



T.C.

TOKAT GAZİOSMANPAŞA ÜNİVERSİTESİ

LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

BİYOSİSTEM MÜHENDİSLİĞİ ANABİLİM DALI

**BAZI SERT ÇEKİRDEKLİ MEYVELERDE GÖRÜNTÜ İŞLEME TEKNİKLERİ
KULLANILARAK YAPRAK DELEN (*WILSONOMYCES CARPOPHILUS* LÉV.)
HASTALIĞININ HASAR DÜZEYİNİN BELİRLENMESİ**

YÜKSEK LİSANS TEZİ

Derya GÜVEN

Birinci Danışman: Doç. Dr. Mehmet Metin ÖZGÜVEN

İkinci Danışman: Prof. Dr. Yusuf YANAR

TOKAT- 2024

ETİK SÖZLEŞME

Tokat Gaziosmanpaşa Üniversitesi Lisansüstü Eğitim Enstitüsü tez yazım kılavuzuna göre, Doç. Dr. Mehmet Metin ÖZGÜVEN danışmanlığında hazırlamış olduğum “Bazı Sert Çekirdekli Meyvelerde Görüntü İşleme Teknikleri Kullanılarak Yaprak Delen (*Wilsonomyces Carpophilus* Lév.) Hastalığının Hasar Düzeyinin Belirlenmesi” adlı Yüksek Lisans tezinin bilimsel etik değerlere ve kurallara uygun, özgün bir çalışma olduğunu, aksinin tespit edilmesi halinde her türlü yasal yaptırımını kabul edeceğimi beyan ederim.

26/06/2024

Derya GÜVEN

JÜRİ KABUL VE ONAY



ÖNSÖZ

Lisans eğitimimden bu yana danışmanlığımı üstlenen, bu tezde ve çeşitli konularda çalışma fırsatı sunan, birlikte çalışmaktan büyük keyif aldığım, insani ve ahlaki değerleriyle örnek olan danışman hocam Sayın Doç. Dr. Mehmet Metin ÖZGÜVEN'e; bilgi ve tecrübeleriyle çalışmama ışık tutan ikinci danışman hocam Sayın Prof. Dr. Yusuf Yanar'a,

Tez Değerlendirme Jüri hocalarım olarak katkı sağlayan Sayın Prof. Dr. Engin ÖZGÖZ ve Sayın Prof. Dr. Ali İhsan ACAR hocalarıma,

Çalışmam süresince yardımlarını esirgemeyen, her zaman ulaşılabilir olan, bilgi ve desteğini her an hissettiğim Sayın Dr. Ziya ALTAŞ ve Sayın Dr. Tahsin UYGUN'a; yüksek lisans eğitimi boyunca zorlukların üstesinden birlikte geldiğimiz, her koşulda birbirimize destek olan Biyosistem Mühendisi Arif ÇAM'a,

Son olarak, her zaman yanımda olan, hayatıma neşe katan, maddi ve manevi her konuda destek veren, beni değerli hissettiren sevgili aileme en içten sevgi, saygı ve şükranlarımı sunarım.

Derya GÜVEN

26 Haziran 2024

ÖZET

YÜKSEK LİSANS TEZİ

BAZI SERT ÇEKİRDEKLİ MEYVELERDE GÖRÜNTÜ İŞLEME TEKNİKLERİ KULLANILARAK YAPRAK DELEN (*WILSONOMYCES CARPOPHILUS* LÉV.) HASTALIĞININ HASAR DÜZEYİNİN BELİRLENMESİ

Derya GÜVEN

Biyosistem Mühendisliği Anabilim Dalı

Tez Danışmanı: Doç. Dr. Mehmet Metin ÖZGÜVEN

İkinci Danışman: Prof. Dr. Yusuf YANAR

Haziran 2024, xii + 62 sayfa

Tarım, insanlığın yaşamını sürdürebilmesi için kritik öneme sahip bir sektördür ve ekonomi, beslenme ve çevre koruması gibi alanlarda büyük rol oynamaktadır. Ancak, bitki hastalıkları ve zararlıları, tarımsal üretimi olumsuz etkileyen önemli bir sorundur. Bu hastalıkların etkilerini azaltmak ve verimliliği artırmak için erken teşhis ve etkili müdahaleler gereklidir. Bu araştırmada, ülkemiz açısından önemli olan meyvelerde ürün kayıplarına neden olan yaprak delen (çil) hastalığının (*Wilsonomyces carpophilus* Lév.) görüntü işleme teknikleri kullanılarak hastalığın hasar düzeyinin belirlenmesi amaçlanmıştır. Bu amaç doğrultusunda K-Means ve Gaussian Karışım Modelleri (GMM) kümeleme algoritmalarının birleşimi ile bir görüntü işleme algoritması geliştirilmiştir. Yaprak delen hastalığının belirtilerinin bulunduğu kayısı meyvesi ve yaprağı ile kiraz ve şeftali yapraklarından oluşan toplamda 200 görüntü içeren bir veri seti oluşturulmuştur. Edinilen görüntüler, MATLAB programının Image Processing Toolbox modülü ve geliştirilen algoritma ile işlenmiştir. Daha sonra, görüntü işleme algoritmasından elde edilen sonuçlar uzman gözlemi ile karşılaştırılmıştır. Karşılaştırma sonucunda, toplam 200 görüntü için genel sonuç, görüntü işleme yöntemiyle hastalık seviyelerini 2.86 RMSE ve Theil UII'si 0.1164 ile tahmin etmiştir. Verilerin normallik varsayımı için Kolmogorov-Smirnov testi kullanılmış ve verilerin normal dağılım gösterdiği tespit edilmiştir ($p>0.05$). Görüntü işleme sonuçları ile uzman değerlendirmesi arasındaki regresyon katsayısı ($R^2 = 0.986$, $p<0.01$) ve Pearson korelasyon katsayısı ($r = 0.993$, $p<0.01$) olarak bulunmuştur. Çalışma sonucunda, geliştirilen görüntü işleme algoritmasının kayısı, kiraz ve şeftali meyvelerinde yaprak delen hastalığının teşhisinde uzman değerlendirmesi yerine başarıyla kullanılabileceği gösterilmiştir.

Anahtar Kelimeler: Görüntü İşleme, Yaprak Delen Hastalığı, Kayısı, Kiraz, Şeftali

ABSTRACT

MASTER'S THESIS

DETERMINING THE DAMAGE LEVEL OF LEAF BORER (*WILSONOMYCES CARPOPHILUS* LÉV.) IN SOME STONE FRUITS USING IMAGE PROCESSING TECHNIQUES

Derya GÜVEN

Department of Biosystems Engineering

Advisor: Assoc. Prof. Dr. Mehmet Metin ÖZGÜVEN

Second Advisor: Prof. Dr. Yusuf YANAR

June 2024, xii + 62 pages

Agriculture is a critical sector for human survival and plays a major role in the economy, nutrition and environmental protection. However, plant diseases and pests are a major problem that negatively affect agricultural production. Early detection and effective interventions are necessary to reduce the effects of these diseases and increase productivity. In this study, it was aimed to determine the damage level of leaf borer (freckle) disease (*Wilsonomyces carpophilus* Lév.), which causes crop losses in fruits important for our country, by using image processing techniques. For this purpose, an image processing algorithm was developed by combining K-Means and Gaussian Mixture Models (GMM) clustering algorithms. A dataset containing 200 images of apricot fruit and leaves, cherry and peach leaves, and apricot fruit and leaves with symptoms of leaf borer disease was created. The acquired images were processed with the Image Processing Toolbox module of the MATLAB program and the developed algorithm. Then, the results obtained from the image processing algorithm were compared with expert observation. As a result of the comparison, the overall result for a total of 200 images was that the image processing method predicted the disease levels with an RMSE of 2.86 and Theil UII of 0.1164. The Kolmogorov-Smirnov test was used for the normality assumption of the data, and it was found that the data were normally distributed ($p > 0.05$). The regression coefficient ($R^2 = 0.986$, $p < 0.01$) and Pearson correlation coefficient ($r = 0.993$, $p < 0.01$) between image processing results and expert opinion were found. As a result of the study, it was shown that the developed image processing algorithm can be successfully used instead of expert observation in the diagnosis of leaf borer disease in apricot, cherry and peach fruits.

Keywords: Image Processing, Leaf Shot Hole Disease, Apricot, Cherry, Peach

İÇİNDEKİLER

Sayfa

ETİK SÖZLEŞME	i
JÜRİ KABUL VE ONAY	ii
ÖNSÖZ.....	iii
ÖZET	iv
ABSTRACT	v
İÇİNDEKİLER.....	vi
ÇİZELGELER LİSTESİ	viii
ŞEKİLLER LİSTESİ.....	ix
KISALTMALAR VE SİMGELER LİSTESİ	xi
1. GİRİŞ	1
2. LİTERATÜR ÖZETLERİ.....	22
3. MATERYAL ve YÖNTEM.....	29
3.1. Materyal.....	29
3.1.1. Araştırma alanları	29
3.1.2. Çalışmada değerlendirilen yaprak delen hastalığı	30
3.1.3. Çalışmada kullanılan cihazlar.....	31
3.1.4. MATLAB	32
3.1.5. SPSS istatistik programı	32
3.2. Yöntem	33
3.2.1. Hastalığın uzman tarafından tespit edilmesi.....	33
3.2.2. Görüntülerin toplanması.....	34
3.2.3. Görüntülerin düzenlenmesi	35
3.2.4. Yaprak delen hastalığının hasar düzeyinin belirlenmesi	36
3.2.5. İstatistiksel analiz	42
4. BULGULAR	43
4.1. Kayısı Yaprak Sonuçları.....	43
4.2. Kayısı Meyve Sonuçları	45
4.3. Kiraz Sonuçları.....	47
4.4. Şeftali Sonuçları	49
4.5. İstatistiksel Analiz Sonuçları	51
5. SONUÇ	56

6. KAYNAKLAR.....	58
7. ÖZGEÇMİŞ	62



ÇİZELGELER LİSTESİ

Sayfa

Çizelge 1. Ülkemiz kayısı, kiraz ve şeftali istatistik bilgileri.....	3
Çizelge 2. GoPro Hero 7 Black kameranın teknik özellikleri.....	31
Çizelge 3. Kullanılan akıllı telefonun teknik özellikleri	31
Çizelge 4. Çalışmada kullanılan bilgisayarın teknik özellikleri.....	32
Çizelge 5. Görüntülerin alınmasıyla ilgili bilgiler.....	35
Çizelge 6. Görüntü sayıları.....	36



ŞEKİLLER LİSTESİ

Sayfa

Şekil 1. 2018-2022 yılları arası kıtalar bazında kayısı üretim miktarı dağılımı.....	4
Şekil 2. 2018-2022 yılları arası kıtalar bazında kiraz üretim miktarı dağılımı	4
Şekil 3. 2018-2022 yılları arası kıtalar bazında şeftali ve nektari üretim miktarı dağılımı	5
Şekil 4. Dünya kayısı üretim miktarı	6
Şekil 5. Dünya kiraz üretim miktarı	6
Şekil 6. Dünya şeftali ve nektarin üretim miktarı	7
Şekil 7. Yaprak delen hastalığının kayısı yaprağında belirtisi	9
Şekil 8. Yaprak delen hastalığının kayısı meyvesinde belirtisi.....	10
Şekil 9. Yaprak delen hastalığının kirazda belirtisi.....	11
Şekil 10. Yaprak delen hastalığının şeftalide belirtisi	12
Şekil 11. Görüntü işlemenin aşamaları	16
Şekil 12. Görüntü işleme ile karıştırılan alanlar.....	20
Şekil 13. Araştırma yapılan iller.....	29
Şekil 14. Tokat Gaziosmanpaşa Üniversitesi Tarımsal Uygulama ve Araştırma Merkezi meyve bahçeleri	30
Şekil 15. Çalışmada değerlendirilen yaprak delen hastalığı (a: kayısı meyvesi, b: kayısı meyvesi, c: kiraz yaprağı, d: şeftali yaprağı.....	30
Şekil 16. GoPro Hero 7 Black ve iPhone 11	31
Şekil 17. Yaprak delen hastalığının yaprak görsel skala.....	33
Şekil 18. Yaprak delen hastalığının meyve görsel skala	34
Şekil 19. Görüntülerin toplanması	35
Şekil 20. Görüntü işleme diyagramı.....	36
Şekil 21. Ön işleme örneği, a) delik saydırma ve b) delik ve yırtık alan doldurma....	37
Şekil 22. Örnek kümeleme sonrası segment edilmiş görüntü	39
Şekil 23. Kümeleme sonucu oluşan görüntüler.....	40
Şekil 24. Hastalıklı ve sağlıklı bölgelerin ayrı ayrı görselleştirilmesi	41
Şekil 25. Genel akış diyagramı	41
Şekil 26. Kayısı yaprak-1 (a: orjinal görüntü, b: hastalıklı bölge ve c: sağlıklı bölge)43	
Şekil 27. Kayısı yaprak-2 (a: orjinal görüntü, b: hastalıklı bölge ve c: sağlıklı bölge)43	
Şekil 28. Kayısı yaprak-3 (a: orijinal görüntü, b: hastalıklı bölge ve c: sağlıklı bölge)44	

Şekil 29. Kayısı yaprak-4 (a: orijinal görüntü, b: hastalıklı bölge ve c: sağlıklı bölge)	44
Şekil 30. Kayısı yaprak-5 (a: orijinal görüntü, b: hastalıklı bölge ve c: sağlıklı bölge)	45
Şekil 31. Kayısı meyve-1 (a: orijinal görüntü, b: hastalıklı bölge ve c: sağlıklı bölge)	45
Şekil 32. Kayısı meyve-2 (a: orijinal görüntü, b: hastalıklı bölge ve c: sağlıklı bölge)	46
Şekil 33. Kayısı meyve-3 (a: orijinal görüntü, b: hastalıklı bölge ve c: sağlıklı bölge)	46
Şekil 34. Kayısı meyve-4 (a: orijinal görüntü, b: hastalıklı bölge ve c: sağlıklı bölge)	46
Şekil 35. Kayısı meyve-5 (a: orijinal görüntü, b: hastalıklı bölge ve c: sağlıklı bölge)	47
Şekil 36. Kiraz yaprak-1 (a: orijinal görüntü, b: hastalıklı bölge ve c: sağlıklı bölge)	47
Şekil 37. Kiraz yaprak-2 (a: orijinal görüntü, b: hastalıklı bölge ve c: sağlıklı bölge)	48
Şekil 38. Kiraz yaprak-3 (a: orijinal görüntü, b: hastalıklı bölge ve c: sağlıklı bölge)	48
Şekil 39. Kiraz yaprak-4 (a: orijinal görüntü, b: hastalıklı bölge ve c: sağlıklı bölge)	48
Şekil 40. Kiraz yaprak-5 (a: orijinal görüntü, b: hastalıklı bölge ve c: sağlıklı bölge)	49
Şekil 41. Şeftali yaprak-1 (a: orijinal görüntü, b: hastalıklı bölge ve c: sağlıklı bölge)	49
Şekil 42. Şeftali yaprak-2 (a: orijinal görüntü, b: hastalıklı bölge ve c: sağlıklı bölge)	50
Şekil 43. Şeftali yaprak-3 (a: orijinal görüntü, b: hastalıklı bölge ve c: sağlıklı bölge)	50
Şekil 44. Şeftali yaprak-4 (a: orijinal görüntü, b: hastalıklı bölge ve c: sağlıklı bölge)	50
Şekil 45. Şeftali yaprak-5 (a: orijinal görüntü, b: hastalıklı bölge ve c: sağlıklı bölge)	51
Şekil 46. Edinilen görüntülerdeki yaprak delen hastalığının şiddetinin kayısı yaprak için gözlem ve görüntü işleme arasındaki ilişki	52
Şekil 47. Edinilen görüntülerdeki yaprak delen hastalığının şiddetinin kayısı meyve için gözlem ve görüntü işleme arasındaki ilişki	52
Şekil 48. Edinilen görüntülerdeki yaprak delen hastalığının şiddetinin kiraz için gözlem ve görüntü işleme arasındaki ilişki	53
Şekil 49. Edinilen görüntülerdeki yaprak delen hastalığının şiddetinin şeftali için gözlem ve görüntü işleme arasındaki ilişki	54
Şekil 50. Edinilen görüntülerdeki yaprak delen hastalığının şiddetinin tüm görüntüler için gözlem ve görüntü işleme arasındaki ilişki	55

KISALTMALAR ve SİMGELER LİSTESİ

GLCM: Gri Seviye Birlikte Oluşum Matrisi

FAO: Gıda ve Tarım Örgütü

HSI: Ton, Doygunluk, Yoğunluk

MATLAB: MATrix LABoratory

PSO: Parçacık Sürüsü Optimizasyonu

RGB: Kırmızı-Yeşil-Mavi

RMSE: Kök Ortalama Kare Hatası

SRC: Seyrek Temsil Sınıflandırması

SVM: Destek Vektör Makinesi

TÜİK: Türkiye İstatistik Kurumu

GMM: Gaussian Karışım Modelleri

1. GİRİŞ

Tarım biliminde birçok uzmanlık gerektiren alanlar bulunmakla birlikte, tarım biyolojik, fiziksel ve kimyasal süreçlerin olduğu karmaşık olaylardan oluşmaktadır. Tarımsal üretim, kontrol edilemeyen hava koşulları, iklim, toprak özellikleri, hastalık ve zararlılar, çevre kirliliği gibi pek çok faktörden etkilenebilmektedir. Bu nedenle, verimli bir tarımsal üretim için sadece uzmanlık yeterli değildir. Aynı zamanda yetiştirme koşullarının da uygun olması gerekmektedir. Bitki ve hayvan tür ve cinsinin uygunluğuyla, yetiştirme şartlarının optimal düzeyde sağlanmasıyla en verimli üretim elde edilebilmektedir. Ancak, bu optimum koşulların sağlanması oldukça zor ve maliyetli olabilmektedir. Başarılı bir tarımsal işletmecilik için, değişimlerin doğru ve zamanında belirlenmesi ve olası etkileşimlerin göz önünde bulundurularak uygulamaların yapılması gereklidir (Ozguven, 2023).

