



T.C.

TOKAT GAZİOSMANPAŞA ÜNİVERSİTESİ

LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

BİYOSİSTEM MÜHENDİSLİĞİ ANABİLİM DALI

YÜKSEK LİSANS TEZİ

Görüntü İşleme Yöntemiyle Üzüm Veriminin Belirlenmesi

YÜKSEK LİSANS TEZİ

Mihriban DOĞAN

Danışman: Doç. Dr. Mehmet Metin ÖZGÜVEN

TOKAT-2023

ETİK SÖZLEŞME

Tokat Gaziosmanpaşa Üniversitesi Lisansüstü Eğitim Enstitüsü tez yazım kılavuzuna göre, Doç. Dr. Mehmet Metin ÖZGÜVEN danışmanlığında hazırlamış olduğum “Görüntü İşleme Yöntemiyle Üzüm Veriminin 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.

01/08/2023

Mihriban DOĞAN

JÜRİ KABUL VE ONAY



ÖNSÖZ

Tez çalışmamda görüntü işleme yöntemiyle üzüm veriminin belirlenmesine değinilmiştir. Bu çalışmamda değerli bilgilerini benimle paylaşan, kendisine ne zaman danışsam bana kıymetli zamanını ayırıp sabırla ve büyük bir ilgiyle bana faydalı olabilmek için elinden geleni yapan ve manevi destek sağlayan danışman hocam Sayın Doç. Dr. Mehmet Metin ÖZGÜVEN'e teşekkürü bir borç bilirim. Çalışmamda bana yardımlarını esirgemeyen, her saat ulaşabildiğim, bilgi ve desteğini her zaman hissettiğim Sayın Dr. Ziya ALTAŞ ve Sayın Biyosistem Yük. Müh. Tahsin UYGUN ile Tez Değerlendirme Jüri hocalarım olarak katkı sağlayan Sayın Prof. Dr. Engin ÖZGÖZ ve Sayın Doç. Dr. Necati ÇETİN hocalarıma teşekkürlerimi sunarım.

MİHRİBAN DOĞAN

1 Ağustos 2023

ÖZET

GÖRÜNTÜ İŞLEME YÖNTEMİYLE ÜZÜM VERİMİNİN BELİRLENMESİ

Mihriban DOĞAN

Yüksek Lisans, Biyosistem Mühendisliği Anabilim Dalı

Tez Danışmanı: Doç. Dr. Mehmet Metin ÖZGÜVEN

Ağustos 2023, xlv + 44 sayfa

Bu çalışmada, görüntü işleme teknikleri kullanılarak Michele Palieri, İtalya ve Mevlana üzüm çeşitlerinde verimin belirlenmesi amaçlanmıştır. Tez çalışması, Tokat Gaziosmanpaşa Üniversitesi Tarımsal Uygulama ve Araştırma Merkezi bünyesindeki bağ alanında yürütülmüştür. Üzüm veriminin tahmin edilebilmesi için üzümün olgunlaşmasıyla, hasat edilmeden önce görüntüler alınmıştır. Alınan görüntülerden 267 adet görüntü MATLAB Image Processing Toolbox modülü kullanılarak görüntü işleme ile işlenmiştir. Çalışma sonucunda, Michele Palieri, İtalya ve Mevlana üzüm çeşitleri için RMSE tahmin değerleri sırasıyla 4.86, 4.00 ve 2.88 olarak bulunmuştur. 3 üzüm çeşidinin toplam RMSE değeri ($R^2 > 0.9989$) olarak bulunmuştur. Uygulanan yöntem ve algoritma ile çeşitler üzerindeki verim tahminleri başarılı bir şekilde yapılmıştır. Bu çalışmadan elde edilen yöntem geliştirilerek ileriki çalışmalarda makine, sistem veya robotlara entegre edilerek insan işgücünden, zamandan ve ekonomik tasarruf sağlanabilir.

Anahtar Kelimeler: Görüntü İşleme, Bağ, Üzüm, Verim Tahmini

ABSTRACT
DETERMINATION OF GRAPE PRODUCTION BY IMAGE PROCESSING METHOD

Mihriban DOĞAN

Master's Thesis, Division of Biosystems Engineering

Advisor: Assoc. Prof. Dr. Mehmet Metin ÖZGÜVEN

August 2023, xlv + 44 pages

In this study, it was aimed to determine the yield of Michele Palieri, Italy and Mevlana grape varieties by using image processing techniques. The thesis study was carried out in the vineyard area of Tokat Gaziosmanpaşa University Agricultural Application and Research Center. In order to predict the grape yield, images were taken as the grapes matured and before they were harvested. 267 images from the captured images were processed with image processing using the MATLAB Image Processing Toolbox module. As a result of the study, RMSE estimation values for Michele Palieri, Italy and Mevlana grape varieties were found as 4.86, 4.00 and 2.88, respectively. The total RMSE value of 3 grape cultivars was found as ($R^2 > 0.9989$). Yield estimations on the cultivars were made successfully with the applied method and algorithm. Methods from this study will be studied in future studies. By integrating with machines, systems or robots, human labor, time and economic savings can be achieved.

Keywords: Image Processing, Vineyard, Grape, Yield Estimation

İÇİNDEKİLER

Sayfa

ETİK SÖZLEŞME	i
JÜRİ KABUL VE ONAY	ii
ÖNSÖZ.....	iii
ÖZET	iv
ABSTRACT	v
İÇİNDEKİLER.....	vi
ÇİZELGELER LİSTESİ	vii
ŞEKİLLER LİSTESİ.....	viii
KISALTMALAR VE SİMGELER LİSTESİ	ix
1. GİRİŞ	1
2. KAYNAK ÖZETLERİ	9
3. MATERYAL ve YÖNTEM.....	15
3.1. Materyal.....	15
3.1.1. Araştırma alanları	15
3.1.2. Çalışmada kullanılan cihazlar.....	16
3.1.3. MATLAB	17
3.1.4. Çalışmada kullanılan üzüm çeşitleri.....	17
3.2. Yöntem	21
3.2.1. Veri toplama	21
3.2.2. Veri seti oluşturma	22
3.2.3. Algoritma geliştirme.....	22
3.2.4. Sonuçların değerlendirilmesi.....	26
4. BULGULAR	27
5. SONUÇ	39
6. KAYNAKLAR.....	41
7. ÖZGEÇMİŞ	44

