve yabancı otlar kutucuk içerisine alıp sınıflandırılarak işaretlenmiştir. Bu

işlemi farklı uygulamak ya da programlar ile yapmak mümkündür. Şekil 4.3'te Labelimg uygulaması ile tanımlamalar ve kutucuk işaretlemeleri yapılmıştır.



Şekil 4.3: Nesne tespiti işleminden önce mısırların tespiti ve işaretlenmesi (Zhao ve diğ.,2023)

Veri seti oluşturup bu veri setindeki görüntüleri sınıflandırıp kutucuk yardımı ile sınırları belirlenmiştir. Bu çalışmada Roboflow adlı uygulama kullanılmıştır. Roboflow'un ayrıntılı olarak tanımı aşağıda verilmiştir.

Roboflow, bilgisayarlı görme (computer vision) projeleri için veri setlerini yönetmeyi, etiketlemeyi sağlayan bir platformdur. Roboflow, bilgisayarla görme projelerini daha kolay, hızlı ve verimli bir şekilde yürütmek için güçlü bir platformdur. Veri etiketleme, veri zenginleştirme, model eğitimi ve dağıtım gibi süreçlerde kapsamlı bir çözüm sunarak görüntü işleme projelerinde kullanıcıların iş yükünü hafifletir ve sonuçları iyileştirir. Roboflow'un Temel Kullanım Amaçları aşağıda verilmiştir.

Veri Toplama ve Yönetme: Görüntü verilerini toplama, düzenleme ve yönetme sürecini kolaylaştırır. Farklı kaynaklardan görüntüleri toplayabilir ve projelere entegre edebilir. Platform, veri kümelerini kolayca yüklemenize, görüntülerinizi etiketlemenize ve organize etmenize olanak tanır.

Veri Etiketleme (Annotation): Roboflow, veri etiketleme sürecini hızlandırır ve basitleştirir. Nesne tespiti, segmentasyon veya görüntü sınıflandırma için görüntüleri

manuel veya otomatik olarak etiketlemenizi sağlar. Etiketleme araçları sayesinde, görüntülerdeki nesnelerin konumları (bounding box), sınıfları ve özellikleri kolayca tanımlanabilir.

Veri Zenginleştirme ve Dönüştürme (Augmentation): Görüntü verilerini artırmak için veri zenginleştirme (augmentation) teknikleri sunar. Bu teknikler arasında döndürme, yansıtma, yeniden boyutlandırma, parlaklık ayarları gibi işlemler bulunur. Bu sayede modelin daha çeşitli veri kümeleri üzerinde eğitilmesini sağlayarak modelin genel performansını artırır.

Model Eğitimi (Training): Roboflow, eğitim verilerini hazırladıktan sonra farklı model mimarileriyle (örneğin, YOLO, SSD, Faster R-CNN gibi) model eğitimi yapmanıza olanak tanır. Platform, kullanıcıların kendi bilgisayarlarında veya bulut tabanlı GPU kaynaklarında modelleri eğitmelerine destek sağlar.

Model Dağıtım (Deployment): Eğitim tamamlandıktan sonra, modelin API'ler aracılığıyla her yerde anlık olarak kullanılması için dağıtım çözümleri sunar. Roboflow, modelinizi bulut üzerinde barındırarak görüntü tespiti ve sınıflandırma işlemlerini gerçek zamanlı olarak uygulamanızı sağlar.