Tarımsal üretimin öncelikli hedefi, bitkisel ve hayvansal üretimde ekonomik, sürdürülebilir ve verimli işletmecilik sağlamaktır. Bu amaçla, tarımda teknolojinin kullanımıyla verimliliğin artırılması, ürün kalitesinin yükseltilmesi, girdi kullanımının minimize edilmesi, gıda güvenliğinin sağlanması ve doğal kaynakların korunması gibi birçok konu üzerinde çalışılmaktadır. Ancak, bitkilerdeki hastalık ve zararlılar, tarımsal üretimde büyük verim ve ekonomik kayıplara yol açmaktadır. Bu kayıpların azaltılması, ürün miktarının artırılması ve kalitenin iyileştirilmesi için bitki sağlığının izlenmesi, hastalık ve zararlıların erken tespiti ve gerekli tedbirlerin zamanında alınması gerekmektedir. Bu amaçla, görüntü işleme teknikleri tarımsal üretimde yaygın bir şekilde kullanılmaktadır (Avelino ve ark., 2015; Ozguven, 2018; Savary ve Willocquet, 2014). Hastalıkların teşhisinde, hastalıkların şiddetinin ve değişiminin belirlenmesinde daha hızlı, daha pratik ve insan hatası payını ortadan kaldıran teknolojik yöntemlerin uygulanması çok önemli avantajlar sunmaktadır (Ozguven ve Yanar, 2022). Bu nedenle bitki hastalıklarının insan hatalarından bağımsız otomatik olarak teşhis edilmesini sağlayan görüntü işleme gibi teknikler yoğun bir şekilde araştırılmaktadır (Ozguven ve Altas, 2022).

Görüntü işleme yöntemi, dijital görsellerin bilgisayar ve yazılım desteğiyle belirli bir amaç doğrultusunda değiştirilmesini ifade etmektedir. Bu yöntemler genellikle kamera, fotoğraf makinesi veya tarayıcı gibi cihazlarla elde edilen görüntüler üzerinde kullanılmaktadır. Elde edilen görüntüler, nesnelere ait özelliklerin belirlenmesi ve amaca uygun şekilde çıkarılması için görüntü ön işleme adımlarından geçirilmektedir. Nesnelerin tespit edilmesi veya belirlenmesi için karmaşık arka plan çıkarımı, tanıma, renk belirleme, şekil belirleme, köşe ve

kenar belirleme, örüntü tanıma, şablon eşleme gibi yöntemler kullanılmaktadır (Ağın ve Malaslı, 2016; Demir ve ark., 2016; Hussin ve ark., 2012; Sonka ve ark., 2013).

Görüntü işleme tekniklerinin tarım sektöründe kullanımı, hastalık, zararlı ve yabancı ot tespiti, bitki streslerinin belirlenmesi, verim tahmini, ürün gelişiminin izlenmesi, sulama yöntemlerinin modellenmesi, toprak özelliklerinin belirlenmesi, hayvan gelişiminin izlenmesi, topallık tespiti, hayvanların ağrı noktalarının tespiti ve vücut sıcaklıklarının belirlenmesi gibi birçok alanda çalışmaları teşvik etmektedir. Bu çalışmalar sırasında edinilen deneyimler, makine öğrenmesi, derin öğrenme, yapay zeka, modelleme ve simülasyon uygulamaları ile birleştirilerek, gerçek zamanlı ve otomatik çalışan uzman sistemlerin, otonom traktörlerin veya tarım makinelerinin ve tarımsal robotik uygulamaların geliştirilmesine olanak sağlamaktadır (Altaş ve ark., 2019). Son yıllarda tarımsal uygulamalarda büyük öneme sahip olan görüntü işleme teknikleri, özellikle bitki hastalıkları ve zararlılarının tespiti gibi konularda değerli bir bilgi kaynağı haline gelmektedir. Tarımsal üretimde ekonomik ve kaliteli üretimi desteklemek amacıyla, görüntü işleme teknikleri önemli bir araç olarak öne çıkmaktadır (Altaş ve ark., 2021).

Kayısı, kiraz ve şeftali meyvelerinin ülkemizdeki önemi

Sert çekirdekli meyvelerde şeker, glikoz, früktoz ve sakkaroz formunda bulunmaktadır. Kiraz %11.6 ile en yüksek şeker içeriğine sahipken, kayısı %10.5 ile onu takip etmektedir. Bu meyveler aynı zamanda malik asit bakımından zengin olmakla birlikte, olgunlaştıkça suda eriyen kuru madde miktarı artmaktadır. Hasat edilmeden önce, çözünür katı madde, titre edilebilir asitlik, et sertliği, kabuk ve et rengi, meyve suyu içeriği, fenolik madde gibi birçok özellik sağlam olmalıdır. Ancak, sert çekirdekli meyveler olgunlaşmadan hasat edilirse, pazar kaybına ve tüketici memnuniyeti ile lojistik yönetimi arasında denge kurulması zorlaştırmaktadır. Bununla birlikte, içerdikleri etilen hormonu nedeniyle hasat edildikten sonra da olgunlaşmaya devam edebilmektedir (klimakterik özellik). Bu nedenle, hasat edildikten sonra olgunlaşma durumunun iyi ayarlanması önemlidir (Manganaris ve Crisosto, 2020; Özcan, 2020).


Türkiye, iklim koşullarının elverişliliği sayesinde birçok meyve çeşidine ev sahipliği yapmaktadır. Bu meyve çeşitlerinin başında kiraz, vişne, kayısı, şeftali, nektarin ve erik gibi sert çekirdekli meyveler gelmektedir. Bu meyve çeşitlerinin hepsi farklı iklim istekliliğine rağmen, Türkiye dünyada söz sahibi konumdadır (Duru ve ark., 2022). Çizelge 1’de Türkiye İstatistik Kurumu (TÜİK) verilerine göre, 2018 ile 2022 yılları arasında sert çekirdekli

meyvelerden kayısı, kiraz ve şeftalinin ağaç sayısı (adet), üretim (ton) ve hasat edilen alan (hektar) bilgileri verilmektedir (TUİK, 2024). Bu yıllar arasında kiraz ağaçları, sert çekirdekli meyveler arasında en fazla ağaca sahip olmuştur. Ancak, üretim açısından en büyük pay şeftali meyvesine aittir. Çizelge 1 incelendiğinde, ülkemizde 2022 yılına kadar kayısıda ağaç sayısı artarken, üretimde düşüş yaşanmıştır. Kirazda ise ağaç sayısında ciddi bir artış görülmemiş, ancak üretimde düşüş görülmektedir. Şeftali ise hem ağaç sayısı hem de üretim bakımından artış göstermektedir. Yıllar arasındaki olumsuz değişkenliklerin nedeni verim kayıplarıdır. Bu kayıpların başlıca sebeplerinden biri bitki hastalıklarıdır.


Çizelge 1. Ülkemiz kayısı, kiraz ve şeftali istatistik bilgileri (TUİK, 2024)

Meyveler	Parametreler	2018	2019	2020	2021	2022
Kayısı	Ağaç Sayısı (adet)	19 125	20 695	21 294	21 784	23 427
	Üretim (ton)	750 000	846 606	833 398	800 000	803 000
	Hasat Edilen Alan (ha)	125 756	131 178	132 748	134 879	141 851
Kiraz	Ağaç Sayısı (adet)	26 940	27 032	27 384	27 533	27 712
	Üretim (ton)	639 564	664 224	724 944	689 834	656 041
	Hasat Edilen Alan (ha)	84 087	83 447	82 729	81 547	80 482
Şeftali	Ağaç Sayısı (adet)	21 096	21 384	21 707	23 537	25 513
	Üretim (ton)	789 457	830 577	892 048	891 857	1 008 185
	Hasat Edilen Alan (ha)	46 361	46 294	46 918	50 127	53 532


2018-2022 yılları arası kıtalar bazında kayısı, kiraz ve şeftali-nektarin üretim verileri Şekil 1, 2 ve 3'te verilmiştir. Dünya kayısı üretiminde Asya, birinci sıradadır. 2 425 218 tonluk Asya kayısı üretiminin 806 630 tonu Türkiye'de gerçekleşmektedir. Bu, dünya kayısı üretiminin %33.30'unu oluşturarak Türkiye'yi önemli bir konuma getirmektedir. Kiraz için, Asya'da üretilen toplam 1 179 852 tonun 674 921 tonu Türkiye'de üretilmektedir. Bu da Asya'daki kiraz üretiminin %57.20'sini oluşturarak Türkiye'nin önemli bir paya sahip olduğunu göstermektedir. Şeftali için ise, Asya'da üretilen toplam 18 148 362 tonun 882 424 tonu Türkiye'de üretilmektedir. Bu da Asya'daki toplam şeftali üretiminin %4.86'sını oluşturarak Türkiye'nin şeftali üretiminde daha küçük bir paya sahip olduğunu göstermektedir.



Şekil 1. 2018-2022 yılları arası kıtalar bazında kayısı üretim miktarı dağılımı (FAO, 2024)



Şekil 2. 2018-2022 yılları arası kıtalar bazında kiraz üretim miktarı dağılımı (FAO, 2024)



Şekil 3. 2018-2022 yılları arası kıtalar bazında şeftali ve nektari üretim miktarı dağılımı (FAO, 2024)


FAO verilerine göre, 2018 ile 2022 yılları arasında dünya genelindeki sert çekirdekli meyvelerden kayısı, kiraz ve şeftali-nektarin üretimi incelendiğinde, Türkiye'nin durumu Şekil 4 - 6 'da gösterilmiştir. Türkiye, kayısı ve kiraz üretiminde birinci sırada yer alırken, şeftali ve nektarin üretiminde dördüncü sıradadır (FAO, 2024). Bu veriler, Türkiye'nin sert çekirdekli meyve üretiminde dünya çapında önemli bir konumda olduğunu göstermektedir. Ayrıca, Türkiye'nin üretimdeki bu lider konumu, ürün kalitesini artırması ve hedef pazarlardaki standartlara uygun şekilde paketlenmiş ürünleri sunmasıyla desteklenmektedir. Bu çalışmalar, Türkiye'nin dünya üretim sıralamasındaki yerini yükseltmesine katkı sağlamaktadır.



Şekil 4. Dünya kayısı üretim miktarı (ton) (FAO, 2024)



Şekil 5. Dünya kiraz üretim miktarı (ton) (FAO, 2024)



Şekil 6. Dünya şeftali ve nektarin üretim miktarı (ton) (FAO, 2024)

1950'li yıllardan günümüze kadar sert çekirdekli meyvelerin üretim ve tüketiminde hızlı gelişmeler yaşanmıştır. Bu gelişmelerin arkasındaki başlıca faktörler arasında, seyahat imkanlarının artmasıyla insanların egzotik meyveleri tanınması, soğuk hava depoları ve ulaşım ağlarının gelişmesiyle meyvelerin bozulma süresinin uzatılması, ulaşım sürelerinin kısaltılması, işleme yöntemlerindeki ilerlemelerle meyvelerin dayanıklı formlara dönüştürülmesi, dağıtım sistemlerinin iyileştirilmesi, tanıtım ve bilgi ediniminin hızlanması ve üretim yöntemleri, mekanizasyon ve teknolojik yenilikler üzerine yapılan çalışmalar yer almaktadır. Ancak özellikle hastalık ve zararlılarla mücadelede yapılan hatalar tüm emeğin ve masrafların bir anda boşa gitmesine yol açabilmektedir (Storey, 1969; Samson, 1980). Bu nedenle bitki hastalıklarının tespit edilmesi ile verim ve kalitenin artırılması oldukça önemlidir. Böylece yetiştiriciler için önemli ekonomik kayıplar azaltılabilecektir.

Yaprak delen (Çil) hastalığı (*Wilsonomyces Carpophilus* Lév.)

Yaprak delen (Çil) hastalığı (*Wilsonomyces Carpophilus* Lév.), sert çekirdekli meyve ağaçlarının yaprak, meyve, tomurcuk ve genç dalları üzerinde belirti oluşturmaktadır. Fungusun miselyumu bölünmüş, farklı kalınlıklarda ve eklemlili yapıdadır. Konidiosporlar, konidioforlar üzerinde ve aservuluslar içinde oluşmaktadır. Konidioforlar kısa olup, konidiosporlar elipsoid şeklinde ve 2-8 bölmelidir. Bölme kısmı boğumlu olup, rengi parlak sarı ile açık kahverengi arasındadır. Fungusun eşeysiz üremesinde aservuluslar önemli rol oynamaktadır. Genellikle kışa tomurcuk ve dallarda miselyum olarak geçirmektedir. Primer enfeksiyonlar

konidiosporlarla gerekleşmekte ve hastalıklı tomurcuklar ile kanserler enfeksiyon kaynaklarıdır. İkincil enfeksiyon kaynakları ise hastalıklı sürgünler ve yapraklardır. Bu sürgünlerde oluşan zank akıntısı içinde konidiosporlar bulunmaktadır. Zank akıntısının yağmurla erimesiyle konidiosporlar yayılmaktadır. Yeni enfeksiyonların oluşması için yağmur gereklidir. Etmen, tüm yıl boyunca hasta tomurcuklarda kalabilmektedir (Anonim, 2022a).

Kayısıda yaprak delen (Çil) hastalığı

Kayısı (*Prunus armeniaca*), Gülgiller (Rosaceae) familyasından orta boyutlu bir meyve ağacıdır. Dünya genelinde neredeyse her yerde yetiştirilen popüler bir meyvedir. Ülkemizde özellikle Malatya yöresinde yetiştirilen kayısılar, büyük bir üne sahiptir. Kayısı ağacı, Nisan sonlarına doğru çiçeklenmekte ve bu süreç yaklaşık iki ay sürdükten sonra Haziran ortalarında meyve vermeye başlamaktadır. Kayısı, ülkemizde en çok tüketilen meyvelerden biri olmasının yanı sıra çeşitli işlenmiş ürünler olarak da geniş bir kullanım alanına sahiptir. Dondurulmuş kayısı, kayısı konservesi, kayısı pulpu ve nektarı, kayısı içeren meşrubatlar, kayısı pulp konsantresi, kayısı jölesi, kayısı reçeli ve marmelatı, yeşil kayısı turşusu ve kayısı pestili gibi ürünler bulunmaktadır. Ayrıca, toz ve kuru kayısı çeşitleri (çir, gün kurusu ve patik), doğranmış ve kıyılmış kuru kayısı ürünleri, ekstrüzyon yöntemiyle elde edilen kayısı mamulleri ve kayısı şekerlemeleri, kayısı ekstraktı ve esansı, kayısı pastası, keki, dondurması ve gofretleri gibi çeşitli ürünler de mevcuttur (Karhan, 2011).

Kayısı ağaçlarında görülen yaprak delen hastalığı, yapraklar, meyveler, tomurcuklar ve genç dallar üzerinde belirtiler oluşturmaktadır. Yapraklardaki lekeler başlangıçta 1 mm apında, yuvarlak ve yağ lekesi görünümündedir. Zamanla kenarları kırmızımsı, orta kısımları ise koyu kahverengiye dönebilmektedir. Bu lekeler zamanla dökülerek yaprakta delikler oluşmaktadır (Şekil 7). Bazı durumlarda birleşen lekeler, apı 1 cm'yi bulan delikler meydana getirebilmektedir. Belirtilerin ortaya çıkmasından 5-10 gün sonra yapraklar dökülmeye başlamaktadır. Bu hastalık ayrıca yaprak saplarını da enfekte edebilmektedir (Karhan, 2011).



Şekil 7. Yaprak delen hastalığının kayısı yaprağında belirtisi

Meyve yüzeyindeki lekeler genellikle 1-2 mm çapında, yuvarlak ve rastgele bir şekilde dağılmıştır. Ancak bazen, bu lekelerin bir araya gelerek meyve yüzeyini kapladığı bir sıvama oluşturduğu gözlemlenebilmektedir. Lekelerin merkezi genellikle koyu renkte olup, etrafı açık kırmızı tonlarına sahip olabilmektedir. Zamanla merkez gri veya kirli beyaza dönerken, çevresi koyu kırmızı, koyu kahverengi veya siyah renge doğru değişebilmektedir. Meyve lekelerindeki kahverengi merkez genellikle içe doğru çöküntülü bir görünüme sahip olabilmektedir. Bu hastalık ayrıca tomurcuklara da zarar verebilmektedir. Sonbahar ve kış aylarında enfekte olan tomurcuklar, ilkbaharda uyanma döneminde sağlıklı tomurcuklardan kolayca ayırt edilebilmektedir. Enfekte olmayan tomurcuklar dokunulduğunda sağlam kalırken, hastalıklı tomurcuklar hafif bir dokunuşla bile dökülebilmektedir. Hastalık, sürgünler üzerinde genellikle yuvarlak ve kahverengi-kırmızı renkli lekeler oluşturmaktadır (Şekil 8). Genç sürgünlerdeki lekeler kısa sürede zamk çıkararak küçük kanser yaralarına dönüşebilmektedir (Karhan, 2011).



Şekil 8. Yaprak delen hastalığının kayısı meyvesindeki belirtisi

Kirazda yaprak delen hastalığı

Gülgiller familyasına ait olan kiraz ağacının Latince adı *Prunus avium* olan kiraz, kendine özgü tatlı aroması ve eşsiz lezzetiyle birçok tarifi vazgeçilmez bileşenlerinden biridir. Türkiye'nin iklim koşulları ve coğrafi konumu, kiraz yetiştiriciliği için elverişli bir ortam sağlamaktadır. Türkiye'de yetiştirilen kiraz çeşitleri arasında en yaygın olanı 0900 Ziraat çeşididir. Bu çeşit, geç olgunlaşan bir türdür. Meyvesi geniş kalp şeklinde, oldukça büyük, parlak kırmızı renkte, son derece sert, çıtır, suludur ve üst düzey kalitededir (Başkaya 2009). Kiraz ağacı yetiştirmek istendiğinde sıcak hava koşullarına dikkat etmek önemlidir. Kışın sıcaklığın -20°C 'ye kadar düştüğü bölgelerde kiraz yetiştiriciliği yapılamaz. Ancak yüksek rakımlı bölgeler, kiraz yetiştirmek ve kaliteli meyve elde etmek için en uygun yerlerdir.

