T.C.
ERCİYES ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİYOSİSTEM MÜHENDİSLİĞİ ANABİLİM DALI

SERALARDA YETİŞTİRİCİLİĞİ YAPILAN DOMATES BİTKİSİNDE GÖRÜLEN DOMATES BAKTERİYEL BENEK HASTALIĞI (*Pseudomonas syringae* pv. *tomato*)'NIN GÖRÜNTÜ İŞLEME TEKNİKLERİ KULLANILARAK BELİRLENMESİ

Hazırlayan
İsmail ÖZTÜRK

Danışman
Doç. Dr. Bahadır DEMİREL

Yüksek Lisans Tezi

Haziran 2024
KAYSERİ

T.C.
ERCİYES ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİYOSİSTEM MÜHENDİSLİĞİ ANABİLİM DALI

SERALARDA YETİŞTİRİCİLİĞİ YAPILAN DOMATES BİTKİSİNDE GÖRÜLEN DOMATES BAKTERİYEL BENEK HASTALIĞI (*Pseudomonas syringae* pv. *tomato*)'NIN GÖRÜNTÜ İŞLEME TEKNİKLERİ KULLANILARAK BELİRLENMESİ

(Yüksek Lisans Tezi)

Hazırlayan
İsmail ÖZTÜRK

Danışman
Doç. Dr. Bahadır DEMİREL

Bu çalışma, Erciyes Üniversitesi Bilimsel Araştırma Projeleri Birimi tarafından FYL-2022-11958 kodlu proje ile desteklenmiştir.

Haziran 2024
KAYSERİ

BİLİMSEL ETİĞE UYGUNLUK

Bu çalışmadaki tüm bilgilerin, akademik ve etik kurallara uygun bir şekilde elde edildiğini beyan ederim. Aynı zamanda bu kural ve davranışların gerektirdiği gibi, bu çalışmanın özünde olmayan tüm materyal ve sonuçları tam olarak aktardığımı ve referans gösterdiğimi belirtirim.

İsmail ÖZTÜRK

“Seralarda Yetiştiriciliği Yapılan Domates Bitkisinde Görülen Domates Bakteriyel Benek Hastalığı (*Pseudomonas syringae* pv. *tomato*)'nın Görüntü İşleme Teknikleri Kullanılarak Belirlenmesi” adlı Yüksek Lisans Tezi, Erciyes Üniversitesi Lisansüstü Tez Önerisi ve Tez Yazma Yönergesi’ ne uygun olarak hazırlanmıştır.

Hazırlayan	**Danışman**
İsmail ÖZTÜRK	Doç. Dr. Bahadır DEMİREL
İmza	

Biyosistem Mühendisliği ABD Başkanı

Prof. Dr. Sinan GERÇEK

İmza

TEŞEKKÜR

Çalışmalarım boyunca bana her türlü yardım ve fedakarlığı sağlayan, başta ailem ve hocalarım Doç. Dr. Bahadır DEMİREL, Doç. Dr. Sümer HORUZ ve Doç. Dr. Bilal BABAYİĞİT'e emekleri için teşekkür ederim.

İsmail ÖZTÜRK

Haziran 2024, KAYSERİ

SERALARDA YETİŞTİRİCİLİĞİ YAPILAN DOMATES BİTKİSİNDE GÖRÜLEN DOMATES BAKTERİYEL BENEK HASTALIĞI (*Pseudomonas syringae* pv. *tomato*)'NIN GÖRÜNTÜ İŞLEME TEKNİKLERİ KULLANILARAK BELİRLENMESİ

İsmail ÖZTÜRK

Erciyes Üniversitesi, Fen Bilimleri Enstitüsü
Yüksek Lisans Tezi, Haziran 2024
Danışman: Doç. Dr. Bahadır DEMİREL
İkinci Danışman: Doç. Dr. Sümer HORUZ

ÖZET

Domatesin kalite ve verimliliği, yetiştirme sürecinde dikkatli izleme ve doğru müdahalelerin zamanında yapılmasına bağlıdır. Bu çalışmada, *Pseudomonas syringae pv. tomato*'nun (*Pst*) neden olduğu domateste bakteriyel leke hastalığının yaprakta oluşturduğu nekrozların düzeyinin görüntü işleme teknikleri kullanılarak belirlenmesi amaçlanmıştır. Serada yürütülen denemelerde sırık çeşit domates fideleri kullanılmıştır. Patojen bakteri, domates fidelerinin yapraklarına püskürtüldükten sonra yapraklarda kloroz ve nekroz gibi tipik hastalık belirtileri gözlenene kadar 20-24°C ve %70-80 nemde tutulmuştur. Görüntü işleme ve bilgisayarla görme görevlerini yerine getirebilen Python kütüphanesi olan OpenCV kullanılarak hastalığın ilk teşhisi yapılmıştır. Yaprak görüntülerinin incelenmesi sonucunda elde edilen verilere göre, hastalık yüzdesi ve gözlem aralıkları belirlenmiştir. Skala 0'da hastalık yüzdesi %0.00, Skala 1'de %8.64, Skala 2'de %24.94, Skala 3'te %27.78, Skala 4'te %62.97, Skala 5'te ise %89.69 olarak tespit edilmiştir. Hastalık tespit oranının artmasıyla doğruluk oranının yüksekliği paralelinde standart sapmanın azaldığı belirlenmiştir. Skala 1'de 0.02695 olan standart sapma, Skala 5'te 0.02131'e düşmüştür. Kullanılan algoritmalar, hastalık şiddeti arttıkça bakteriyel lekeleri daha doğru bir şekilde tespit etmiş ve bu süreçte standart hata azalmıştır. Sera ortamında yapılan araştırmanın sonuçları, benzer ortamlarda uygulandığında, hastalıkların erken teşhis edilmesine olanak sağlayarak ürün kaybını azaltabileceğini göstermiştir

Anahtar Kelimeler: Python, OpenCV kütüphanesi, Görüntü İşleme, Domates, Bakteriyel Benek Hastalığı

DETERMINATION OF TOMATO BACTERIAL SPOT DISEASE (*Pseudomonas syringae* pv. *tomato*) ON TOMATO PLANT GROWN IN GREENHOUSES USING IMAGE PROCESSING TECHNIQUES

İsmail ÖZTÜRK

Erciyes University, Graduate School of Natural and Applied Sciences
Master Thesis, June 2024
Supervisor: Assoc. Prof. Dr. Bahadır DEMİREL
Second Supervisor: Assoc. Prof. Dr. Sümer HORUZ

ABSTRACT

The quality and productivity of tomato depends on careful monitoring and timely interventions during the growing process. The aim of this study was to determine the level of leaf necrosis caused by bacterial spot disease of tomato caused by Pseudomonas syringae pv. tomato (Pst) using image processing techniques. Pole variety tomato seedlings were used in the greenhouse experiments. After the pathogenic bacteria were sprayed on the leaves of tomato seedlings, they were kept at 20-24°C and 70-80% humidity until typical disease symptoms such as chlorosis and necrosis were observed on the leaves. The initial diagnosis of the disease was made using OpenCV, a Python library that can perform image processing and computer vision tasks. According to the data obtained as a result of examining the leaf images, the disease percentage and observation intervals were determined. The disease percentage was 0.00% in Scale 0, 8.64% in Scale 1, 24.94% in Scale 2, 27.78% in Scale 3, 62.97% in Scale 4 and 89.69% in Scale 5. As the disease detection rate increased, the standard deviation decreased in parallel with the increase in the accuracy rate. The standard deviation decreased from 0.02695 at Scale 1 to 0.02131 at Scale 5. The standard error decreased as the algorithms used detected bacterial stains that increased with disease severity. The results of the research conducted in the greenhouse environment have shown that when applied in similar environments, it can allow for the early diagnosis of diseases, thereby reducing product loss.

Keywords: Python, The OpenCV library, Image Processing, Tomato, Bacterial Speck Disease

İÇİNDEKİLER

SERALARDA YETİŞTİRİCİLİĞİ YAPILAN DOMATES BİTKİSİNDE GÖRÜLEN DOMATES BAKTERİYEL BENEK HASTALIĞI (*Pseudomonas syringae* pv. *tomato*)'NIN GÖRÜNTÜ İŞLEME TEKNİKLERİ KULLANILARAK BELİRLENMESİ

BİLİMSEL ETİĞE UYGUNLUK ii
YÖNERGEYE UYGUNLUK ii
KABUL VE ONAY iii
TEŞEKKÜR v
ÖZET vi
ABSTRACT vii
İÇİNDEKİLER viii
KISALTMALAR xi
TABLOLAR LİSTESİ xii
ŞEKİLLER LİSTESİ xiii
GİRİŞ 1

1. BÖLÜM

GENEL BİLGİLER ve LİTERATÜR ÇALIŞMASI

1.1. Genel Bilgiler 4
1.1.1. Görüntü 4
1.1.2. Görüntü İşleme 4
1.1.3. Görüntü İşlemede Kullanılan Bazı Terimler 5
1.1.3.1. Renk Modelleri 5
1.1.3.2. Gri Tonlamalı Renk Uzayı 6
1.1.3.3. RGB (Kırmızı – Yeşil –Mavi) Renk Uzayı 6
1.1.3.4. HSV (Hue – Saturation – Value) Renk Uzayı 8
1.1.3.5. Görüntü Geliştirme 8
1.1.3.6. Histogram Eşitleme 9
1.1.3.7. Filtreleme 10
1.1.3.8. Görüntü Eşikleme 11
1.1.3.9. Morfolojik İşlemler 12
1.1.4. Görüntü İşlemede Kullanılan Bazı Teknikler 12
1.1.4.1. Python 12

1.1.4.2. Opencv **13**
1.1.4.3. Anaconda **15**
1.1.4.4. Sypder **15**
1.2. Problem Durumu **16**
1.3. Araştırmanın Amacı **17**
1.4. Araştırmanın Önemi **17**
1.5. Literatür çalışması **17**

2. BÖLÜM

MATERYAL ve YÖNTEM

2.1. Materyal **24**
2.1.1. Çalışma Alanı **24**
2.1.2. Çalışmada Kullanılan Fotoğraf Makinası **24**
2.1.3. Domates Fideleri **25**
2.1.4. Toprak ve Saksı Özellikleri **25**
2.1.5. OpenCV Kütüphanesi **26**
2.1.6. Domateste Bakteriyel Benek Hastalığı **26**
2.2. Yöntem **27**
2.2.1. Hastalık Etmeni Bakterinin Bulaştırılması **27**
2.2.2. Hastalığın Tespitinde Kullanılan Görsel Skala Hakkında Bilgi **27**
2.2.3. Görüntü Alma **28**
2.2.4. Ön İşleme **28**
2.2.4.1. Arka Plan Çıkarma **29**
2.2.4.2. Renk Dönüşümü **30**
2.2.5. Renk Tabanlı Kümeleme **31**
2.2.6. Bölümlendirme (Segmantasyon) **31**
2.2.7. Kontrast Geliştirme **32**
2.2.8. Yaprak Üzerindeki Hastalık Şiddeti Hesabı **32**

3. BÖLÜM

BULGULAR

3.1. Skalanın Geliştirilmesi ve Test Edilmesi **33**
3.2. Python Sonuçlarının Görsel Skalayla Karşılaştırılması **37**

4. BÖLÜM

TARTIŞMA, SONUÇ ve ÖNERİLER

4.1. Tartışma 40
4.2. Sonuç ve Öneriler 42
KAYNAKÇA 44
ÖZGEÇMİŞ 51

KISALTMALAR

%	: Yüzde
°C	: Santigrat derece
ABD	: Amerika Birleşik Devletleri
BSD	: Berkeley Software Distribution
FAO	: Gıda ve Tarım Örgütü
HSV	: Ton – Doygunluk – Açıklık Uzayı
IDE	: Entegre geliştirme ortamı
İHA	: İnsansız Hava Aracı
MATLAB	: Matrix Laboratory
NDVI	: Normalize Edilmiş Fark Bitki Örtüsü İndeksi
OpenCV	: Open Source Computer Vision
PST	: *Pseudomonas syringae pv. tomato*
XEU	: *Xanthomonas euvesicatoria*
RGB	: Kırmızı-Yeşil-Mavi Renk Uzayı
SPSS	: Statistical Package for the Social Sciences
TUİK	: Türkiye İstatistik Kurumu
CNN	: Konvolüsyonel Sinir Ağları
SLIC	: Simple Linear Iterative Clustering
YSA	: Yapay Sinir Ağları

TABLOLAR LİSTESİ

Tablo 1.1. Karışım oranına göre ortaya çıkan renkler 7
Tablo 2.1. Domates bakteriyel benek hastalığı tespitinde kullanılan 0-5 skalası 27
Tablo 3.1. Hastalık skalası 33
Tablo 3.2. SPSS programı verileri 37
Tablo 3.3. Karşılaştırılan değerler..... 38
Tablo 4.1. Sayısal Veriler 42

ŞEKİLLER LİSTESİ

Şekil 1.1. Gri tonları (0 – 255) 6
Şekil 1.2. RGB renk düzeni 6
Şekil 1.3. RGB renk uzayı bileşenleri. 7
Şekil 1.4. RGB renk uzayı koordinat ekseni 8
Şekil 1.5. Histogram grafiği ve histogram okuma 9
Şekil 1.6. Histogram eşitleme uygulaması 10
Şekil 1.7. Eşikleme uygulaması 11
Şekil 1.8. Morfolojik işlemler 12
Şekil 1.9. OpenCV temel bileşenleri 14
Şekil 2.1. Çalışma alanı 24
Şekil 2.2. Çalışmada kullanılan fotoğraf makinası 25
Şekil 2.3. Domates fidesi 25
Şekil 2.4. Saksı ve yetişmiş domates fideleri 26
Şekil 2.5. Domates bakteriyel benek hastalığı görsel skala 28
Şekil 2.6. Serada ortam nemlendirmesi 28
Şekil 2.7. Arka plan çıkarma 29
Şekil 2.8. RGB görüntüsünü HSV görüntüsüne çevirme 30
Şekil 3.1. Skala 0 seviyesinde yaprak görüntüsü 34
Şekil 3.2. Skala 1 seviyesinde yaprak görüntüsü 34
Şekil 3.3. Skala 2 seviyesinde yaprak görüntüsü 35
Şekil 3.4. Skala 3 seviyesinde yaprak görüntüsü 35
Şekil 3.5. Skala 4 seviyesinde yaprak görüntüsü 36
Şekil 3.6. Skala 5 seviyesinde yaprak görüntüsü 36
Şekil 3.7. Skala verilerinin dağılımları 37
Şekil 3.8. Görsel skala ile python analizi sonucu elde edilen sınır değerlerinin karşılaştırılması 38
Şekil 3.9. Görsel skala ile python analizi sonucu elde edilen maksimum sınır değerleri ile karşılaştırılması 39

GİRİŞ

Dünya genelinde en yaygın yetiştirilen sebzelerden biri domatestir. *Solanaceae* familyasına ait olan bu sebze, *Lycopersicon* cinsinde ve *Solanoideae* alt familyasında yer alır. Domates, meyvesinin yenilebilir olmasıyla bilinen tek yıllık otsu bir bitki türüdür. İsveçli botanikçi *Carolus Linnaeus*, 1753 yılında domates bitkisine *Solanum lycopersicon* adını vermiştir. Ancak, 15 yıl sonra Philip Miller domatesin adını *Lycopersicon esculentum* olarak değiştirmiştir (Taylor, 1986).

Orta ve Güney Amerika domatesin ana vatanıdır. 16. yüzyılın başında İspanyollar domatesi Avrupa'ya tanıttılar. Avrupa'da domatesin bitkisel ürün olarak kabulü ve mutfağa girişi nispeten yavaş olmuştur. Başlangıçta, bu meyve zehirli olarak kabul edilmiş ve peyzajlı alanlarda süs bitkisi olarak yetiştirilmiştir. Domates, Güney Avrupa'da 16. yüzyılın ortalarından beri yetiştirilmekte ve yenmektedir. Domates 18. yüzyılın sonunda Kuzeybatı Avrupa'ya yayılmıştır (Harvey vd., 2002). 17. yüzyılda Avrupalılar, Çin, Güney ve Güneydoğu Asya'ya domatesi tanıtmışlardır. Ardından, 18. yüzyılda Japonya ve Amerika Birleşik Devletleri'ne de domatesi ihraç etmişlerdir. Bu dönemlerde domatesin farklı bölgelere yayılması, kültürel etkileşim ve tarımsal alışverişin bir sonucudur (Engels ve Jeffrey, 1993). Türkiye'ye ise domates 19. yüzyılda Suriye üzerinden getirilmiş ve ilk olarak Adana'da yetiştirilmiştir (Şeniz, 1992).

Domates bilimsel olarak *Solanum lycopersicum* adı ile bilinir. Bitki, *Solanaceae* familyasına ait bir türdür. Aynı ailede patates, biber ve bunlara benzer diğer sebzeler de bulunur. Tek yıllık ve çok yıllık çeşitler bölgeden bölgeye farklı şekilde yayılır. Domates bitkisi 2 çenekli otsu bir bitkidir. Büyüdükçe odunsu bir bitkiye dönüşür. Oluşturduğu kazık kök sistemi 2 metre kadar derinliğe ulaşabilir. Meyvelerini kümeler halinde üretir. Gövdenin üst kısmında 3 tomurcuk oluşur ve bu tomurcuğun gelişimi sona erdiğinde bitki yan göze bir sinyal gönderir ve meyve verir (Colvine ve Branthôme, 1993).

Bitkisel faaliyetlerin önemli bir parçası olan domateste, *Pseudomonas syringae pv. tomato (Pst)* (Okabe) Young, Dye ve Wilkie'nin sebep olduğu domates bakteriyel leke hastalığı, domatesin pazar değerini ve verimini düşüren önemli bir bakteriyel hastalıktır. *Pseudomonas syringae pv. tomato (Pst)*, domatesin yaprak, gövde ve meyvelerinde siyah lekelere ve nekroza neden olan gram-negatif bir bakteridir (Jones vd., 1991).