ÇİZELGELER LİSTESİ

Sayfa

Çizelge 1.1. 2010-2022 yılları arası Türkiye’de toplam üzüm üretimi ve çeşit tablosu	3
Çizelge 4.1. Michele Palieri üzüm çeşidi için sonuçlar	27
Çizelge 4.2. İtalya üzüm çeşidi için sonuçlar	30
Çizelge 4.3. Mevlana üzüm çeşidi için sonuçlar	33



ŞEKİLLER LİSTESİ

Sayfa

Şekil 1.1. Görüntü işlemede kullanılan temel adımlar	5
Şekil 1.2. Gri renkli görüntünün matrislerden oluşumu	5
Şekil 1.3. Dijital görüntü çeşitleri	7
Şekil 3.1. Araştırma alanı	15
Şekil 3.2. Çalışmanın yürütüldüğü bağ alanı	15
Şekil 3.3. GoPro Hero 7 Black kamera	16
Şekil 3.4. Hassas tartı	17
Şekil 3.5. Michele Palieri üzüm çeşidi	18
Şekil 3.6. İtalya üzüm çeşidi	19
Şekil 3.7. Mevlana üzüm çeşidi	19
Şekil 3.8. Omca ve salkımların numara verilerek etiketlenmiş hali.....	21
Şekil 3.9. Omca ve salkımları etiketleme.....	21
Şekil 3.10. Görüntü alma.....	22
Şekil 3.11. Orijinal görüntü.....	23
Şekil 3.12. Gri tonlamalı görüntü.....	23
Şekil 3.13. İkili (binary) görüntü.....	24
Şekil 3.14. Hasat zamanı hassas tartı ile üzüm ağırlıklarının tartımı.....	26
Şekil 4.1. Michele Palieri üzüm çeşidinin görüntü işlemeyle elde edilen ağırlık ile geleneksel tartım sonucu arasındaki ilişki.....	29
Şekil 4.2. İtalya üzüm çeşidinin görüntü işlemeyle elde edilen ağırlık ile geleneksel tartım sonucu arasındaki ilişki	33
Şekil 4.3. Mevlana üzüm çeşidinin görüntü işlemeyle elde edilen ağırlık ile geleneksel tartım sonucu arasındaki ilişki	35
Şekil 4.4. Görüntü işlemeyle elde edilen ağırlık ile geleneksel tartım sonucu arasındaki ilişki	36

KISALTMALAR

ATV: All-Terrain Vehicle, Araç

CNN Modeli: Evrişimli Sinir Ağı

DETR: Değerlendirme Zamanı ve Referans Noktası

DFNN: Derin ve Tam Bağlı Sinir Ağları

DR: Doğrusal Regresyon

ESA: Evrişimsel Sinir Ağları

Faster R-CNN: Daha Hızlı Bölge Konvolüsyonlu Ağ

GA: Genetik Algoritma

HSV: Renk Tonu, Doyma ve Parlaklık

IoU: Kesişim Üzeri Birleşim

İHA: İnsansız Hava Aracı

LSTM: Uzun Kısa Süreli Bellek

mAP: Ortalama Hassaslık Puanı

MATLAB: MATrix LABoratory

MSE: Ortalama Kare Hatası

RF: Rastgele Orman

RGB: Red, Green, Blue

RMSE: Kök Ortalama Kare Hatası

SSD: Tek Atış Çoklu Kutu Dedektörü

Swing Transformer: Salınım Dönüşümcü

SwinGD: Salınım Grafik Detektörü

YOLO: Sadece Bir Kez Bakılan Yer

YSA: Yapay Sinir Ağları

1. GİRİŞ

Günümüzde dünya nüfusunun hızlı bir şekilde artması, doğal kaynakların azalmasını hızlandırırken, sınırlı tarım alanlarının izlenmesi ve yönetimi, sağlıklı gıda teminini güvence altına almak için kritik bir rol oynamaktadır. Kaynak eksikliği ve sınırlı alanlar, sürdürülebilir tarımın ve verimliliğin zorluklarıdır (Yaşar, 2017). Bu nedenle, tarım alanlarının izlenmesi ve etkili yönetimi, üretimi artırmak ve gıda güvenliğini sağlamak için önemlidir. Teknolojik ilerlemeler ve uzaktan algılama yöntemleri, tarımın izlenmesi ve verimliliğinin artırılmasında önemli rol oynamaktadır (Yılmaz ve ark., 2018).

Tarımsal üretimin öncelikli hedefi, bitkisel ve hayvansal üretimde ekonomik, sürdürülebilir ve üretken işletmeciliğin sağlanmasıdır. Bu amaçla, tarımda verimliliğin ve ürün kalitesinin artırılması, minimum girdi kullanımı, gıda güvenilirliği, doğal kaynakların ve çevrenin korunması gibi çeşitli konularda teknoloji kullanılmasıyla, tarımsal işlemlerin kolaylaştırılması ve çözüm veya iyileştirme bekleyen sorunlara alternatif çözümler geliştirilmektedir (Ozguven, 2018). Bilginin elde edilmesi, işlenmesi, depolanması, aktarılması ve kullanılması süreçlerini yöneten teknolojik yöntem, model ve araçların, işlem ve hesaplama gücü yüksek, taşınabilir bilgisayarların ve donanımların piyasada kolay bulunabilir olmasıyla saha uygulamalarında kullanımı artmış ve kullanım sırasında elde edilen tecrübeye bağlı olarak da gelişme farklı alanlara da uygulanarak daha da hızlanmıştır (Özgüven ve ark., 2020).

Günümüzde bilgi teknolojilerindeki hızlı gelişim, tarımda geleneksel yöntemlerin yerine hassas tarım tekniklerinin kullanımına yol açmıştır. Geliştirilen donanım, algoritma ve yazılımların tarımda kullanımı, işletmecilik ve karar verme sürecinde önemli değişikliklere neden olmuştur. Tarımda mevcut bilgi ve tecrübelerin bilgi teknolojileriyle entegre edilmesi ile bitki görüntülerinden hastalıkları belirlemek, ürün verimini tahmin etmek en önemli araştırma alanlarından biri olmuştur (Özgüven, 2018).