Kiraz, son derece çeşitli kullanım alanlarına sahiptir. En yaygın olarak taze olarak tüketilmektedir. Yaz aylarında özellikle hoşaf yapımında serinletici bir içecek olarak tercih edilmektedir. Kiraz reçeli, tatlı ve eşsiz bir lezzet sunarak kahvaltılık sofralarının vazgeçilmezidir. Ayrıca, kurabiyeler ve tatlılar için kullanılan kiraz marmeladıyla da benzersiz tatlar elde edilmektedir. Kiraz, doğal bir ağrı kesici olarak da kullanılmaktadır ve bunun yanı sıra kirazdan elde edilen sirke çeşitleri de bulunmaktadır. Yazın toplandıktan sonra temizlenip dondurucuya konulan kirazlar, kış aylarında da ara sıra kullanılabilir. Ayrıca, içecek olarak da oldukça popülerdir (Anonim, 2022b).

Kiraz ağaçlarında görülen yaprak delen hastalığı genellikle genç yapraklarda 1 mm çapında, yuvarlak ve kırmızı lekelerle başlar, etrafı ise açık renkli bir haleyle çevrilmiştir. Zamanla bu lekeler kahverengimsi merkezli, kızıl kahverengi ve yaklaşık 3 mm çapında lekeler dönüşmektedir (Şekil 9). Bu lekeler 5-10 gün sonra dökülerek yaprakta delikler oluşturmaktadır, yapraklar adeta saçmayla delinmiş gibi bir görünüm kazanmaktadır. Bu belirti, yaprak delen hastalığının tipik özelliklerindendir. Bazen birbirine bitişik lekeler birleşerek dökülebilmekte ve çapı 1 cm'yi bulan delikler oluşabilmektedir. Etmen ayrıca yaprak saplarını ve orta damarı da enfekte edebilmektedir. Kiraz meyvelerinde ise 2-3 mm çapında çöküntüler oluşmakta ve bu çöküntülerin etrafında açık renkte haleler görülebilmektedir. Bu belirtiler, meyvelerin hem yeşil hem de olgunlaşma dönemlerinde ortaya çıkabilmektedir (Anonim, 2022c).



Şekil 9. Yaprak delen hastalığının kirazda belirtisi

Şeftalide yaprak delen hastalığı

Şeftali ağacı, Gülgiller familyasına ait olup Latince adı *Prunus persica*'dır. Ülkemizde ticareti yapılan şeftali ağaçları, genellikle ılıman iklim bölgelerinde yetiştirilmektedir. Şeftalinin ekonomik değeri yüksek olup ülkemizde oldukça rağbet gören bir meyvedir. Şeftalinin taze olarak tüketilmesi en yaygın kullanım şeklidir. Bunun yanı sıra, meyve suyu üretiminde, püre yapımında, bebek maması hazırlığında, pastaların ve tatlıların süslenmesinde, reçel ve komposto yapımında da sıkça tercih edilmektedir. Ayrıca şeftali, kozmetik ürünlerden sürdürülebilir doğal enerji kaynaklarına kadar pek çok alanda kullanılmaktadır. Endüstriyel ve hayvan yemi üretiminde de yaygın olarak kullanılan meyveler arasındadır (Anonim, 2022d).

Yaprak delen hastalığı, özellikle şeftali ağaçlarının yapraklarında ve uygun iklim koşullarında meyve, tomurcuk ve genç dallar üzerinde 2-3 mm çapında çöküntüler ve etrafında açık renkli haleler oluşturmaktadır. Bu belirtiler, meyvelerin hem yeşil hem de olgunlaşma dönemlerinde görülebilmektedir. Genç yapraklarda başlangıçta 1 mm çapında, yuvarlak ve kırmızı renkte lekeler oluşur; bu lekelerin etrafı açık renkli bir hale ile çevrilidir. Zamanla bu lekeler kahverengimsi merkezli, kızıl kahverengi ve yaklaşık 3 mm çapında lekelere dönüşmektedir. Lekeli kısımlar 5-10 gün sonra dökülerek yaprakta delikler oluşturur, yapraklar adeta saçmayla delinmiş gibi bir görünüm almaktadır. Bu belirti, yaprak delen hastalığının tipik özelliklerindendir. Bazen birbirine bitişik lekeler birleşerek dökülmekte ve çapı yaklaşık 1 cm olan delikler oluşturabilmektedir (Şekil 10). Etmen ayrıca yaprak saplarını ve orta damarı da enfekte edebilmektedir (Anonim, 2022e).



Şekil 10. Yaprak delen hastalığının şeftalide belirtisi

Genel olarak, yaprak delen hastalığı sert çekirdekli meyve yetiştiriciliği yapılan bölgelerde yaygın olarak görülmektedir. Şeftali, nektarin, kiraz, vişne, kayısı, erik ve badem ağaçlarında hasara neden olabilmektedir. Hastalık yapraklara, tomurcuklara ve sürgünlere zarar verirken aynı zamanda meyvenin kalitesini de düşürebilmektedir. Lekeli meyvelerin piyasa değeri düşük olup, hastalığın verim üzerinde %30-60 oranında düşüşe sebep olduğu belirlenmiştir. Bu durum üreticiler için ekonomik açıdan önemli kayıplara neden olabilmektedir. Dolayısıyla, verimliliği

ve ürün kalitesini artırmak için bitkilerin gelişim sürecinin titizlikle takip edilmesi ve gerekli işlemlerin en uygun zamanda gerçekleştirilmesi gereklidir (Anonim, 2022f).

Yaprak delen hastalığıyla mücadelede ilk adım olarak sonbaharda yapraklar döküldükten sonra %2'lik bordo bulamacı kullanılarak kışın dalları enfeksiyondan korunmaktadır. İlkbaharda çiçek tomurcukları kabardığında %1'lik bordo bulamacı uygulanması olumlu sonuçlar vermektedir. Üçüncü ilaçlamada, çiçek taç yapraklarının %70-80 döküldüğü dönemde %1'lik bordo bulamacı ve %0.4'lük bakır oksit ilacının kullanılması tavsiye edilmektedir. Dördüncü ilaçlama ise meyveler yaklaşık nohut büyüklüğüne ulaştığında yukarıdaki bakırlı veya koruyucu ilaçlarla yapılmaktadır. Eğer hava şartları yağışlı giderse, dördüncü ilaçlamadan 12 gün sonra bir ilaçlama daha yapılabilir. Uygulamada, birinci ilkbahar ilaçlaması tomurcuklar patlamadan en az bir hafta önce yapılacaksa bordo bulamacının dozu %2'ye, bakırlı ilaçların dozu ise %0.6'ya yükseltilmelidir. Ayrıca ilaçlı mücadele dışında, sonbaharda yaprak dökümünden sonra ve kış yağmurlarının başlamasından önce ağaç üzerindeki kurumuş dallar, hastalıklı tomurcuklar ve dökülmemiş yaprakları içeren dalların budanması önerilmektedir. Kış yağmurlarının erken başladığı durumlarda yaprak dökümü beklenmeden budama yapılabilir (Anonim, 2022f).

Görüntü İşleme

Görüntü işleme tekniği, kamera, tarayıcı veya sensörlerle elde edilen fotoğraf veya video karesindeki görüntünün kayıt sonrasında dijital formata dönüştürülmesi ve bu dijital verilerden birtakım algoritmalar yardımıyla bazı yararlı bilgilerin çıkarılması için kullanılan bir yöntemdir. Bu teknikte görüntüler çeşitli işlemlerle yeniden düzenlenmektedir ve bu işlemlerle son olarak anlamlı sonuçlar elde edilmektedir. Bu işlemler sırasında görüntüdeki önemli verileri temsil eden tanımlayıcı parametreler elde edilmeye çalışılmaktadır. Bu sayede ölçülecek özelliklerin tanımlanması ve ayrılması, görüntü kusurlarının düzeltilmesi, bazı özelliklerin görünürlüğünün artırılması ve arka planda eşiklenmesi gerçekleştirilmektedir (Ozguven ve Yanar, 2022).

Görüntü işleme sistemlerinin tasarımının altında yatan önemli bir özellik, kabul edilebilir bir çözüme ulaşmadan önce gerekli olan test ve denemelerin kolaylıkla gerçekleştirilebilmesidir. Bu özellik, yaklaşımları formüle etme ve aday çözümleri hızla prototipleme yeteneğinin uygulanabilir bir sistem uygulamasına ulaşmak için gereken maliyet ve süreyi azaltmada

önemli bir rol oynamasını sağlamaktadır (Gonzalez ve ark., 2009). Genel amaçlı bir görüntü elde etme ve işleme sistemi tipik olarak dört temel bileşenden oluşmaktadır (Jähne, 2005):

1. Bir görüntü edinme sistemi, En basit durumda bu bir CCD kamera, düz yataklı tarayıcı veya video kaydedici olabilmektedir.
2. Görüntü elde etme sisteminin, elektrik sinyalinin saklanabilecek dijital bir görüntüye dönüştürmek için çerçeve yakalayıcı olarak bilinen bir cihaz.
3. İşlem gücünü sağlayan kişisel bilgisayar veya iş istasyonu.
4. Görüntüleri işlemek ve analiz etmek için araçlar sağlayan görüntü işleme yazılımıdır.

Kavramlar

Görüntü işleme ile ilgili kavramlar aşağıdaki şekilde açıklanmaktadır (Çayıroğlu, 2024):

Görüntü, nesnelerin yüzeylerine çarpan veya içlerinden geçen ışınları yansıtarak algılanmasını ifade etmektedir. Bu algılama sürecine görme denir ve nesnelerin bu şekilde algılanabilen içeriği görünüm olarak adlandırılmaktadır. Görünüm, sağlanmış bir biçimde iki boyutlu (2-B) çizge olarak tanımlanmaktadır. Ayrıca, üç boyutlu nesnelerin iki boyutlu bir yüzey üzerine düşürülmüş haritası olarak da düşünülebilmektedir. Bu haritalamada, her noktanın konum bilgisi $f(x, y)$ ve renk bilgisi bulunmaktadır. Görüntü, analog ve dijital olarak iki ayrı kısımda incelenebilmektedir.

Analog görüntü: Görüntüyü oluşturan $f(x, y)$ fonksiyonunun reel değerler alması durumunda tanımlanmaktadır. Başka bir deyişle tüm sayıları kapsamaktadır. Örneğin mikroskopla yakından incelendiğinde, görüntüyü oluşturan renkler hala görülebilmektedir. Ancak, sayısal bilgisayarlar doğrudan sürekli fonksiyonları veya parametreleri işleyemezler. Bu nedenle, bu fonksiyonlar sayısal bir formata dönüştürülerek (sayısallaştırılarak), sayısal bilgisayarlar tarafından işlenebilir hale getirilmektedir. Bu işlem, analog görüntünün dijital bir formata dönüştürülmesini ve sayısal işlemlerle işlenebilir hale getirilmesini sağlamaktadır.

Dijital (sayısal) görüntü: Sürekli görüntünün (analog görüntü) $f(x, y)$ şeklinde temsil edilen ve ayrık örnekler cinsinden (discrete) ifade edilmesidir. Gösterimi $f[x, y]$ şeklindedir. Bu ifadeyle, görüntünün her bir noktasının sabit bir çözünürlükle (adım aralığıyla) belirlendiği ve sınırlı bir sayıda örnekleme noktasının bulunduğu bir yapı ifade edilmektedir. Böylece, analog görüntüde

her noktanın tam bir renk deęerine sahip olduęu yerine, dijital grntde her nokta belirli bir renk koduyla temsil edilmektedir.

Piksel: Dijital bir grntnn her bir elemanının 2 boyutlu dizisi olarak tanımlanmaktadır. Dijital grntnn veya ekranın en kk birimi olup "resim ęesi" anlamına gelmektedir. Pikseller, tek bir rengi temsil eden ve dijital grntlerde en temel rol oynayan ok kk izole noktalardır. Her bir pikselde renk, parlaklık ve konum bilgileri bulunmaktadır. Bu pikseller, dięerleriyle bir araya getirildięinde grlebilen eksiksiz bir grnt oluřturmaktadır.

znrlk: Dijital bir fotoęraftaki piksel adı verilen kk karelerin sayısını ifade etmektedir. Genellikle geniřlik ve ykseklik boyutuyla llmektedir. znrlk iin yaygın ller, in başına piksel (PPI) ve santimetre başına piksel (PPCM) olarak kullanılmaktadır. rneęin, 1920x1080 znrlkteki bir grntde, soldan saęa doęru daha fazla kk nokta veya piksel bulunmakta ve yatayda 1920 piksel, dikeyde ise 1080 piksel bulunmaktadır. Bu sayılar, grntnn geniřlik ve ykseklik boyutlarını belirlemekte ve grntnn detay dzeyini tanımlamaktadır.

Renk derinlięi: Her pikselin rengini ka bitin gsterdięi anlamına gelmekte ve genellikle bit derinlięi olarak da adlandırılmaktadır. Genel olarak, 8 bit, 16 bit ve 24 bit renk seviyeleri yaygın olarak kullanılmaktadır. Bir pikselin bit sayısı ne kadar fazlaysa, o kadar fazla renk gsterebilmektedir. Daha yksek bit derinlięi, daha geniř ve daha derin bir renk yelpazesi saęlamaktadır. rneęin, 8 bit renk derinlięi 256 farklı renk tonunu temsil ederken, 24 bit renk derinlięi milyonlarca renk tonunu temsil edebilir, bu da daha doęal ve zengin renkler saęlamaktadır.

En boy oranı: Bir grntnn geniřlięi ve ykseklilięi arasındaki dengeyi ifade etmektedir. Yaygın en boy oranları 4:3, 16:9 ve 1:1'dir. Bu oranlar, bir grntnn geniřlięinin ykseklilięine oranını belirtmekte ve grntnn nasıl biimlendirileceęini ve sunulacaęını belirlemektedir. rneęin, 16:9 en boy oranına sahip bir grnt, geniř bir yatay alanı kapsayarak daha modern bir grnt sunabilirken, 1:1 en boy oranına sahip bir grnt kare bir forma sahip olmakta ve genellikle sosyal medya platformlarında paylaşılan kare grntler iin tercih edilmektedir.

Görüntü işleme aşamaları

Görüntü işleme tekniğinin kullanıldığı alanlar farklı olsa da birçok uygulamada gerçekleştirilen bazı temel aşamalar bulunmaktadır (MathWorks, 2008). Şekil 11’de görüntü işlemenin aşamaları verilmektedir.



Şekil 11. Görüntü işlemenin aşamaları

Şekil 11’de verilen görüntü işleme aşamaları aşağıda açıklanmıştır (Gonzalez ve Woods, 2008):

1. Elde Etme: Görüntü işlemedeki başlangıç adımı, sayısal bir kamerayla görüntünün elde edilmesidir.
2. Ön işleme: Sayısal bir görüntünün elde edilmesinden sonra gerçekleştirilen bir aşamadır. Bu aşamada, elde edilen sayısal görüntü daha iyi sonuçlar almak amacıyla çeşitli işlemlerden geçirilmektedir. Ön işleme, görüntü iyileştirme (image enhancement), görüntü onarımı (image restoration), ve görüntü sıkıştırma (image compression) olmak üzere genellikle üç ana başlık altında toplanabilmektedir. Görüntünün elde edilmesi ve ön işlemeye tabi tutulması düşük seviyeli görüntü işlemesi olarak adlandırılmaktadır.
3. Bölümleme: Ön işlem aşamasından sonra, bölümleme (segmentasyon) aşamasına geçilmektedir. Kesimleme, görüntü işlemenin en zor uygulamalarından biridir ve bir görüntüdeki nesne ve arka planın veya görüntüdeki farklı özelliklere sahip bölgelerin birbirinden ayrılması işlemidir. Bölümleme, bir görüntüdeki nesnenin sınırlarını ve alanlarını tespit ederek şekli üzerinde temel bilgiler üretmektedir. Nesnelerin şekilleriyle ilgileniyorsak, kesimleme nesnenin kenarları, köşeleri ve sınırları hakkında

bilgi sağlamaktadır. Diğer yandan, görüntüdeki nesnelerin yüzey kaplaması, alanı, renkleri, iskeleti gibi iç özelliklerine odaklanılıyorsa, bölgesel kesimleme kullanılmaktadır. Karakter tanıma veya genel olarak desen tanıma gibi karmaşık problemlerin çözümü için sınırlamakta ve alanlar gibi her iki kesimleme yöntemi bir arada kullanılabilir.

4. Çıkarım: Görüntüden elde edilen temel bilgilerin, belirli özelliklerin belirlenmesi ve vurgulanması işlemidir. Bu aşamada, ilgili alanlar diğerlerinden ayrıştırılarak öne çıkarılır ve arka planla ayrıştırılmaktadır.
5. Yorumlama: Yüksek seviyeli görüntü işleme kategorisine giren bu aşamada, görüntüdeki nesnelerin veya alanların arka planından ayrıştırılması ve daha sonra etiketlenip sınıflandırılması için çeşitli karar verme mekanizmaları kullanılmaktadır.

Görüntü işleme teknikleri

Görüntü işleme birtakım teknikleri ve algoritmaları içermektedir. En temsili görüntü işleme operasyonları aşağıda verilmektedir (Marques, 2011; Tyagi, 2018):

- İkilileştirme: Birçok görüntü işleme görevinde, işlemeyi basitleştirmek ve hızlandırmak amacıyla genellikle renkli bir görüntü veya gri tonlamalı görüntü, iki düzeyli (siyah-beyaz) bir görüntüye dönüştürülmektedir. Bu işlem, görüntüyü ön plan ve arka plan olarak ikiye bölmek için yapılmaktadır.
- Yumuşatma: Görüntüdeki nesnelerin ayrıntılarını bulanıklaştırmak veya yumuşatmak için kullanılan bir tekniktir.
- Keskinleştirme: İnsanların bir görüntüdeki nesnelerin kenarlarını ve ince ayrıntılarını görebilmelerini sağlamak için keskinleştirme teknikleri kullanılmaktadır.
- Gürültü giderme: Görüntü işleme öncesinde gürültü giderme filtreleri kullanılarak görüntülerdeki gürültü miktarı azaltılmaktadır. Gürültünün türüne bağlı olarak farklı gürültü giderme teknikleri kullanılmaktadır.
- Bulanıklığın giderilmesi: Bir görüntü, merceğin yanlış odaklanmasından hızlı hareket eden bir nesne için yetersiz deklanşör hızına kadar birçok nedenden dolayı bulanık görünebilmektedir. Görüntü işlemeden önce çeşitli algoritmalar kullanılarak bulanıklık giderilmektedir.