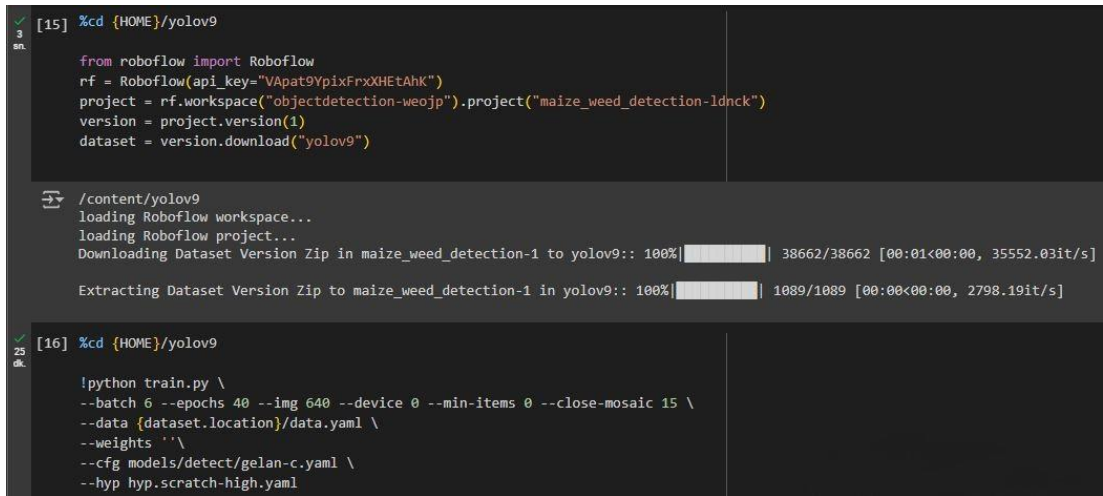
Desteklenen Formatlar ve Model Çıktıları: Roboflow, eğitim ve çıktı dosyalarının farklı makine öğrenmesi arayüzleriyle uyumlu olmasını sağlar. YOLO, TensorFlow, PyTorch gibi farklı derin öğrenme çerçevelerini destekler. Farklı dosya formatlarında veriler model eğitime uygun hale getirebilir.



Şekil 4.4: Roboflow ile mısır ve yabancı otların seçilip sınıflandırılması

4.2.3 Google Colab ile Python Dilinde Programlanması

Google Colab, veri bilimi ve makine öğrenmesi amacıyla yaygın olarak kullanılan bir platformdur. Bulut tabanlı bir hizmet olan Jupyter Notebook'un bir türevidir. Araştırma, öğrenme ve proje geliştirme için kullanılır. Bulut tabanlı bir hizmet olduğu için internet tarayıcınız üzerinden erişilebilir ve güçlü bir donanım gerektiren işlemleri gerçekleştirilebilir. Colab, ücretsiz kaynaklar sunarıyla proje geliştirme için maliyetlerini düşürmeye yardımcı olur. Python kodunu hücrelere ayırarak etkileşimli bir şekilde çalışmasına olanak sağlar. Kod parçaları adım adım çalıştırabilir, sonuçlar görüntülenebilir ve belgeleme yapılabilir. Veri analizi, veri görselleştirme, makine öğrenmesi ve derin öğrenme gibi veri bilimi ve yapay zekâ alanlarında çalışmak için ideal bir platformdur. Colab üzerinden projeler paylaşılabilir ve iş birliği yapmayı kolaylaştırır. Büyük veri kümeleriyle çalışmaya ve işlemleri hızlandırmak için GPU veya TPU gibi yüksek performanslı donanımları kullanma olanağı sağlar. Böylece, karmaşık veri analizleri, model eğitimi veya büyük ölçekli hesaplamalar gibi görevleri daha hızlı gerçekleştirilebilir.



```
[15] %cd {HOME}/yolov9
from roboflow import Roboflow
rf = Roboflow(api_key="VApat9YpifrxXXHtAhk")
project = rf.workspace("objectdetection-weojp").project("maize_weed_detection-1dnck")
version = project.version(1)
dataset = version.download("yolov9")

/content/yolov9
loading Roboflow workspace...
loading Roboflow project...
Downloading Dataset Version Zip in maize_weed_detection-1 to yolov9:: 100%|██████████| 38662/38662 [00:01<00:00, 35552.03it/s]

Extracting Dataset Version Zip to maize_weed_detection-1 in yolov9:: 100%|██████████| 1089/1089 [00:00<00:00, 2798.19it/s]

[16] %cd {HOME}/yolov9
!python train.py \
--batch 6 --epochs 40 --img 640 --device 0 --min-items 0 --close-mosaic 15 \
--data {dataset.location}/data.yaml \
--weights '' \
--cfg models/detect/gelan-c.yaml \
--hyp hyp.scratch-high.yaml
```