Bağcılık, ekonomik büyüme ve tarımsal çeşitlilik açısından stratejik bir sektördür. Bağlar, tarım yapılamayan yamaçlarda kurulabildiği için bu alanların değerlendirilmesine ve erozyonun engellenmesine katkı sağlamaktadır. Bu nedenle bağcılık, yerel ekonomilerin canlanması ve sürdürülebilir kalkınma için çeşitli faydalı bulunmaktadır. Üzüm, esnek iklim ve toprak gereksinimlerine sahip olması ve çeşitli kullanım alanlarına yönelik uygun olması nedeniyle dünyada ve Türkiye'de yaygın olarak yetiştirilen kültür bitkilerinden biridir (Gözener ve ark., 2014; Semerci ve ark., 2015; Bashimov, 2017).

Bağcılıkta verimlilik, birim alanda bulunan omca sayısının yanı sıra, omca üzerinde meydana gelen salkım ve tanelerin sayısı ve büyüklüğü ile de yakından ilişkilidir. Bu verimlilik özellikleri, bağın kurulduğu yerin coğrafi konumu, rakımı, sıcaklık, yağış, nem ve güneşlenme süresi gibi iklim faktörlerine, üzüm çeşidinin genetik yapısına, kullanılan çeşit anaç ile yapılan kültürel uygulamalara göre değişiklik gösterebilmektedir. Dolayısıyla, bağcılık sektöründe verimlilik ve üretim kalitesinin artırılabilmesi için doğru tarım uygulamaları yapılmalı ve teknoloji kullanımı ile coğrafi faktörlere uygun üretim yapılmalıdır (Kılıç, 2021).

Sofralık üzüm, kurutmalık üzüm, şıralık üzüm ve şaraplık üzüm bulunmaktadır. Coğrafi bölgelere göre üretimde Ege Bölgesi birinci sırayı alırken, onu Akdeniz Bölgesi ikinci sırada takip etmektedir. Üçüncü sırayı ise Güneydoğu Anadolu Bölgesi almaktadır (Binici ve ark., 2021). Bölgelere göre yapılan incelemelerde, Ege Bölgesi çekirdeksiz kuru üzüm üretimine odaklanırken, Akdeniz Bölgesi ilk turfanda sofralık üzüm yetiştiriciliğine yönelmiştir. Marmara Bölgesi hem sofralık hem de şaraplık üzüm yetiştiriciliği için uygundur. İç Anadolu ve Güneydoğu Anadolu bölgeleri ise şaraplık, şıralık, sofralık ve tüketimlik kurutmalık üzüm üretiminde öncü bölgelerdir (Anonim, 2020a).

Türkiye İstatistik Kurumu'na (TÜİK) göre, 2022'de Türkiye'de yaklaşık 4.17 milyon ton üzüm üretilmiştir. Türkiye aynı zamanda önemli bir üzüm ihracatçısı konumunda olup başlıca ihracat yerleri Rusya, Irak ve Suudi Arabistan olarak karşımıza çıkmaktadır. Türkiye, yüksek kaliteli sofralık üzümleriyle tanınmakta ve aynı zamanda önemli bir kuru üzüm ve şarap üretimi için üzüm bağı varlığına sahiptir. Ülkenin iklimi, toprağı ve uzun üzüm yetiştirme geleneğı, farklı iklim ve toprak tiplerine uyum sağlayan üzüm çeşitlerinin gelişmesine olanak sağlamaktadır (Anonim, 2023).

2010-2022 yılları arası sofralık, kurutmalık, şaraplık çeşitlerinin toplam üretim miktarı ve toplam bağ alanı Çizelge 1.1'de verilmektedir.

Çizelge 1.1. 2010-2022 yılları arası Türkiye’de toplam üzüm üretimi (TÜİK, 2023)

Yıl	Alan (da)	Üretim (ton)			
		Toplam	Sofralık	Kurutmalık	Şaraplık
2022	3 845 365	4 165 000	2 099 859	1 681 808	383 333
2021	3 902 211	3 670 000	1 856 929	1 430 160	382 911
2020	4 009 979	4 208 908	2 218 056	1 534 499	456 353
2019	4 054 387	4 100 000	2 050 000	1 599 000	451 000
2018	4 170 410	3 933 000	1 945 262	1 524 091	463 647
2017	4 169 068	4 200 000	2 109 000	1 603 000	488 000
2016	4 352 269	4 000 000	1 990 604	1 536 862	472 534
2015	4 619 557	3 650 000	1 891 910	1 334 563	423 527
2014	4 670 929	4 175 356	2 166 749	1 563 480	445 127
2013	4 687 922	4 011 409	2 132 602	1 423 578	455 229
2012	4 622 959	4 234 305	2 219 813	1 613 833	400 659
2011	4 725 454	4 296 351	2 268 967	1 562 064	465 320
2010	4 777 856	4 255 000	2 249 530	1 543 962	461 508

2010 yılında 4.78 milyon dekar olan üzüm üretim alanı, 2022 yılında 3.85 milyon dekara, 2010 yılında 4.26 milyon ton olan üretim miktarı ise 2022 yılında 4.17 milyon tona düşmüştür.

Dünya’da 2021 yılında 6.7 milyon ha alanda, 73 milyon ton üzüm üretimi yapılmıştır. İspanya, Çin, İtalya yaş üzüm üretiminde ilk sıralardadır (Anonim, 2022). Dünyadaki üzüm üretimi yapılan alanların ve üzüm üretimi miktarının güncel olan durumuna bakıldığında, sekiz ülkenin üretimde öne çıktığı görülmektedir. Türkiye bu sıralamada üzüm üretimi yapılan alanda beşinci, toplam üzüm üretiminde ise altıncı sırada bulunmaktadır (Terzi ve ark., 2023).