- Bulanıklaştırma: Bazen bir görüntüdeki doku ve ince ayrıntıların önemini en aza indirmek için, örneğin nesnelerin şekillerine göre daha iyi tanınabileceği durumlarda, görüntüyü bulanıklaştırmak gerekebilmektedir.
- Kenar çıkarma: Bir görüntüdeki kenarların kaldırılması, içeriklerini belirlemeden önce nesneleri birbirinden ayırmak için kullanılan temel bir ön işleme adıdır.
- Segmentasyon ve etiketleme: Bir görüntü içindeki nesneleri segmentlere ayırma ve etiketleme görevi, çoğu nesne tanıma ve sınıflandırma işleminin ön koşuludur. İlgilenilen nesneler bölümlere ayrıldıktan ve etiketlendikten sonra, bunların ilgili özellikleri çıkarılabilmekte ve söz konusu nesneleri sınıflandırmak, karşılaştırmak, kümelemek veya tanımak için kullanılabilmektedir.

Görüntü işlemede bazı konular

Görüntü işlemeye dair bazı önemli konular şunlardır (Gonzalez ve ark., 2004):

- Görüntü edinme (Image Acquisition): Kamera veya tarayıcı gibi görüntü yakalama cihazları kullanılarak görüntünün elde edilmesidir.
- Görüntü iyileştirme (Image Enhancement): Görüntünün niteliğini geliştirme, daha üstün bir görünüm kazandırma işlemidir. Bu süreç, koyulaştırma, parlaklık artırma veya kontrastı iyileştirme gibi prosedürleri kapsayabilir ve ayrıca daha karmaşık filtrelerin de kullanılmasını içerebilmektedir.
- Görüntü onarma (Image Restoration): Bozulmuş veya gürültülü görüntünün temiz, orijinal hâline getirilmesi işlemidir.
- Morfolojik operasyonlar (Morphological Operations): Küme teorisine dayalı işlemlerle genişletme, erozyon, kenar belirleme, iskelet çıkarma ve dışbükey kabuk bulma gibi işlemler gerçekleştirilmektedir.
- Kenar tespiti (Edge Detection): Görüntüdeki keskin ton değişikliklerini ve süreksizlikleri tespit etme işlemidir.
- Bölütme (Segmentation): Görüntünün parçalara ve nesnelere ayrılması işlemidir. Bu süreçte nesneler, arka plandan ve diğer nesnelerden ayrıştırılmaktadır.
- Tanıma (Recognition): Nesnelere etiket atama veya sınıflandırma işlemi olup, tanımlayıcılarına dayalı olarak yapılmaktadır.

- Nesne izleme (Object Tracking): Görüntüdeki nesnelerin konumlarını tespit etme ve zaman içinde takip etme işlemidir.
- Şablon eşleştirme (Template Matching): Belirli bir şablon görüntüsü ile uyumlu parçaların bulunması işlemidir.
- Görüntü sıkıştırma (Image Compression): Görüntü boyutunu küçültme sürecidir. Bellek miktarını ve iletim için gerekli bant genişliğini azaltmayı hedeflemektedir. Bu sıkıştırma işlemi, kayıplı veya kayıpsız olabilmektedir.

Dijital görüntü işlemenin avantajları (Szeliski, 2022):

- Geliştirilmiş görüntü kalitesi: Dijital görüntü işleme algoritmaları, görüntülerin görsel kalitesini iyileştirerek onları daha net, daha keskin ve daha bilgilendirici hale getirebilmektedir.
- Otomatik görüntü tabanlı görevler: Dijital görüntü işleme, nesne tanıma, model algılama ve ölçüm gibi birçok görüntü tabanlı görevi otomatikleştirebilmektedir.
- Artan verimlilik: Dijital görüntü işleme algoritmaları, görüntüleri insanlardan çok daha hızlı işleyerek büyük miktarda veriyi kısa sürede analiz etmeyi mümkün kılmaktadır.
- Artan doğruluk: Dijital görüntü işleme algoritmaları, özellikle hassas ölçümler veya niceliksel analiz gerektiren görevlerde insanlardan daha doğru sonuçlar sağlayabilmektedir.

Dijital görüntü işlemenin dezavantajları (Szeliski, 2022):

- Yüksek hesaplama maliyeti: Bazı dijital görüntü işleme algoritmaları hesaplama açısından yoğundur. Önemli hesaplama kaynakları gerektirmektedir.
- Sınırlı yorumlanabilirlik: Bazı dijital görüntü işleme algoritmaları, özellikle karmaşık veya gelişmiş algoritmalar için, insanların yorumlaması zor sonuçlar üretebilmektedir.
- Giriş kalitesine bağımlılık: Dijital görüntü işleme algoritmalarının çıktısının kalitesi, büyük ölçüde giriş görüntülerinin kalitesine bağlı olmaktadır. Düşük kaliteli giriş görüntüleri, düşük kaliteli çıktıya neden olabilmektedir.

kullanılarak hastalığın hasar düzeyinin belirlenmesi amaçlanmıştır. Çalışma, kayısı, kiraz ve şeftali olmak üzere üç farklı meyvede, farklı doğal koşullarda sabit bir arka plan kullanılmadan, gerçek ortamdan görüntüler alınmıştır. Görüntü işlemede renk tabanlı segmentasyon tekniği kullanılmıştır. Renkli nesnelerin tanınması, bitki hastalık seviyelerinin tespitinde önemli bir rol oynamaktadır. Görüntü işleme tekniklerini kullanarak nesnelerin renk özelliklerine dayalı algılama ve tanıma sistemlerinin doğruluğunu önemli ölçüde artırılabilir.



2. LİTERATÜR ÖZETLERİ

Karhan (2011) çalışmasında, görüntü bölütleme algoritmalarını kullanarak kayısıda yaprak delen hastalığının meyve üzerinde oluşturduğu lekeleri (çilleri) tespit etmek ve bu lekelere bağlı kayısıdaki kaliteyi yorumlamaya yönelik görüntü işleme tekniklerini kullanmıştır. Çalışmada, USB kamera ile görüntüler alınmış ve gerçek zamanlı çalışan bir sınıflandırma sistemi uygulanmıştır. Görüntü işleme kısmında, görüntü iyileştirme ve renk tabanlı bölütleme yöntemleri kullanılmıştır. Lekelerin tespiti için Otsu eşikleme yöntemi uygulanmış ve sonuçlar renk tabanlı bölütleme ile karşılaştırılmıştır. Çalışma sonunda, renk tabanlı bölütleme yönteminin daha başarılı sonuçlar verdiği bildirilmiştir.

Chaudhar ve ark. (2012) çalışmalarında, bitki yapraklarındaki hastalık noktalarının bölütlenmesi için görüntü işleme tekniklerini kullanmışlardır. Çalışmada, bitki yaprağının arka planından ve türünden etkilenmeyen en iyi hastalık noktası tespit yöntemini bulmak amacıyla pirinç, mısır, buğday, iris, pamuk, soya fasulyesi, hardal, manolya, elma ve kiraz yaprağı görüntüleri toplanmıştır. Görüntüler, RGB'den YCbCr, (Ton, Doygunluk, Yoğunluk) HSI ve CIELAB renk uzaylarına dönüştürülmüştür. Medyan filtre ile gereksiz noktalar temizlenmiştir. Hastalık noktalarını tespit etmek için CIELAB 'A', HSI 'H' ve YCbCr 'Cr' bileşenleri kullanılarak RGB görüntüsüne Otsu eşiği uygulanmıştır. Çalışma sonunda, araştırmacılar bölütlenmiş görüntüleri karşılaştırmış ve en iyi tespit yöntemi olarak CIELAB renk modelinin 'A' bileşenini tercih ettiklerini bildirmişlerdir.

He ve ark. (2013) çalışmalarında, pamuk yaprağındaki hastalık veya zararlılardan kaynaklanan hasar oranını belirlemek amacıyla makine görme teknikleri ve görüntü işleme yöntemlerini kullanmışlardır. MATLAB R2011a yazılımı üzerinde yapılan çalışmada, hasarlı alanların tespiti için RGB, HSI ve YCbCr renk modelleri kullanılmıştır. Çalışma sonunda, üç renk modelinin de pamuk yapraklarındaki hasarlı alanları başarılı bir şekilde belirlediği, en iyi sonuçların ise YCbCr renk modelinin verdiği vurgulanmıştır.

Barbedo (2014) çalışmasında, geleneksel renkli dijital görüntüler kullanılarak yaprak semptomlarının tespit edilmesi ve ölçülmesi amacıyla görüntü işleme tekniklerini kullanmıştır. Çalışmada, hastalıklı kahve yaprağı ve çarkıfelek meyvesi yaprağı görüntülerinden oluşan bir veri tabanından elde edilen örnekler üzerinde bir görüntü analiz yöntemi geliştirilmiştir. Morfoloji tanıma işlemleri ve basit görüntü manipülasyonu yöntemleri kullanılarak, algoritma birden fazla yaprak içeren görüntülerle uğraşarak süreyi azaltmakta ve doğru sonuçlar

sağlamaktadır. Geliştirilen algoritma, hastalıklı bitki yapraklarından elde edilen örnekler üzerinde tamamen otomatik olarak tasarlanmıştır. Araştırmacı, algoritmanın tahmini semptom alanları için genel doğruluğunun %96 civarında olduğunu ve çeşitli koşullarda doğru tahminler sağladığını bildirmiştir.

Kaur ve ark. (2016) yaptıkları çalışmada, bitki yaprak hastalıklarının (bakteriyel yanıklık, *Alternaria alternata*, mantar yaprak lekesi ve antraknoz mantarı) görüntü işleme teknikleri kullanılarak tespit edilmesi ve sınıflandırılması amaçlanmıştır. Çalışmada, yaprak hastalıklarının tespiti ve optimizasyonu için temel görüntü işleme adımları uygulanmıştır. RGB tabanlı görüntüler histogram eşitleme ile iyileştirilmiş ve K-means kümeleme yöntemi ile segmentasyon yapılmıştır. Hastalık belirtileri gri seviye oluşum matrisleri ile çıkarılmıştır. Hastalık tespiti ve sınıflandırması için Destek Vektör Makinesi (SVM) kullanılmış ve karınca kolonisi optimizasyonu ile süreç optimize edilmiştir. Kullanılan yöntemin doğruluğu %96.77 ile %98.42 arasında değişmektedir. Araştırmacılar, kullanılan görüntü işleme yönteminin bitki hastalıklarının tespiti için etkili bir yöntem olduğunu raporlamışlardır.

Zhang ve ark. (2017) çalışmalarında, hıyar bitkisinin yapraklarında görülen hastalıkların tanınması amacıyla yedi farklı hastalığı tespit etmek için yaprak görüntülerine dayanan Seyrek Temsil Sınıflandırması (SRC) yöntemini kullanmışlardır. Bu hastalıklar tüylü küf, bakteriyel açılmal leke, *Corynespora cassiicola*, uyuz, gri küf, antraknoz ve toz halinde küf olarak belirtilmiştir. Çalışmada toplamda 420 yaprak görüntüsü elde edilmiş ve her bir hastalık türünden 60 görüntü seçilmiştir. Çevresel faktörlerin etkisinden kaçınmak için yaprak görüntüleri, çeşitli cihazlarla aynı koşullarda çekilmiştir. Araştırmacılar, kullandıkları yöntemin SVM, K-Araçlarına dayalı segmentasyonun ardından Sinir Ağı Tabanlı Sınıflandırma (KMSNN), Doku Özelliği (TF) ve Bitki Yaprak Görüntüsü (PLI) gibi dört özellik çıkarımına dayalı yöntemlerle karşılaştırıldığında daha etkili olduğunu bildirmişlerdir. Ek olarak, kullanılan yöntemin yedi ana hıyar hastalığının tanınmasında %85.7 genel tanınma oranına sahip olduğunu belirtmişlerdir.

Solak ve Altınışik (2018) çalışmalarında, fındık meyvesinin tespiti ve sınıflandırılması için görüntü işleme teknikleri ve kümeleme yöntemlerini kullanmışlardır. Çalışmada fındık meyvesine ait görüntüler kamera aracılığıyla kaydedilmiş ve daha sonra görüntü işleme teknikleri kullanılarak analiz edilmiştir. Fındık meyvelerinin görüntü düzlemi üzerindeki boyutları ve alanları belirlenmiştir. Elde edilen veriler, ortalama tabanlı sınıflandırma ve K-means kümeleme yöntemleri kullanılarak fındıklar küçük (K1), orta (K2) ve büyük (K3) olmak

üzere üç farklı gruba ayrılmıştır. Çalışma, fındık meyvesi verilerinden oluşturulan bir veri tabanı üzerinden gerçekleştirilmiştir. Sonuç olarak, görüntü işleme teknikleri kullanılarak fındık meyvelerinin %100 oranında başarıyla tespit edildiği ve ortalama tabanlı ile K-means kümeleme yöntemleriyle sınıflandırılan fındık meyveleri arasında %90 ila %100 arasında benzerlik gösteren başarılı sonuçlar elde edildiği rapor edilmiştir.

Oo ve Htun (2018) çalışmalarında, bitki yaprak hastalıklarının analizi ve tespiti için dijital görüntü işleme tekniklerini kullanmak amacıyla cercospora yaprak lekesi, bakteriyel yanıklık, külleme ve pas gibi dört tip bitki hastalığını tanımlayabilen ve sınıflandırabilen bir sistem geliştirmişlerdir. Çalışmada, biber, üzüm, pirinç, soya fasulyesi, buğday, gül, pamuk, elma, mango vb. bitkilerde bulunan bu dört hastalık tipinde toplam 560 görüntü örneği kullanılmıştır. Çalışma ilk olarak, görüntü edinme, ön işleme, segmentasyon ve özellik çıkarma işlemleri Gri Düzey Birlikte Oluşum Matrisi (GLCM) ve Bölgesel İkili Model (LBP) yöntemleriyle gerçekleştirilmiştir. Daha sonra, örnek görüntüler Destek Vektör Makineleri (SVM) sınıflandırıcısı ile test edilmiştir. Kullanılan yöntemin %98.2 doğrulukla bitki hastalıklarını tespit edip sınıflandırabildiği belirlenmiştir. Araştırmacılar, gelecekteki çalışmalarda, veri tabanlarının genişletilerek daha fazla bitki hastalığının tanımlanması ve daha fazla verinin kullanılmasını planladıklarını vurgulamışlardır.

Altas ve ark. (2018) yaptıkları çalışmada, drone kullanılarak şeker pancarı tarlasından elde edilen görüntülerin, geliştirilen görüntü işleme algoritmalarıyla yaprak lekesi hastalığının (*Cercospora beticola* Sacc) bulunup bulunmadığı ve hastalığın şiddetini tespit etmesi amaçlanmıştır. Bu amaçla, sahadan farklı zamanlarda ve değişen doğal ışık koşullarında drone ile 30-60 cm aralığında çekilen 12 görüntü kullanılmıştır. MATLAB programının Image Processing Toolbox modülü, hastalığın farklı gelişim düzeylerini gösteren bu görüntüler üzerinde görüntü işleme tekniği uygulanmıştır. Araştırmacılar, uzman değerlendirmeleriyle karşılaştırıldığında, hastalıklı alanın kesin değerini belirlemede gözlemlenemeyecek kadar hassas olduğunu bildirmişlerdir.

Meyyappan ve Chandramouleeswaran (2018) çalışmalarında, bitki hastalıklarının etkili ve doğru bir şekilde tespit edilmesi ve sınıflandırılması amacıyla görüntü işleme tekniği kullanılarak antraknoz, cercospora yaprak lekesi ve bakteriyel yanıklık olmak üzere üç hastalık incelenmiştir. Çalışmada, farklı bitkilerin enfekte yapraklarının görüntüleri, cep telefonları veya dijital kameralar kullanılarak elde edilmiştir. Kullanılan görüntü işleme algoritmaları, bitki enfeksiyonunu veya hastalığını tanımlamak için yaprak bölgesinin renk özelliklerini

kullanarak geliştirilmiştir. Renk segmentasyonu için K-means algoritması ve hastalıkların sınıflandırılması için Gri Düzey Birlikte Oluşum Matrisi (GLCM) kullanılmıştır. Çalışma sonunda, hastalıkları tanımlama ve sınıflandırmada %98.27'lik bir doğruluk oranına sahip olduğu belirtilmiştir. Araştırmacılar, geliştirilen yöntemin çiftçilere zaman ve işgücü maliyeti tasarrufu sağlayabileceğini ve hastalıkların erken aşamada tespit edilmesine yardımcı olabileceğini vurgulamışlardır.

Khojastehnazhand ve ark. (2019) yaptıkları çalışmada, kayısların görsel özelliklerine dayalı olarak sınıflandırılması görüntü işleme tekniklerini kullanmışlardır. Çalışmada, kayıslar olgunlaşmamış, olgunlaşmış ve aşırı olgunlaşmış olmak üzere üç olgunluk aşamasına ayrılmıştır. Ardından, kayısların hacmi hesaplanmıştır. Elde edilen görüntüler, önceden geliştirilen otomatik bir algoritma kullanılarak işlenmiş, kırılmış ve filtrelenmiştir. Kayısı görüntülerinden çeşitli özellikler çıkarılmış ve hacim hesaplanmıştır. Yapılan istatistiksel analizler sonucunda, olgunluk aşamaları arasında G, gri skala, L* ve b* özelliklerine göre anlamlı farklar tespit edilmiş ve renk özelliklerine dayalı olarak kayısları %90.4 ve %92.3 hassasiyetinde sınıflandırılmıştır. Araştırmacılar, algoritmanın kayısların görüntü özelliklerini kullanarak meyveleri doğru şekilde sınıflandırdığını raporlamışlardır.