Şekil 4.5: Google Colab'a Roboflow'daki veri setimizin ve Yolo v9'un yüklenmesi

Bu çalışmada Şekil 4.5'ten anlaşılacağı üzere her eğitim döngüsünde (iterasyon) işlenecek olan 6 görüntü sayısı (batch) belirlenmiştir. Eğitim setinin tamamının kaç kez işleneceğini (epoch) belirler. Bu durumda, model veri seti üzerinde 40 kez eğitilecek. Eğitim sırasında kullanılacak görüntülerin boyutunu belirtir. Her bir

görüntü 640x640 piksel olarak yeniden boyutlandırılacak. Eğitimin hangi cihazda (örneğin bir GPU) gerçekleştirileceğini belirtir. "0" ilk GPU'yu işaret eder. Eğitim görüntüsünde bulunması gereken minimum nesne sayısını 0 olarak belirlenmiştir. Bu durumda, sıfır nesne içeren görüntüler dahi eğitimde kullanılabilir. Görüntülerinin mozaik işlemi sırasında nesnelerin birbirine ne kadar yakın olabileceğini 15 piksel cinsinden mesafesi belirlenmiştir. Weight ise eğitime başlarken kullanılacak önceden eğitilmiş ağırlık belirtilir. Tırnak işareti içerisine herhangi bir şey yazılmadığı için bu eğitimde hazır ağırlık kullanılmayıp, kendi ağırlık modelimizi oluşturacağımız anlamına gelir.

5. BULGULAR VE TARTIŞMALAR

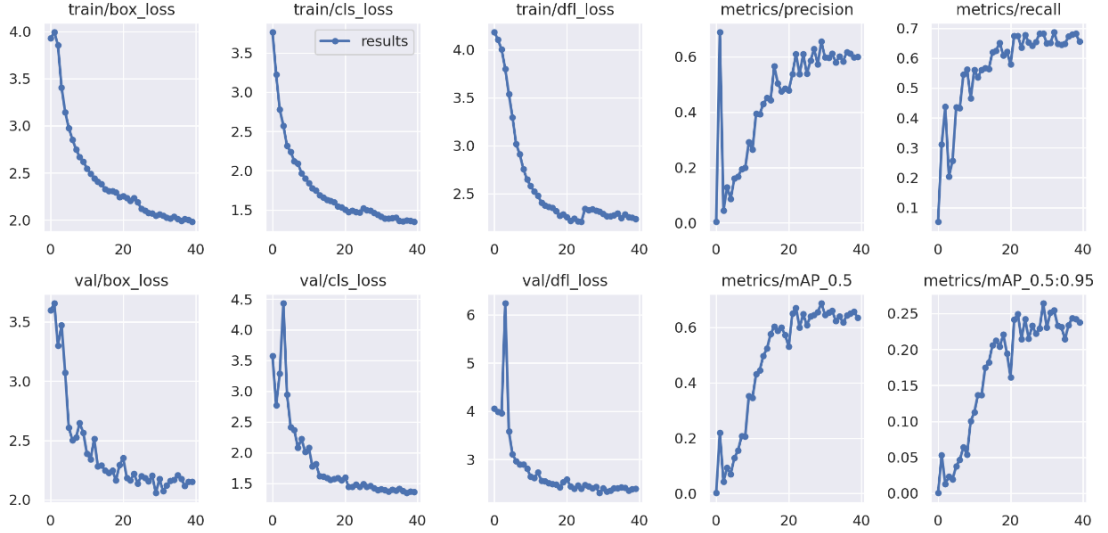
Bu çalışmada şekil 4.5'teki API ile veri seti yüklemesi ve sonrasında YOLO modelimizin eğitimini tamamladı. Öğrenme seti için (Train Set) 513 görüntü, Doğrulama seti için (Validation Set) ise 27 görüntü kullanılmıştır. Modelimiz bulut tabanlı Google Colab üzerinden eğitimi yaklaşık olarak 25 dakika sürmüştür. Colab'ın bize sunduğu nvidia Tesla T4 grafik kartı ile yüksek GPU, 2560 cuda çekirdek sayısı, 320 adet Tensorflow çekirdeği, 51gb gddr6 ram bellek ve 15gb grafik kartı sayesinde eğitim işlemi kısa sürede tamamlanmıştır. Bu işlem sıradan bilgisayarlar üzerinden yapılmış olsaydı uzun vakitler alabilirdi.

```
Epoch GPU_mem box_loss cls_loss dfl_loss Instances Size
38/39 8.16G 2.002 1.359 2.249 69 640: 100% 86/86 [00:30<00:00, 2.78it/s]
Class Images Instances P R mAP50 mAP50-95: 100% 3/3 [00:00<00:00, 3.89it/s]
all 27 909 0.597 0.682 0.656 0.242

Epoch GPU_mem box_loss cls_loss dfl_loss Instances Size
39/39 8.16G 1.979 1.348 2.236 72 640: 100% 86/86 [00:30<00:00, 2.78it/s]
Class Images Instances P R mAP50 mAP50-95: 100% 3/3 [00:00<00:00, 3.89it/s]
all 27 909 0.6 0.655 0.634 0.238

0 epochs completed in 0.406 hours.
ptimizer stripped from runs/train/exp/weights/last.pt, saved as runs/train/exp/weights/last_stripped.pt, 51.5MB
ptimizer stripped from runs/train/exp/weights/best.pt, saved as runs/train/exp/weights/best_stripped.pt, 51.5MB
```