Bakteriyel benek hastalığı dünyanın birçok yerinde domatesin en önemli hastalıklarından biri olarak kabul edilmektedir. Örneğin, Kuzey Amerika'da Ontario, Kanada ve Kuzey Carolina'da bakteriyel benek hastalığı domates bitkisinde görülen en yaygın hastalık olarak kabul edilmektedir (Wilson vd., 2002).

Tarımda görüntü işleme uygulamaları günümüzde giderek daha fazla popülerlik kazanmaktadır. Bu alandaki en önemli araştırma, nesnelerin renge dayalı olarak ayrılmasıdır. Görüntü işleme yoluyla elde edilen dijital görüntü verileri, geliştirilebilir veya farklı görüntüler elde edilip ilgili bir programa yönelik bir dizi işlem gerçekleştirilerek nesne tanıma gerçekleştirilebilir (Samtaş ve Gülesin, 2012).

Tarımsal verimlilik büyük ölçüde ekonomiye bağlıdır. Hastalık tespitinin tarımda bu kadar önemli bir rol oynamasının nedenlerinden biri, hastalıkların mahsullerde oldukça yaygın olmasıdır. Bu alanda yeterli dikkat gösterilmezse hastalık, mahsulü ciddi şekilde etkileyebilir ve kalitesini, miktarını veya verimliliğini etkileyebilir (Sing ve Misra, 2012).

Bitki hastalıkları ve zararlıları, tarımsal üretimde önemli kayıplara yol açmaktadır. Bu kayıpları en aza indirmek ve mahsul verim kalitesini artırmak için bitki sağlığını izlemek, hastalık ve zararlıları erken tespit etmek ve önlemleri zamanında almak hayati önem taşır. Bu nedenle görüntü işleme teknolojisi önemli bir araçtır. Bu araştırmanın yürütülmesi, derin öğrenme, makine öğrenmesi, modelleme, yapay zekâ, uzman ve otomatik sistemler, otonom traktörler ve tarımsal robotların geliştirilmesine katkı sağlamıştır (Altaş vd., 2018).

Bu çalışmada uygulanan görüntü işleme teknikleri, domates yapraklarında bakteriyel benek hastalığının erken teşhisinde geleneksel gözlem yöntemlerine göre daha yüksek doğruluk ve hız sağlayarak, verim kayıplarını ve ürün kalitesindeki düşüşleri minimize etmede etkili olacaktır.

Türkiye’de Domates Üretimi

Dünyada en yaygın olarak yetiştirilen sebzelerden biri olan domates, ülkemizde de önemli bir yetiştirme alanıdır. Türkiye, domates yetiştiriciliği için elverişli iklim koşulları ve 1970'lerden bu yana domates işleme endüstrisinin gelişmesi sayesinde küresel domates üretiminde önemli bir konuma yükselmiştir (Keskin ve Karakayacı, 2014). Ülkemiz, domates üretiminde Çin, Hindistan, Avrupa Birliği ve ABD'nin ardından dördüncü sırada yer almaktadır. Türkiye, 2014 yılında 11.8 milyon ton domates üretmiştir. 1970 yılından 2014 yılına kadar ülkemizde domates üretimi ortalama 6 kat artarak 1.8 milyon tondan 11.8 milyon tona yükselmiştir. Ülkemizde üretilen domateslerin çoğu taze olarak tüketilmektedir. Türkiye'nin domates verimi yıldan yıla artarak 1970 yılında hektar başına 24.1 ton iken, 2014 yılında hektar başına 64.7 tona yükselmiştir. Ülkemizdeki domates üretimi dünya ortalamasının üstünde bir değerdedir. Türkiye'de domates verimi, yüksek nitelikli tohum kullanımı ve modern üretim sistemleri sayesinde son yıllarda artış göstermiştir (Ertürk ve Çirka, 2015).

FAO verilerine göre 2020 itibariyle Türkiye’de domates üretimi yaklaşık 1.320 milyon ton olup, Çin ve Hindistan'dan sonra dünyanın en büyük 3. domates üretimine sahiptir. TÜİK verilerine göre 2021 yılı itibarıyla Türkiye'nin sebze üretimi yaklaşık 3.2 milyon tondur. Türkiye’de en fazla üretimi yapılan sebzelerden biri olan domates, üretim miktarı açısından 2021 yılı toplam sebze üretiminde %41.2‘lik (13.1 milyon ton) bir paya sahiptir. Türkiye’de domates üretimi hem örtü altında hem de açıkta yapılmaktadır. 2021 yılında Türkiye’de örtü altında 4.4 milyon ton domates üretimi gerçekleşmiştir (FAOSTAT, 2021).

Ülkemizde 1960’lı yıllarda başlayan sanayi domatesi üretiminde tamamıyla açık tozlanan çeşitler kullanılmıştır. Bu süreçte Rio Grande, Rio Fuego, VF-6203, Campel-37, İnterpeel ve T2 Improved çeşitleri büyük alanlarda üretim şansı bulmuşlardır. Türkiye’de 1980’li yılların ortasından itibaren ihracat ve ithalat yollarında başlayan serbest uygulama sonrasında hem ülkemize yurt dışından ithal edilen F1 hibrit sanayi domatesi çeşitleri hem de Türkiye’de faaliyete başlayan yurt dışı kaynaklı tohum firmaları Türkiye’deki sanayi domatesi üretimine yeni bir ivme kazandırmışlardır (Vural vd., 2000).

1. BÖLÜM

GENEL BİLGİLER VE LİTERATÜR ÇALIŞMASI

1.1. Genel Bilgiler

1.1.1. Görüntü

Görüntü, çeşitli yöntemlerle elde edilen bilgileri görsel olarak saklamak ve görüntülemek için kullanılan bir resimdir. Herhangi bir iki boyutlu bilgi bir görüntü olarak ele alınabilir (Ertürk ve Urhan, 2013).

1.1.2. Görüntü İşleme

Görüntü işleme, bir görüntünün kamera veya tarayıcı gibi bir cihaz kullanılarak yakalanması ve değerlendirme sürecinden sonra bilgisayar veya başka bir araç tarafından okunabilecek veya bir dijital ortamdan diğerine aktarılabilecek şekilde dönüştürülmesi işlemidir. Görüntü işleme yöntemleri ile elde edilen görüntüler işlendikten sonra yorumlanmaktadır. Görüntü işlemede, görüntüde bozulmalar varsa bunları düzeltmek için birtakım işlemlerin yapılması gerekmektedir. Bu düzeltme işlemi için de çeşitli yöntemler geliştirilmiştir. Örneğin sınır algılama yöntemi kullanılarak gerekli alanlar tespit edilebilmekte ve diğer gereksiz kısımlar silinebilmektedir. Görüntü işleme temel olarak üç adımda ele alınmakta olup bu adımlar; görüntülerin çeşitli cihazlar kullanılarak elektronik ortama aktarılması, görüntüler üzerinde analitik işlemler gerçekleştirilerek işlenmesi ve işlenen görüntülere ait veri raporlarının ve çıktılarının elde edilmesidir. Görüntü işleme adımının analiz basamağı, görüntü üzerindeki gürültüyü (görüntü bulanıklığı, keskinlik ve kötü görüntüler) azaltmayı amaçlamaktadır. Bu hedefe ulaşmak için, giriş ve çıkış görüntülerinin gerçekliğini filtreleyen düşük seviyeli işlemler uygulanmaktadır. Bu işlemler, temelde görüntüdeki piksel değerlerini düzenleyerek gürültüyü azaltmayı ve görüntü kalitesini artırmayı hedefler (Aksoy, 2021).

Görüntü işleme, çeşitli uygulamalarda kullanılan bir dizi işlemi içerir. Bu işlemler arasında diyafram ayarlarının yapılması, fotoğraflar ve videolar için doğru ışık ve renk kalitesinin ayarlanması, güvenlik taraması için renklerin iyileştirilmesi, keskinliğin artırılması, görüntülerin verimli bir şekilde depolanması ve aktarılması, görüntü boyutunun, renginin ve tonunun ayarlanması, barkodların okunması ve plakaların okunması yer alır. Görüntü işlemenin bir ortamdaki insan sayısını bulma, yüzlerin otomatik olarak gizlenmesi, üç boyutlu görüntülerin oluşturulması, diyafram ayarı, sanal ve gerçek dünya görüntülerinin bileşimi, tıp alanında 3D yazıcılar tarafından oluşturulan nesnelerin görüntülerinin analizi ve basılması gibi birçok uygulama alanı vardır (Aksoy, 2021). Görüntü işleme, görüntü dijital forma dönüştürüldükten sonra elde edilen verilere matematiksel işlemler ve farklı yöntemler uygulayarak farklı çıkarımlar oluşturma veya yeni görüntüler üretme sanatıdır. Görüntü işleme teknikleri bir görüntünün netliğini artırmak, ışık değerlerini değiştirmek veya herhangi bir görüntüyü tanımlamak için kullanılabilir. Araç içi otomasyon sistemlerinden robotik uygulamalara, askeri uygulamalardan tarımsal uygulamalara kadar birçok alanda yaygın olarak kullanılmaktadır (Samtaş ve Gülesin, 2012).

1.1.3. Görüntü İşlemede Kullanılan Bazı Terimler

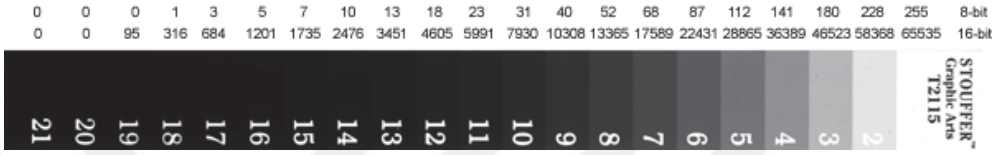
1.1.3.1. Renk Modelleri

Bir renk modeli, dijital bir görüntüde bulunan renkleri belirlemek için kullanılan sistemdir. Bu çalışmada, renkleri tanımlamanın farklı yöntemlerini temsil eden iki renk modeli RGB (Red-Green-Blue, yani Kırmızı-Yeşil-Mavi) ve HSV (Hue-Saturation-Value, yani Ton-Doygunluk-Değer) kullanılmıştır (Adobe Photoshop).

Renk uzayı, belirli bir renk gamına sahip renk modeli türüdür. Örneğin, RGB renk modelinin birçok renk uzayı vardır. Monitörler ve yazıcılar gibi cihazların kendi renk uzayları vardır ve yalnızca bu aralıktaki renkleri üretebilirler. Her cihazın kendi renk uzayı vardır, bu nedenle görüntüler cihazdan cihaza farklılık gösterebilir.

1.1.3.2. Gri Tonlamalı Renk Uzayı

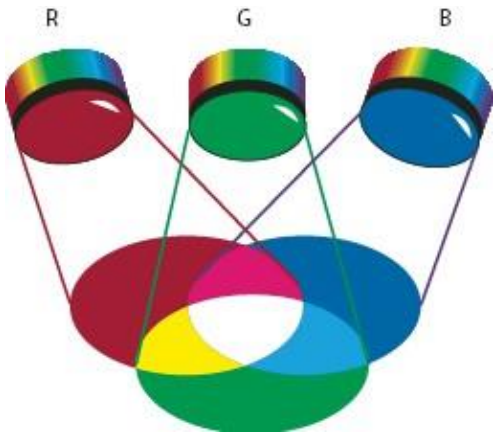
Bir görüntüde 0 – 255 arasında toplamda grinin *256* tonunun kullanıldığı renk uzayıdır. Gri tonlamalı bir görüntünün bit derinliği 8 bittir. Gri tonlamalı bir görüntüdeki her pikselin parlaklık değeri 0 ile 255 arasında değişir. Aradaki değerler grinin farklı tonlarını temsil eder. Bu renk uzayı tek kanalı temsil eder ve siyahtan beyaza tüm gri tonlarını ışık yoğunluğuna göre ayarlamaktadır (Şekil 1.1).



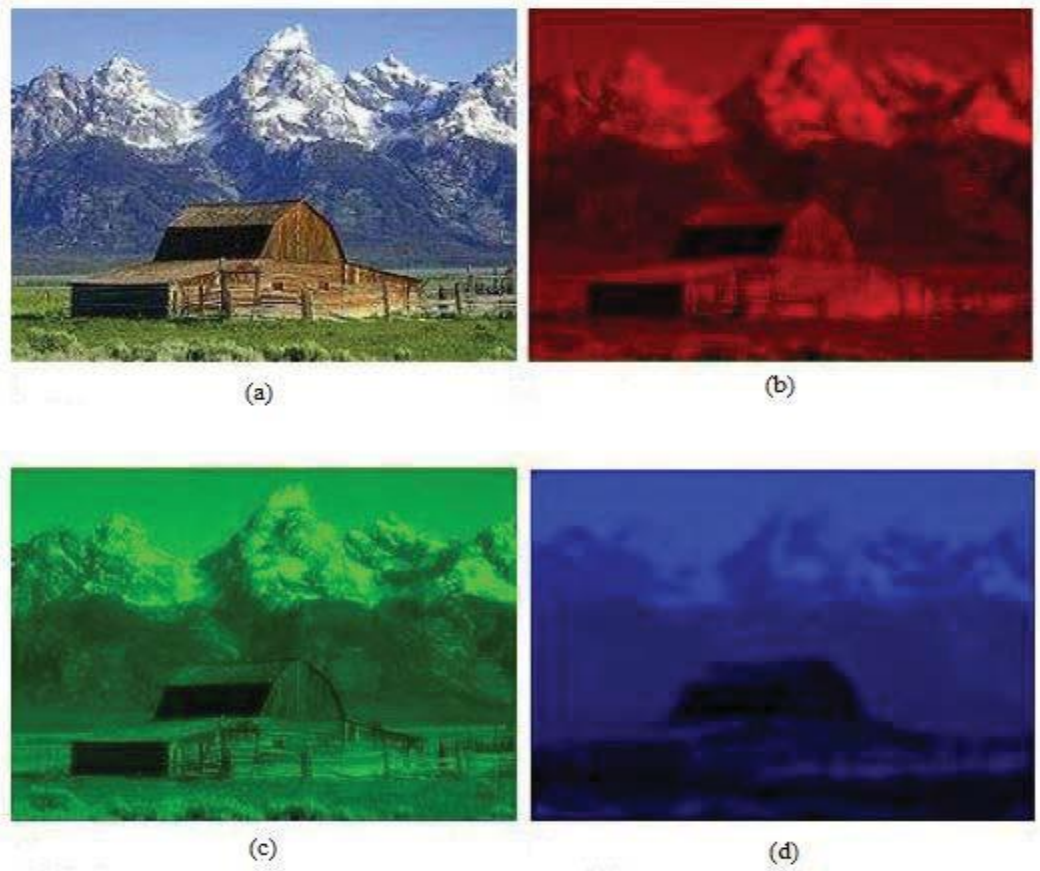
Şekil 1.1. Gri tonları (0 – 255)

1.1.3.3. RGB (Kırmızı – Yeşil –Mavi) Renk Uzayı

RGB: Kırmızı, Yeşil ve Mavinin kısaltmasıdır. Kırmızı 'R' ile, yeşil 'G' ile ve mavi 'B' ile gösterilir (Polat, 2012). Bu renk uzayında tüm renkler kırmızı, yeşil ve mavinin farklı oranlarda karıştırılmasıyla elde edilmektedir. RGB renk uzayında beyaz; kırmızı, yeşil ve mavinin %100 karışımından elde edilirken, siyah ise bu renklerin %0 karışımından oluşur (Şekil 1.2). Bu temel renklerin farklı oranlarda karıştırılmasıyla, birbirinden farklı renk tonları elde edilebilir. Ancak, bazı renklerin RGB karışımları insan gözü tarafından algılanamaz ve doğada bu renklere karşılık gelmez. Bu durum, sınırlı renk algısı veya renk görüşüne sahip olduğu anlamına gelir.



Şekil 1.2. RGB renk düzeni

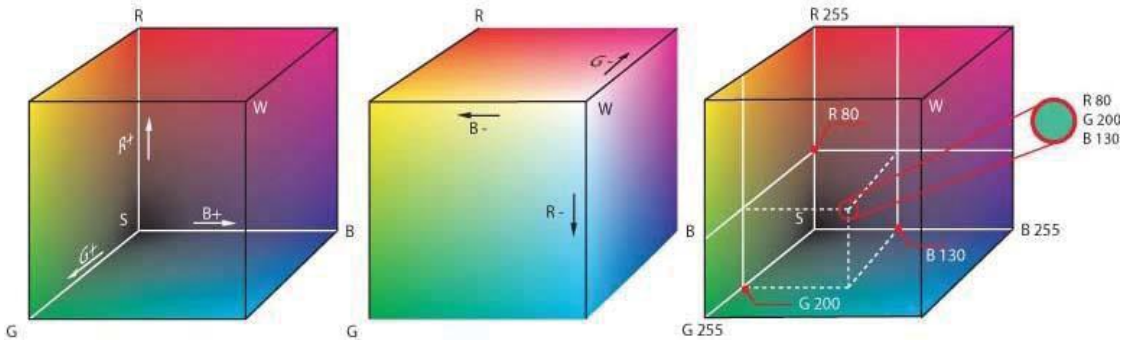


Şekil 1.3. RGB renk uzayı bileşenleri. (a) kırmızı, yeşil, mavi tonların bileşimi ile oluşmuş orijinal görüntü. (b) kırmızı rengin tonları ile oluşmuş görüntü. (c) yeşil rengin tonları ile oluşmuş görüntü. (d) mavi rengin tonları ile oluşmuş görüntü

Tablo 1.1'de çizelgede karışım oranlarına göre ortaya çıkan renkler gösterilmiştir. RGB renk uzayı, koordinat eksenleri kırmızı, yeşil ve mavi olan üç boyutlu bir uzay olarak düşünülebilir. Üretilen renkler, bu üç ana rengin koordinatları cinsinden ifade edilebilir (Yılmaz, 2002).