Tarım alanlarındaki verime ait bilgilerin hasat önce elde edilebilmesi, tarladaki ürün geliştirme aşamalarının incelenmesinde ve ithalat ihracat planlamalarının yapılmasında büyük bir avantaj sağlamaktadır. Bu nedenle verim tahmini önemlidir. Geleneksel olarak saha ölçümleri ve gözlemcilerin yorumlarına göre yapılan verim tahmin çalışmaları günümüzde farklı şekillerde yapılabilmektedir (Kaya ve Polat, 2021). Rekoltenin bilinmemesi ürün fiyatının belirlenmesinde sorunlar oluşturabilmekte ve üretici gelirlerinde kayıplar olabilmektedir. Rekoltenin uzaktan algılama, görüntü işleme ve yapay zeka teknikleri ile ürün fiyatlarına ilişkin öngörülebilir ve belirli olması konusunda fayda sağlayabilmektedir (Özgüven, 2023).

Bağlarda üzüm verimi; iklim, toprak koşulları ve zararlılardaki farklılıklar nedeniyle yıldan yıla ve ayrıca alansal olarak önemli ölçüde değişebilmektedir. Üzüm verimine ilişkin doğru bilgi,

bağcılarının bağlarını daha iyi yönetmelerine olanak sağlayacaktır. Verim tahmini için mevcut uygulanan geleneksel yöntemler zor ve pahalıdır. Geleneksel yöntemde büyüme mevsimi boyunca üzüm bağlarından küçük numuneler alınmakta ve genel verimi belirlemek için tahmin edilmektedir (Ozguven, 2023).


Geleneksel rekolte tahmini süreci, arazi planlamasıyla başlamaktadır. Bu aşamada, en az dört kişilik bir ekip, gezici ve hesaplamaları gerçekleştirecek şekilde oluşturulmaktadır. Bu ekip, doğru tahminler elde etmek amacıyla bağcılık yapılan yerleri detaylı bir şekilde incelemekte ve analiz etmektedir. Lokasyonların tespiti sürecinde, verimli ve uygun bölgeler seçilmektedir. Ardından, gezilip değerlendirmeye alınacak bağ alanları belirlenmektedir. Seçilen her bir asma için, salkım sayısı ve tahmini salkım ağırlığı gibi veriler temel alınarak hesaplamalar yapılmaktadır. Toplam verim tahmini için komisyon toplanmakta, komisyon üyelerinin bildirdiği rakamların ortalaması alınmakta ve belirlenmeye çalışılan üzüm çeşidine ait verim tahmini böylece belirlenmektedir (Teker, 2017).

Özellikle üzüm bağlarında, verim tahmini, bağ yönetimini optimize etmek ve istenen üzüm kalitesini elde etmek için önemli bir faktördür. Geleneksel verim tahmini araştırmaları temsili verim verilerini elde etmek için çoğu zaman yetersizdir. Bu nedenle, üzüm verim tahminini hızlı bir şekilde değerlendirmek ve uygulamak için görüntü işleme tekniği kullanılabilmektedir (Gennaro ve ark., 2019).

Görüntü işleme tekniği, bir kamera, tarayıcı veya sensörler ile elde edilen fotoğraf veya video karesindeki görüntüyü kayıttan sonra dijital formata dönüştürmek ve bu dijital verilerden birtakım algoritmalar yardımıyla bazı faydalı bilgiler çıkarmak için kullanılan bir yöntemdir. Bu teknikte görüntüler çeşitli işlemlerle yeniden düzenlenmekte ve sonunda bu işlemlerden anlamlı sonuçlar elde edilmektedir. Bu işlemler sırasında görüntüdeki önemli verileri temsil eden tanımlayıcı parametreler elde edilmeye çalışılmaktadır. Bu sayede ölçülecek özneliklerin tanımlanması ve ayrılması, görüntü bozukluklarının düzeltilmesi, belirli özneliklerin görünürlüğünün artırılması ve arka planda eşiklenmesi gerçekleştirilmektedir (Ozguven ve Yanar, 2022).


Görüntü işleme teknikleri farklı alanlarda pek çok uygulamada kullanılmasına rağmen işlemler bazı temel adımlar halinde yapılmaktadır. Bu adımlardan ilki görüntü edinme ile verilerin programa aktarılmasıdır. Ön işleme ile görüntüler daha kolay ve hızlı işlenebilecek hale getirilmektedir. Segmentasyon aşamasında nesneler ile arka plan birbirinden ayrılmaktadır. Özellik çıkartma ile önemli özellikler temsil edilmekte ve temsilin karmaşıklığı azaltılmaktadır.

Bağılı bileşenleri bulmak ve özellikleri ayıklamak için analiz hesaplamaları yapılmaktadır. Sınıflandırma ile de nesnenin türü belirlenmektedir (MathWorks, 2008).



Şekil 1.1. Görüntü işlemede kullanılan temel adımlar (Altaş ve ark., 2019).

Görüntüler aslında parçalardan oluşan yapılardır, bu parçalara "piksel" denilmektedir. Her görüntü, iki boyutlu piksel dizisidir. Kamera çözünürlükleri, görüntünün yatay ve dikey uzunluklarda bulunan piksel sayılarını ifade etmektedir. Örneğin, 1280 x 720 veya 1920 x 1080 gibi sayılar, görüntünün yatayda 1280 veya 1920 piksel, dikeyde ise 720 veya 1080 piksel içerdiğini göstermektedir (Anonim, 2020b).



Şekil 1.2. Gri renkli görüntünün matrislerden oluşumu (Wevers ve Smits, 2019).

Görüntü işleme, renkli görüntülerin bilgisayar tarafından işlenerek analiz edilmesini ve özelliklerinin çıkarılmasını sağlayan bir teknolojidir. Bu işlem, RGB (Red-Green-Blue) renklerin çeşitli yoğunluklarının bir araya gelmesiyle oluşturulan piksellerin değerlerini kullanmaktadır. Her renk bileşeni, 0 ile 255 arasında bir değerle temsil edilmekte ve bu değerler piksellerin rengini belirlemektedir. Bu RGB bileşenleri, piksellerin rengini oluşturmak için bir araya gelmekte ve böylece farklı renkler elde edilmektedir. Bu renkler daha sonra sayısal verilere dönüştürülerek bilgisayarın anlayabileceği '0' ve '1' olarak kodlanmaktadır. Bu sayısal değerler, bilgisayar ekranında görüntülenen renkleri oluşturmak için kullanılmaktadır. Sayısallaştırılan görüntüler, bilgisayar tabanlı görüntü işleme yazılımları ile analiz edilmekte ve renk, şekil, desen gibi özellikler çıkarılmaktadır. MATLAB ve C++ gibi programlama dilleri, bu alanda yaygın olarak kullanılan araçlardır. Görüntü işleme teknolojisi, robotik sistemler ve otomasyon alanında önemli bir rol oynamaktadır (Kahya, 2022).