Şekil 5.1: Eğitim modelinin son iterasyonundaki veriler



Şekil 5.2: Modelimizin eğitim süreçlerindeki grafikleri

Şekil 5.2’de her bir grafik, modelin farklı yönlerini değerlendiren ölçümleri elde ederiz.

Eğitim Kutu Kaybı (train/box_loss): Modelin eğitim sürecinde, tahmin ettiği sınırlayıcı kutuların gerçek kutularla olan farkını ölçen kayıptır. Bu metrik zamanla düzenli bir şekilde azalmaktadır, bu da modelin kutu tahminlerinin giderek daha doğru hale geldiğini gösterir.

Doğrulama Kutu Kaybı (val/box_loss): Doğrulama setindeki kutu kaybı, eğitim setine benzer şekilde düşüş göstermektedir fakat bazı yükselmelerle daha dalgalı bir seyir izlemektedir. Bu, modelin yeni verilere karşı hala bazı hatalar yapabileceğini işaret eder.

Eğitim Sınıflandırma Kaybı (train/cls_loss): Modelin nesne sınıflarını ne kadar doğru tahmin ettiğini gösteren kayıptır. Bu değer de zamanla düşmekte, modelin sınıflandırma doğruluğunun arttığını göstermektedir.

Doğrulama Sınıflandırma Kaybı (val/cls_loss): Doğrulama setinde sınıflandırma kaybı, eğitim setindekinden daha dalgalı olmakla birlikte, genel bir düşüş trendi gösterir.


Eğitim/Derinlik Kaybı ve Doğrulama/ Derinlik Kaybı (df_loss ve val/df_loss): Bu grafikler, modelin eğitim ve doğrulama süreçlerindeki derin özellik kaybını gösterir. Her iki grafikte de genel bir düşüş görülmekte, ancak özellikle doğrulama kaybında sert dalgalanmalar dikkat çekicidir. Bu, modelin bazı durumlarda derin özellikleri tutarlı bir şekilde öğrenemediğini gösterebilir.

Hassasiyet (Precision): Modelin yaptığı doğru pozitif tahminlerin, toplam pozitif tahminlere oranını gösterir. Bu oranın yükselmesi, modelin yanlış alarm sayısını azalttığını gösterir.

Geri Çağırma (Recall): Gerçekte pozitif olan durumların, model tarafından ne kadarının doğru tahmin edildiğini gösterir. Artan bir eğilim, modelin daha fazla gerçek pozitif kaçırmadığını gösterir.

Ortalama Kesinlik Oranı (mAP) 0.5: Bu metrik, Intersection over Union (IoU) değeri 0.5 olan durumlarda modelin performansını ölçer. Artan eğilim, modelin bu kesinlik düzeyinde iyileştiğini gösterir.