Veling (2019) yaptıkları çalışmada, mango bitkisinin görüntü işleme kullanılarak antraknoz, külleme, siyah bantlı ve kızıl pas gibi dört hastalığın tespiti ve bu hastalıklara çözüm sağlanması amaçlanmıştır. Çalışmada MATLAB R2013a kullanılmış ve daha iyi bir kullanıcı deneyimi için aynı platformda Grafiksel Kullanıcı Arayüzü (GUI) oluşturulmuştur. Görüntüler çiftçiler tarafından 8 MP kamera ile elde edilmiştir. Yapraklar, meyveler ve sapsar, dijital kamera kullanılarak sağlıklı ve hastalıklı görüntüler olarak yakalanmıştır. Görüntü iyileştirme amacıyla, özellikle kontrast iyileştirme için "Imadjust" fonksiyonu kullanılmıştır. Kullanılan özellikler arasında korelasyon, enerji, entropi, homojenlik, küme belirginliği, küme gölgesi, varyans ve farklılık bulunmaktadır. Sınıflandırıcı olarak destek vektör makineleri kullanılmıştır. Çalışma sonunda yapılan testlerde önerilen sistemin 92 örnek üzerinde %90 doğruluk sağladığı bildirilmiştir.

Singh (2019) tarafından yapılan çalışmada, ayçiçeği yapraklarında beş farklı hastalığın tespiti amacıyla Parçacık Sürüşü Optimizasyonu (PSO) algoritması kullanılarak bir sistem geliştirilmiştir. Bu hastalıklar arasında beyaz pas, bakteriyel yaprak lekesi, tüylü küf, külleme, septoria yaprak yanıklığı ve güneş pası yer almaktadır. Çalışmada, dijital kamera veya benzeri cihazlarla alınan yaprak görüntüleri üzerinde segmentasyon ve sınıflandırma işlemleri

gerçekleştirilmiştir. Görüntülerin analizi için çeşitli görüntü işleme teknikleri kullanılarak faydalı özellikler elde edilmiştir. Çalışma sonunda, kullanılan algoritmanın ortalama sınıflandırma doğruluğunun %98 olduğu raporlanmıştır.

Uygun ve ark. (2020) çalışmalarında, iki noktalı kırmızı örümcek akarının (*Tetranychus urticae* Koch) hıyar bitkisine verdiği zarar düzeyinin ve akar sayısındaki değişimlerin belirlenmesi amacıyla görüntü işleme tekniğini kullanmışlardır. Bu amaçla, kamera stabilitesini sağlamak için METAZI adlı yeni bir tarım platformu tasarlanmış ve imal edilmiştir. Bu platform ile 5 hafta boyunca, haftalık olarak *T. urticae* ile bulaşık 50 yaprağın görüntüsü çekilmiş ve toplamda 250 görüntü elde edilmiştir. Bu görüntülerden 50'si rastgele seçilerek MATLAB'ın görüntü işleme araç kutusu kullanılarak işlenmiştir. *T. urticae*'nin neden olduğu hasarın belirlenmesinde K-means kümeleme algoritması kullanılmıştır. Görüntü işleme sonuçları, uzman gözlemleriyle karşılaştırılmış ve hasarın 3.91 kök ortalama kare hatası (RMSE) ile tahmin edildiği bulunmuştur. Görüntü işleme ile uzman gözlemleri arasında anlamlı pozitif bir ilişki bulunmuştur. Araştırmacılar, bu yöntemin seralarda *T. urticae* hasarını belirlemek için uzman gözlemi yerine başarıyla kullanılabileceğini bildirmişlerdir.

İhsan ve ark. (2020) çalışmalarında, pirinç bitkisinde bakteriyel yaprak yanıklığı ve kahverengi noktaları tespit etmek için bir görüntü işleme yaklaşımı kullanmışlardır. Çalışmada, 13MP kameraya sahip bir akıllı telefon ile çekilen fotoğraflar test verisi olarak kullanılmıştır. Eğitim verileri her hastalık için 40, test verileri ise her hastalık için 12 görüntüden oluşmaktadır. Pirinç yapraklarının görüntüleri, K-Means Kümeleme algoritması ile segmentlere ayrıldıktan sonra, Gri Düzey Birlikte Oluşum Matrisi (GLCM) kullanılarak doku ve şekil özellikleri çıkarılmıştır. Ayrıca metrik ve eksantriklik özellikleri hesaplanarak eğitim veri tabanına eklenmiştir. Test verileri sisteme girildikten sonra, K-Means Kümeleme ile segmentlere ayrılarak GLCM, metrik ve eksantriklik özellikleri çıkarılmıştır. Eğitim veri tabanı ile Öklid Uzaklığı algoritması kullanılarak karşılaştırmalar yapılmış ve tanımlama sonuçları elde edilmiştir. Araştırmacılar, sistemin önceki çalışmalara göre daha yüksek bir doğruluk düzeyine sahip olduğunu ve 0.007282214 Ortalama Kare Hata (MSE) değeriyle %100 doğruluk elde ettiğini bildirmişlerdir.

İncekara ve Selek (2020) yaptıkları çalışmada, kiraz meyvelerinin boyutlarına göre sınıflandırılması amacıyla görüntü işleme yöntemlerini kullanmışlardır. Matlab R2013a yazılımıyla meyvelerin görüntüleri çekilmiş ve küçük, orta ve büyük boy olarak sınıflandırılmıştır. Kirazlar, üst üste gelmeden tek tek resmedilmiş ve bu yöntemle sınıflandırma başarıları %100 olarak elde edilmiştir. Ancak, kirazların üst üste gelmesi

durumunda sınıflandırma başarısının düşebileceği gözlemlenmiştir. Araştırmacılar, görüntü işleme tekniklerinin kullanılmasıyla, kiraz meyvelerinin klasik sınıflandırma yöntemlerine kıyasla uluslararası standartlara daha uygun bir şekilde sınıflandırılmasının ülke ekonomisine daha fazla katkı sağlayabileceğini bildirmişlerdir.

Deng ve ark. (2020) çalışmalarında, üç ana mısır hastalığı ve zararlısı hakkında etkili bilgiler elde etmek amacıyla, görüntü işleme ve analizde temel bir teknoloji olan görüntü segmentasyonunu kullanmışlardır. Çalışmada, mısır bitkisinin kök, gövde ve yapraklarına ait görüntüler toplanmıştır. Toplanan görüntüler, hastalık ve zararlıların varlığı, noktaların boyutu ve hastalıklı kısımların konumu gibi çeşitli kriterlere göre sınıflandırılmıştır. İlk olarak, görüntüler gri tonlamaya dönüştürülmüş ve bulanık kümeleme ile AdaBoost algoritması kullanılarak histogram analizi yapılmıştır. Ardından, eşik segmentasyonu ve kenar tespiti ile hastalıklı bölgeler yeniden konumlandırılmıştır. Son olarak, minimum yinleme Gauss yöntemi ve GrabCut algoritması ile analiz sonuçları elde edilmiştir. Araştırmacılar, doğruluğun ve zaman verimliliğinin büyük ölçüde arttığını ve görüntü toplu işlemenin etkin bir şekilde gerçekleştirilebildiğini raporlamışlardır.

Göğçe ve ark. (2021) çalışmalarında, yapraklardaki hastalıklı lekelerin tespiti için temel görüntü işleme tekniklerini kullanarak düşük hesaplama yüküne sahip orijinal bir algoritma geliştirmişlerdir. Çalışmanın performansını değerlendirmesi için internetten temin edilen 35 farklı hastalıklı yaprak kullanılmıştır. Geliştirilen algoritma, renkli görüntünün kırmızı, yeşil, mavi kanalları ile gri seviyeli görüntüden elde edilen standart sapma görüntüsünden faydalanılmıştır. Elde edilen görüntülerdeki leke bölgeleri, geliştirilen bir eleme mekanizması ile tespit edilmiştir. Algoritmanın test edilmesi için karmaşık arka plana sahip görüntüler kullanıldığı halde, leke türünden bağımsız olarak yapraktaki lekelerin büyük ölçüde tespit edildiği gözlemlenmiştir. Özellikle beyaz yerine kahverengi lekelerle sahip hastalıklarda performansın daha iyi olduğu belirtilmiştir. Ayrıca, test görüntülerinde ana yaprak arkasında bulanık bir şekilde görünen yapraklardaki lekelerin dahi başarılı bir şekilde tespit edildiği vurgulanmıştır.

Altaş ve ark. (2021) yaptıkları çalışmada, bağ yaprak uyuzu hasarının tespit edilmesi amacıyla görüntü işleme tekniklerini kullanmışlardır. Çalışmada rastgele seçilen 50 görüntü, MATLAB çalışma ortamına aktarılmıştır. Görüntüler, $l*a*b^*$ renk uzayına dönüştürülerek nesneler ve arka plan renk bazlı segmentasyon yöntemi ile ayrılmıştır. Görüntüler çeşitli faktörlere göre bölünebilmektedir. Araştırmada, " $a^* b^*$ " alanında sınıflandırılan renklere sahip görüntülerde

Öklid mesafesi kullanılarak lekeli piksellerin ("a*" ve "b*" değerleri ile taşınan renkler) kümelenmesi amacıyla K-means kümeleme yöntemi uygulanmıştır. Bu yöntemle lekeli pikseller etkin bir şekilde tespit edilip sınıflandırılmıştır. Çalışmanın sonunda, bağ yaprak uyuzu lekelerinin başarılı bir şekilde tespit edilip hasar seviyeleri belirtilmiştir. Araştırmacılar, bu görüntü işleme yönteminin düşük maliyetli, hızlı ve başarılı sonuçlar verdiğini bildirmişlerdir.

Ozguven ve Altas (2022) çalışmalarında, hıyar bitkisinde küf hastalığının neden olduğu zararın düzeyini belirlemek amacıyla görüntü işleme algoritmaları kullanmışlardır. Çalışmada, enfekte olmuş 50 bitki görüntüsü rastgele seçilmiş ve MATLAB'ın görüntü işleme araç kutusu modülü kullanılarak geliştirilen görüntü işleme algoritmasıyla işlenmiştir. Daha sonra, görüntü işleme algoritmasından elde edilen sonuçlar uzman değerlendirmeleriyle karşılaştırılmıştır. Çalışma sonunda görüntü işleme yöntemi, hastalık seviyelerini 1.90 RMSE ve Theil UII'si 0.0312 ile tahmin etmiştir. Ayrıca verilerin normallik varsayımını test etmek için Kolmogorov-Smirnov testi uygulanmış ve test sonuçları normal dağılım göstermiştir ($p > 0,05$). Belirleme katsayısı ($R^2 = 0.995$, $p < 0.01$) ve Pearson korelasyon katsayısı ($r = 0.997$, $p < 0.01$), görüntü işleme ile uzman değerlendirmeleri arasında anlamlı pozitif bir ilişki olduğu belirtilmiştir. Araştırmacılar, mevcut görüntü işleme algoritmasının hıyar bitkisinde küf hastalığının teşhisinde uzman değerlendirmesi yerine başarıyla kullanılabileceğini bildirmişlerdir.

Hosseini ve ark. (2023) çalışmalarında, hıyar bitkisi seralarında külleme ve antraknoz mantar hastalıklarının en fazla zararı vermesi üzerine görüntü işleme tekniği ve yapay sinir ağına dayalı bir yöntem geliştirmişlerdir. Çalışmada analiz için sağlıklı ve hastalıklı yaprakları içeren 150 hıyar yaprağı görüntüsü kullanılmıştır. Kullanılan yöntem, segmentasyon, hasarlı kısımların yapraktan ayrılması ve hastalık tipinin sınıflandırılması olmak üzere üç bölümden oluşmaktadır. Renk ve doku özellikleri çıkarıldıktan sonra, hata difüzyon sonrası öğrenme algoritmasına sahip çok katmanlı bir algılayıcı sinir ağı kullanılarak farklı görüntü sınıfları ayırt edilmiştir. Sinir ağı, Geri Yayılım (BP) algoritması ve Lovenerg Marquart (LM) fonksiyon eğitimini kullanarak bitki hastalıklarını 6 saniyede %99.95 doğrulukla teşhis edip sınıflandırmıştır. Araştırmacılar, kullanılan algoritmaların, bitki hastalıklarının test ve analizlerinin geliştirilmesinde, yapılandırılmasında veya seralarda kontrol ve izleme sistemleri olarak etkili olabileceğini vurgulamışlardır.

3. MATERYAL VE YÖNTEM

3.1. Materyal

3.1.1. Araştırma alanları

Çalışma kapsamında, kayısı, kiraz ve şeftali ağaçlarındaki hastalık hasarı görüntülerinin elde edilmesi amacıyla Tokat, Yozgat, Kayseri, Malatya ve Ankara illerinde araştırmalar yapılmıştır. Araştırma yapılan alanların bulunduğu iller Şekil 13’de verilmiştir. Şekil 14’de ise, görüntülerin elde edildiği Tokat Gaziosmanpaşa Üniversitesi Tarımsal Uygulama ve Araştırma Merkezi meyve bahçelerine ait görsel sunulmuştur. Aşağıda sıralanan illerden hastalık hasarı görüntüleri alınmıştır:

- Tokat Gaziosmanpaşa Üniversitesi Tarımsal Uygulama ve Araştırma Merkezi meyve bahçeleri
- Tokat Pazar ilçesi Erkilet köyü
- Yozgat Merkez
- Kayseri Kocasinan ilçesi
- Malatya merkez, Doğanşehir ilçesi ve Darende ilçesi Yeniköy
- Ankara Kahramankazan ilçesi




Şekil 13. Araştırma yapılan iller



Şekil 14. Tokat Gaziosmanpaşa Üniversitesi Tarımsal Uygulama ve Araştırma Merkezi meyve bahçeleri

3.1.2. Çalışmada değerlendirilen yaprak delen hastalığı

Hastalık, sert çekirdekli meyve yetiştiriciliğinin yoğun olduğu bölgelerde sıkça karşılaşılan bir durumdur. Yaprak delen hastalığı, şeftali, nektarin, kiraz, vişne, kayısı, erik ve badem ağaçlarında zarar verebilmektedir. Bu çalışma, kayısı, kiraz ve şeftali ağaçlarında yapılmıştır. Değerlendirilen hastalığın belirtileri, kayısı meyve ve yaprağı ile kiraz ve şeftali yapraklarında Şekil 15'de gösterilmiştir.



Şekil 15. Çalışmada değerlendirilen yaprak delen hastalığı (a: kayısı meyvesi, b: kayısı meyvesi, c: kiraz yaprağı, d: şeftali yaprağı)

3.1.3. Çalışmada kullanılan cihazlar

Çalışmada değerlendirilen yaprak delen hastalığının görüntülerini elde etmek için GoPro Hero 7 Black model kamera ve iPhone 11 akıllı telefon kullanılmıştır (Şekil 16). GoPro Hero 7 Black kameranın özellikleri Çizelge 2'de, akıllı telefonun özellikleri Çizelge 3'de ve çalışmada kullanılan bilgisayarın teknik özellikleri ise Çizelge 4'de verilmiştir.



Şekil 16. GoPro Hero 7 Black ve iPhone 11

Çizelge 2. GoPro Hero 7 Black kameranın teknik özellikleri

Donanım	Teknik Özellik
Görüntü İşlemcisi	GoPro GP1
Sensör Tipi	CMOS
Etkin Piksel	12 MP
Azami Çözünürlük	4 000×3 000
Görüntü Oranı	4:3
Sensör Formatı	12 MB
Sensör Boyutu (Genişlik)	6.17 mm
Sensör Boyutu (Uzunluk)	4.62 mm
En Düşük ISO	100
En Yüksek ISO	6 400
GPS (Konum) özelliği	Mevcut
Optik İmaj Sabitleme	Mevcut

Çizelge 3. Kullanılan akıllı telefonun teknik özellikleri

Donanım	Teknik Özellik
İşletim Sistemi	IOS
İşlemci Türü	Apple A13 Bionic
Ekran Boyutu	6.1 inç
İşlemci Hızı	2.6 GHz
İşlemci Çekirdek Sayısı	6
Ekran Çözünürlüğü	828x1 792 (HD+) Piksel
Etkin Piksel	12 MP
Video Çözünürlüğü	3 840 x 2 160
Odak Uzaklığı	26 mm
Kamera Sensör Boyutu	1/2.55 İnç

Çizelge 4. Çalışmada kullanılan bilgisayarın teknik özellikleri

Donanım	Teknik Özellik
İşlem üreticisi	DELL
İşlemci tipi	8.Nesil Intel Core i5
İşlemci hızı	3.40 GHz
Ram (sistem belleği	8 GB
SSD Kapasitesi: 128 GB	128 GB
Ekran Kartı	4 GB AMD Radeon (TM) 520

3.1.4. MATLAB

Görüntü işleme yazılımı olarak MATLAB kullanılmıştır. MATLAB, sayısal hesaplama ve dördüncü nesil bir programlama dilidir. Matris işlemleri, fonksiyonlar, veri görselleştirmesi, algoritmaların uygulanması, kullanıcı arayüzleri oluşturma ve diğer dillerle etkileşim gibi birçok işlevi desteklemektedir. MATLAB, C, C++, Java ve Fortran gibi dillerle uyumludur. MATLAB'ın dijital görüntü işleme alanındaki gücü, çok boyutlu dizilerin işlenmesi için geniş bir işlev koleksiyonunu içermektedir. Görüntü işleme, MATLAB'ın Image Processing Toolbox modülü kullanılarak gerçekleştirilmiştir. Bu modül, MATLAB'ın sayısal bilgi işlem kapasitesini artıran bir dizi fonksiyon içermektedir. MATLAB dilinin ifade gücüyle birlikte, görüntü işleme operasyonlarının net ve kompakt bir şekilde yazılmasını sağlamaktadır. Bu da görüntü işleme problemlerinin çözümü için ideal bir yazılım prototipleme ortamı sunmaktadır.