Tablo 1.1. Karışım oranına göre ortaya çıkan renkler

	Aralık	**Beyaz**	**Sarı**	**Camgöbeği**	**Yeşil**	**Eflatun**	**Kırmızı**	**Mavi**	**Siyah**
R	**0- 255**	**255**	**255**	**0**	**0**	**255**	**255**	**0**	**0**
G	**0- 255**	**255**	**255**	**255**	**255**	**0**	**0**	**0**	**0**
B	**0- 255**	**255**	**0**	**255**	**0**	**255**	**0**	**255**	**0**



Şekil 1.4. RGB renk uzayı koordinat ekseni

RGB renk uzayında görüntü işlemek, özellikle renk yoğunluğunu değiştirirken, her üç renk yoğunluğunu (kırmızı, yeşil ve mavi) okuyup değişiklikleri uygulamak karmaşık ve zaman alıcı olabilir (Şekil 1.4). Bu nedenle, farklı renk uzayları kullanarak, görüntü yoğunluğuna ve renk biçimine daha hızlı ve kolay erişim sağlamak, belirli işlemleri daha verimli hale getirmek mümkündür. Parlaklık ve iki farklı renk sinyali kullanarak geliştirilen renk uzayları, bu tür zorlukları aşmak için tasarlanmıştır. Bu bağlamda, HSV (Hue-Saturation-Value) renk uzayı gibi renk standartları, belirli görüntü işleme görevlerini daha hızlı ve etkili bir şekilde gerçekleştirebilmek adına tercih edilebilir.

1.1.3.4. HSV (Hue – Saturation – Value) Renk Uzayı

Renkli görüntülerde ışık yoğunluğu ve doygunluğunun algılanması ve değiştirilmesi, RGB renk uzayında oldukça yoğun matematiksel işlemler gerektirir. Bu durum iş yükünü artırmakta ve araştırmacıları renkli görme uygulamalarında daha kolay çözümler bulmaya yöneltmektedir. Bu amaçla, renk seçimini daha kolay ve sezgisel hale getirmek için HSV renk uzayı geliştirilmiştir: HSV renk uzayında, RGB renk uzayının aksine, ortamın renkleri ton, doygunluk ve açıklık olarak tanımlanır. Bu, HSV renk uzayında ışıktaki değişiklikleri tanımayı kolaylaştırır ve böylece görüntü işlemedeki zorlukları ortadan kaldırabilmektedir (Smith, 1978).

1.1.3.5. Görüntü Geliştirme

Görüntü iyileştirmenin temel yollarından biri parlaklık ve kontrastı değiştirmektir. Bu nitelikler aşağıdaki gibi değiştirilebilir (MATLAB, 2008):

- Renk dağılımının uzatılması,

- Renk dağılımını tüm renk aralıklarından yararlanmak için eşitlemek,

- Renklerin ölçeklendirilmesinin ayarlanması.

1.1.3.6. Histogram Eşitleme

Histogram, bir görüntüdeki renk değerlerinin sayısını gösteren grafik olarak temsil edilebilir. Histogram eşitleme, bir görüntüdeki renk değerlerinin belirli yerlerde kümelenmesinden kaynaklanan renk dağılımındaki bozulmaları gidermek için kullanılan bir yöntemdir. Görüntü işlemede histogramların kullanılması görüntüleri daha net hale getirebilir (Karakoç, 2012). Histogram eşitleme, bir görüntünün parlaklığını ve kontrastını iyileştirmek için kullanılır (Bagio vd., 2012). Histogram eşitleme;

$$Sk = T(rk) = \sum_{j=0}^{k} \frac{n_j}{n} (L-1)$$

Formülü ile ifade edilir. Bu formülde:

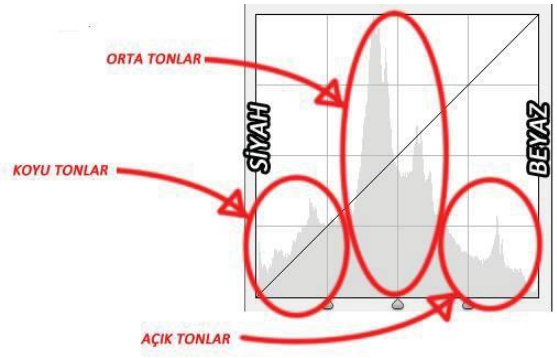
k = 0, 1, 2, …… L-1

L = Görüntünün gri seviyelerinin sayısı

nj = Görüntüdeki j gri pikselin değeri

n = Görüntüdeki toplam piksel sayısı olarak kullanılmaktadır (Kuba, 2013).

Histogram okuma sürecinde (Şekil 1.5), histogram grafiğinin sol ucu koyu renkleri, yani siyahı, sağ ucu ise açık renkleri, yani beyazı temsil eder (Şekil 1.6).



Şekil 1.5. Histogram grafiği ve histogram okuma



Şekil 1.6. Histogram eşitleme uygulaması

1.1.3.7. Filtreleme

Filtreler görüntüleri iyileştirmek, bir görüntüde istenen özellikleri vurgulamak, gürültüyü gidermek, ayrıntıları netleştirmek ve belirli ayrıntıları çıkarmak için kullanılır. Filtreler görüntü işlemede, görüntüleri dijital olarak kaydeden cihazlar tarafından görüntülerin yanlış elde edilmesinden veya aydınlatma gibi uygun olmayan çevresel koşullardan kaynaklanan pürüzleri ve kayıpları en aza indirmek için kullanılır (Akar, 2009).

Sayısal filtreler görüntüleri geliştirmek, görüntüde istenen özellikleri vurgulamak, gürültüyü gidermek vb. için kullanılır. Uzamsal tanım kümelerinde, konvolüsyon işlemleri tipik olarak filtreleme, görüntüdeki kenarları ve özel şekilleri aramak için kullanılır. Konvolüsyonda, iki matris üst üste bindirilir, birleştirilir ve aralarındaki ilişki araştırılır. Görüntü işleme, görüntünün belirli bir çekirdek matrise ne kadar iyi uyduğunu sembolize eden bir çıkış örüntüsü üretir (Baykan, 2007).

Farklı amaçlar için kullanılan filtreleme operatörleri mevcuttur. Örnek olarak, kenar yakalama, kenar keskinleştirme ve görüntü yumuşatma gibi çeşitli amaçlara yönelik filtreler bulunmaktadır. Bu filtreler, görüntü işleme uygulamalarında belirli özellikleri vurgulamak, iyileştirmek veya düzeltmek amacıyla kullanılır (Akar, 2009).

Filtreler genellikle çekirdek matrisler olarak adlandırılan 3x3 matrislerden oluşur. Bu matrisler filtreleme işlemi sırasında görüntü üzerinde hareket ettirilir. Filtreleme işlemi, örtüşen değerlerin çarpılması ve elde edilen tüm ürünlerin toplamının filtre elemanlarının toplamına bölünmesi ile gerçekleştirilir. Her seferinde merkez pikselin yani ortadaki pikselin değeri değiştirilir. Bu işlemler sırayla tüm piksellere uygulanır ve görüntü pikselleri güncellenir (Atasever vd., 2010).

1.1.3.8. Görüntü Eşikleme

Eşiklemenin amacı, bir görüntüdeki nesneleri görüntünün arka planından ayırmaktır (Bagio vd., 2012). Eşikleme, görüntüyü iki renk ile temsil edilebilecek bir forma dönüştürür. Bir eşik belirlenir ve bu eşikten yüksek gri seviye değerine sahip piksellere "1" değeri verilirken, düşük gri seviye değerine sahip piksellere "0" değeri verilir.

Eşiklemenin temel gösterimi.;

$G(i,j) = 1\ f(i,j) \geq T\ için$

$G(i,j) = 0\ f(i,j) < T\ için$

olarak verilmektedir.

Burada:

T →Eşik değeri

G(i,j) = 1 → Objenin görüntü elemanları

G(i,j) = 0 → Objenin görüntü elemanlarıdır.

Doğru eşik değerinin seçilmesi başarılı bir sonuç için çok önemlidir. Bu seçim çeşitli eşikleme algoritmaları tarafından yapılır. Tüm görüntü için tek bir eşik değeri kullanmak daha az tercih edilir. Tek bir eşik değerinin kullanılması global eşikleme olarak adlandırılır (Alçı ve Akdemir, 2005). Segmentasyon eşiği, görüntünün bölgesel özelliklerinin bir fonksiyonu olarak görüntü üzerinde değişiyorsa, değişken eşikler kullanılarak bir çözüm üretilir (Şekil 1.7). Bu segmentasyon adaptif segmentasyon olarak da adlandırılır (Wilson ve Noble, 1999).



(a) (b)

Şekil 1.7. Eşikleme uygulaması (a) orjinal resim, (b) global eşikleme uygulanmış resim

1.1.3.9. Morfolojik İşlemler

Biçim bilimi olarak bilinen morfoloji, biyolojideki organizmaların şekli ve yapısı ile ilgilenen ve matematikteki görüntü sınırlarını, iskelet yapılarını ortadan kaldıran gürültü azaltma, segmentasyon gibi uygulamalarda kullanılan bir araçtır. Morfolojik manipülasyon, görüntü üzerinde ilgili alana odaklanarak istenen bilgiyi elde etmek için bir nitelik çıkarma adımı olarak gerçekleştirilir. Görüntüdeki her piksel, etrafındaki diğer piksellerin değerlerine bağlı olarak morfolojik manipülasyon ile ayarlanabilir. Gri düzey görüntülere veya genellikle ikili görüntülere uygulanabilir. Kullanılan iki temel morfolojik süreç, yani difüzyon (genleşme) ve aşındırma, Şekil 1.8'de gösterilmiştir.



Şekil 1.8. Morfolojik işlemler

1.1.4. Görüntü İşlemede Kullanılan Bazı Teknikler

1.1.4.1. Python

Python programlama dili Hollandalı yazılım geliştiricisi Guido van Rossum tarafından geliştirilmiştir. Van Rossum Python yazılım dilini ilk olarak 1989 yılında yayınladı ve şu an da birçok alanda kullanılmaktadır. Python açık kaynaklı bir dildir, yani kullanıcılar tarafından geliştirilebilir. Python yüksek seviyeli, güçlü bir programlama dilidir. Python, yazılım geliştirme, veri bilimi ve makine öğrenimi de dahil olmak üzere birçok alanda kullanılmaktadır. Python çok okunabilir, anlaşılabilir ve kolay bir dil olduğu için özellikle acemi programcılar tarafından sıklıkla tercih edilir. Python çeşitli işletim sistemlerinde çalıştırılabilir ve birçok programlama dilini destekler. Python bir konsol üzerinden veya komut dosyası olarak kullanılabilir, yazılabilir ve çalıştırılabilir. Ayrıca Entegre Geliştirme Ortamları (IDE'ler) gibi geliştirme ortamlarıyla da kullanılabilir (Rossum, 2003).

Yorumlanan bir dil, yazılım dillerini yorumlayan ve yürüten bir dil türüdür. Yorumlayıcı diller derleyici dillerden daha yavaş olabilir, ancak program yazmak derleyici dillerden daha kolaydır. Python yorumlanmış bir dil olarak tasarlanmış ve yürütülmüştür. Bu, Python kodunun çalıştırılmadan önce derlenmediği anlamına gelir. Bunun yerine, Python kodu satır satır yorumlandığında yürütülür. Bu, Python kodunun hızlı bir şekilde yazılmasını ve test edilmesini sağlar, ancak yürütme hızında hafif bir azalma olur (Rossum, 2003).

Python, özellikle veri bilimi ve makine öğrenimi gibi alanlarda çok faydalı olan çeşitli paketlere ve kütüphanelere sahiptir. Python açık kaynaklı bir dil olduğu için bazı paketler kullanıcılar tarafından geliştirilmiştir ve bu paketler Python'da geliştirilen uygulamaların daha kolay ve hızlı bir şekilde geliştirilmesine yardımcı olur. Python programlama dilinin esnekliği, zengin bir görüntü işleme ve görüntü görselleştirme kütüphanesinin mevcudiyeti, Python'un diğer programlama dillerine göre avantajlarını oluşturmaktadır. Özellikle, görüntü işleme için kullanılan OpenCV kütüphanesi ve görüntü bitlerinin 2 boyutlu görselleştirilmesi için matplotlib kütüphanesi gelişmiş özelliklere sahip kütüphaneler olarak öne çıkmaktadır (Rossum, 2003).

Python, görüntü işleme için ideal bir programlama dilidir; Python, görüntüler üzerinde çeşitli işlemler gerçekleştirmeye yardımcı olan bir dizi önemli görüntü işleme kütüphanesine sahiptir (Rossum, 2003).

1.1.4.2. OpenCV

OpenCV, görüntü ve videolardan anlamlı bilgiler çıkarmak ve işlemek amacıyla Intel tarafından C ve C++ dilleri kullanılarak geliştirilmiş açık kaynaklı bir "Bilgisayarla Görme" kütüphanesidir (Erişti, 2010). OpenCV özellikle gerçek zamanlı uygulamalara odaklanmıştır ve ticari kullanımları da dahil olmak üzere ücretsiz olarak kullanılabilir.

Açık kaynaklı bir görüntü işleme kütüphanesi olan OpenCV'nin geliştirilmesi dünyanın dört bir yanından yazılım geliştiriciler tarafından sağlanmıştır dolayısıyla projenin adı 'Open Source Computer Vision Library' cümlesinden türetilmiştir. Bu cümlenin Türkçesi ise' Açık Kaynak Kodlu Bilgisayarlı Görü Kütüphanesi' anlamına gelmektedir.

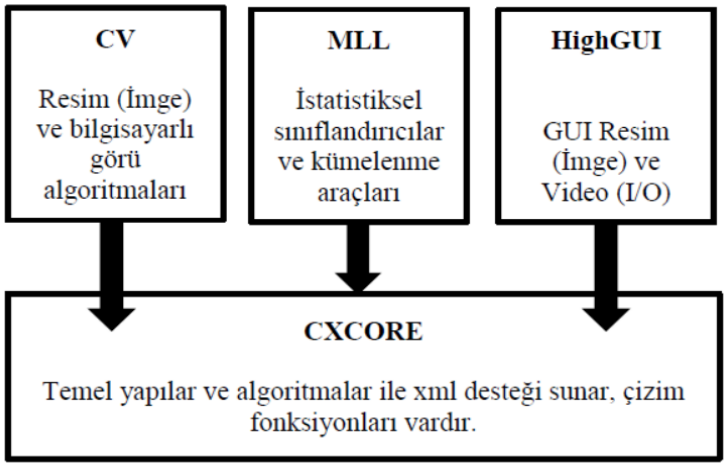
OpenCV kütüphanesi, kodu alan herkesin özgürce kullanmasına izin veren BSD lisansı altında lisanslanmıştır. Kütüphane akademik ve ticari kullanım için ücretsizdir ve Windows ve MacOS X dahil olmak üzere çeşitli platformlarda kullanılabilmektedir.

OpenCV'nin geliştirilmesi için çok çekirdekli mimariden yararlanmak üzere C ve C++ dilleri seçilmiştir. Bu proje, Intel tarafından oluşturulan ana ekip tarafından yönetilmiştir. OpenCV'nin Intel işlemcilerinde yüksek performans elde etmesini sağlamak amacıyla Gömülü Performans İlkeleri (IPP) de geliştirilmiştir (Türkoğlu, 2010).

OpenCV kütüphanesi, makine öğreniminden robotiğe, kamera kalibrasyonundan tıpta görüntü işlemeye, otomatik tanımlama ve izleme teknolojisine kadar yaklaşık 500 kullanıma hazır işlev içerir.

OpenCV kütüphanesi beş temel bileşenden oluşmaktadır (Şekil 1.9):

- CV bileşeni
- MLL bileşeni
- HighGUI bileşeni
- CXCore bileşeni
- CvAux bileşeni



Şekil 1.9. OpenCV temel bileşenleri

1.1.4.3. Anaconda

Anaconda, bir dizi çalışma ortamı, kütüphane ve araç seti içeren bir Python dağıtımıdır. Dağıtım veri bilimi, makine öğrenimi, multimedya uygulamaları ve bulut hizmetleri gibi alanlarda kullanılmaktadır.

Anaconda birçok açık kaynak, özel kütüphaneler ve araç setleri içerir. Örneğin NumPy, SciPy, Pandas, Matplotlib, Jupyter Notebook ve Spyder gibi popüler kütüphaneler Anaconda ile gelmektedir. Bu kütüphaneler veri bilimi, makine öğrenimi ve matematiksel işlemler gibi alanlarda kullanılmaktadır.

Anaconda ayrıca birden fazla ortamın oluşturulmasını ve yönetilmesini de destekler. Bu ortamlar, birbirinden bağımsız olarak çalışan Python uygulamaları için kullanılabilir ve her ortamda farklı kütüphaneler ve araç takımları kullanabilir. Bu sayede aynı bilgisayarda birden fazla proje üzerinde çalışılabilmekte ve her proje için gerekli kütüphaneler yüklenebilmektedir Anaconda ayrıca birçok platformda çalışabilir ve bu nedenle Windows, macOS ve Linux gibi farklı işletim sistemlerinde kullanılmaktadır.

Sonuç olarak, Anaconda veri bilimi ve matematiksel işlemler gibi alanlarda kullanılan birçok kütüphane ve araç setini içeren bir Python dağıtımıdır. Birden fazla ortamın oluşturulmasını ve yönetilmesini destekler ve farklı platformlarda çalışabilir. Anaconda platformunun bu çalışma için arka uç olarak kullanılmasının nedeni budur.