Genel olarak dijital görüntüler 4 farklı grupta toplanmaktadır (Perihanoğlu, 2015).

- 1) Binary Görüntü: 0 veya 1 olmak üzere iki değer (siyah ve beyaz) almaktadır.
- 2) Gri Renk Seviyeli Görüntü: Tek renkli görüntülerdir. Renk bilgisi içermez sadece parlaklık bilgisi içermektedir.
- 3) Renkli Görüntü: Bilgisayar ekranlarında 24 bitlik veri olarak görüntülenmektedir.

Görüntüleme R (Kırmızı), G (Yeşil), B (Mavi) kodlanmış aynı objeye ait üç adet gri düzeyli görüntünün üst üste ekrana iletilmesi ile oluşmaktadır.

- 4) Çok Spektrumlu Görüntü: Görünür spekturumun dışındaki bölgelerden alınan ve yanlış renkli görüntü olarak da adlandırılan görüntülerdir.



Şekil 1.3. Dijital görüntü çeşitleri (Perihanoğlu, 2015)

Görüntü işlemede yapılması gereken temel adımlar (Yılmaz, 2016):

Görüntü işleme, farklı bir açı ile çekilen görüntünün istenilen açıdan çekilmiş gibi görünmesini sağlayan tekniktir. Görüntü iyileştirme, görüntünün niteliğini istenilen seviyeye yükseltme işlemidir. Bu işlem, karlı görüntüleri, aşırı keskin, aşırı parlak, bulanık vb. görüntüleri çeşitli filtrelerden geçirilerek görüntü kalitesinin yükseltilmesini amaçlamaktadır.

Görüntü onarma, bozulmuş veya gürültüye maruz kalmış görüntüyü orijinal resim seviyesine çekme işlemidir. Görüntü bölümleme algoritmaları, bir görüntüdeki elemanların veya nesnelerin gruplandırılması, sınıflandırılması için kullanılmaktadır. Bölümleme bir görüntüdeki çizgilerin, dairelerin veya arabalar, yollar, binalar gibi belirli şekillerin ele alınıp incelenmesi için yapılan bir gruplandırma işlemidir.

Görüntü sıkıştırma, sayısal bir görüntüyü sıkıştırmak için ihtiyaç duyulan bellek miktarını azaltmak amacıyla yapılan görüntü işleme tekniğidir. Görüntü sunma, sınır tanımlama ve alan tanımlama olmak üzere iki alt başlıktan oluşmaktadır. Her iki tanımlama için görüntü üzerindeki objelerin belirginleştirilmesinin amaçladığı işlemleri içerdiği söylenebilmektedir.

Görüntü algılama, yeryüzüne fiziksel bir temas olmaksızın cisimlerin gözlenmesi ve ölçülmesine ilişkin bilgi sağlayan bir bilimdir. Görüntü algılama teknolojileri yer yüzeyinden yansıyan ve yayılan enerjinin algılanması, kaydedilmesi, elde edilen materyalin bilgi çıkarmak üzere işlenmesi ve analiz edilmesinde kullanılmaktadır.

Bu çalışma, Tokat Gaziosmanpaşa Üniversitesi Tarımsal Uygulama ve Araştırma Merkezi bünyesindeki bağ alanında Michele Palieri, İtalya ve Mevlana üzüm çeşitlerinden hasat öncesi etiketlenen salkımlardan 1500 görüntü alınmıştır. Etiketlenen salkımlar aynı zamanda hassas tartı ile gerçek ağırlıkları tespit edilmiştir. Elde edilen görüntüler, MATLAB programının Image Processing araç kutusu ile geliştirilen görüntü işleme algoritmaları kullanılarak çeşitlerine göre üzüm verimleri belirlenmeye çalışılmıştır. Elde edilen sonuçlar gerçek verim sonuçları ile karşılaştırılmıştır.



2. KAYNAK ÖZETLERİ

Nuske ve ark. (2011) yaptıkları çalışmada, üzüm meyvelerini tespit etmek ve saymak için bilgisayarla görme temelli otomatik bir yöntem sunmuşlardır. Çalışma üç farklı üzüm çeşidini içermektedir. Bir bağ alanında gerçekleştirilen en büyük otomatik mahsul görüntüleme yöntemi olarak kabul edilmekte ve bu yöntem hakkında değerlendirmeler yapılmaktadır. Yaklaşık 450 m uzunluğundaki asma sırasından, alınan görüntülerden kullanarak hasat veriminin otomatik bir tahmini yapılmış ve hasat zamanında elle ölçülen gerçek verimle karşılaştırılmıştır. Sonuçlar bir sıra asmanın ağırlığının % 9.8 hata ile tahmin edebileceğini göstermektedir.

Liu ve ark. (2013) yaptıkları çalışmada, üzüm salkımlarının hasat sonrası ağırlıklarını tahmin etmek için laboratuvar koşullarında fotoğraflar çekilmiştir. Çalışmada farklı salkım parametrelerinin salkım ağırlığına etkisi incelenmiş ve üzüm salkımlarının ağırlıklarını tahmin etmek amacıyla manuel olarak etiketlenmiş veri kümeleri üzerinde çeşitli ölçümlerin performansı değerlendirilmiştir. Çalışma sonunda tane sayısı, salkım çevresi, salkım alanı ve tahmini salkım hacmi gibi özellikler kullanılarak doğrusal regresyon yaklaşımının ideal koşullarda %5.3'lük bir doğrulukla salkım ağırlığının tahmin edebileceği sonucuna ulaşılmıştır. Araştırmacılar bu çalışmanın, üzüm salkımlarının ağırlık tahmininde görüntü analizi ve özellik çıkarımının etkili bir yol olarak ortaya koyduğunu bildirmişlerdir.