3.1.5. SPSS İstatistik Programı

SPSS bilgisayar programı (Statistical Package for the Social Sciences), istatistiksel analizler için kullanılan bir araç olup birçok veri operasyonunu ve istatistiksel işlemi desteklemektedir. Bazı temel özellikleri şunlardır:


- Tanımlayıcı istatistik: "Cross Tabulation (karşılıklı tabülasyon)"; "Frequencies frekanslar"; "Descriptives (tanımlayıcılar)"; "Explore (araştırma)"; "Descriptive Ratio İstatistiks (tanımlayıcıya oran istatistikleri),
- İki değişkenli istatistik: "Means (ortalamalar)", "t-testi", varyant Analizi, korelasyon (iki değişkenli, kısmî, uzaklıklar); parametrik olmayan sınamalar,
- Sayısal sonuçların tahmin edilmesi: Doğrusal regresyon,
- Grupları tespit etmek için tahminler: Faktör analizi, kümeleşme analizi (iki-basamaklı, K-ortalamlar, hiyerarşik), Diskriminant analizi,

SPSS, bir grafik arayüze sahiptir. Kullanıcılar açılır menüler ve grafiksel araçlar aracılığıyla işlemleri kolayca gerçekleştirebilmektedir. Ayrıca, kullanıcılar kendi amaçları doğrultusunda programı yönlendirmek için makro dilleri kullanabilmektedir.


3.2. Yöntem

3.2.1. Hastalığın uzman tarafından tespit edilmesi

Yaprak delen hastalığı, bitki koruma uzmanları tarafından yapılan yerinde gözlemlerle tespit edilmektedir. Uzmanlar tarafından, gözlem sırasında Şekil 17 ve Şekil 18’de verilen yaprak delen hastalığının yaprak ve meyve görsel skalası kullanılarak, hastalığın şiddetine bağlı olarak görülen ölü alanlar tespit edilmeye çalışılmaktadır. Bu skalalar göz önünde bulundurularak yaprakların ve meyvelerin hastalık durumu belirlenmekte ve varsa hastalığın hangi evrede olduğu tespit edilmeye çalışılmaktadır. Uzmanlar, yaprak üzerindeki ölü alanın yaprak alanına oranını ve meyve üzerindeki ölü alanın meyve alanına oranını kullanarak hastalığın yayılımını belirlemeye çalışmaktadır. Ancak, yapılan gözlemler uzmanlar arasında farklılık gösterebilmektedir. Bu çalışmada, GoPro Hero 7 Black model kamerası ve iPhone 11 akıllı telefon kullanılarak alınan görüntüler, geliştirilen görüntü işleme algoritmalarıyla işlenerek hastalıklı alanlar tespit edilmiştir.



Şekil 17. Yaprak delen hastalığının yaprak görsel skala



Şekil 18. Yaprak delen hastalığının meyve görsel skala

3.2.2. Görüntülerin toplanması

Sert çekirdekli meyvelerde yaprak delen hastalık, genellikle Mart ile Eylül arasındaki sıcak ve nemli dönemlerde ortaya çıkmaktadır. Hava koşulları ve yetiştirme yöntemleri gibi faktörler hastalığın yayılma zamanını etkileyebilmektedir. Özellikle bitkilerin yeni büyüme döneminde ve meyve olgunlaşma sürecinde hastalığın belirtileri daha belirgin olabilmektedir. Hastalık, sert çekirdekli meyvelerin yetiştirildiği tüm bölgelerde görülebilmektedir. Sert çekirdekli meyve ağaçlarının yaprak, meyve, tomurcuk ve genç dalları üzerinde belirti oluşturmaktadır. Çalışma, hastalığın en yoğun görüldüğü zaman ve farklı gelişim düzeylerini dikkate alarak, çoğunlukla Tokat koşullarında gerçekleştirilmiş olup, ardından Yozgat, Kayseri, Malatya ve Ankara'da kayısı, kiraz ve şeftali ağaçlarından yaprak ve meyve fotoğrafları çekilmiştir (Çizelge 5).

Çizelge 5. Görüntülerin alınmasıyla ilgili bilgiler

İller	Yaprak Delen Hastalığı				
	Kayısı (meyve)	Kayısı (yaprak)	Kiraz	Şeftali	Toplam görüntü sayısı
Tokat	30.06.2022	30.06.2022	18.06.2022	21.06.2022	180
			30.06.2022	30.06.2022	
			26.06.2022	03.07.2022	
Yozgat	10.07.2022	10.07.2022	-	-	60
		27.04.2024			
Kayseri	13.07.2023	21.07.2022	-	-	60
Malatya	21.07.2022	14.07.2022	-	-	60
Ankara	-	-	06.06.2023	06.06.2023	40
Toplam görüntü sayısı	100	100	100	100	

Kayısı ağaçlarından hem yaprak hem de meyve, kiraz ve şeftali ağaçlarından ise sadece yaprak görüntüleri alınmıştır (Şekil 19). Çalışmada akıllı telefon kullanılarak 3 024 x 4 032 piksel çözünürlükte 300 adet görüntü ve GoPro Hero Black 7 kamera kullanılarak 4 000 x 3 000 piksel çözünürlükte 100 adet görüntü olmak üzere toplam 400 görüntü elde edilmiştir. Görüntüler farklı doğal aydınlanma koşullarında temin edilerek, görüntü işleme başarısının artırılmasına katkı sağlanmıştır.



Şekil 19. Görüntülerin toplanması

3.2.3. Görüntülerin düzenlenmesi

Alınan görüntüler bilgisayara aktarılıp her bir meyve ağacı türü için ayrı ayrı dosyalanarak düzenlenmiştir. Kayısı yaprakları ve meyveleri için ayrı klasör, kiraz ve şeftali için ise her biri


ayrı bir klasör oluşturulmuştur. Çalışmada kullanılan görüntü sayıları Çizelge 6'da verilmiştir. Çizelgede gösterildiği gibi, her bir klasörde bulunan en az 100 görüntü içerisinde hastalığın farklı gelişim düzeylerini gösteren 50 adet görüntü rastgele seçilmiştir. Toplamda 200 adet görüntü işlenmiştir.

Çizelge 6. Görüntü sayıları

	Görüntü Sayısı (Adet)		
	Kayısı	Kiraz	Şeftali
Yaprak	50	50	50
Meyve	50	-	-
Toplam	200		

3.2.4. Yaprak delen hastalığının hasar düzeyinin belirlenmesi


Yaprak delen hastalığı yaprak ve meyve kısımlarında farklı düzeyde zarar oluşturmaktadır. Yapraklarda önce kahverengi ve kırmızı lekelenmeler görülmektedir. Ardından bu lekeler yerini delinme şeklinde dökülmelere bırakmaktadır. Meyve kısmında oluşturduğu hasar ise sadece lekelenme şeklinde gerçekleşmektedir. Çalışma kapsamında bu hasarların şiddet tespitlerinin hesaplanması için farklı görüntü işleme yöntemleri uygulanmıştır. Bu işlemler Şekil 20'de bulunan diyagramda ve alt başlıklar halinde detaylandırılmıştır.



Şekil 20. Görüntü işleme diyagramı

Ön işleme

Çalışmada görüntüler arazi şartlarında elde edildiğinden karmaşık arka plana sahiptir. Bu nedenden dolayı görüntüler üzerinde otomatik arka plan kaldırma işlemi uygulanmıştır. Hastalığın yapraklarda delinme türünde oluşturduğu hasarlarda ilk olarak Şekil 21a’da görüldüğü gibi delik tespiti ve piksel saydırmaları “bwconncomp” komutu ile yapılmıştır. Ancak Şekil 21b’ de kırmızı halkalar içerisinde gösterilen yırtık alanlar delik olarak saydırılamamıştır. Bu nedenden dolayı yaprakların kenar kısımlarına sınırlar çizdirilerek “imfill” komutu ile 0 ve 1 değerine sahip siyah-beyaz pikseller haricinde otomatik renkli piksel doldurma işlemi gerçekleştirilmiştir.



Şekil 21. Ön işleme örneği, a) delik saydırma ve b) delik ve yırtık alan doldurma

Görüntü okuma ve dönüştürme

Alınan görüntüler, MATLAB programının çalışma alanına “imread” komutu kullanılarak tanımlanmıştır. Giriş görüntüleri PNG formatında RGB (Red, Green, Blue) görüntüleri olarak alınmıştır. RGB görüntüleri, parlaklıktan kaynaklanan görüntü bozulmalarını sınırlandırmak amacıyla “makecform” ve “applycform” komutları kullanılarak Lab* renk uzayına dönüştürülmüştür. Lab* renk uzayı, üç bileşenden oluşmaktadır: ‘L*’ parlaklık katmanı, ‘a*’ renklerin kırmızı-yeşil ekseninde nereye düştüğünü gösteren kromatiklik katmanı ve ‘b*’ rengin mavi-sarı ekseninde nereye düştüğünü gösteren kromatiklik katmanıdır. Renk bilgisinin tümü ‘a*’ ve ‘b*’ katmanlarında bulunduğundan, hastalık bilgisi de Lab* renk uzayındaki bu iki kanalda saklanmaktadır. Ayrıca kümeleme işleminin daha hızlı yapılabilmesi için verinin %10’unu rastgele örneklemek için algoritmada “sample_rate” belirlenmiştir. Ardından

“randperm” fonksiyonu ile ab matrisindeki satırların rastgele permütasyonunu oluşturulmuş ve bu permütasyondan %10 oranında rastgele indeks seçilmiştir. Bu indeksler “sample_idx” adının verildiği değişkende saklanmıştır.

Renk tabanlı kümeleme ve segmentasyon

K-means


Kümeleme, nesneleri gruplarına ayırmanın bir yoludur. K-Means kümeleme, bir veri noktası kümesinin özelliklerini öğrenmekte ve benzer özelliklere sahip verileri temsil eden kümeler olarak adlandırılan bölümler oluşturmaktadır (Tan ve ark., 2006). K-means kümeleme, her nesneyi uzaydaki bir konuma sahip olarak değerlendirmekte ve verileri birbirinden bağımsız kümeler ayırmaktadır. Her gözlemi, atadığı kümenin dizinini döndürerek gerçekleştirmektedir. K-means, hiyerarşik kümelemeden farklı olarak, gerçek gözlemler üzerinde çalışmakta ve tek bir küme düzeyi oluşturmaktadır. K-means algoritması, her küme içindeki nesnelerin birbirine yakın, diğer kümelerden ise uzak olmasını sağlamaya çalışmaktadır. Bu süreçte, bölünecek kümelerin sayısını ve iki nesnenin birbirine ne kadar yakın olduğunu belirlemek için bir mesafe metriği belirtilmesi gerekmektedir.

Gaussian mixture models (GMM)


GMM, veri ve model arasındaki uyumu optimize etmek için olasılıksal bir yaklaşım kullanan ve birden fazla Gaussian dağılım fonksiyonuna dayalı bir popüler bir kümeleme tekniğidir (Kasa ve Rajan, 2023; Weber ve ark., 2022). GMM, veri setini daha detaylı ve esnek bir şekilde modellemek ve kümelemeyi daha hassas bir şekilde gerçekleştirmek için kullanılmaktadır. Ayrıca bu model veri setinin daha sofistike bir şekilde analiz edilmesini sağlamaktadır. GMM'nin diyagonal kovaryans matrisi kullanılarak her bir kümenin varyansları hesaplanmakta ve bu sayede daha esnek bir kümeleme sağlanmaktadır. K-Means, basit ve hızlı bir kümeleme yöntemidir. Gaussian Karışım Modelleri (GMM) ise karmaşık desenleri keşfedebilmekte ve bunları veri kümesi içindeki gerçek desenlerin yakın temsilleri olan tutarlı, homojen bileşenlere ayırabilmektedir (Patel ve Kushwaha, 2020).

Çalışmada, hem K-means hem de Gaussian Mixture Model (GMM) kümeleme yöntemlerinin birleşimini içeren görüntü işleme algoritması geliştirilmiştir. Bu iki aşamalı kümeleme yaklaşımı, K-means'in hızlı ve basit doğasını GMM'nin esnekliği ve doğruluğu ile birleştirmektedir. İlk adımda, K-means algoritması kullanılarak renk uzayındaki (a^* , b^*

bileşenleri) örneklenmiş pikseller üzerinde başlangıç kümeleri belirlenmiştir. Oluşturulan K-means başlangıç kümeleri GMM için başlangıç noktalarını belirlemek amacıyla kullanılmıştır. K-means algoritması, veriyi hızlı ve basit bir şekilde ön kümelere ayırarak başlangıç noktalarını belirlemektedir. Ardından, bu başlangıç noktaları GMM algoritmasına aktarılmıştır. GMM, veri setini daha detaylı ve esnek bir şekilde modellemek için bu başlangıç kümeleri kullanılmaktadır. GMM algoritmasında “statset” fonksiyonu ile modelin kümeleme iterasyon sayısı 500 olarak ayarlanmıştır. Ayrıca modelin kovaryans tipi diyagonal olarak belirlenmiş ve düzenleme değeri 0.01 olarak ayarlanmıştır. Tüm bu aşamalardan sonra görüntü Şekil 22’de gösterildiği gibi görüntüdeki farklı renk bölgeleri ayrıntılı bir şekilde segment edilmiştir. Ardından veri renk yakınlıklarına göre GMM tarafından 9 kümeye bölünmüştür (Şekil 23).



Şekil 22. Örnek kümeleme sonrası segment edilmiş görüntü




Şekil 23. Kümeleme sonucu oluşan görüntüler

Yaprak ve meyve üzerindeki hastalık hasar şiddeti hesabı

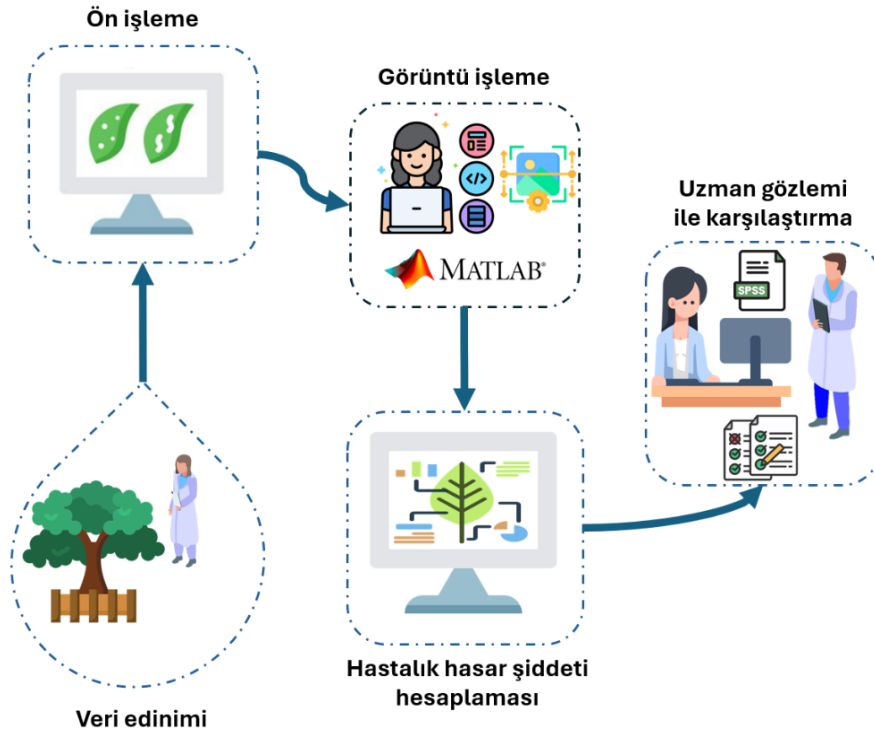
Segmentasyon ve kümeleme işlemlerinin tamamlanmasının ardından, istenen kümeler hastalıklı ve sağlıklı kümelerin seçimleri yapılarak 9 kümeye ayrılan görüntüler Şekil 24’de verildiği gibi 2 görüntü haline getirilmiştir. Son olarak oluşturulan 2 görüntüdeki 0-1 değerine sahip siyah ve beyaz pikseller haricindeki hastalıklı bölge ve tüm renkli pikseller saydırılmıştır. Bu doğrultuda hastalık hasarının hesaplanması için aşağıdaki Eşitlik 1.1 oluşturulmuştur.

$$\text{Hastalıklı Alan Yüzdesi} = \frac{\text{Hastalıklı Bölge Piksel Sayısı}}{\text{Toplam Piksel Sayısı}} \times 100 \quad (1.1)$$



Şekil 24. Hastalıklı ve sağlıklı bölgelerin ayrı ayrı görselleştirilmesi

Bu aşamaya kadar, Şekil 25'de gösterildiği gibi, veri toplama, ön işleme ve algoritma geliştirme aşamasına kadar olan süreçler tamamlanmıştır. Bu aşamadan sonra ise, geliştirilen algoritma ve belirlenen yöntemler doğrultusunda görüntülerin işlenmesi, hastalık hasarının belirlenmesi ve uzman gözlem değerleriyle istatistiksel karşılaştırmalar yapılmıştır.



Şekil 25. Genel akış diyagramı

3.2.5. İstatistiksel analiz

Kök ortalama kare hatası (RMSE), genellikle bir model veya tahminci tarafından tahmin edilen değerler ile gözlemlenen değerler arasındaki farkları ölçmek için kullanılmaktadır. RMSE, bir veri kümesindeki hataların karelerinin toplamının veri sayısına bölünmesi ve bölümün karekökünün alınmasıyla hesaplanmaktadır (Willmott ve Matsuura, 2005).

$$RMSE = [\sum_{i=1}^N (x - x')^2 / n]^{1/2} \quad (1.2)$$

Burada, RMSE denklemi, x gerçek değer, x' tahmin edilen değer ve n veri sayısını ifade etmektedir. RMSE denkleminde hataların kareleri alındığından veri setindeki büyük hataların ortalamaya etkisi de büyüktür. Bu da büyük hataların ölçümün tamamı üzerindeki etkisinin belirlenmesine olanak sağlamaktadır (Chai ve Draxler 2014). RMSE değeri yaygın olarak modellerin tahmininin değerlendirme kriteri olarak kullanılmakta ve genellikle <%10 olması beklenmektedir (Lee, 2014).