1.1.4.4. Sypder

Spyder, Scientific Python Development Environment (spyder) adlı bir Python geliştirme ortamıdır. Spyder, birçok popüler Python kütüphanesini (NumPy, Matplotlib, SciPy, vb.) destekler ve bunlar Spyder'da kullanılmaktadır. Spyder ayrıca Python kodu yazmayı, test etmeyi ve kaydetmeyi kolaylaştıran Python ile ilgili birçok araç ve özellik içerir.

Spyder, çeşitli Python dillerinde çalışan ve bu nedenle Python ile ilgili birçok proje için kullanılabilen bir geliştirme ortamıdır. Örneğin, veri görselleştirme projeleri, makine öğrenimi modellemesi ve sayısal hesaplamalar Spyder kullanılarak gerçekleştirilebilir.

Spyder, Python kodu yazmayı, test etmeyi ve kaydetmeyi kolaylaştıran bir dizi araç ve özelliğe sahiptir. Örneğin Spyder, Python kodu yazmak için Python kodunu düzenlemek ve yazmak için yararlı araçlar sağlayan bir kod editörü içerir. Spyder ayrıca Python

kodunu test etmek için bir konsol ve hata ayıklayıcı içerir. Bu araçlar Python kodunun yürütülmesini izlemek ve hata ayıklamak için kullanılmaktadır. Spyder ayrıca Python kodunu depolamak için bir proje yöneticisi içerir, bu sayede Python kod sürümlerini yönetebilir ve kod değişikliklerini takip edilebilir.

Kod editörü: Spyder, kod yazmayı kolaylaştıran birçok özelliğe sahip bir kod editörü içerir. Örneğin, otomatik tamamlama, kelime önerileri ve ek açıklama işaretleri gibi özellikler vardır.

Yürütme penceresi: Spyder, komut dosyalarını çalıştırmak için bir yürütme penceresine sahiptir. Bu yürütme penceresi, komut dosyalarını çalıştırmanıza ve çıktılarını görüntülemenize olanak tanımaktadır.

Hata Ayıklama: Spyder, komut dosyalarında hata ayıklamak için bir hata ayıklama aracı içerir. Hata ayıklama aracı, kod yürütme sırasında oluşan hata mesajlarını görüntüleyerek hata ayıklamaya yardımcı olur.

Konsol: Spyder, komut dosyalarının bir konsol kullanılarak yazılmasına ve yürütülmesine olanak tanır. Bu konsol, kodun daha hızlı yürütülmesini ve test edilmesini sağlar.

1.2. Problem Durumu

Domates, ülkemizde olduğu gibi dünyanın birçok yerinde üretim ve tüketim miktarının çok yüksek olduğu bir sebzedir. Domateste sorun olan pek çok bakteriyel hastalık, farklı ülkelerde olduğu gibi ülkemizde de domates üreticisinin sorunları arasındadır. Bu hastalıklar içerisinde en yaygın görülenlerden biri *Pseudomonas syringae pv. tomato(pst)'nun* sebep olduğu domates bakteriyel benek hastalığıdır. Hastalık bitkinin tüm toprak üstü organlarında lekelenme belirtilerine neden olur. Belirti oluşumu fide aşamasında, fidelerin yapraklarında ve gövdelerinde çok sayıda kahverengi-siyah lekeler görüldüğünde başlar. Bu lekeler sonunda tüm fidenin kurumasına neden olur. Tarlada yapraklarda, gövdelerde, çiçeklerde ve meyve saplarında fide aşamasında oluşanlara benzer kahverengi ila siyah lekeler oluşur. Bu lekelerin etrafında genellikle sarı renkli hale görülmektedir. Lekeler zamanla kaynaşarak yaprak deformasyonuna ve kurumaya neden olur.

1.3. Araştırmanın Amacı

Bu tez çalışmasının temel amacı, gerçek zamanlı görüntüler kullanarak domateste bakteriyel benek hastalığını tespit etmektir. Bu amaç doğrultusunda geliştirilecek hastalık tespit sistemi, uzmanların hastalıktan kaynaklanan verim kaybının önlemesine yardımcı olacak ve hastalık tespitinin daha kolay ve hızlı uygulanmasını sağlayacaktır. Önerilen çalışma, domates yaprağı hastalıklarını tespit etmek amacıyla başlatılan bitki patolojisi çalışmalarına katkı sağlayarak çiftçilere destek olacak bir metodoloji geliştirmeyi hedeflemektedir.

1.4. Araştırmanın Önemi

Dünyada üretimi en çok yapılan sebzelerden biri olan domatesin kalitesinin ve verimliliğinin artırılması hedeflenmektedir. Ülkemizde domates yetiştiriciliği oldukça yaygındır. 2020 yılında taze domatesten 313 milyon ABD doları döviz elde edilirken, 2021 yılında bu rakam %16 artışla 363 milyon ABD dolarına ulaşmış ve bu sonuçlar, ülkemizde domatesten verim almanın önemini ortaya koymuştur. Tarımsal amaçlı domates üretimi yapan vatandaşlarımızın yetiştirdikleri domatesten aldıkları verimin artırılması hedeflenmektedir.

1.5. Literatür çalışması

Antalya ilinde gerçekleştirilen gözlem, izolasyon ve tanı çalışmaları neticesinde *Clavibacter michiganensis subsp. michiganensis* (domates bakteriyel solgunluğu) ile *Pseudomonas syringae pv. tomato* (domates bakteriyel leke hastalığı) tespit edilmiştir. *Clavibacter michiganensis subsp. Michiganensis,* Alanya, Elmalı, Kaş, Korkuteli, Kumluca, Manavgat, Merkez ve Serik ilçelerinde tespit edilmiştir. *Pseudomonas syringae pv.* ise Kaş, Manavgat, Merkez ve Serik ilçelerinde saptanmış; ancak Elmalı ve Korkuteli ilçelerinde görülmemiştir. Saha çalışması kapsamında, örtü altı yetiştiriciliği ve tarlalarda solgunluk gösteren bitkilerden izole edilen 72 izolat üzerinde petiol yöntemiyle morfolojik, biyokimyasal ve patojenik testler uygulanmıştır. Sonuçlar, *Clavibacter michiganensis subsp. michiganensis* ve *Pseudomonas syringae pv.*'nin Antalya'da domates bitkilerinde geniş bir yayılıma sahip olduğunu göstermiştir (Kahveci ve Gürcan, 1993).

Bakteriyel lekelenme genellikle kültürel ve kimyasal yöntemlerle kontrol edilir. Kültürel kontroller arasında hastalıklı bitkilerin imha edilmesi, hastalıksız ve sağlıklı fidelerin kullanılması, kapalı yetiştirme alanları ve seralarda kapalı alanların havalandırılması, yağmurlama sulama sistemlerinden kaçınılması, temiz veya kontrollü tohumların kullanılması ve çapraz tozlaşma yer almaktadır (Aysan ve Çınar, 2000).

Pseudomonas syringae pv. tomato (pst) bakterisinin sebep olduğu bakteriyel leke hastalığının biyolojik kontrolü için bir alternatif olarak, araştırmacılar tarafından bakteriyofajların kullanılabileceği belirtilmiştir. Yapılan denemelerde, farklı bakteriyofajların tohumlara uygulanması sonucunda, bazı fajların sporojenik hastalığı tamamen kontrol edebildiği, diğer fajların ise hastalığı %15-66 oranında baskılayabildiği gözlemlenmiştir. Bu çalışma, ülkemizde bu hastalığın biyolojik kontrolü için faydalı bir virüsün ilk defa kullanıldığını vurgulamaktadır. Sonuçlar, belirli bakteriyofaj türlerinin hastalığın biyolojik kontrolünde etkili olduğunu göstermiştir. Bu bağlamda, çalışma, belirli bir fajın hastalığın biyolojik kontrolü için potansiyel bir tehlike oluşturabileceğini ortaya koymaktadır (Cement vd.,2018).

Ülkemiz için yüksek ekonomik değere sahip şeftali meyvesinin verim haritalaması için, gelişimin erken aşamalarında doğal bahçe alanlarında çekilen görüntülerden meyveyi tespit etmek ve saymak için araştırmacılar görüntü işleme tekniklerini kullanan bir bilgisayar görüntü algoritmasının geliştirilmesini rapor etmiştir (Kurtulmuş, 2012).

Tarımda uygulanan en etkili tekniğin kimyasal mücadele olmasına karşılık çevre ve insan sağlığı açısından da olumsuz sonuçlar doğurduğunu, renk özelliklerinin bilinmesinin gerekli olduğunu, yabancı otların ve ekinlerin ayırt edilmesini sağlayacağını belirtmiştir. Kimyasal pestisit tüketimini ortadan kaldıran sistemler geliştirmek için alan çalışmasında 3 farklı ürünün (ayçiçeği, domates, salatalık) yaprak rengi özellikleri ve 3 farklı çimin yaprakları ürünün büyümesini engellemektedir. Kameralar ve kolorimetrik ekipman tekniği ile RGB renk uzayında test edildiği söylenmiştir (Örge, 2012).

Araştırmacılar tarafından yapılan çalışmada, ilçenin morfolojisini, dokusunu ve rengini değerlendirme kriteri olarak dikkate alıp, görüntü işleme teknikleri kullanarak ekmeklik buğday çeşitlerinin kaliteye dayalı bazı özellikleri belirlenmeye çalışılmıştır. Buğday kalitesinin belirlenmesinde genel bir başarı oranına ulaşılmış ve görüntü işleme

uygulamalarının diğer tahılların kalitesini belirlemede veya temizleme makineleri üretiminde başarıyla kullanılabileceği bildirilmiştir (Masoumi, 2013).

Araştırmacılar, sabit bir platformda görüntü işleme teknikleri kullanarak meyve boyutu ve renk sınıflandırması üzerine bir ön çalışma yapmış ve daha sonra elde edilen verileri kullanarak mobil bir platforma aktarmışlardır. Donanım ve yazılım birlikte çalıştırıldığında, sistemin önce boyut analizi yaptığı, ardından bu analizden elde edilen verileri renk analizi için kullandığı belirtilmiştir. Analizden elde edilen veriler, elma ve diğer meyve ile sebzelerdeki hasar ve lekeleri analiz etmenin mümkün olduğunu göstermiştir (Tonguç, 2007).

Bu çalışmada, dört geleneksel İtalyan fındık çeşidinin (San Giovanni, Mortarella, Tonda di Giffoni ve Tonda Romana) tanımlanması için şekil tabanlı tekniklerin kullanılmasının fizibilitesi ve etkinliği değerlendirilmiştir. Fındık çeşitlerine ait dört yüz renkli görüntü, ayrımcılık analizi ile sınıflandırma için kullanılmıştır. Sonuçlar, sınıflandırma başarı oranının %77.5- 98.8 arasında değiştiğini göstermiştir. Dijital görüntüler üzerinde şekil tabanlı yöntemler kullanan çok değişkenli istatistiksel yöntemlerin fındık çeşitlerinin sınıflandırılmasında yüksek verim elde etmek için önemli olduğunu belirtmişlerdir (Menesatti vd., 2008).

İHA sistemini kullanarak elde edilen RGB görüntülerinden, sezon başından ortasına kadar olan süreçte bitki büyüme aşamalarını ve mısır tane verimini tahmin etmeyi amaçlayan bir çalışma gerçekleştirilmiştir. Araştırmacılar, hava fotoğrafçılığına ve 3B bitki yüzeyi modellemesine dayalı birleşik mekânsal ve spektral modellemenin, mahsul ortası mısır verimini tahmin etmek için uygun bir yöntem olduğu sonucuna ulaşmışlardır (Geipel vd., 2014).

Drone ile elde edilen fotoğrafların işlenmesi sonuçları, tesiste potansiyel olumsuzlukların önceden tespit edilmesine ve ilaç kullanımının azaltılmasına katkı sağlayabilir. Sahada uygulanacak kimyasal miktarının ayarlanması, toprak sağlığı açısından önemli bir faktördür (Reis, 2014).

Yapılan çalışmada, şeker pancarı tarımı yapan bir çiftçinin arazisindeki yaprak lekesi hastalığını (*Cercospora beticola Sacc.*) tespit etmek ve hastalığın evresini belirlemek amacıyla görüntü işleme algoritmaları kullanılmıştır. Tokat koşullarında çekilen insansız

hava aracı görüntüleri, MATLAB programının Image Processing Toolbox modülü aracılığıyla hastalık gelişim derecelerini incelemek için kullanılmıştır. Çalışmanın sonunda elde edilen hastalık şiddeti değerleri ile gözlemlenen sonuçlar karşılaştırılmış ve benzerlik gösterdiği görülmüştür. Ayrıca, görüntü işleme tekniklerini kullanan bu çalışmanın, lezyon konumunu belirlemede insan gözlemine kıyasla daha doğru değerlerle sonuçlandığı gözlemlenmiştir (Altaş vd., 2018).

Bitkiler hastalandığında, bireysel lezyonlar için şekil ve boyut olarak değişen renkli noktalar veya bitkinin yapraklarında, gövdelerinde ve tabanında oluşabilen çizgiler gibi bir dizi belirti sergilerler. Bu görsel belirtiler, hastalık ilerledikçe sürekli olarak renk, şekil ve boyut değiştirir. Renkli nesnelerin görüntü işleme teknikleri kullanılarak ayrılması, bitki hastalıkları ve zararlıları ile mücadelede görüntü işleme teknikleri büyük önem taşımaktadır. Bu teknikler, araştırmacılara nesne algılama ve renk tabanlı tanıma konusunda önemli gelişmeler sağlama imkânı tanır (Altaş, 2019).

Bu çalışmada, tarımsal üretim tesislerinde yetiştirilen ürünlerin sağlığını izlemek amacıyla, dronlarla çekilen hava fotoğraflarının kullanılması önerilmiştir. Özellikle, normalleştirilmiş fark bitki örtüsü indeksi (NDVI) gibi bilinen yöntemlerin görüntü işleme teknikleriyle birleştirilerek bitki örtüsünün canlılığının hesaplanması hedeflenmektedir. Elde edilen verilere dayanarak, üreticiler alan başına değişken girdiler uygulayarak hektar başına verimliliği ve maliyeti en aza indirebilirler (Serrano vd., 2017).

Yetiştirme koşulları için önemli bir temel olan salatalık sebzelerinin görünüm kalitesini tespit etmek için araştırmacılar tarafından GrabCut algoritması kullanıldı. Salatalıkların doku ve şekil özelliklerini doğru bir şekilde çıkarmak amacıyla bir görüntü kalitesi algılama cihazı tasarlandı. Bu cihaz, salatalığın görünüm kalitesini belirlemelerini ve büyümesini etkili bir şekilde değerlendirmelerini sağlamaktadır. Bir seradaki salatalıkların yaklaşık 300 gerçek görüntüsü üzerinde yapılan segmentasyon deneylerinin sonuçları, geliştirilmiş GrabCut algoritmasının salatalıkların doğru ve pürüzsüz sınırlarını etkili bir şekilde çıkarabildiğini göstermiştir. Nispeten yüksek segmentasyon değerlendirme endeksi, doğruluk, geri çağırma ve F-Measure endeksleri sırasıyla %93.88, %99.35 ve %96.53'e ulaşırken, yanlış sınıflandırma minimum %5.84'e kadar düşürülebilmiştir. Ayrıca, sistemin ortalama yürütme süresi 1.4023 saniyeye indirilmiştir. Karşılaştırma sonuçları, geliştirilmiş GrabCut algoritmasının en iyi performansı

sergilediğini, bunu SLIC ve geleneksel GrabCut yöntemlerinin izlediğini göstermektedir (Lin vd., 2018).

Araştırmacılar, ayçiçeği (*Helianthus annuus*), toprak ve durabla otunu (*Xanthium strumarium*) tespit etmek için görüntüleri ve piksel değerlerini kullanmışlardır. Bu amaçla, üç seviyeli çıktılara sahip bir JST modeli geliştirilmiştir. JST modeli, ilgili materyalin 129 görüntüsü üzerinde test edilmiş ve 103 çıktıyı doğru tahmin etmiştir (Kavdır vd., 2004).

Bitki hastalıklarının tespiti üzerine yapılan çalışmada, hazır veri seti kullanılarak domates üzerindeki bakteriyel leke, sarı yaprak kıvrılma virüsü ve geç yanıklık hastalıkları derin öğrenme yöntemleriyle belirlenmiştir. Çalışmanın sonucunda elde edilen genel doğruluk %98.59 olarak belirlenmiş ve bu, bitki hastalığı tespitinde önemli bir başarıyı ifade etmektedir (Dhakal ve Shakya, 2018).

Araştırmacılar, tek bir kamera kullanarak 19.5 cm mesafeden elde edilen görüntülerle sırlı ve sırsız buğday tanelerini tespit etmeyi amaçlamıştır. Çalışmalarında materyal olarak kullandıkları buğday tanelerini camsılık derecelerine göre sınıflandırmışlar ve bu verilere dayanarak çeşitli YSA modelleri geliştirmişlerdir. Geliştirilen modeller aparat ile desteklenmiştir. Sonuçlar, kullanılan aparatın buğday tanelerinin parlaklık derecesini sınıflandırmada %81-90 tahmin başarısına sahip olduğunu göstermiştir (Wang vd., 2002).

Yapılan çalışmada, üzüm salkımlarının hasat sonrası ağırlığını tahmin etmek için laboratuvar koşullarında fotoğraflar çekilmiştir. Çalışmada üzüm salkımlarının ağırlığını tahmin etmek için farklı salkım parametrelerinin salkım ağırlığı üzerindeki etkisi araştırılmış ve manuel olarak etiketlenmiş bir veri seti üzerinde farklı ölçümlerin performansı değerlendirilmiştir. Çalışma, ideal koşullar altında, tane sayısı, salkım çevresi, salkım alanı ve tahmini salkım hacmi gibi özellikleri kullanan doğrusal bir regresyon yaklaşımının salkım ağırlığını %5.3 doğrulukla tahmin edebileceği sonucuna varmıştır. Araştırmacılar, görüntü analizi ve özellik çıkarımının üzüm salkımı ağırlığını tahmin etmek için etkili bir yöntem olduğunu kanıtladığını bildirmiştir (Liu vd., 2013).