Diago ve ark. (2014) yaptıkları çalışmada, hızlı ve ekonomik bir şekilde üzüm küme verim bileşenlerini belirlemek için görüntü analizine dayalı yeni bir yöntem geliştirilmişlerdir. Bu metodoloji, yedi farklı kırmızı asma çeşidini içermektedir. Çalışmada, hasat zamanında her çeşit için genel özellikleri yansıtan 10 farklı üzüm kümesi rastgele seçilmiş ve ağırlıkları kaydedilmiştir. Alınan bu görüntüler sonrasında, her bir üzüm kümesi manuel olarak tanımlanmış ve meyvelerin sayısı ile ortalama meyve ağırlığı manuel olarak değerlendirilmiştir. Çalışmada, Canny ve logaritmik görüntü işleme yaklaşımlarına dayalı iki algoritma kullanılarak gerçekleştirilmiştir. Çalışma sonunda modelin görüntü analizine dayalı olarak meyve ağırlığını tahmin etme yeteneğinin %84 olduğu belirlenmiştir. Araştırmacılar bu çalışma ile üzüm küme verim bileşenlerinin belirlenmesinde görüntü analizinin başarılı bir şekilde kullanılabileceğini ortaya koyduğunu bildirmişlerdir.

Nuske ve ark. (2014), bağlarda üzüm verimini doğru ve yüksek çözünürlükte otomatik olarak tahmin eden bir vizyon sistemi sunmuşlardır. Geleneksel yöntemlerde verim tahmini için el ölçümü gerekmekte ve bu bazı durumlarda yetersiz, zaman alıcı ve yanıltıcı olabilmektedir. Çalışmada önerilen yöntemin, verimi etkili ve yüksek çözünürlükte tahmin edebildiği

bildirilmiş ve gerçek dünya bağlarında yüzlerce asmadan oluşan büyük veri kümeleri ile birkaç yıl boyunca değerlendirilmiştir. Geliştirilen sistemde, bağ boyunca bir araca monte edilmiş kameralar ve aydınlatma kullanılmaktadır. Görüntüleri işlemek için renk, doku ve şekil özelliklerini kullanarak, asma yapraklarına benzer renkte olsa bile üzüm salkımlarını algılayan güçlü bir sınıflandırıcı geliştirilmiştir. Deneyler ise, farklı üzüm bağlarında dört büyüme mevsimi boyunca gerçekleştirilmiştir. Bu deneyler, gerçek verim varyasyonuna ve hareketli bir araçtan elde edilen gerçek dünya görüntüleme koşullarına karşı adil değerlendirme için yeterince büyük boyutta yapıldığı rapor edilmiştir. Çalışma sonunda elde edilen sonuçlar, mekânsal verim varyansının %75'ine kadar ve toplam verimin %3 ila %11'i arasında bir ortalama hata ile verim tahminini yapabildiği belirtilmiştir.

Behrooz-Khazaei ve Maleki (2017), yaptıkları çalışmada hasata yakın renk özelliklerini kullanarak üzüm kümelerini yapraklardan ve arka plandan bölümlere ayırmak için yapay sinir ağına (YSA) ve genetik algoritmaya (GA) dayanan sağlam bir algoritma önermişlerdir. Önerilen bu algoritmanın geliştirilmesi üç aşamadan oluşmaktadır. Birinci aşama, renk özniteliklerinin çıkarılması ve veri seti matrisinin hazırlanması için görüntü işleme algoritmasının geliştirilmesidir. İkinci aşama, sınıflandırma algoritması olarak YSA'nın veri setinden ve en iyi yapısından üstün renk özniteliklerinin seçilmesidir. Üçüncü aşama ise, sınıflandırma algoritması olarak değerlendirilmesidir. Araştırmacılar algoritmanın geliştirmesi için MATLAB yazılımı kullanmıştır. Önerilen yeni algoritma, yaprakların arkasında bulunan üzüm kümesini tespit etmek için sınırlı olduğu, ancak hasat verimini verimli bir şekilde tahmin etmek için kullanılabilecek görüntülerdeki görünür üzüm kümesini otomatik olarak algıladığı ve algoritmanın genel doğruluğunun %99.4 olduğu bildirilmiştir.

Dorj ve ark. (2017) görüntü işleme tekniklerini kullanarak, ağaçtaki narenciyeyi tespit etmek ve saymak için etkili, basit ve uygun bir bilgisayar görme algoritması geliştirmişlerdir. Çalışmada, gün ışığında narenciye görüntüleri alınmış ve 21 ağaçtan toplanan 84 görüntü üzerinde narenciye tanıma ve sayma algoritması test edilmiştir. Geliştirilen narenciye sayma algoritması ilk olarak, girdi olarak alınan RGB görüntüsü, renk bilgilerini daha kolay işleyebilmek için HSV (Renk Tonu, Doyma ve Parlaklık) renk uzayına dönüştürmektedir. Narenciye sayma algoritması ile insan gözlemi yoluyla gerçekleştirilen ölçümlerde determinasyon katsayısı $R^2=0.93$ bulunmuştur.

Millan ve ark. (2018) yaptıkları çalışmada, segmentasyon hatalarına karşı güvenilirliği, bağ verimi tahmini için ideal bir çözüm sunmak amacıyla, üzüm bağlarında invaziv olmayan,

objektif ve otomatikleştirilmiş verim değerlendirmesi için görüntü analizi ve Boolean modeli kullanarak yeni bir metodoloji geliştirmişlerdir. Bu metodoloji, üç farklı veri seti üzerinde değerlendirilmiştir. Küme görüntüleri, manuel olarak elde edilen asma görüntüleri ve hareket halindeyken dört çeker bir ATV araç kullanılarak çekilen asma görüntülerinden oluşmaktadır. Önerilen algoritma, manuel olarak alınan asma görüntülerinde değerlendirilmiştir. Çalışma sonunda 310 gram ortalama hata elde edildiği ve determinasyon katsayısının $R^2=0.81$ olarak belirlendiği bildirilmiştir. Çalışmada ayrıca yapay ışık ve otomatik kamera tetikleme ile donatılmış bir dörtlü kullanılarak çekilen görüntüler de analiz edilmiştir. Boolean modeli uygulanarak elde edilen tahmin, segment başına 610 gram ortalama hata sağlamıştır ve determinasyon katsayısı $R^2=0.78$ olarak bulunmuştur. Boolean modelinin segmentasyon hatalarına karşı güvenilirliği, bağ verimi tahmini için ideal hale getirmiştir.