Theil'in UII İstatistiği ise tahmin edilen değerler ile gerçek değerler arasındaki farkı ölçmek için kullanılmakta ve 0 ile 1 arasında bir değer almaktadır. Daha düşük değerler, modelin daha iyi performans gösterdiğini, yani tahminlerin gerçek değerlere daha yakın olduğunu göstermektedir (Bliem, 1973).

$$UII = U = \frac{[\sum_{i=1}^n (P_i - A_i)^2]^{1/2}}{[\sum_{i=1}^n A_i^2]^{1/2}} \quad (1.3)$$

Burada, Theil'in UII eşitliğinde, Pi = tahmini değer, Ai = gözlem değeri ve n = toplam veri sayısını ifade etmektedir.


Çalışmada, görüntü işleme yöntemi ile elde edilen değerler, bitki koruma uzmanının gözlem değerleri ile karşılaştırılmıştır. Veri analizi, SPSS yazılımının SPSS 21 versiyonu kullanılarak gerçekleştirilmiştir. İlk olarak, elde edilen verilerin dağılımı Kolmogorov–Smirnov testi ile normallik analizi yapılarak değerlendirilmiştir. Daha sonra, görüntü işleme sonuçları ile uzman görüşleri arasındaki regresyon katsayısı ve pearson korelasyon katsayısı testleri yapılarak, gözlemlenen ve görüntü işlemeyle tahmin edilen değerler arasında anlamlı bir fark olup olmadığı incelenmiştir. Son olarak, çalışmada geliştirilen görüntü işleme algoritmasının performansı RMSE ve Theil UII istatistikleri ile değerlendirilmiştir.

4. BULGULAR

Çalışma kapsamında 3 farklı bitki türünde yaprak ve meyve kısımları işlenerek deneyler gerçekleştirilmiştir. Çalışma alanlarında elde edilen ve görüntü işleme yapılan 200 görüntüden 20 adet görüntü örnek olarak verilmiştir. Geliştirilen görüntü işleme algoritması ile bu fotoğraflar, her bitkiye özel alt başlıklar altında ayrı ayrı verilmiştir.


4.1. Kayısı yaprak sonuçları

Şekil 26'da yaprak delen hastalığının kayısı yaprağında oluşturduğu hasar, uzman değerlendirmesine göre %3 olarak belirlenmiştir. Oluşan bu hasar yapılan görüntü işleme sonucunda ise %2.66 olarak tespit edilmiştir. Bu sonuçlara göre görüntü işlemenin daha hassas sonuçlar verdiği görülmektedir.




Şekil 26. Kayısı yaprak-1, (a: orijinal görüntü, b: hastalıklı bölge ve c: sağlıklı bölge)

Şekil 27'de yaprak delen hastalığının kayısı yaprağında oluşturduğu hasar, uzman değerlendirmesine göre %5 olarak belirlenmiştir. Oluşan bu hasar yapılan görüntü işleme sonucunda ise %4.25 olarak tespit edilmiştir. Uzman değerlendirmesi ile görüntü işleme sonuçları birbirine yakın değerler olduğu görülmektedir.




Şekil 27. Kayısı yaprak-2, (a: orijinal görüntü, b: hastalıklı bölge ve c: sağlıklı bölge)

Şekil 28’de yaprak delen hastalığının kayısı yaprağında oluşturduğu hasar, uzman değerlendirmesine göre %10 olarak belirlenmiştir. Oluşan bu hasar yapılan görüntü işleme sonucunda ise %7.28 olarak tespit edilmiştir. Uzman değerlendirmesinin hassasiyetinin görüntü işleme hassasiyetinde olmadığı görülmektedir.




Şekil 28. Kayısı yaprak-3, (a: orijinal görüntü, b: hastalıklı bölge ve c: sağlıklı bölge)

Şekil 29’da yaprak delen hastalığının kayısı yaprağında oluşturduğu hasar, uzman değerlendirmesine göre %10 olarak belirlenmiştir. Oluşan bu hasar yapılan görüntü işleme sonucunda ise %13.21 olarak tespit edilmiştir. Uzman değerlendirmesinin görüntü işleme ile elde edilen değere yakın tam sayılar olduğu görülmektedir.



Şekil 29. Kayısı yaprak-4, (a: orijinal görüntü, b: hastalıklı bölge ve c: sağlıklı bölge)


Şekil 30’da yaprak delen hastalığının kayısı yaprağında oluşturduğu hasar, uzman değerlendirmesine göre %35 olarak belirlenmiştir. Oluşan bu hasar yapılan görüntü işleme sonucunda ise %37.85 olarak tespit edilmiştir. Sonuçların birbirine yakın değerler olduğu ve görüntü işleme ile daha hassas sonuçlar elde edildiği görülmektedir.



Şekil 30. Kayısı yaprak-5, (a: orijinal görüntü, b: hastalıklı bölge ve c: sağlıklı bölge)


4.2. Kayısı meyve sonuçları

Şekil 31’de yaprak delen hastalığının kayısı meyvesinde oluşturduğu hasar, uzman değerlendirmesine göre %5 olarak belirlenmiştir. Oluşan bu hasar yapılan görüntü işleme sonucunda ise %6.38 olarak tespit edilmiştir. Uzman değerlendirmesinin görüntü işleme ile elde edilen değere yakın tam sayılar olduğu görülmektedir.




Şekil 31. Kayısı meyve-1, (a: orijinal görüntü, b: hastalıklı bölge ve c: sağlıklı bölge)

Şekil 32’de yaprak delen hastalığının kayısı meyvesinde oluşturduğu hasar, uzman değerlendirmesine göre %30 olarak belirlenmiştir. Oluşan bu hasar yapılan görüntü işleme sonucunda ise %30.70 olarak tespit edilmiştir. Sonuçların birbirine çok yakın değerler olduğu ve görüntü işleme ile daha hassas sonuç elde edildiği görülmektedir.




Şekil 32. Kayısı meyve-2, (a: orijinal görüntü, b: hastalıklı bölge ve c: sağlıklı bölge)

Şekil 33'de yaprak delen hastalığının kayısı meyvesinde oluşturduğu hasar, uzman değerlendirmesine göre %60 olarak belirlenmiştir. Oluşan bu hasar yapılan görüntü işleme sonucunda ise %60.73 olarak tespit edilmiştir. Sonuçların birbirine çok yakın değerler olduğu ve görüntü işleme ile elde edilen sonuçlardaki hassasiyetin uzman değerlendirmesi ile belirlenemeyeceği görülmektedir.




Şekil 33. Kayısı meyve-3, (a: orijinal görüntü, b: hastalıklı bölge ve c: sağlıklı bölge)

Şekil 34'de yaprak delen hastalığının kayısı meyvesinde oluşturduğu hasar, uzman değerlendirmesine göre %85 olarak belirlenmiştir. Oluşan bu hasar yapılan görüntü işleme sonucunda ise %87.58 olarak tespit edilmiştir. Elde edilen sonuçlara göre görüntü işlemenin daha hassas sonuçlar verdiği görülmektedir.



Şekil 34. Kayısı meyve-4, (a: orijinal görüntü, b: hastalıklı bölge ve c: sağlıklı bölge)


Şekil 35’de yaprak delen hastalığının kayısı meyvesinde oluşturduğu hasar, uzman değerlendirmesine göre %95 olarak belirlenmiştir. Oluşan bu hasar yapılan görüntü işleme sonucunda ise %90.02 olarak tespit edilmiştir. Uzman değerlendirmesinin hassasiyetinin görüntü işleme hassasiyetinde olmadığı görülmektedir.



Şekil 35. Kayısı meyve-5, (a: orijinal görüntü, b: hastalıklı bölge ve c: sağlıklı bölge)


4.3. Kiraz sonuçları

Şekil 36’da yaprak delen hastalığının kiraz yaprağında oluşturduğu hasar, uzman değerlendirmesine göre %3 olarak belirlenmiştir. Oluşan bu hasar yapılan görüntü işleme sonucunda ise %4.87 olarak tespit edilmiştir. Uzman değerlendirmesinin görüntü işleme ile elde edilen değere yakın tam sayılar olduğu görülmektedir.




Şekil 36. Kiraz yaprak-1, (a: orijinal görüntü, b: hastalıklı bölge ve c: sağlıklı bölge)

Şekil 37’de yaprak delen hastalığının kiraz yaprağında oluşturduğu hasar, uzman değerlendirmesine göre %5 olarak belirlenmiştir. Oluşan bu hasar yapılan görüntü işleme sonucunda ise %4.12 olarak tespit edilmiştir. Bu sonuçlara göre görüntü işlemenin daha hassas sonuçlar verdiği görülmektedir.




Şekil 37. Kiraz yaprak-2, (a: orijinal görüntü, b: hastalıklı bölge ve c: sağlıklı bölge)

Şekil 38’de yaprak delen hastalığının kiraz yaprağında oluşturduğu hasar, uzman değerlendirmesine göre %9 olarak belirlenmiştir. Oluşan bu hasar yapılan görüntü işleme sonucunda ise %7.63 olarak tespit edilmiştir. Sonuçlar birbirine çok yakın değerlerdir. Görüntü işleme ile elde edilen sonuçlardaki hassasiyetin uzman değerlendirmesi ile belirlenemeyeceği görülmektedir.




Şekil 38. Kiraz yaprak-3, (a: orijinal görüntü, b: hastalıklı bölge ve c: sağlıklı bölge)

Şekil 39’da yaprak delen hastalığının kiraz yaprağında oluşturduğu hasar, uzman değerlendirmesine göre %15 olarak belirlenmiştir. Oluşan bu hasar yapılan görüntü işleme sonucunda ise %12.15 olarak tespit edilmiştir. Sonuçlar birbirine yakın değerlerdir.



Şekil 39. Kiraz yaprak-4, (a: orijinal görüntü, b: hastalıklı bölge ve c: sağlıklı bölge)


Şekil 40'da yaprak delen hastalığının kiraz yaprağında oluşturduğu hasar, uzman değerlendirmesine göre %30 olarak belirlenmiştir. Oluşan bu hasar yapılan görüntü işleme sonucunda ise %26.25 olarak tespit edilmiştir. Görüntü işleme sonuçlarındaki hassasiyet uzman değerlendirmesine göre daha fazladır.



Şekil 40. Kiraz yaprak-5, (a: orijinal görüntü, b: hastalıklı bölge ve c: sağlıklı bölge)


4.4. Şeftali sonuçları

Şekil 41'da yaprak delen hastalığının şeftali yaprağında oluşturduğu hasar, uzman değerlendirmesine göre %5 olarak belirlenmiştir. Oluşan bu hasar yapılan görüntü işleme sonucunda ise %5.59 olarak tespit edilmiştir. Görüntü işleme ile elde edilen sonuçlardaki hassasiyete uzman değerlendirmesi ile ulaşılmasının zor olduğu görülmektedir.




Şekil 41. Şeftali yaprak-1, (a: orijinal görüntü, b: hastalıklı bölge ve c: sağlıklı bölge)

Şekil 42'de yaprak delen hastalığının şeftali yaprağında oluşturduğu hasar, uzman değerlendirmesine göre %15 olarak belirlenmiştir. Oluşan bu hasar yapılan görüntü işleme sonucunda ise %13.51 olarak tespit edilmiştir. Sonuçların birbirine yakın değerler olduğu ve görüntü işleme ile daha hassas sonuç elde edildiği görülmektedir.




Şekil 42. Şeftali yaprak-2, (a: orijinal görüntü, b: hastalıklı bölge ve c: sağlıklı bölge)

Şekil 43’de yaprak delen hastalığının şeftali yaprağında oluşturduğu hasar, uzman değerlendirmesine göre %10 olarak belirlenmiştir. Oluşan bu hasar yapılan görüntü işleme sonucunda ise %9.83 olarak tespit edilmiştir. Sonuçların birbirine çok yakın değerler olduğu ve uzman değerlendirmesi ile bu hassasiyette sonuç elde edilmesinin zor olduğu görülmektedir.




Şekil 43. Şeftali yaprak-3, (a: orijinal görüntü, b: hastalıklı bölge ve c: sağlıklı bölge)

Şekil 44’de yaprak delen hastalığının şeftali yaprağında oluşturduğu hasar, uzman değerlendirmesine göre %20 olarak belirlenmiştir. Oluşan bu hasar yapılan görüntü işleme sonucunda ise %18.77 olarak tespit edilmiştir. Sonuçları benzer şekilde yakın değerler olduğu görülmektedir.



Şekil 44. Şeftali yaprak-4, (a: orijinal görüntü, b: hastalıklı bölge ve c: sağlıklı bölge)


Şekil 45’de yaprak delen hastalığının şeftali yaprağında oluşturduğu hasar, uzman değerlendirmesine göre %30 olarak belirlenmiştir. Oluşan bu hasar yapılan görüntü işleme sonucunda ise %26.93 olarak tespit edilmiştir. Uzman değerlendirmesinin görüntü işleme ile elde edilen değere yakın tam sayılar olduğu görülmektedir.



Şekil 45. Şeftali yaprak-5, (a: orijinal görüntü, b: hastalıklı bölge ve c: sağlıklı bölge)


4.5. İstatiksel analiz sonuçları

Verilerin normallik varsayımı için Kolmogorov-Smirnov testi kullanılmış ve verilerin normal dağılım gösterdiği tespit edilmiştir ($p > 0.05$). Görüntü İşleme sonuçları ile uzman değerlendirmeleri arasındaki regresyon katsayısı ($R^2 = 0.941$, $p < 0.01$) ve pearson korelasyon katsayısı ise ($r = 0.970$, $p < 0.01$) olarak bulunmuştur (Şekil 46). Paired sample t-testi sonuçlarına göre, 0.00 olan P değeri 0.05'ten küçüktür, bu da boş hipotezin reddedildiği anlamına gelmektedir. Dolayısıyla testin sonucu, gözlemlenen ve görüntü işlemeyle tahmin edilen değerler arasında anlamlı bir fark olduğu belirlenmiştir. Görüntü işleme yöntemi hastalık seviyelerini 3.42 RMSE ve Theil UII'si 0.2764 ile tahmin edilmiştir.



Şekil 46. Edinilen görüntülerdeki yaprak delen hastalığının şiddetinin kayısı yaprak için gözlem ve görüntü işleme arasındaki ilişki

Verilerin normallik varsayımı için Kolmogorov-Smirnov testi kullanılmış ve verilerin normal dağılım gösterdiği tespit edilmiştir ($p > 0.05$). Görüntü İşleme sonuçları ile uzman değerlendirmeleri arasındaki regresyon katsayısı ($R^2 = 0.992$, $p < 0.01$) ve pearson korelasyon katsayısı ise ($r = 0.996$, $p < 0.01$) olarak bulunmuştur (Şekil 47).




Şekil 47. Edinilen görüntülerdeki yaprak delen hastalığının şiddetinin kayısı meyve için gözlem ve görüntü işleme arasındaki ilişki

Paired sample t-testi sonuçlarına göre, 0.03 olan P değeri 0.05'ten küçüktür. Bu da boş hipotezin reddedildiği anlamına gelmektedir. Dolayısıyla testin sonucu, gözlemlenen ve görüntü

işlemeyle tahmin edilen değerler arasında anlamlı bir fark olduğu belirlenmiştir. Görüntü işleme yöntemi hastalık seviyeleri 2.73 RMSE ve Theil UII'si 0.0600 ile tahmin edilmiştir.


Verilerin normallik varsayımı için Kolmogorov-Smirnov testi kullanılmış ve verilerin normal dağılım gösterdiği tespit edilmiştir ($p>0.05$). Görüntü İşleme sonuçları ile uzman görüşleri arasındaki regresyon katsayısı ($R^2 = 0.914$, $p<0.01$) ve pearson korelasyon katsayısı ise ($r = 0.956$, $p<0.01$) olarak bulunmuştur (Şekil 48).



Şekil 48. Edinilen görüntülerdeki yaprak delen hastalığının şiddetinin kiraz için gözlem ve görüntü işleme arasındaki ilişki

Paired sample t-testi sonuçlarına göre, 0.00 olan P değeri 0.05'ten küçüktür. Bu da boş hipotezin reddedildiği anlamına gelmektedir. Dolayısıyla testin sonucu, gözlemlenen ve görüntü işlemeyle tahmin edilen değerler arasında anlamlı bir fark olduğu kanıtlanmıştır. Görüntü işleme yöntemi hastalık seviyelerini 2.64 RMSE ve Theil UII'si 0.2881 ile tahmin etmiştir.


Verilerin normallik varsayımı için Kolmogorov-Smirnov testi kullanılmış ve verilerin normal dağılım gösterdiği tespit edilmiştir ($p>0.05$). Görüntü İşleme sonuçları ile uzman değerlendirmeleri arasındaki regresyon katsayısı ($R^2 = 0.864$, $p<0.01$) ve pearson korelasyon katsayısı ise ($r = 0.930$, $p<0.01$) olarak bulunmuştur (Şekil 49).



Şekil 49. Edinilen görüntülerdeki yaprak delen hastalığının şiddetinin şeftali için gözlem ve görüntü işleme arasındaki ilişki

Paired sample t-testi sonuçlarına göre, 0.00 olan P değeri 0.05'ten küçüktür. Bu da boş hipotezin reddedildiği anlamına gelmektedir. Bu nedenle testin sonucu, gözlemlenen ve görüntü işlemeyle tahmin edilen değerler arasında anlamlı bir fark olduğu belirlenmiştir. Görüntü işleme yöntemi hastalık seviyelerini 2.59 RMSE ve Theil UII'si 0.2329 ile tahmin etmiştir.

Verilerin analizi için SPSS yazılımı kullanılmıştır. Verilerin normallik varsayımı için Kolmogorov-Smirnov testi kullanılmış ve verilerin normal dağılım gösterdiği tespit edilmiştir ($p > 0.05$). Görüntü İşleme sonuçları ile uzman görüşleri arasındaki regresyon katsayısı ($R^2 = 0.986$, $p < 0.01$) ve pearson korelasyon katsayısı ise ($r = 0.993$, $p < 0.01$) olarak bulunmuştur (Şekil 50). İki yöntem arasındaki bu ilişkinin istatistiki olarak önemli olması, hastalık hasar şiddeti seviyesinin belirlenmesinde uzman görüşüne alternatif olarak oluşturulan görüntü işleme yönteminin kullanılabileceğini göstermektedir.