Görüntü işleme teknikleri kullanılarak ağaçlardaki turunçgilleri tespit etmek ve saymak için etkili, basit ve kullanışlı bir bilgisayarla görme algoritması geliştirilmiştir. Bu çalışmada, turunçgil görüntüleri gün ışığında çekilmiş ve turunçgil tanıma ve sayma

algoritması 21 ağaçtan toplanan 84 görüntü üzerinde test edilmiştir. Turunçgil sayma algoritması ilk olarak RGB görüntülerini HSV (renk tonu, doygunluk ve açıklık) renk uzayına dönüştürülmüştür, böylece renk bilgisi daha kolay işlenebilmiştir. Turunçgil sayım algoritması kullanılarak yapılan insan gözlemi ölçümleri R2 = 0.93 belirleme katsayısı vermiştir (Dorj vd., 2017).

Araştırmacılar elma bahçelerindeki ağaçlarda kırmızı renkli elmaları tespit etmek ve saymak için görüntü işleme tekniklerini kullanan bir bilgisayar yazılımı geliştirmişlerdir. Yazılım, ağaçlardaki elmaları tespit etmek için dijital ortamdan aktarılan elma ağaçlarının görüntüleri üzerinde görüntü işleme tekniklerini kullanmaktadır. Tespit edilen elmanın merkez noktası işaretlenerek elma sayımı gerçekleştirmişlerdir. Uygulama fotoğraflardan, anlık görüntülerden veya canlı videolardan görüntüleri içe aktarabilir. Bu çalışmada, ağaç üzerindeki kırmızı renkli elmalar renk açısından %78.47'lik bir başarı oranıyla tespit edilmiştir (Kaymak vd., 2019).

Bilgisayarla görme ve görüntü işleme teknolojileri, tarımsal uygulamalar ve araştırmaların yanı sıra çeşitli endüstrilerde gözlem ve ölçüm amacıyla kullanılmaya başlanmıştır. Yaprak alanı indeksi, bitki büyümesini izlemek için önemli bir göstergedir. Yaprak alanı indeksini ölçmek için kullanılan birçok yöntem yapraklara zarar verir. Bu çalışmada turunçgiller sera ortamında yetiştirilmiştir. Fidanların yapraklarının görüntüleri bir kamera yardımıyla haftalık olarak çekilmiştir. Bunlar çeşitli görüntü işleme yöntemleri kullanılarak yaprak alanı hesaplanarak kaydedilip analiz edilmiştir. Yaprak alanının bitkiye zarar vermeden ölçülebileceği ve bu yöntemlerin bitki büyümesini izlemek için kullanılabileceği saptanmıştır. Ayrıca, görüntüleme yöntemlerinin de bu amaçla kullanılabileceği belirlenmiştir (Yılmaz ve Başçetinçelik, 2003).

Görüntü işleme teknolojisi şu anda tarımda yaprak alanını ölçmek, meyve rengini analiz etmek ve sınıflandırmak, ilaçlamada damlacık boyutunu, damlacık yoğunluğunu ve kimyasal kapsamını belirlemek, yaprak alanını belirlemek, meyve rengini analiz etmek, yabani otları tespit etmek, ezilme derecesini belirlemek ve bitki büyümesini ve kök gelişimini izlemek için kullanılmaktadır. Bu teknoloji sayesinde, bu karmaşık ölçümler kolay, hızlı ve doğru bir şekilde gerçekleştirilebilmektedir (Karabacak, 2007).

Araştırmacıların çalışmasında fındık kullanılarak nesneleri gerçek zamanlı olarak tespit etmeyi ve sınıflandırmayı amaçlamıştır. Çevreden alınan görüntüler üzerinde görüntü işleme teknikleri kullanılarak fındıklar tespit edilmiştir. Fındıkları küçük, orta ve büyük olarak sınıflandırmak için ortalama tabanlı sınıflandırma ve K-means kümeleme yöntemleri kullanılmıştır. Ortamdaki fındıkları %100 olasılıkla tespit etmek için görüntü işleme teknikleri kullanılmıştır (Solak ve Altınışık, 2018).

Araştırmacılar tarafından yürütülen çalışmada, elmaların sınıflandırılması ve lekelerin tespiti hedeflenmiştir. Görüntülerin elde edilmesi için MATLAB uyumlu bir kamera seçilmiş ve bu çalışma için MATLAB programı kullanılarak özel bir yazılım geliştirilmiştir. Elmaların görüntüleri çeşitli filtrelerden geçirilmiş, boyutları belirlenmiş ve lekeler tespit edilmeye çalışılmıştır. Yapılan çalışmanın başarı oranı %70 olarak belirlenmiştir (Sofu vd., 2013).

Araştırmacıların çalışması, meyvenin dal üzerinde nerede bulunduğunu tespit etmeyi amaçlamıştır. Kivi meyvesinin görüntüleri bir kamera ile çekilmiş ve bilgisayar ortamında işlenmiştir. Görüntü işleme için C# programında geliştirilen yazılım kullanılmıştır. Bu çalışma sonucunda meyvelerin dallar üzerindeki koordinat değerleri belirlenmiştir (Kâhya ve Arın, 2014).

Bu çalışmanın amacı Napolyon tipi kirazları sınıflandırmaktır. Bu sınıflandırma için kirazların fotoğrafları fotoğraf makinesi ile çekilmiş ve görüntüler bilgisayar ortamına aktarılmıştır. Görüntü dosyaları RGB-uint8 formatından Gray-uint8 formatına dönüştürülmüştür. Görüntü işleme tekniklerinin uygulandığı görüntülerdeki her bir kirazın kalibresini belirlemek için Matlab programı kullanılmıştır (Balcı vd., 2016).

Bu çalışmanın temel amacı, görüntü işleme ve yapay sinir ağları kullanarak patatesleri boyutlarına göre sınıflandırmaktır. Sınıflandırma süreci sırasında, yüzey ve dış kusurlara sahip olan patatesler dışında tutulmuştur. Çalışmada, görüntü işleme algoritmaları için Matlab yazılımı kullanılmıştır. Görüntüler üzerinde histogram eşitleme ve Otsu yöntemi gibi teknikler de uygulanmıştır. Elde edilen sonuçlar doğrultusunda, patatesler büyük, orta ve küçük olarak sınıflandırılmıştır. Bu yöntem, patateslerin boyutlarına dayalı sınıflandırılmasında etkili bir yaklaşım sağlayarak tarım alanında otomasyon ve kalite kontrol uygulamalarına katkı sağlayabilir (Sabancı vd., 2012).

2. BÖLÜM

MATERYAL VE YÖNTEM

2.1. Materyal

2.1.1. Çalışma Alanı

Erciyes Üniversitesi Ziraat Fakültesine ait ısıtmalı serada tez çalışmasının denemesi Kasım 2022- Ocak 2023 tarihleri arasında yürütülmüştür (Şekil 2.1).



Şekil 2.1. Çalışma alanı

2.1.2. Çalışmada Kullanılan Fotoğraf Makinası

Bu çalışmada kullanılan fotoğraf makinesi, Nikon D5100 marka ve modelidir (Şekil 2.2). Nikon D5100, 1080p çözünürlükte video kaydı yapabilen ve saniyede 30 kare hıza kadar video çekebilen, aynı zamanda 16 megapiksel çözünürlüğe sahip bir fotoğraf makinesidir (Fotopedi, n.d.).



Şekil 2.2. Çalışmada kullanılan fotoğraf makinası

2.1.3. Domates Fideleri

Saksı denemeleri için Newton F1 sırık domates fideleri kullanılmıştır (Şekil 2.3). Fideler Antalya'daki İstanbul Fide firmasından temin edilmiştir. 50 adet domates fidesi denemede kullanılmıştır.



Şekil 2.3. Domates fidesi

2.1.4. Toprak ve Saksı Özellikleri

Bu çalışmada saksı denemelerinde Şekil 2.4'te görüldüğü gibi 25 x 22 cm'lik saksılar kullanılmış ve her saksıya 2000 g kum + turba (%75 kum ve %25 turba) toprak karışımı konulmuştur.



Şekil 2.4. Saksı ve yetişmiş domates fideleri

2.1.5. OpenCV Kütüphanesi

Görüntü işleme algoritmaları kullanılarak renkli nesne algılama teknikleri bu çalışmada kullanılmıştır. Görüntü işleme için Intel'in açık kaynak görüntü işleme kütüphanesi olan Open Source Computer Vision (OpenCV) kullanılmıştır. OpenCV kütüphanesinin bu çalışmada kullanılmasının temel amacı gerçek zamanlı görüntü işleme uygulamalarına olanak sağlamasıdır. OpenCV tarafından sağlanan renk tespiti ve tespit edilen renk bileşenlerinin birbirine benzer bölgelere ayrılması gerçekleştirilmiş ve nesnelerin konumlarının koordinat olarak belirlenerek takip edilmesi için bir algoritma tanımlanmıştır.

2.1.6. Domateste Bakteriyel Benek Hastalığı

13-28°C'de ve yüksek nemde *Pseudomonas syringae pv. tomato* büyür ve yayılır. Erken enfekte olmuş bitkiler ortalama %75, geç enfekte olmuş bitkiler ise yaklaşık %5 verim kaybına sebep olmaktadır (Yunis ve Bashan, 1980). Sağlıklı fidelerde enfeksiyon, tohum kaynaklı enfeksiyon veya önceki ürünlerden tarlada kalan hastalıklı bitki kalıntıları yoluyla başlar. Enfeksiyonun bir sonucu olarak, hastalık organizmaları enfekte fideler aracılığıyla tarlaya taşınır ve uygun koşullar altında salgınlara neden olmaktadır. Topraktaki bulaşık bitki artıkları yaralar yoluyla sağlıklı bitkilere bulaşmaktadır (Aysan ve Saygılı, 2008).

2.2. Yöntem

2.2.1. Hastalık Etmeni Bakterinin Bulaştırılması

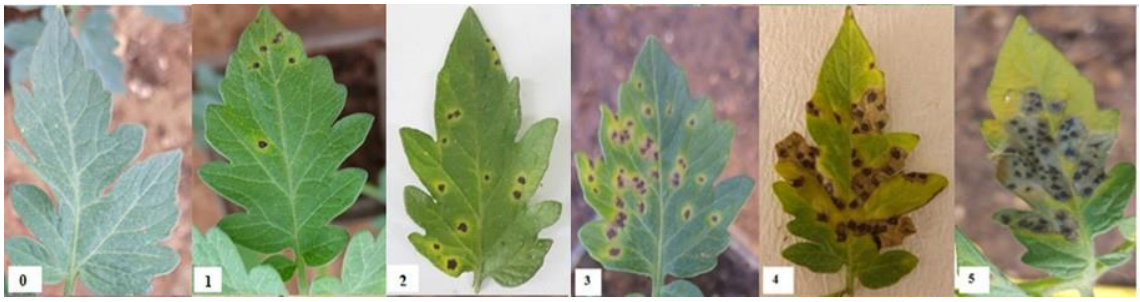
Bu çalışmada izole ve teşhis edilen *Pseudomonas syringe pv. tomato* DG 1-2 1R izolatı, yapraktan ilaçlama için patojen olarak kullanılmıştır. Erciyes Üniversitesi Ziraat Fakültesi Bitki Koruma Bölümü bakteriyolojik kültür koleksiyonunda izolat -20°C'de saklanmıştır. Ertesi gün domates fidelerine 10^8 bakteri/ml yoğunlukta hazırlanan izolat yapraklara püskürtülmüştür. Püskürtülen bitkiler, hastalık belirtileri gözlenene kadar serada (16 saat aydınlık, 8 saat karanlık, sıcaklık 27°C, nem %70-80) tutulmuştur.

2.2.2. Hastalığın Tespitinde Kullanılan Görsel Skala Hakkında Bilgi

Bitki koruma uzmanları tarafından yapılan saha gözlemleri sonucunda, domates bitkisinde bakteriyel benek hastalığı tespit edilmiştir. Gözlem sırasında uzman, kendi oluşturduğu 0-5 skalasını (Tablo 2.1) kullanarak domates yapraklarında hastalık olup olmadığını ve eğer hastalık varsa, hastalığın hangi aşamada olduğunu belirlemeye çalışmıştır. Bu skala, hastalığın evresini belirlemede rehberlik eder. Domatesteki bakteriyel leke hastalığı için, Şekil 2.5'te gösterilen görsel skala kullanılarak hastalığın şiddetine bağlı olarak ölü bölgeler tespit edilmeye çalışılmıştır. Uzman, ölü yaprakların bulunduğu alan ile bu alanın genel yaprağa oranını inceleyerek hastalığın yayılımını belirlemeye çalışmıştır. Yapılan gözlemler uzmanlar arasında farklılık gösterebilir. Bu çalışmada, fotoğraf makinesi ile alınan görüntüler, geliştirilen görüntü işleme algoritmaları ile işlenerek hastalıklı alanlar tespit edilmiştir.

Tablo 2.1. Domates bakteriyel benek hastalığı tespitinde kullanılan 0-5 skalası (Aysan vd., 2019).

Skala No	Açıklama
0	Hastalık belirtisi yok (%0)
1	Yaprağın %1-%15'i enfekteli
2	Yaprağın %16-%30'u enfekteli
3	Yaprağın %31-%45'i enfekteli
4	Yaprağın %46-%60'ı enfekteli
5	Yaprağın %60-%100'i enfekteli



Şekil 2.5. Domates bakteriyel benek hastalığı görsel skala (Aysan vd., 2019).

2.2.3. Görüntü Alma

Domates, iki çenekli ve otsu bir bitkidir. Ilıman ve yüksek sıcaklık iklimlerinde yetişen domates, sera ortamında da yetiştirilebilir. Domateslerde hastalık belirtilerini gözlemlemek için sera içerisindeki sıcaklık 30°C'nin üzerine çıkarılmamış ve nem oranı %70'in altına düşürülmemiştir (Şekil 2.6). Enfekte edilen bitkilerin yapraklarından her hafta doğal aydınlanma koşullarında ilk görüntü 22 Kasım 2022 tarihinde alınarak 2023 Ocak'a kadar her 15 günde bir olmak üzere doğal aydınlanma koşullarında 4.928 x 3.264 piksel çözünürlükte görüntüler alınmıştır.



Şekil 2.6. Serada ortam nemlendirmesi

2.2.4. Ön İşleme

Yaprak hastalığı tanıma işleminin uygun hale gelmesi için giriş görüntüsüne bir dizi ön işleme adımı uygulanmıştır. Giriş görüntüsüne uygulanan ilk ön işleme adımı görüntünün

yeniden boyutlandırılmasıdır. Orijinal görüntüler daha büyük boyuttadır ve işlenmesi daha fazla zaman alır. Bu nedenle zaman kaybını önlemek için tüm görüntüler 512x512 gibi daha küçük bir boyuta yeniden boyutlandırılmıştır.

2.2.4.1. Arka Plan Çıkarma

Arka plan çıkarma, görüntü işleme uygulamalarında yaygın olarak kullanılan bir tekniktir. Genellikle sabit bir arka plan üzerinde hareketli nesneleri (örneğin insanlar, araçlar, ürünler) algılamak ve izlemek için kullanılır. Bu işlemin mantığı, sabit bir arka planı referans olarak almak ve üzerindeki değişiklikleri yakalamaktır. Algoritma, sabit kısmı yani arka planı tespit ederek ve daha sonra üzerindeki değişiklikleri tespit ederek hareketi yakalayabilir. Bu algoritma, diğer hareketli nesne tespit yöntemlerine göre daha hızlıdır çünkü sadece sabit arka planı yakalar ve diğer her şeyi bu kritere göre değerlendirir. Şekil 2.7'de fotoğrafın arka fonunun nasıl çıkarıldığı gösterilmektedir.



```
from rembg import remove
from PIL import Image
import easygui as eg
input_path = eg.fileopenbox(title='Select image file')
output_path = eg.filesavebox(title='Save file to..')
input = Image.open(input_path)
output = remove(input)
output.save(output_path)
```

Şekil 2.7. Arka plan çıkarma

2.2.4.2. Renk Dönüşümü

Ön işlemde yer alan bir sonraki adım renk dönüşümüdür. Giriş RGB görüntüleri Ton Doygunluk Değeri (HSV) renk uzayına dönüştürülür. HSV insan algısına daha yakındır. Ton bileşeni genellikle bir gözlemci tarafından algılanan baskın renk olduğundan daha ileri analizler için dikkate alınmıştır. RGB'den HSV'ye renk dönüşümünün OpenCV'de nasıl yapıldığını gösterilmiştir (Şekil 2.8).



```
import cv2
bgr_img = cv2.imread('goruntu.png')
hsv_img = cv2.cvtColor(bgr_img, cv2.COLOR_BGR2HSV)
cv2.imwrite('hsv_goruntu.png', hsv_img)
cv2.imshow('HSV image', hsv_img)
cv2.waitKey(0)
cv2.destroyAllWindows()
```

Şekil 2.8. RGB görüntüsünü HSV görüntüsüne çevirme

2.2.5. Renk Tabanlı Kümeleme

Otsu yöntemi, görüntü işleme ve görüntü analizi alanında kullanılan bir görüntü işleme tekniğidir. Bir görüntü üzerindeki nesne veya nesneleri tanımlamak için ve buna ilaveten özellikle nesne sınırlarını tanımlamak için kullanışlıdır. Görüntü işleme, nesne tanıma, nesne izleme ve benzeri uygulamalarda yaygın olarak kullanılmaktadır. Otsu yöntemi, bir görüntüdeki piksellerin gri seviyelerini analiz eder ve bu gri seviyeleri farklı nesne veya arka plan bölgelerine ayırmayı amaçlar. Temel prensip, en iyi sınır gri seviyesini belirlemek için görüntüdeki piksellerin gri seviyeleri arasındaki varyasyonu ve dağılımı kullanmaktır. Bu sınır gri seviyesi, nesne ve arka plan bölgelerini en iyi şekilde ayıran eşik olarak kullanılır. Otsu yöntem, görüntüdeki gri seviyelerin histogramı kullanılarak çalışır. İlk adım, görüntünün histogramını hesaplamak ve her gri seviyeyi bir eşik olarak denemektir. Her eşik için iki sınıf ayırma ölçüsü hesaplanır. Bu eşik, Otsu eşikleme işleminde kullanılan verilere karşılık gelir. Bu işlem tüm olası eşikler için tekrarlanır ve en büyük ölçeğe sahip eşik seçilir. Sonuç olarak, Otsu yöntemi görüntü üzerindeki nesne ve arka plan bölgelerini otomatik olarak ayırmak için bir eşik değeri üretir. Bu eşik, görüntü işleme uygulamalarında nesne tespiti ve nesne tanımlama için kullanılabilir. Otsu yöntemi görüntü işleme uygulamalarında kullanılan basit ve etkili bir yöntemdir.