Altas ve ark. (2018) tarafından drone kullanılarak görüntü işleme tekniği ile şeker pancarı yaprak lekesi hastalık (*Cercospora Beticola*) düzeyinin belirlenmesi çalışması yapılmıştır. Çalışmada şeker pancarı yetiştirilen yerel bir çiftçi tarlasında hastalığın yoğun olarak görüldüğü yaklaşık 200 m² alandan alınan DJI Phantom 3 Advanced marka drone ile alınan görüntüler R2014a versiyon MATLAB programının Image Processing Toolbox modülü kullanılarak işlenmiştir. Araştırmacılar geleneksel olarak şeker pancarında görülen yaprak lekesi hastalığı, bitki koruma uzmanları tarafından yapılan gözlemler ile tespit edildiğini, şeker pancarı yapraklarında hastalık olup olmadığı, hastalık olması durumunda hastalığın hangi evrede olduğu ve hastalığın şiddetine bağlı olarak görülen ölü alanlar yaprak alanına oranlanarak hastalığın yayılımı belirlenmeye çalışıldığını ve yapılan bu gözlemler uzmandan uzmana değişebildiğini belirtmişlerdir. Çalışmada, drone'a takılı fotoğraf makinesi kullanılarak alınan görüntüler, geliştirilen görüntü işleme algoritmaları ile işlenerek hastalıklı alanlar tespit edilmiştir. Çalışma sonunda yersel tarla gözlemi değerlendirilmesi sonucu hastalık şiddeti %50-55 bulunmuş ve görüntü işleme sonucunda ise m görüntüsündeki alanda hastalık şiddeti %51 hesaplanmıştır.

Gennaro ve ark. (2019) yaptıkları çalışmada, bağ yönetiminin desteklenmesi amacıyla erken bir verim değerlendirmesi (hasat öncesi) sağlamak için hızlı ve otomatik bir metodoloji geliştirmişlerdir. Araştırmacılar, uydu görüntüleri veya sensör verileri ile bitki büyümesi, su kullanımı, toprak durumu gibi faktörlerin izlenmesi ve analizi için kullanıldığını belirtmişlerdir. Bu çalışmada ise özellikle canlılık değişkenliği yüksek bölgelerde düşük maliyetli bir İnsansız Hava Aracı (İHA) platformu kullanılarak yüksek çözünürlüklü RGB görüntülerden faydalandığı bildirilmiştir. Elde edilen görüntülerden otomatik olarak farklı koşullarda tespit

edilen küme sayısı ve her canlılık bölgesi için ağırlık tahmin edilmiştir. Böylece, canlılık değişkenliği olan alanlarda verimli bir şekilde analiz yaparak, tarım veya çevresel süreçlerde daha etkili kararlar alınabilmesine olanak sağlandığı rapor edilmiştir. Önerilen metodoloji, İHA kullanılarak ticari bir dijital kamera ile ve yapay ışık yardımı olmadan elde edilen yüksek çözünürlüklü RGB görüntüleri ile değerlendirilmiştir. Çalışma sonunda yaprak çıkarma ve tam olgun durumdaki verim tahminleri, segmentasyon sonuçlarıyla değerlendirilmiş ve asma verimi hasattan birkaç hafta önce %84'ten fazla doğrulukla tahmin edilmiştir. Araştırmacılar, otomatik görüntü işleme teknikleriyle bağ verimi tahmininin başarılı bir şekilde gerçekleştirilebileceğini gösterdiğini rapor etmişlerdir.

Kaymak ve ark. (2019), görüntü işleme teknikleri ile bir elma bahçesinde bulunan ağaçlar üzerindeki kırmızı renkli elmaların tespit edilmesi ve sayılması için bilgisayar ortamında bir yazılım geliştirmişlerdir. Yazılım, dijital ortamdan aktarılan elma ağacı görüntüleri üzerinde, görüntü işleme tekniklerini kullanarak ağaç üzerindeki elmaları bulmaktadır. Tespit edilen bu elma nesnelerinin merkez noktaları işaretlenerek elma sayımı gerçekleştirilmektedir. Uygulama, fotoğraf veya anlık çekilen görüntü ya da canlı video üzerinden görüntü alabilmektedir. Çalışmada ağaçtaki kırmızı renkli elmalar, renk bakımından % 78.47 başarı ile tespit edilmiştir.

Bhookya ve ark. (2020), acı biber bitki görüntülerinden olgunlaşmış Byadagi çeşidi kırmızı biber meyvesini tespit etmek ve saymak için yeni bir yaklaşım önermişlerdir. Çalışmada, acı biber bitkilerinin meyvelerle dolu 31 görüntüsü 7 farklı günde doğal gün ışığı koşullarında çekilmiş, geliştirilen algoritma ile görüntü işlemede RGB görüntüsünü HSV (Renk Tonu, Doyma ve Parlaklık) renk uzayına dönüştürülmüş ve görüntü işleme teknikleri uygulanması sonucu % 92.7 doğruluk elde edilmiştir.

Haki ve ark. (2020) yaptıkları çalışmada, mahsul verimi tahmininin çok zor olduğu gerçeğine dikkat çekerek, mahsul genotipi, çevresel faktörler, yönetim uygulamaları ve bu faktörler arasındaki etkileşimler nedeniyle tahminin karmaşık bir süreç olduğunu belirtmişlerdir. Çalışmada, mısır ve soya fasulyesi verimini tahmin etmek için Amerika Birleşik Devletleri'ndeki tüm Mısır Kuşağı boyunca (13 eyalet dahil), 2016, 2017 ve 2018 yılları boyunca tarihsel verileri kullanarak bir CNN-RNN modeli önermişlerdir. Bu yeni model, rastgele orman (RF), derin tam bağlı sinir ağları (DFNN) ve LASSO gibi diğer popüler yöntemlerle karşılaştırılmıştır. Elde edilen sonuçlar, önerilen CNN-RNN modelinin mahsul verimi tahmininde yüksek performans (RMSE) elde edilerek, test edilen diğer yöntemlerden

önemli ölçüde daha iyi sonuç alındığı bildirilmiştir. Buna göre araştırmacılar, CNN-RNN modelinin, çevresel faktörlerin ve yönetim uygulamalarının karmaşıklığına rağmen, mahsul verimi tahmininde etkili bir araç olduğunu belirtmektedirler.