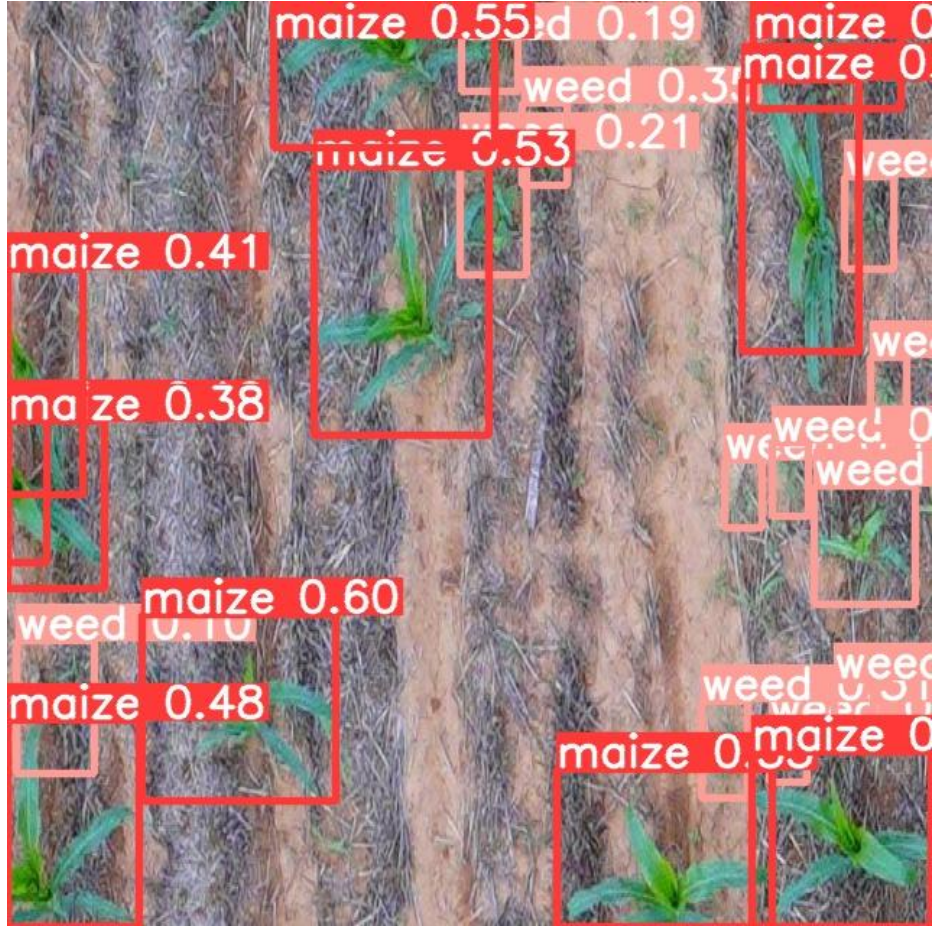
Ortalama Kesinlik Oranı (mAP) 0.5:0.95: Bu geniş aralıkta mAP, modelin 0.5'den 0.95'e kadar olan IoU değerleri için genel performansını değerlendirir. İyileşme gösteren bu eğilim, modelin çeşitli IoU değerlerinde iyi performans gösterdiğini işaret eder.



Şekil 5.3: Modelimizin karışıklık matrisi

Şekil 5.3'teki karışıklık matrisi modelin gerçekte olan sınıfları (mısır, yabancı ot ve arka plan) tahmin edilen sınıflarla nasıl eşleştirdiğini gösterir. Bu matris, modelin sınıflandırma performansını değerlendirmek için kullanılır. Model mısırı mısır olarak tahmin etme oranı %96 (0.96) olarak çok yüksektir. Bu, modelin mısırı doğru bir şekilde tanıma konusunda oldukça başarılı olduğunu gösterir. Ancak, model mısırı yabancı ot olarak %4 (0.04) oranında yanlış tanımıştır. Yabancı otu doğru olarak tahmin etme oranı %44 (0.44), bu modelin yabancı ot sınıfında zayıf performans gösterdiğini işaret eder. Yabancı otun %56'sı yanlışlıkla arka plan olarak sınıflandırılmıştır. Bunun

sebebi veri setindeki eğitimde kullanılan görüntülerdeki otların büyük, fakat gerçekte test için kullanılan görüntüdeki otların küçük olmasından kaynaklanmıştır. Bu sebepten dolayı çok küçük yabancı otlar arka plan ile ayrıştırması karışmış ve ayrıştırıp sınıflandırması zor hale gelmiştir.



Şekil 5.4: Test görüntüsündeki tespit edilen mısır ve yabancı otlar

6. SONUÇ VE ÖNERİLER

Bu çalışmada mısır tarlasındaki mısırların ve yabancı otların tespiti yapılarak bölgesel olarak tespit edilip, o bölgelere lokal herbisit uygulaması yapılması sağlanmıştır. Modelimiz mısırları yüksek doğrulukta tespit ederken, yabancı otları tespit etme durumu istenilenden biraz düşük kalmıştır. Bunun sebebi zeminde kuru ot yoğunluklarının fazla olması, eğitim veri setindeki seçilen yabancı otların büyük boyutta olup, gerçekte daha küçük otların var olması durumundan kaynaklanmaktadır. Bunun çözümü için ise veri setindeki görüntü sayısını arttırarak ve zemini çeşitli filtreler yardımıyla filtreleyerek görüntülerde sadece mısır ve yabancı otların kalması sağlanarak bu durum çözülebilir. Bir diğer yöntem ise modelin aşırı uyumu (overfitting) yapmadan ise epoch değerini arttırarak tekrar eğitilebilir.