2.2.6. Bölümlendirme (Segmantasyon)

Otsu segmentasyonu, gri tonlama değerine göre pikselleri iki sınıfa böler, böylece nesneleri veya bölgeleri arka plandan ayırır. Bu yöntem özellikle tek eşikli görüntülerde etkilidir ve basitçe uygulanabilir. Hastalıklı kısımların segmentasyonu gereklidir, aksi takdirde hastalıklı olmayan kısım sonuçlara hâkim olacaktır. Önerilen sistemimizde, ilgili bölgeleri ve arka planı ayırmak için otsu yöntemi kullanmayı amaçlamak gereklidir.

```
# Otsu segmentasyonu
ret, otsu_threshold = cv2.threshold(image, 0, 255, cv2.THRESH_BINARY + cv2.THRESH_OTSU)
```

2.2.7. Kontrast Geliştirme

Kontrast geliştirme, bir görüntüdeki parlaklık dağılımına odaklanır. Akromatik bir görüntüde grinin tüm tonları kullanılmazsa, görüntü daha az ayrıntıya sahip olur ve düşük kontrastlı görüntü olarak adlandırılır. Kontrastı artırılmış görüntüler siyahtan beyaza dengeli bir parlaklık dağılımı gösterir. Düşük kontrastlı görüntüler soluk görüntüler olarak algılanır. Kontrast geliştirmenin nihai amacı görüntünün temel, değişmeyen özelliklerini ortaya çıkarmaktır.

```
# Kontrast geliştirme işlemi

clahe = cv2.createCLAHE(clipLimit=2.0, tileGridSize=(8, 8))

enhanced_image = clahe.apply(image)
```

2.2.8. Yaprak Üzerindeki Hastalık Şiddeti Hesabı

Bölütlenmiş HSV renkli görüntü gri tonlamalı görüntüye dönüştürülür. Gri tonlamalı görüntüden beyaz olmayan piksel alanı eşiklenerek eşik görüntüsü elde edilir. Arka plan pikselleri dışındaki pikselleri ölçmek için OpenCV count non-zero fonksiyonu kullanılır. Benzer şekilde orijinal görüntüden tüm yaprak bölgesinin alanı eşikleme kullanılarak elde edilir. Hastalıklı yaprak bölgesinin yüzdesi şu şekilde elde edilir.

$$\text{Hastalık Şiddeti (\%)} = \frac{\text{Hastalık algılanan bölgenin alanı}}{\text{Tam yaprak görüntüsünün alanı}} * 100$$

3. BÖLÜM

BULGULAR

Araştırma sonuçlarında elde edilen skala ile daha önce geliştirilen görsel skala karşılaştırılarak sonuçlarının değerlendirilmesi bu bölümde yapılmıştır.

3.1. Skalanın Geliştirilmesi ve Test Edilmesi

Bu çalışma, Kasım 2022 ile Ocak 2023 tarihleri arasında gerçekleştirilen bir nicel durum çalışması modeline dayanmaktadır. Çalışmanın gerçekleştirilebilmesi için izole ve teşhis edilen *Pseudomonas syringe pv. tomato* DG 1-2 1R izolatı, yapraktan ilaçlama için patojen olarak kullanılmıştır. Patojenler sprey şişesine doldurulmuş ve yapraklara püskürtülmüştür. Püskürtme işlemi sonrasında bitkiler, Erciyes Üniversitesi Ziraat Fakültesi Dekanlığına bağlı serada, 20-24°C sıcaklık ve %70-80 nemde tutularak hastalık seyri izlenmiştir. Patojen enjekte edilmiş domates bitkisi yapraklarının hastalık seyrini gözlemleyebilmek için 3006 adet sağlıklı ve sağlıksız domates yaprağının belirli günlerde fotoğrafları çekilmiştir. Yapılan çalışmaların sonucunda elde edilen 6 adet görüntünün araştırmanın görsel skalalarını temsil etme yeterliliğine sahip olduğu için sadece bunlar dikkate alınmış ve elde edilen 6 adet görüntünün bulgusu ve görsel skala tablosu (Tablo 3.1) geliştirilen algoritmalarla birlikte aşağıda sunulmuştur (Şekil 3.1, 3.2, 3.3., 3.4, 3.5 ve 3.6).

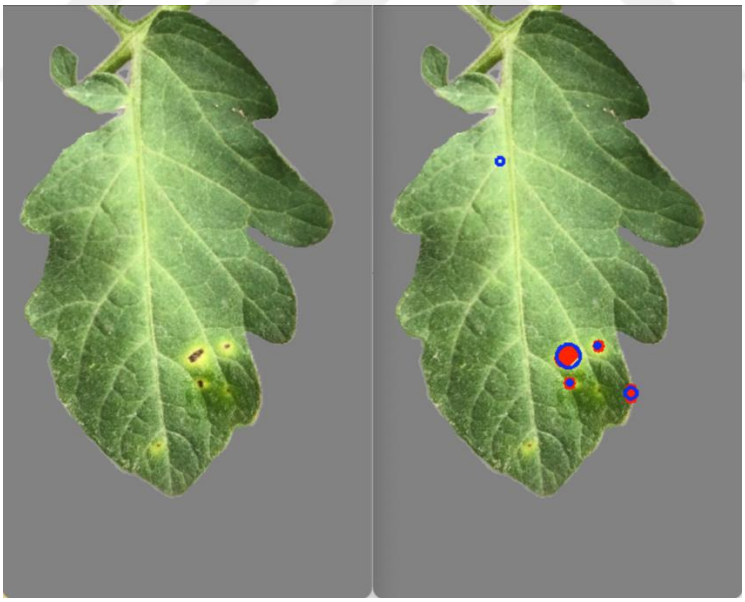
Tablo 3.1. Hastalık skalası

Skala 0	Hastalık belirtisi yok (%0)
Skala 1	Yaprağın %1-%10'u enfekteli
Skala 2	Yaprağın %11-%25'i enfekteli
Skala 3	Yaprağın %26-%50'si enfekteli
Skala 4	Yaprağın %51-%75'i enfekteli
Skala 5	Yaprağın %76-%100'ü enfekteli



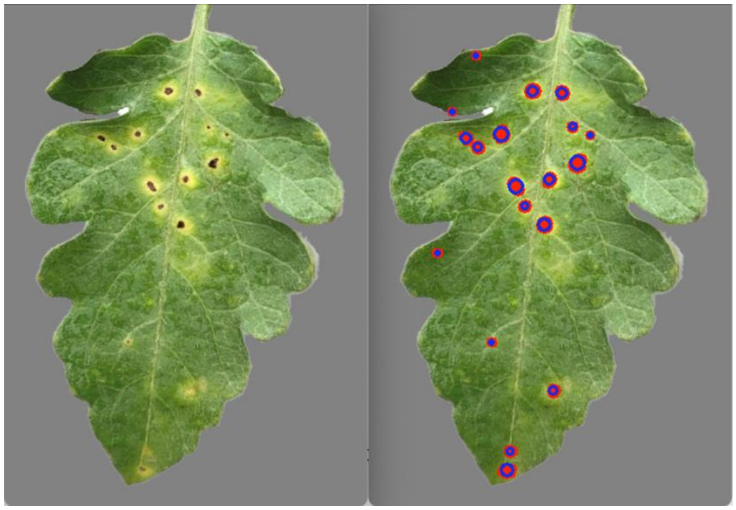
Skala 0, Hastalık yüzdesi %0.00	
Skala No	Açıklama
0	Bu yaprağın yapılan işlemler neticesinde görsel skalaya uygun olarak hastalıksız olduğu tespit edilmiştir.

Şekil 3.1. Skala 0 seviyesinde yaprak görüntüsü



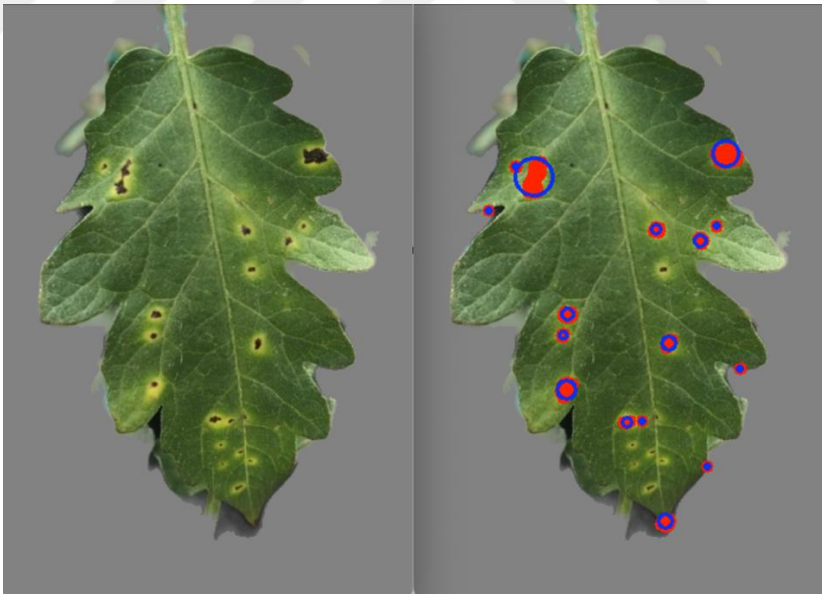
Skala 1, Hastalık yüzdesi %8.64	
Skala No	Açıklama
1	Bu yaprağın yapılan işlemler neticesinde görsel skalaya uygun olarak hafif patojenik olduğu tespit edilmiştir. (**%1-%10)**

Şekil 3.2. Skala 1 seviyesinde yaprak görüntüsü



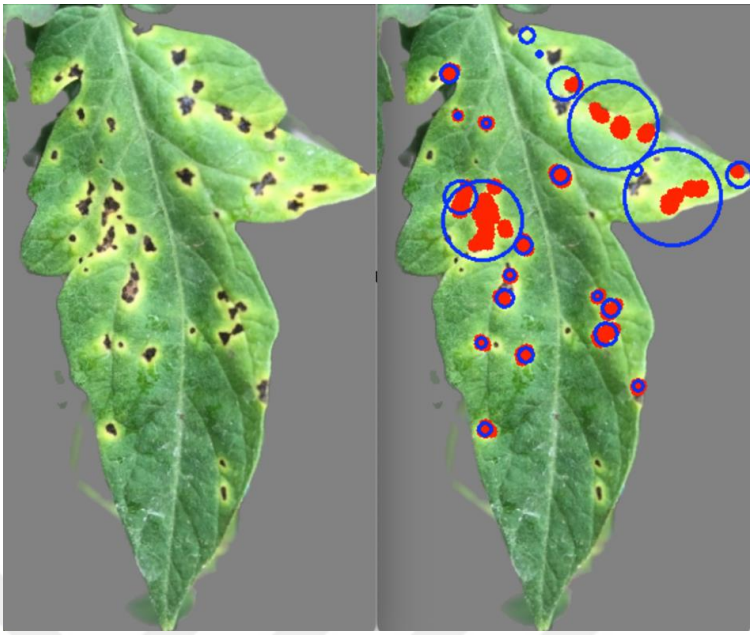
Skala 2, Hastalık Yüzdesi %24.94	
Skala No	Açıklama
2	Bu yaprağın yapılan işlemler neticesinde görsel skalaya uygun olarak patojenin ilerlemiş olduğu tespit edilmiştir. (**%11-%25)**

Şekil 3.3. Skala 2 seviyesinde yaprak görüntüsü



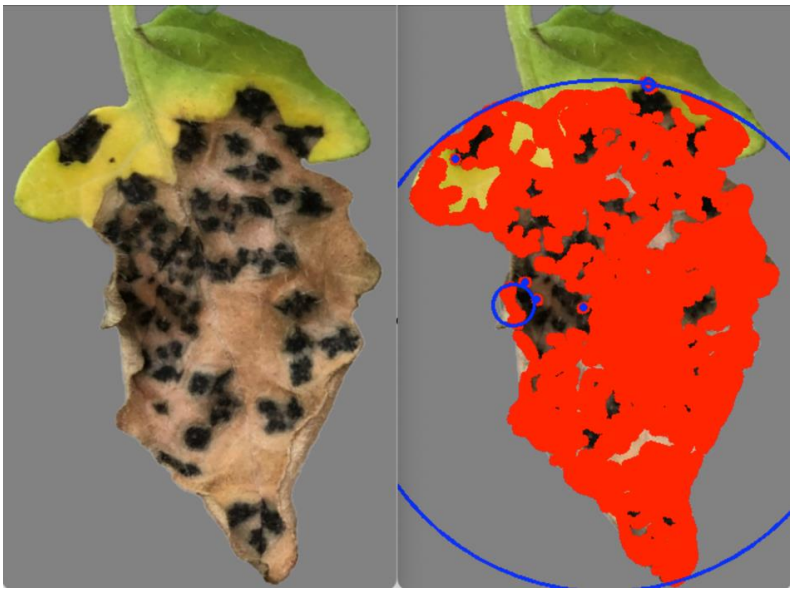
Skala 3, Hastalık Yüzdesi %27.78	
Skala No	Açıklama
3	Bu yaprağın yapılan işlemler neticesinde görsel skalaya uygun olarak patojenin ilerleme seviyesinin yükseldiği ve yapraklara orta öldürücü olduğu tespit edilmiştir. (**%26-%50)**

Şekil 3.4. Skala 3 seviyesinde yaprak görüntüsü



Skala 4, Hastalık Yüzdesi %62.97	
Skala No	Açıklama
4	Bu yaprağın yapılan işlemler neticesinde görsel skalaya uygun olarak patojenin ilerleme seviyesinin yükseldiği ve yapraklara son derece öldürücü olduğu tespit edilmiştir. (**%51-%75)**

Şekil 3.5. Skala 4 seviyesinde yaprak görüntüsü



Skala 5, Hastalık Yüzdesi %89.69	
Skala No	Açıklama
5	Bu yaprağın yapılan işlemler neticesinde görsel skalaya uygun olarak patojenin ilerleme seviyesinin yükseldiği ve yapraklara son derece yüksek öldürücü olduğu tespit edilmiştir. (**%76-%100)**

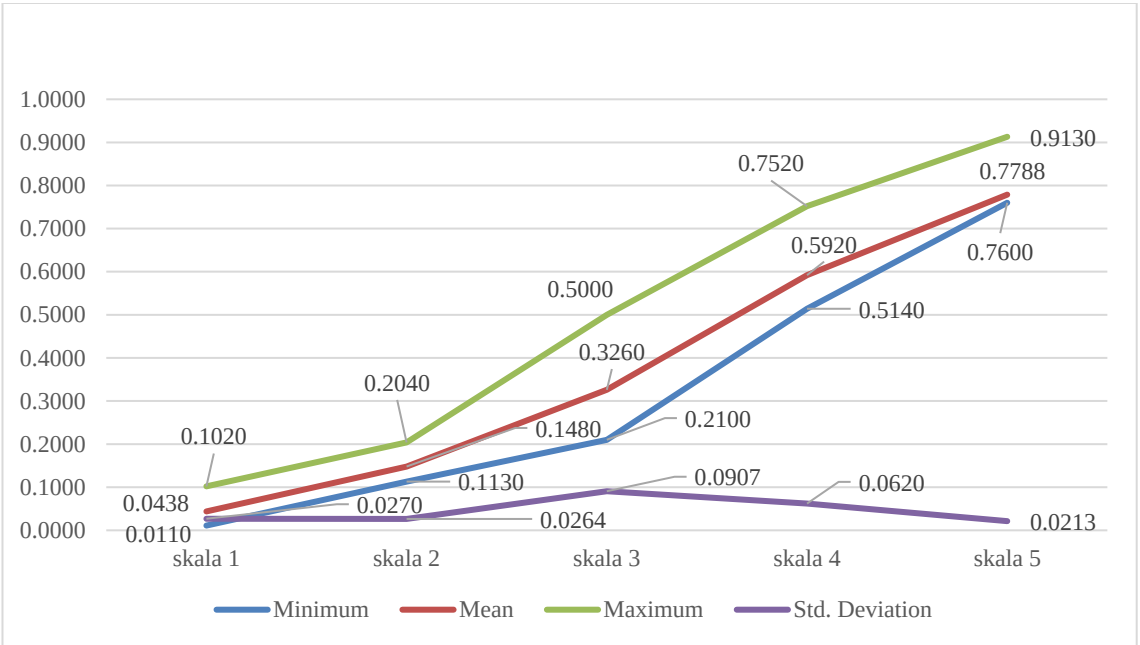
Şekil 3.6. Skala 5 seviyesinde yaprak görüntüsü

3.2. Python Sonuçlarının Görsel Skalayla Karşılaştırılması

Belirtilen yöntem çerçevesinde, sera ortamında çekilen 1504 adet hastalıklı yaprak görüntüsü, hastalığın şiddetini ölçmek için Python ortamında geliştirilen algoritmalar kullanılarak görüntü işlemeye tabi tutulmuştur. Ölçülen hastalık şiddetinin güvenilirliğini değerlendirmek amacıyla SPSS programı kullanılmıştır. Bu programda kullanılan skalaların minimum ve maksimum değerleri, ayrıca ortalama ve standart hata değerleri sunulmuştur. Elimizde 3006 adet domates yaprağı görüntüsü bulunmaktadır ve 2 hafta sonra 491 tanesine hastalık bulaştığı tespit edilmiştir. Tablo 3.2'de, hastalığın şiddetinin zamanla azaldığı ve yapraklarda yayılma eğiliminin olduğu görülmüştür. Sera ortamında yapay yollarla oluşturulan nem miktarının, nemli bölgelerdeki nem değerlerine yaklaşamamasının, hastalığın seyrini etkilediğini gösterdiği ifade edilmiştir.