Şekil 50. Edinilen görüntülerdeki yaprak delen hastalığının şiddetinin tüm görüntüler için gözlem ve görüntü işleme arasındaki ilişki

Paired sample t-testi sonuçlarına göre, 0.00 olan P değeri 0.05'ten küçüktür. Bu sonuç boş hipotezin reddedildiği anlamına gelmektedir. Bu nedenle testin sonucu, gözlemlenen ve görüntü işlemeyle tahmin edilen değerler arasında anlamlı bir fark olduğu belirlenmiştir. Görüntü işleme yöntemi hastalık seviyelerini 2.86 RMSE ve Theil UII'si 0.1164 ile tahmin etmiştir. Bu tahmin başarısı yüksek olup değerler sıfıra yakındır. Bu sonuçlar, hastalığın seviyesinin belirlenmesinde görüntü işleme tekniğinin kullanılmasının bitki koruma uzmanlarına yardımcı veya destek olabileceğini göstermiştir.

5. SONUÇ

Görüntü işleme teknikleri kullanılarak yaprak delen hastalığının kayısı meyve ve yaprakları, kiraz ve şeftali yaprakları üzerindeki hasar düzeyinin belirlenmesi amacıyla yapılan bu çalışmada, normallik testi için Kolmogorov-Smirnov testi kullanılmış ve verilerin normal dağılım gösterdiği tespit edilmiştir. Yapılan değerlendirme sonucunda, toplam 200 görüntü için genel sonuçlar, görüntü işleme yöntemiyle hastalık seviyelerinin 2.86 RMSE ve Theil UII'si 0.1164 ile tahmin edildiğini göstermiştir. Bu sonuçlar incelendiğinde, geliştirilen görüntü işleme algoritması ile belirlenen hastalık hasar şiddetinin uzman değerlendirmelerine güvenilir bir alternatif olarak kullanılabileceği sonucuna varılmıştır.

Ülkemizde birçok hastalık ve zararlı bulunmaktadır. Verim ve kaliteli ürün elde edebilmek için hastalıklar ve zararlılarla mücadele mutlaka yapılmalıdır. Ancak, zamansız ve gereksiz ilaç kullanımı doğal dengeyi bozmakta ve insan sağlığına zarar vermektedir. Bu durum, ürünlerde kalite ve verim kayıplarına yol açmaktadır. Bu nedenle, hastalıkların erken veya başlangıç aşamasında teşhisi ve tanısı büyük önem taşımaktadır. Yürütülen bu çalışma, çözüm bekleyen bu sorunlara alternatif bir çözüm sunabilecektir. Aynı zamanda çalışmada uygulanan yöntem sayesinde, gelecekte otonom robotlar ve dronelar aracılığıyla tarımsal alanlarda hastalık ve zararlıların erken tespiti gerçekleştirilebilecektir. Çalışmanın elde ettiği sonuçların topluma çeşitli yararlar sağlayabileceği de düşünülmektedir. Bunlar:

Bilim Açısından: Görüntü işleme teknikleri, bitki hastalıklarının erken tespitinde kritik bir rol oynamaktadır. Tarımsal faaliyetlerde bu tekniklerin uygulanmaya başlanmasıyla birlikte çeşitli alanlarda önemli çalışmalar gerçekleştirilmektedir. Bu çalışmalar sırasında kazanılan deneyimler, makine öğrenmesi, derin öğrenme, yapay zekâ, modelleme ve simülasyon uygulamalarının geliştirilmesine katkı sağlamaktadır. Bu teknikleri kullanacak araştırmacıların, gelecekte farklı bitki hastalıkları üzerine yapacakları çalışmalara rehberlik edeceği ve yeni araştırma konularına öncülük edeceği öngörülmektedir.

Çiftçi/Üretici Açısından: Toprağın birinci derecede faydalanıcıları, onu işleyip üzerinde üretim yapan çiftçiler ve üreticilerdir. Bitki hastalıkları, üreticinin verimini düşüreceği için öncelikle onları olumsuz etkilemektedir. Bu olumsuz etkileri önlemek için, erken uyarı sistemlerinin geliştirilmesiyle gerekli tedbirler zamanında alınabilecektir. Böylelikle, üreticiler verim kaybına uğramadan olumsuz etkilerden korunabileceklerdir.

Sanayi Açısından: Bitki hastalıkları ile mücadelede en yaygın yöntem kimyasal ilaç kullanımınıdır. Ancak, ilaçların zamanında ve doğru şekilde uygulanmaması bitkilere ve çevreye zarar vererek doğal dengeyi bozabilir ve insan sağlığını tehdit edebilmektedir. Bu sorunları önlemek için, ilaçların doğru zamanda ve doğru yerlere uygulanması büyük önem taşımaktadır.

Ülke Ekonomisi Açısından: Tarım ürünleri fiyatlarının giderek arttığı günümüz ekonomisinde, verimli ve kaliteli üretim yapmak ülke ekonomisine önemli katkılar sağlayacaktır. Verimlilik ve kalite artışı, hem iç piyasada hem de ihracatta ekonomik büyümeye destek olacaktır.



6. KAYNAKLAR

- Ağın, O. ve Malaslı, M.Z., 2016. Görüntü işleme tekniklerinin sürdürülebilir tarımdaki yeri ve önemi: Literatür çalışması. Tarım Makinaları Bilimi Dergisi (Journal of Agricultural Machinery Science), 12(3), 199-206.
- Altaş, Z., Özgüven, M.M. ve Yanar, Y., 2019. Bitki hastalık ve zararlı düzeylerinin belirlenmesinde görüntü işleme tekniklerinin kullanımı: Şeker Pancarı Yaprak Leke Hastalığı Örneği. International Erciyes Agriculture, Animal & Food Sciences Conference 24-27 April 2019- Erciyes University- Kayseri/Türkiye.
- Altas, Z., Ozguven M.M. ve 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, Doi: 10.32474/CIACR.2018.05.000214.
- Altaş, Z., Özgüven, M.M. ve Dilmaç, M., 2021. Görüntü işleme teknikleri ile bağ yaprak uyuzu hasarının belirlenmesi. Gaziosmanpaşa Bilimsel Araştırma Dergisi (Gbad). 10 (3), 77-87.
- Anonim, 2022a. Ziraî mücadele teknik talimatları cilt 4. Gıda Tarım ve Hayvancılık Bakanlığı, Tarımsal Araştırmalar ve Politikalar Genel Müdürlüğü, Bitki Sağlığı Araştırma Daire Başkanlığı, 2008.
- Anonim, 2022b. <https://bilgihanem.com/kiraz-nedir/> Erişilme Tarihi (25.09.2022).
- Anonim, 2022c. Kiraz ve vişne entegre mücadele teknik talimatı. Gıda Tarım ve Hayvancılık Bakanlığı, Tarımsal Araştırmalar ve Politikalar Genel Müdürlüğü, Gıda ve Kontrol Genel Müdürlüğü, 2017.
- Anonim, 2022d. <https://bilgihanem.com/seftali-nedir/> Erişilme Tarihi (25.09.2022).
- Anonim, 2022e. Şeftali ve nektarin entegre mücadele teknik talimatı. Gıda Tarım ve Hayvancılık Bakanlığı, Tarımsal Araştırmalar ve Politikalar Genel Müdürlüğü, Gıda ve Kontrol Genel Müdürlüğü, 2017.
- Anonim, 2022f. <https://www.entofito.com/yaprak-delen-cil-hastaligi/> Erişilme Tarihi (25.09.2022).
- Avelino, J., Cristancho, M., Georgiou, S., Imbach, P., Aguilar, L. ve Bornemann, G., 2015. The coffee rust crises in Colombia and Central America (2008–2013): impacts, plausible causes and proposed solutions. Food Security. 7(2), 303–21.
- Barbedo, J.G.A., 2014. An automatic method to detect and measure leaf disease symptoms using digital image processing. Plant Disease 98(12), 1709–1716. doi:10.1094/pdis-03-14-0290-re.
- Başkaya, Z., 2009. Türkiye’de kiraz tarımının coğrafi esasları. Doğu Coğrafya Dergisi, 26(26), 45–72.
- Bliem F., 1973. Theil's forecast accuracy coefficient: A Clarification. J Market Res Vol. 10(4),444–446.
- Chai T. ve Draxler RR., 2014. Root mean square error (RMSE) or mean absolute error (MAE)? -Arguments against avoiding RMSE in the literature. Geosci Model Dev 7:1247–1250. <https://doi.org/10.5194/gmd-7-1247-2014>.
- Chaudhar, P., Chaudhari, A.K., Cheeran, A.N. ve Godara, S., 2012. Color Transform Based Approach for Disease Spot Detection on Plant Leaf. International Journal of Computer Science and Telecommunications 3(6), 65-70.
- Çayıroğlu, İ., 2024. Görüntü işleme. Karabük Üniversitesi, Mühendislik Fakültesi, Ders Notları. (Erişim Tarihi: 30.04.2024).
- Demir, B., Çetin, N. ve Kuş, Z.A., 2016. Görüntü işleme tekniği ile yabancı ot renk özelliklerinin belirlenmesi. Alinteri, 31 (B), – 59 – 64, ISSN:1307-3311.

- Deng, L., Wang, Z., Wang, C., He, Y., Huang, T., Dong, Y. ve Zhang, X., 2020. Application of agricultural insect pest detection and control map based on image processing analysis. *Journal of Intelligent & Fuzzy Systems* 38(1), 379–389. doi:10.3233/jifs-179413.
- Duru, S., Hayran, S. ve Gül, A., 2022. Production of stone fruit in turkey and evaluation of competitiveness power on export. *Bahçe*, 51(1), 29–36. doi:10.53471/bahce.1019023.
- FAO, 2024. Food and agriculture organization of the united nations. FAOSTAT. <https://www.fao.org/faostat/en/#data/QCL/visualize> (Erişim Tarihi: 27.04.2024).
- Gonzalez, R.C., Woods, R.E. ve Eddins, S.L., 2004. Digital image processing using MATLAB. Dorling Kindersley, 2004.
- Gonzalez, R.C. ve Woods, R.E., 2008. Digital image processing. Pearson Prentice Hall, USA, ISBN: 0-13-168728-8.
- Gonzalez, R.C., Woods, R.E. ve Eddins, S.L., 2009. Digital image processing using MATLAB. Gatesmark Publishing, USA. ISBN: 978-0-9820854-0-0.
- Göğçe, M., Turgut, K. ve Hocaoglu, A.K., 2021. Yaprakta leke tespiti spot detection on leaves. 978-1-6654-3649-6/21/\$31.00 © 2021 IEEE.
- He, Q., Ma, B., Qu, D., Zhang, Q., Hou, X. ve Zhao, J., 2013. Cotton pests and diseases detection based on image Processing. *Telkomnika* 11(6). doi:10.11591/telkomnika.v11i6.2721.
- Hosseini, H., MohammadZamani, D., Javidan, S.M. ve Arbab, A., 2023. Identify fungal diseases of cucumber (Powdery Mildew and Anthracnose) using image processing and artificial neural network approach. doi:10.21203/rs.3.rs-2513372/v1.
- Hussin, R., Juhari, M.R., Kang, N.W., Ismail, R.C. ve Kamarudin, A., 2012. Digital image processing techniques for object detection from complex background image. *Procedia Engineering*, vol:41, pp:340-344.
- Ihsan, I., Hidayat, E.W. ve Rahmatulloh, A., 2020. Identification of bacterial leaf blight and brown spot disease in rice plants with image processing approach. *JITEKI: Jurnal Ilmiah Teknik Elektro Komputer Dan Informatika* 5 2, 59. doi:10.26555/jiteki.v5i2.14136.
- İncekara, H. ve Selek, M., 2020. Görüntü işleme yöntemleri kullanılarak kiraz meyvesinin sınıflandırılması. *European Journal of Science and Technology*. doi:10.31590/ejosat.801942.
- Jähne, B., 2005. Digital image processing. Springer-Verlag, Berlin Heidelberg. ISBN: 978-3-540-24035-8.
- Karhan, M., 2011. İmge işleme yöntemleri ile kayıslarda yaprak delen hastalığı sonucu oluşan lekelerin tespiti. Namık Kemal Üniversitesi. Fen Bilimleri Enstitüsü. (Yüksek lisans tezi).
- Kasa, S.R. ve Rajan, V., 2023. Avoiding inferior clusterings with misspecified Gaussian mixture models. *Scientific Reports* 13 1. doi:10.1038/s41598-023-44608-3.
- Kaur, I., Aggarwal, G. ve Verma, A., 2016. Detection and classification of disease affected region of plant leaves using image processing technique. *Indian Journal of Science and Technology* 9 48. doi:10.17485/ijst/2016/v9i48/104765.
- Khojastehnazhand, M., Mohammadi, V. ve Minaei, S., 2019. Maturity detection and volume estimation of apricot using image processing technique. *Scientia Horticulturae* 251 (2019) 247–251.
- Lee PH., 2014. Is the cutoff of 10% appropriate for the change-in-estimate confounder identification criterion? *J Epidemiol* 24:161–167.
- Manganaris, G.A. ve Crisosto, C.H., 2020. Stone fruits: Peaches, nectarines, plums, apricots. In *Controlled and Modified Atmospheres for Fresh and Fresh-Cut Produce* (pp:311-322). Academic Press.
- Marques, O., 2011. Practical image and video processing using MATLAB. John Willey & Sons, Inc, Hoboken. ISBN: 978-0-470-04815-3.

- MathWorks, 2008. MATLAB for image processing. The MathWorks Training Services. By The MathWorks, Inc.
- Meyyappan, S. ve Chandramouleeswaran S., 2018. Plant infection detection using image processing. International Journal Of Modern Engineering Research (IJMER).
- Oo, Y.M. ve Htun, N.C., 2018. Plant leaf disease detection and classification using image processing. International Journal of Research and Engineering 5(9), 516–523. doi:10.21276/ijre.2018.5.9.4.
- Ozguven, M.M., 2018. The newest agricultural technologies, Current Investigations in Agriculture and Current Research, 5(1), 573-580. Doi: 10.32474/CIACR.2018.05.000201.
- Ozguven, M.M., Altas, Z., 2022. A new approach to detect mildew disease on cucumber (*Pseudoperonospora cubensis*) leaves with image processing. Journal of Plant Pathology 104 4, 1397–1406. doi:10.1007/s42161-022-01178-z.
- Ozguven, M.M. ve Yanar, Y., 2022. The technology uses in the determination of sugar beet diseases. Sugar Beet Cultivation, Management and Processing. (Editors: Misra, V., Santeshwari and Mall, A.K.) Springer, Singapore, 621-642.
- Ozguven, M. M., 2023. The digital age in agriculture. CRC Press Taylor & Francis Group LLC. ISBN 978-103-23-8577-8.
- Özcan, M., 2020. Ürün muhafazası ve pazarlama ders notu. T.C. Ondokuz Mayıs Üniversitesi Ziraat Fakültesi Bahçe Bitkileri Bölümü. 100s.
- Patel, E., Kushwaha, D.S., 2020. Clustering Cloud Workloads: K-Means vs Gaussian Mixture Model. Procedia Computer Science 171, 158–167. doi:10.1016/j.procs.2020.04.017.
- Samson, J.A., 1980. Tropical Fruits Tropical Agriculture Series. Longman Group Limited ISBN 0-582-46032-8, ABD.
- Savary, S. ve Willocquet, L., 2014. Simulation modeling in botanical epidemiology and crop loss analysis. The Plant Health Instructor. 173 p.
- Singh, V., 2019. Sunflower leaf diseases detection using image segmentation based on particle swarm optimization. Artificial Intelligence in Agriculture 3, 62–68. doi:10.1016/j.aiia.2019.09.002.
- Solak, S. ve Altınışık, U., 2018. Görüntü işleme teknikleri ve kümeleme yöntemleri kullanılarak fındık meyvesinin tespit ve sınıflandırılması. SAÜ Fen Bilimleri Enstitüsü Dergisi 1–1. doi:10.16984/saufenbilder.303850.
- Sonka, M., Hlavac V. ve Boyle, R., 2013. Image processing, analysis, and machine vision. Cengage Learning; 4th ed. ISBN: 978-1133593607.
- Storey, W.B., 1969. Recent developments in tropical fruit crops. Proc. Fla. State Hort. Soc., 82, 333-9, Miami, ABD.
- Szeliski, R., 2022. Computer vision algorithms and applications. Springer Cham, ISBN: 978-3-030-34371-2.
- Tan, P.N., Steinbach, M. ve Kumar, V., 2006. Cluster analysis: basic concepts and algorithms. Introduction to data mining, 8 (pp.487-568).
- TÜİK, 2024. Türkiye istatistik kurumu. <https://data.tuik.gov.tr/Kategori/GetKategori?p=tarim-111&dil=1>. (Erişim Tarihi: 27.04.2024).
- Tyagi, V., 2018. Understanding Digital image processing. CRC Press Taylor & Francis Group LLC, Boca Raton. ISBN: 978-1-138-56684-2.
- Uygun, T., Ozguven, M.M. ve Yanar, D., 2020. A new approach to monitor and assess the damage caused by two-spotted spider mite. Experimental and Applied Acarology 82(3), 335–346. doi:10.1007/s10493-020-00561-8.
- Weber, C.M., Ray, D., Valverde, A.A., Clark, J.A. ve Sharma, K.S., 2022. Gaussian mixture model clustering algorithms for the analysis of high-precision mass measurements. Nuclear Instruments and Methods in Physics Research. Section a, Accelerators,

- Spectrometers, Detectors and Associated Equipment/Nuclear Instruments & Methods in Physics Research. Section a, Accelerators, Spectrometers, Detectors and Associated Equipment 1027, 166299. doi:10.1016/j.nima.2021.166299.
- Willmott C.J. ve Matsuura C., 2005. Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance. *Climate Res* 30(1),79–82.
- Veling, Prof.S., 2019. Mango disease detection by using image processing. *International Journal for Research in Applied Science and Engineering Technology* 7(4), 3717–3726. doi:10.22214/ijraset.2019.4624.
- Zhang, S., Wu, X., You, Z. ve Zhang, L., 2017. Leaf image based cucumber disease recognition using sparse representation classification. *Computers and Electronics in Agriculture* 134, 135–141. doi:10.1016/j.compag.2017.01.014.



7. ÖZGEÇMİŞ