7. KAYNAKLAR

- Bhatt, D., Patel, C., Talsania, H., Patel, J., Vaghela, R., Pandya, S., ... & Ghayvat, H. (2021). CNN variants for computer vision: History, architecture, application, challenges and future scope. *Electronics*, 10(20), 2470.
- Bishop, C. M. (2006). *Pattern recognition and machine learning (Information science and statistics)*. Springer-Verlag.
- Cheng, D., Meng, G., Cheng, G., & Pan, C. (2017). SeNet: Structured edge network for sea-land segmentation. *IEEE Geoscience and Remote Sensing Letters*, 14(2), 247-251.
- Esteva, A., Chou, K., Yeung, S., Naik, N., Madani, A., Mottaghi, A., ... & Socher, R. (2021). Deep learning-enabled medical computer vision. *NPJ Digital Medicine*, 4(1), 5.
- Fischer, M., Heim, D., Hofmann, A., Janiesch, C., Klima, C., & Winkelmann, A. (2020). A taxonomy and archetypes of smart services for smart living. *Electronic Markets*, 30(1), 131-149.
- Funcs., Artificial neuron tructure [online], (15.09.2024), Web adresi: https://commons.wikimedia.org/wiki/File:Artificial_neuron_structure.svg#mw-jump-to-license , (2024).
- Heidler, K., Mou, L., Baumhoer, C., Dietz, A., & Zhu, X. X. (2021). HED-UNet: Combined segmentation and edge detection for monitoring the Antarctic coastline. *IEEE Transactions on Geoscience and Remote Sensing*, 60, 1-14.
- Janiesch, C., Zschech, P., & Heinrich, K. (2021). Machine learning and deep learning. *Electronic Markets*, 31(3), 685-695.
- Jiang, Z., Chen, Z., Ji, K., & Yang, J. (2020). Semantic segmentation network combined with edge detection for building extraction in remote sensing images. In *Proceedings of SPIE (Vol. 11430)*.
- Kaur, A., & Kranthi, B. V. (2012). Comparison between YCbCr color space and CIE Lab color space for skin color segmentation. *International Journal of Applied Information Systems*, 3(4), 30-33.
- Kısa, M. (2019). Grafik tasarım ve baskı ortamında kullanılan görsellerin RGB renk uzayından CMYK renk uzayına dönüşümü esnasında oluşan renk ve ton kayıplarının önlenmesi. *Humanities Sciences*, 14(2), 25-31.
- McCarthy, J., Minsky, M. L., Rochester, N., & Shannon, C. E. (2006). A proposal for the Dartmouth summer research project in artificial intelligence, 1955. *AI Magazine*, 27(1), 12-14.

- Ofer, D., Brandes, N., & Linial, M. (2021). The language of proteins: NLP, machine learning & protein sequences. *Computational and Structural Biotechnology Journal*, 19, 1750-1758.
- Shrestha, Y. R., Krishna, V., & von Krogh, G. (2021). Augmenting organizational decision-making with deep learning algorithms: Principles, promises, and challenges. *Journal of Business Research*, 123, 588-603.
- Steduto, P., Hsiao, T. C., & Fereres, E. (2012). Crop yield response to water. Food and Agriculture Organization of the United Nations. Retrieved from <http://www.fao.org/3/i2800e/i2800e.pdf>
- Wang, C.-Y., & Liao, H.-Y. M. (2024). YOLOv9: Learning what you want to learn using programmable gradient information. arXiv preprint arXiv:2402.13616.
- Wang, P., Zhang, Y., Jiang, B., & Hou, J. (2020). An maize leaf segmentation algorithm based on image repairing technology. *Computers and electronics in agriculture*, 172, 105349.
- Yılmaz, N., & Aydın, O. (2021). Mısır bitkisinde (*Zea mays* L.) yabancı otların mücadele yöntemlerinin bazı bitkisel özellikler ve kalite üzerine etkileri. Ordu Üniversitesi, Ziraat Fakültesi, Tarla Bitkileri Bölümü.
- Zhao, K., Zhao, L., Zhao, Y., & Deng, H. (2023). Study on lightweight model of maize seedling object detection based on YOLOv7. *Applied Sciences*, 13(13), 7731