Tablo 3.2. SPSS programı verileri

Görüntü İşleme (Python)	Skala 1	Skala 2	Skala 3	Skala 4	Skala 5
Minimum Değer	0.0110	0.1130	0.2100	0.5140	0.7600
Ortalama	0.0438	0.1480	0.3260	0.5920	0.7788
Maksimum	0.1020	0.2040	0.5000	0.7520	0.9130
Standart Sapma	0.02695	0.02639	0.0907	0.06204	0.02131
N	491	359	295	275	84



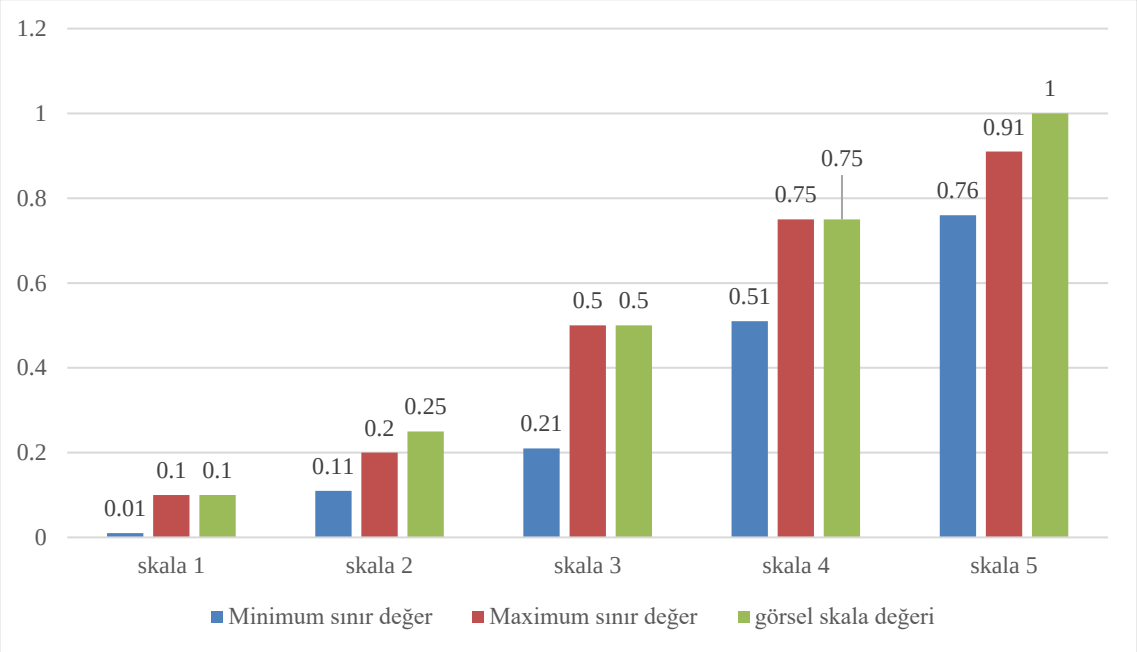
Şekil 3.7. Skala verilerinin dağılımları

Şekil 3.7'den de anlaşılacağı gibi, standart hata skala 3'ten sonra azalma eğilimi göstermektedir. Skala 1'de 0.02695, Skala 2'de 0.02639, Skala 3'te 0.0907, Skala 4'te 0.06204 ve Skala 5'te 0.02131 değerini almaktadır. Kullanılan algoritmaların, hastalığın şiddeti ile artan bakteriyel siyah beneklerin artışını detaylıca yakalaması, standart hatayı azaltmaktadır. Standart hatadaki azalmalar, tahmin edilen rakam yaklaşma düzeyindeki sapmaları ifade ettiğinden, standart sapmadaki azalışlar araştırmanın başarısını ortaya koymaktadır.

Tablo 3.3. Karşılaştırılan değerler

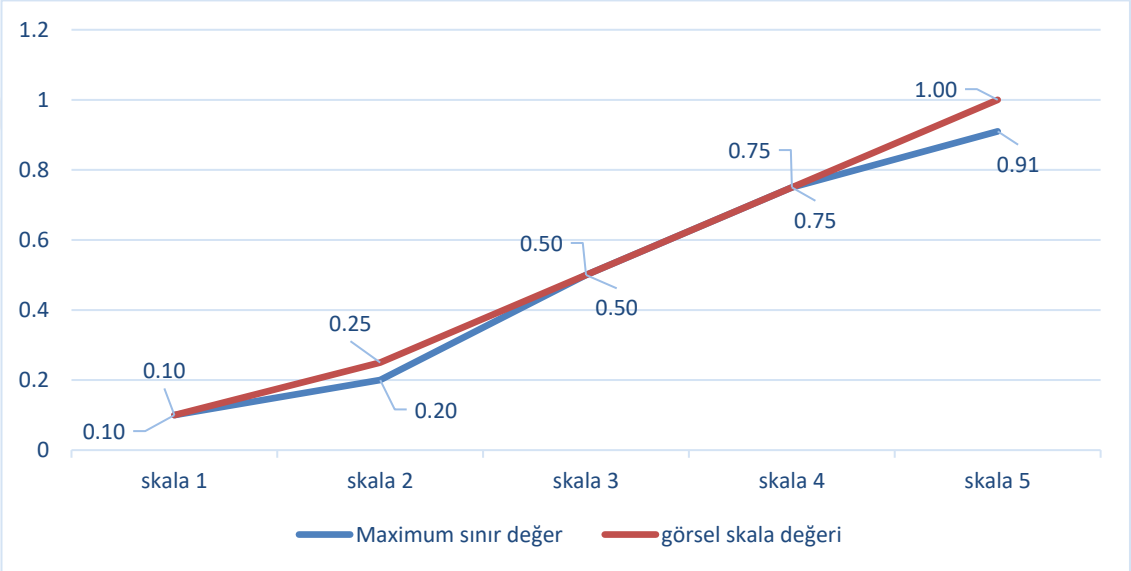
Görüntü İşleme (Python)	Skala 1	Skala 2	Skala 3	Skala 4	Skala 5
Minimum sınır değer	0.01	0.11	0.21	0.51	0.76
Maximum sınır değer	0.10	0.20	0.50	0.75	0.91
Görsel skala değeri	0.10	0.25	0.50	0.75	1.00
N	491	359	295	275	84

Tablo 3.3'te, görsel skala ile Python ile yapılan analizlerde elde edilen değerler verilmiştir. Görsel skala değerleri, araştırmanın başlangıcında belirlendiği için Python değerleri ile karşılaştırılması gerekmektedir.



Şekil 3.8. Görsel skala ile python analizi sonucu elde edilen sınır değerlerinin karşılaştırılması

Şekil 3.8'de görüldüğü gibi, Python analizleri sonucu elde edilen değerler, görsel skalanın minimum değerleri ile Python analizleri sonucu elde edilen minimum değerleri örtüşmekte ve görsel skalanın maksimum değerlerine ise yakın değerler vermektedir. Bu durum aşağıdaki şekilde detaylı olarak gösterilmiştir. Python analizi sonucu elde edilen maksimum sınır değeri, minimum sınır değerleri ile görsel skala değerleri arasında yer almaktadır.



Şekil 3.9. Görsel skala ile python analizi sonucu elde edilen maksimum sınır değerleri ile karşılaştırılması

Şekil 3.9'dan da anlaşılacağı gibi, Python analizleri sonucu elde edilen maksimum sınır değer, görsel skala değeri ile ya aynı değerde ya da daha küçük değerdedir. Buna göre, Python analizleri sonucu elde edilen değerin görsel skala değerini aşmadığını söylemek mümkündür.

4. BÖLÜM

TARTIŞMA, SONUÇ VE ÖNERİLER

4.1. Tartışma

Domates yetiştiriciliğinde karşılaşılan hastalıklar, verimlilik ve ürün kalitesi üzerinde önemli bir etkiye sahiptir. Bu hastalıklardan biri de bakteriyel benek hastalığıdır. Bu hastalık domates bitkilerinin yapraklarında lekelenme ve çürüme gibi belirtilerle ortaya çıkmaktadır. Hastalığın erken teşhisi, bitki sağlığını korumak ve ürün kayıplarını en aza indirmek için kritik bir öneme sahiptir. Son yıllarda yapılan araştırmalar, geleneksel yöntemlerin yanı sıra hiperspektral spektroskopi ve derin öğrenme gibi modern tekniklerin hastalık teşhisi ve sınıflandırmasında etkili olduğunu ortaya koymuştur.

Domates yapraklarında *Pseudomonas syringae pv. tomato (Pst)* ve *Xanthomonas euvesicatoria (Xeu)* tarafından neden olunan bakteriyel hastalıkların teşhisinde hiperspektral spektroskopinin kullanımı araştırılmıştır. Hiperspektral spektroskopinin, bitki hastalıklarının erken teşhisi için etkili, hızlı ve maliyet açısından uygun bir yöntem olduğu belirlenmiştir. Bu teknik, bitki yapraklarında hastalığa neden olan mikroorganizmaların spektral imzalarını belirleyerek hastalığın varlığını tespit etmekte ve böylece tedavi önlemlerinin alınmasına olanak tanımaktadır (Pereira vd., 2023).

Derin öğrenme yöntemlerinin domates hastalıklarının teşhisi ve sınıflandırmasında önemli bir rol oynadığı belirlenmiştir. Özellikle, araştırmacılar tarafından kullanılan ShuffleNet mimarisi ile eğitilen derin öğrenme modeli, yüksek doğruluk oranları ve performans metrikleri ile başarılı sonuçlar elde etmiştir. Bu model, domates yapraklarında bakteriyel benek hastalığının yanı sıra diğer bitki hastalıklarını da tespit etmek için kullanılabilir (Hong ve diğerleri, 2020). Derin öğrenme modellerinin kullanımı, bitki hastalıklarının erken teşhisi ve sürdürülebilir tarım uygulamalarının teşvik edilmesi

açısından önemlidir. Farklı derin öğrenme mimarilerinin karşılaştırılması da bu bağlamda kritik bir rol oynamaktadır.

Araştırmalar, özellikle ResNet34 gibi derin öğrenme modellerinin, geleneksel makine öğrenimi yöntemlerine kıyasla daha yüksek doğruluk sağladığını göstermiştir. Bu bulgu, derin öğrenme modellerinin domates hastalıklarının teşhisi ve sınıflandırmasında kullanılmasının önemini vurgulamaktadır. Ancak, model seçiminde kullanılan veri seti ve özellik çıkarım yöntemleri gibi faktörlerin de sonuçları etkileyebileceği unutulmamalıdır (Tan ve diğerleri, 2021). Gelecekteki araştırmalar, derin öğrenme modellerinin performansını daha da artırmak için önemlidir. Tarım sektöründe derin öğrenme tekniklerinin daha yaygın hale gelmesi için daha büyük ve çeşitlendirilmiş veri setlerine ihtiyaç vardır. Ayrıca, transfer öğrenme ve veri artırma tekniklerinin daha etkili kullanılması, modellerin doğruluğunu ve genelleme yeteneğini artırabilir. Bu, tarım endüstrisindeki veri bilimi ve yapay zekâ alanındaki gelişmelerin, bitki hastalıklarının teşhisi ve yönetimi üzerindeki etkisini artırabilir (Natarajan vd., 2020).

Bir başka önemli nokta da derin öğrenme modellerinin tarımsal uygulamalardaki başarısının, kullanılan veri setlerinin kalitesine ve çeşitliliğine bağlı olmasıdır. Büyük bir veri kümesi kullanılarak CNN ile yapılan sınıflandırma, yüksek doğruluk oranları elde edilmesini sağlamıştır. Ancak, bu tür veri setlerinin oluşturulması ve yönetilmesi zaman alıcı ve maliyetlidir. Bu nedenle, tarım endüstrisinde yapay zekâ tabanlı çözümlerin benimsenmesi için uygun veri altyapısının oluşturulması önemlidir (Brahimi vd., 2017). Ayrıca dikkate değer bir nokta, çoğu literatürde domates yapraklarında görülen hastalığının *Xanthomonas vesicatoria* tarafından neden olduğu bacterial spot hastalığı üzerine odaklanılmış olmasıdır. Ancak, bu tez çalışmasında ele alınan hastalık bacterial speck (*Pseudomonas syringae pv. tomato*) olarak bilinen farklı bir bakteri türüne dayanmaktadır. Bu farklılık, hastalığın teşhisi ve yönetimi için geliştirilen yöntemlerin türler arasında farklılık gösterebileceğini ve dolayısıyla bu çalışmanın bulgularının doğruluğunun ve uygulanabilirliğinin bacterial speck hastalığı için özellikle önemli olduğunu göstermektedir.

4.2. Sonuç ve Öneriler

Bu çalışma, görüntü işleme teknikleri kullanılarak yürütülen araştırmanın başarılı olduğunu gösteren önemli bir sonucu ortaya koymuştur. Gözlem ve değerlendirme sonuçları arasındaki benzerlik, çalışmanın güvenilir ve etkili bir şekilde gerçekleştirildiğini göstermektedir. Ayrıca, görüntü işleme teknolojisinin kullanılmasıyla elde edilen sonuçların, gözlemle belirlenemeyen hassas bölgelerde daha doğru değerler sağladığı vurgulanmaktadır. Bu durum, teknolojinin avantajlarından biri olarak kabul edilebilir çünkü görüntü işleme yöntemleri, belirli ölçümleri hassas bir şekilde gerçekleştirme yeteneğine sahiptir ve gözlemle belirlenemeyen detayları ortaya çıkarabilir. Elde edilen 6 adet görüntünün bulgularını gösteren sayısal veriler Tablo 4.1 görülmektedir.

Tablo 4.1. Sayısal Veriler

Yaprak Görüntüleri	Görüntü İşleme (%)	Gözlem Aralıkları (%)
Skala 0	Hastalık yüzdesi %0.00	Hastalık belirtisi yok (%0)
Skala 1	Hastalık yüzdesi %8.64	Yaprağın %1-%10'u enfekteli
Skala 2	Hastalık Yüzdesi %24.94	Yaprağın %11-%25'i enfekteli
Skala 3	Hastalık Yüzdesi %27.78	Yaprağın %26-%50'si enfekteli
Skala 4	Hastalık Yüzdesi %62.97	Yaprağın %51-%75'i enfekteli
Skala 5	Hastalık Yüzdesi %89.69	Yaprağın %76-%100'ü enfekteli

Domates bakteriyel benek hastalığı genellikle bitki korumacıları tarafından yapılan yer gözlemleriyle tespit edilir. Uzmanlar, domateslerde görülen bakteriyel benek hastalığını, yaprağın etkilenen ve sağlıklı bölgelerini karşılaştırarak hastalığın yayılımını tecrübeleriyle belirlemeye çalışırlar. Ancak bu gözlemler uzmandan uzmana değişebilir. Bu çalışmada, fotoğraf makinası ile çekilen görüntülerin, etkilenen bölgeyi doğru bir şekilde belirlemek için geliştirilmiş bir görüntü işleme algoritması ile işlenmiş olması, gözlem yöntemi yerine kullanılabileceğini ve hatta daha doğru sonuçlar verebileceğini göstermiştir. Bu yaklaşımın başarılı sonuçları, çiftçilere ekili bitkilerin üretim dönemi boyunca emek ve zaman kaybını önlemelerine ve hastalık değişikliklerini daha etkin bir şekilde kontrol altına almalarına yardımcı olur.

Bu çalışmanın başarılı bir şekilde uygulanması, gerekli ilaçlama ve bakım çalışmalarının zamanında gerçekleştirilerek domates bitkisinin hastalıklara bağlı verim kaybını minimize etme potansiyelini beraberinde getirmektedir. Bu durum, ekonomik sürdürülebilirliğe büyük katkı sağlayan domates üretiminde daha sürdürülebilir bir yaklaşımın benimsenmesine olanak tanır. Aynı zamanda, çiftçilere hastalıklarla mücadele konusunda daha etkili ve bilgi temelli bir strateji sunarak, tarım verimliliğini artırma ve ürün kalitesini yükseltme fırsatı da sağlar.

Bu tür sürdürülebilir tarım uygulamaları hem çevresel sürdürülebilirlik hem de ekonomik açıdan avantajlı olabilir. Ayrıca, çiftçilere modern teknoloji ve bilgiye dayalı çözümler sunarak tarım sektöründe daha yenilikçi ve etkili bir yaklaşımın benimsenmesine katkıda bulunabilir.

Gelecekte görüntü işlemeye uygulanabilecek farklı teknolojiler, çeşitli mahsullerin yetiştirilmesinde tarımsal verimliliğin artırılmasına yardımcı olacaktır. Ayrıca bu teknik mobil cihazlar kullanılarak tarım sektöründe önemli kayıpları önlemek amacıyla teknik izleme ve yetiştirme testlerine imkân sağlayacaktır. Bu çalışmanın araştırmacıları benzer çalışmalar yapmaya yönlendirebileceği görülmüştür.

Sonuç olarak bu çalışma önemli bir çıktı olarak gördüğümüz görüntü işleme tekniklerinin daha hızlı ve daha hassas bir şekilde bakteriyel benek hastalığının teşhisini ve seyrini ortaya koyabilme gücüne sahip olduğunu göstermiştir. Bu yöntemlerin kullanılmasıyla gelecekte mevcut bilimsel metodoloji ile uyumu çerçevesinde daha da güçlü ve doğru sonuçlar ortaya koyacağı öngörülmektedir.

KAYNAKÇA

1. Taylor, J. B. (1986). Biosystematics of the Tomato. In J. G. Atherton & J. Rudich (Eds.), The tomato crop: A scientific basis for improvement (s. 1-34). **London: Chapman and Hall.**
2. Harvey, M., Quilley, S., & Beynon, H. (2002). Exploring the Tomato: Transformations of Nature, Society and Economy. Cheltenham, **UK: Edgar Publishing.**
3. Engels, J. M. M., & Jeffrey, C. (1993). Sechium edule (Jacq.) Swartz. In J. S. Siemonsma & K. Piluek (Eds.), Plant Resources of South-East Asia. No. 8. Vegetables. (s. 246-248). **Wageningen: Pudoc Scientific Publishers.**
4. Şeniz, V. (1992). Domates, Biber ve Patlıcan Yetiştiriciliği. **Tarımsal Araştırmaları Destekleme ve Geliştirme Vakfı,** İstanbul, 174.
5. Colvine, S., & Branthôme, F. X. (2016). The tomato: A seasoned traveller. In M. Causse, J. Giovannoni, M. Bouzayen, & M. Zouine (Eds.), **The tomato genome. Compendium of plant genomes** (pp. 1-5). Springer. https://doi.org/10.1007/978-3-662-53389-5_1
6. Jones, J. B., Jones, J. P., Stall, R. E., & Zitter, T. A. (1991). Compendium of Tomato Diseases. **APS Press,** USA.
7. Wilson, M., Campbell, H. L., Ji, P., Jones, J. B., & Cuppels, D. A. (2002). Biological control of bacterial speck of tomato under field conditions at several locations in North America. **Phytopathology**, 92(12), 1284-1292. https://doi.org/10.1094/PHYTO.2002.92.12.1284
8. Samtaş, G., & Gülesin, M. (2012). Sayısal Görüntü İşleme ve Farklı Alanlardaki Uygulamaları. **Electronic Journal of Vocational Colleges,** 2, 85-97.
9. Singh, V., & Misra, A. K. (2017). Detection of Plant Leaf Diseases using Image Segmentation and Soft Computing Techniques. **Information Processing in Agriculture,** 4(1), 41-49.

10. Altas, Z., Ozguven, M. M., & Yanar, Y. (2018). Determination of sugar beet leaf spot disease level (*Cercospora beticola Sacc*.) with image processing technique by using drone. **Current Investigations In Agriculture and Current Research**, 5(3), 621-631.

11. Haşim Keskin, A., & Karakayacı, Z. (2014). Konya İli Çumra İlçesindeki Domates Üretiminde Domates Güvesinin (*Tuta absoluta*) Sosyo-Ekonomik Etkilerinin Değerlendirilmesi. **XI. Ulusal Tarım Ekonomisi Kongresi**, 3-5 Eylül, Samsun, 688-692.

12. Ertürk, Y. E., & Çirka, M. (2015). Türkiye'de ve Kuzey Doğu Anadolu Bölgesi (KDAB)'nde Domates Üretimi ve Pazarlaması. **YYÜ Tarım Bilimleri Dergisi**, 25(1), 84-97.

13. Food and Agriculture Organization. (2021). FAOSTAT- Food and Agriculture Organization. **https://www.fao.org/faostat/en/#data** (Erişim tarihi: Aralık 2023)

14. Vural, H., Esiyok, D., & Duman, I. (2000). Kültür Sebzeleri (Sebze Yetiştirme). **İzmir: Ege Üniversitesi Basımevi.**

15. Doç. Dr. Sarp ERTÜRK., Arş. Gör. Oğuzhan URHAN. (2013). **İmage İşleme Ders Notları**. Kocaeli Üniversitesi Mühendislik Fakültesi Elektronik ve Haberleşme Mühendisliği Bölümü.

16. Aksoy, B. (2021). Python ile İmgeden Veriye Görüntü İşleme ve Uygulamaları. **Ankara: Nobel.**

17. Samtaş, G., & Gülesin, M. (2012). Sayısal Görüntü İşleme ve Farklı Alanlardaki Uygulamaları. **Electronic Journal of Vocational Colleges**, 2(1), 85-97.

18. Adobe Photoshop: Using Color. (Erişim tarihi: Aralık 2023) **http://helpx.adobe.com/tr/photoshop/using/color.html**

19. Polat, H. (2012). Grafik tasarım sürecinde kullanılan aygıtların renk modelleri. **İdil Sanat ve Dil Dergisi**, *1*, Article 08. https://doi.org/10.7816/İdil-01-03-08

20. Yılmaz, İ. (2002). Renk Sistemleri, Renk Uzayları ve Dönüşümler. **Selçuk Üniversitesi Jeodezi ve Fotogrametri Mühendisliği Öğretiminde 30. Yıl Sempozyumu**, Konya. (s. 36).

21. Smith, A. R. (1978). Color Gamut Transform Pairs. **Computer Graphics**, 12, 12-19.

22. The MathWorks Training Services. (2008). **MATLAB for Image Processing**. The MathWorks, Inc.

23. Mehmet K. (2012). **Görüntü İşleme Teknolojileri ve Uygulamaları**. Ege Üniversitesi, İzmir.

24. Bagio, D. et al. (2012). Mastering OpenCV with Practical Computer Vision Project. Packt Publisher.

25. Kuba, A. (2013). **Histogram Transformation In Image Processing And Its Applications**. Szeged Üniversitesi.

26. Akar, F. (2009). Şablon Eşleme Yöntemi ile Plaka Tanıma ve Değerlendirme Sistemi. Doktora Tezi, Atatürk Üniversitesi Fen Bilimleri Enstitüsü, Erzurum.

27. Baykan, Ö. K. (2007). Bilgisayar Destekli Un Kalite İzleme Sistemi Tasarımı. Doktora Tezi, Selçuk Üniversitesi, Konya.

28. Atasever, V., Arslan, D., & Güvenoğlu, E. (2010). Mobil Cihazlarda Online Görüntü İşleme Yazılımının Geliştirilmesi. **Akademik Bilişim Konferansı**, Muğla.

29. Alçı, M., & Akdemir, S. (2005). Beyin Emar Görüntülerinin Watershed Algoritması Yardımıyla Bölütlenmesi. Erciyes Üniversitesi Elektrik-Elektronik Mühendisliği Bölümü, Kayseri.

30. Wilson, D. L., & Noble, J. A. (1999). An adaptive segmentation algorithm for time-of-flight MRA data. **IEEE Transactions on Medical Imaging**, 18(10), 938-945. **https://doi.org/10.1109/42.811277.**

31. Van Rossum, G. (2003). Python Kılavuzu.

32. Erişti, E. (2010). Görüntü İşlemede Yeni Bir Soluk, **OpenCV**. İstanbul Ticaret Üniversitesi, Bilgisayar Mühendisliği Bölümü, İstanbul.

33. Türkoğlu, İ. (2010). T.C. Fırat Üniversitesi Fen Bilimleri Enstitüsü Elektronik ve Bilgisayar Eğitimi Anabilim Dalı Örüntü Tanıma Ders Notları. Elâzığ.

34. Kahveci, E., & Gürcan, A. (1993). Antalya ilinde domateslerdeki bakteriyel hastalık etmenlerinin tespiti. **Bitki Koruma Bülteni**, 33(3-4).

35. Aysan, Y., & Çınar, Ö. (2000). Çukurova Bölgesinde biberlerde bakteriyel leke hastalığının (*Xanthomonas axonopodis pv. vesicatoria*) çıkışı ve kontrolü üzerine araştırmalar. **Türkiye IX. Fitopatoloji Kongresi**, Tekirdağ, S. 549-554.

36. Cement, A. et al. (2018). "Potential of Bacteriophages to Control Bacterial Speck of Tomato (*Pseudomonas syringae pv. tomato*)." **Fresenius Environmental Bulletin,** 27, 9366-9373.

37. Kurtulmuş, F. (2012). Olgunlaşmamış Şeftali Meyvesini Doğal Bahçe Koşullarında Alınmış Görüntülerde Görüntü İşleme Teknikleri ve Yapay Sınıflandırıcılarla Saptayarak Sayan Algoritmaların Geliştirilmesi. Uludağ Üniversitesi Fen Bilimleri Enstitüsü (Doktora Tezi), Tarım Makinaları Anabilim Dalı, Bursa.

38. Örge, G. (2012). Farklı Kültür Bitkileri ve Yabancı Otların Renk Özelliklerinin Görüntü İşleme Tekniği ile Belirlenmesi. Namık Kemal Üniversitesi Fen Bilimleri Enstitüsü, Tarım Makineleri Anabilim Dalı, Yüksek Lisans Tezi, Tekirdağ.

39. Masoumi, A. (2013). Görüntü İşleme Tekniği ile Ekmeklik Buğday Çeşidinde Kaliteye Esas Bazı Özelliklerin Belirlenmesi. Ege Üniversitesi Fen Bilimleri Enstitüsü (Yüksek Lisans Tezi), Tarım Makinaları Anabilim Dalı, İzmir.

40. Tonguç, G. (2007). Görüntü İşleme Teknikleri Kullanılarak Meyve Tasnifi. Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü (Yüksek Lisans Tezi), Makine Eğitimi Anabilim Dalı, Isparta.

41. Menesatti, P., Costa, C., Paglia, G., Pallottino, F., D'Andrea, S., Rimatori, V., & Aguzzi, J. (2008). Shape-based methodology for multivariate discrimination among Italian hazelnut cultivars. Biosystems Engineering, 101, 417–424. **https://doi.org/10.1016/j.biosystemseng.2008.09.013.**

42. Geipel, J., Link, J., & Claupein, W. (2014). Combined Spectral and Spatial Modeling of Corn Yield Based on Aerial Images and Crop Surface Models Acquired with an Unmanned Aircraft System**. Remote Sensing, 6**, 10335-10355.

43. Reis, M. (2014). İnsansız Hava Araçları ile Bitki Koruma ve Tarım Uygulamaları. **ISITES**, (s. 1445-1449). Karabük.

44. Altaş, Z., Özgüven, M. M., & Yanar, Y. (2019, Nisan 24-27). Bitki hastalık ve zararlı düzeylerinin belirlenmesinde görüntü işleme tekniklerinin kullanımı: Şeker pancarı yaprak leke hastalığı örneği [Sözlü sunum]. **International Erciyes Agriculture Animal & Food Sciences Conference**, Kayseri, Türkiye.

45. Serrano, J., Marques Da Silva, J., Shahidian, S., Silva, L., Sousa, A., & Baptista, F. (2017). Differential vineyard fertilizer management based on nutrient's spatio-temporal variability. **Journal of Soil Science and Plant Nutrition**, 17, 46-61. **https://doi.org/10.4067/S0718-95162017005000004.**

46. Lin, C. M., Tsai, C.-Y., Lai, Y.-C., Li, S.-A., & Wong, C.-C. (2018, 15 Kasım). Visual Object Recognition and Pose Estimation Based on a Deep Semantic Segmentation Network. **IEEE Sensors Journal**, 18(22), 9370-9381. **https://doi.org/10.1109/JSEN.2018.2870957.**

47. Kavdır, İ., Turhan, H., Özpınar, S., Çay, A., Pekitkan, G., & Akgül, H. (2004, 8-10 Eylül). Ayçiçeğinde toprak neminden maksimum yarar sağlamak için bazı ekim-bakım uygulamaları. **Tarımsal Mekanizasyon 22. Ulusal Kongresi**, 156-161, Aydın.

48. Dhakal, A., & Shakya, S. (2018). Image-based plant disease detection with deep learning. **International Journal of Computer Trends and Technology** (IJCTT), 61(1), 2231-2803.

49. Wang, N., Dowell, F., & Zhang, N. (2002). Determining wheat vitreousness using image processing and a neural network. **ASAE Annual International Meeting**, Illinois, July 28-31.

50. Liu, S., Marden, S., & Whitty, M. (2013). Towards Automated Yield Estimation in Viticulture. **Proceedings of Australasian Conference on Robotics and Automation**, University of New South Wales, Sydney, Australia.

51. Dorj, U. O., Lee, M., & Yun, S. S. (2017). An yield estimation in citrus orchards via fruit detection and counting using image processing. **Computers and Electronics in Agriculture, 140,** 103–112.

52. Kaymak, A. M., Örnek, M. N., & Kahramanlı, H. (2019). Görüntü İşleme Teknolojilerinin Elma Bahçelerine Yönelik Kullanım Örneği. **Uluborlu Mesleki Bilimler Dergisi,** 2(1), 17-26.

53. Yılmaz, Ş., & Başçetinçelik, A. (2003, 3–5 Eylül). Sera Ortamında Bitki Gelişiminde Görüntü İşleme Yöntemlerinin Kullanılmasına İlişkin Bir Araştırma. **Tarımsal Mekanizasyon 21. Ulusal Kongresi**, S: 376–382, Konya.

54. Karabacak, H. (2007). Bitki Yüzey Artığı Kaplama Oranının Görüntü İşleme Tekniğiyle Belirlenmesi. Yüksek Lisans Tezi, Ankara Üniversitesi Fen Bilimleri Enstitüsü, Ankara.

55. Solak, S., & Altınışık, U. (2018). Detection and classification of hazelnut fruit by using image processing techniques and clustering methods. **Sakarya University Journal of Science**, 22(1), 56-65.

56. Sofu, M. M., Er, O., Kayacan, M. C., & Çetişli, B. (2013). Elmaların Görüntü İşleme Yöntemi ile Sınıflandırılması ve Leke Tespiti. **Gıda Teknolojileri Elektronik Dergisi,** Cilt: 8, No: 1, 12-25.

57. Kâhya, E., & Arın, S. (2014). Görüntü İşleme Yardımıyla Meyvelerin Dal Üzerindeki Yerlerinin Belirlenmesi Üzerine Bir Araştırma. **Namık Kemal Üniversitesi Tekirdağ Ziraat Fakültesi Dergisi**, 11(2), 110-118.

58. Balcı, M., Altun, A. A., & Taşdemir, Ş. (2016). Görüntü İşleme Teknikleri Kullanılarak Napolyon Tipi Kirazların Sınıflandırılması. **Selçuk-Teknik Dergisi**, 15(3), 221-237.

59. Sabancı, K., Aydın, C., & Ünlerşen, M. F. (2012). Görüntü İşleme ve Yapay Sinir Ağları Yardımıyla Patates Sınıflandırma Parametrelerinin Belirlenmesi. **Journal of the Institute of Science and Technology**, 2(2 Sp: A), 59-62.

60. https://www.fotopedi.org/nikon-govdeler/dx-format/nikon-d5100

61. Yunis, H., Bashan, Y., Okon, Y., & Henis, Y. (1980). Two sources of resistance to bacterial speck of tomato caused by Pseudomonas tomato. **Plant Disease**, 64, 851.

62. Aysan, Y., & Saygılı, H. (2008). Domates Bakteriyel Benek Hastalığı. In H. Saygılı, F. Şahin, Y. Aysan (Eds.), Bitki Bakteri Hastalıkları (ss. 123-126). Meta Basım Matbaacılık Hizmetleri, İzmir.

63. Aysan, Y., Üstün, N., Mirik, M., Saygılı, H., & Şahin, F. (2019). Bitki Bakteri Hastalıkları. Toprak Ofset Matbaacılık, Tekirdağ.

64. Reis Pereira, M., Dos Santos, F. N., Tavares, F., & Cunha, M. (2023). Enhancing host-pathogen phenotyping dynamics: Early detection of tomato bacterial diseases using hyperspectral point measurement and predictive modeling. **Frontiers in Plant Science**, 14, Article 1242201. https://doi.org/10.3389/fpls.2023.1242201

65. Hong, H., Lin, J., & Huang, F. (2020). Tomato disease detection and classification by deep learning. In **2020 International Conference on Big Data, Artificial Intelligence and Internet of Things Engineering (ICBAIE**) (pp. 25-29). Fuzhou, China. https://doi.org/10.1109/ICBAIE49996.2020.00012

66. Tan, L., Lu, J., & Jiang, H. (2021). Tomato leaf diseases classification based on leaf images: A comparison between classical machine learning and deep learning methods. **AgriEngineering,** 3(3), 542-558. https://doi.org/10.3390/agriengineering3030035

67. Natarajan, V. A., Babitha, M., & Kumar, M. S. (2020). Detection of disease in tomato plant using deep learning techniques. **International Journal of Modern Agriculture,** 9(4), 525-540. Retrieved from https://modern-journals.com/index.php/ijma/article/view/374

68. Brahimi, M., Kamel, B., & Moussaoui, A. (2017). Deep learning for tomato diseases: Classification and symptoms visualization. **Applied Artificial Intelligence**, 31(1), 1-17. https://doi.org/10.1080/08839514.2017.1315516

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı: İsmail ÖZTÜRK

Uyruğu: Türkiye (T.C)

EĞİTİM

Derece	**Kurum**	**Mezuniyet Tarihi**
Yüksek Lisans	Erciyes Üniversitesi Fen Bilimleri Enstitüsü Biyosistem Mühendisliği Bölümü	2024
Lisans	Erciyes Üniversitesi Mühendislik Fakültesi Harita Mühendisliği Bölümü	2019
Lisans	Anadolu Üniversitesi İktisat Fakültesi Kamu Yönetimi Bölümü	2014
Ön Lisans	Anadolu Üniversitesi Açık öğretim Fakültesi Coğrafi Bilgi Sistemler	2020

İŞ DENEYİMLERİ

Yıl	**Kurum**	**Görev**
2010- 2013	Atatürk Üniversitesi (Erzurum)	Kamu Personeli
2013-	Abdullah Gül Üniversitesi (Kayseri)	Kamu Personeli