Wang ve ark. (2021) yaptıkları çalışmada, meyve bahçesindeki meyvelerin doğru bir şekilde tanınması, doğal ortamda robot kullanarak toplama için önemli bir adım olduğunu belirtmişlerdir. Araştırmacılar bunun sebebini ise üzüm salkımı gibi düzensiz şekilli ve çok yoğun meyvelerle çalışırken birçok CNN modelinin tanıma oranı düşük olması olarak açıklamışlardır. Araştırmacılar, tanıma oranı daha yüksek bir model oluşturma amacıyla Swin Transformer ve DETR modellerini kullanmış ve bu modeller geleneksel CNN modelleri olan Faster-RCNN, SSD ve YOLO gibi yöntemlerle karşılaştırılmıştır. Bu modeller, doğal ışık altında toplanan kırmızı üzüm veri kümeleri üzerinde eğitilmiştir. 200 eğitim dönemi sonunda SwinGD modelinde, IoU=0.5 durumunda %94'lük mAP (ortalama hassasiyet puanı) değeri elde edilmiştir. Aynı zamanda, en yeni YOLOX modeli ile de karşılaştırma yapılmış ve deneysel sonuçlar, YOLOX'un daha yüksek doğruluk ve daha iyi algılama yeteneğine sahip olduğunu göstermiştir. SwinGD'nin evrensel özellikte olduğunu doğrulamak için yeşil üzüm görüntüleri altında bir test yapılmıştır. Yapılan deneysel sonuçlar, SwinGD'nin pratik uygulamalarda başarılı bir performans sergilediğini göstermiştir. SwinGD, araştırmacılar tarafından tarımda hassas hasat için yeni bir çözüm olarak sunulmuştur.

Abd-Elrahman ve ark. (2021) yaptıkları çalışmada, çilek (*Fragaria × ananassa* Duch.) yetiştiriciliğinde, işgücü yönetimi ve pazarlama karar verme süreçlerinin son derece önemli olduğunu ve hızlı bozulabilen meyve olduğu için verimin zamanında tahmin edilmesi amacıyla sezon boyunca farklı aralıklarla (hasattan 3-4 gün, 1 hafta ve 3 hafta önce) verim tahmini için önceki verim ve hava durumu bilgilerine ek olarak yüksek çözünürlüklü yer bazlı görüntülerin kullanımını önermişlerdir. Araştırmacılar, çiçek ve meyve sayımları, verim ve yüksek çözünürlüklü görüntü verileri, büyüme mevsimi boyunca "Florida Radiance" ve "Florida Beauty" olmak üzere iki çeşit için 31 kez toplamışlardır. Çalışmada, kanopi boyutu değişkenlerini (kanopi alanı, ortalama kanopi yüksekliği, kanopi yüksekliği standart sapması ve kanopi hacmi) çıkarmak ve çiçek ve meyve sayısını görsel olarak saymak için ortorektifiye edilmiş mozaikler ve dijital yüzey modelleri oluşturulmuş ve parsel seviyesinde toplanan veriler (çeşit başına 6 parsel, parsel başına 24 bitki) tahmin modellerini geliştirmek için kullanılmıştır. Çalışma sonunda, görüntüye dayalı sayımlar ve kanopi değişkenleri kullanılarak çiçek ve meyve sayıları sırasıyla % 26,3 ve % 25,7'lik yüzde tahmin hatalarıyla tahmin edilmiştir. Ayrıca modellere görüntüden türetilmiş değişkenler eklendiğinde, farklı zaman aralıklarında örnek dışı

verimleri tahmin etme doğruluğu, görüntüden türetilmiş değişkenlerin bulunmadığı modellere kıyasla %10-29 oranında artırıldığı bildirilmiştir. Araştırmacılar bu sonuçların, yakın mesafeli yüksek çözünürlüklü görüntülerin verim tahminine katkıda bulunabileceğini ve yetiştiricilerin tahmin uygulamalarını değiştirerek sektöre karar verme konusunda yardımcı olabileceğini belirtmişlerdir.

Alibabaei ve ark. (2021) doğru tahminlerde bulunmak, gıda güvenliği, ürün yönetimi, sulama planlaması ve hasat ile depolama süreçlerinde ne kadar işgücüne ihtiyaç duyulacağını önceden belirlenmesi için son derece önemli olduğunu belirtmişlerdir. Çalışmada, tarımsal veri setleri gibi zaman serisi verilerinin analizi için Uzun Kısa Süreli Bellek (Long Short-Term Memory, LSTM) ve Kapılı Tekrarlayan Birimler (Gated Recurrent Units) olmak üzere iki derin öğrenme modeli geliştirilmiş ve geliştirilen modeller domates ve patates veriminin tahmini için test edilmiştir. Çalışma sonunda, Çift Yönlü LSTM modeli 0.017 ile 0.039 MSE ile verimi tahmin edilmiş ve testteki Çift Yönlü Uzun Kısa Süreli Belleğin performansı, en yaygın kullanılan derin öğrenme yöntemi olan Evrişimli Sinir Ağı ve Çok Katmanlı Algılayıcılar modeli ve Rastgele Orman Regresyonu içeren makine öğrenme yöntemleri ile karşılaştırıldığında ise, Çift Yönlü LSTM, diğer modellerden R^2 0.97 ile 0.99 arasında daha iyi performans gösterdiği belirlenmiştir.

Ataç ve Kayabaşı (2023) çalışmalarında, elma ağaçlarının toplam rekoltesinin tahmin edilmesi için evrişimsel sinir ağları (ESA), doğrusal regresyon (DR) ve özel olarak hazırlanan bir YSA modeli kullanılmıştır. Farklı yapay zeka modelleri kullanılarak gerçekleştirilen çalışmaların sonuçları karşılaştırıldığında, % 85'in üzerinde doğruluk oranları elde edilmiştir. Araştırmacılar elde edilen bu sonuçlara göre, elma ağaçlarının rekolte tahmini için yapay zeka ve görüntü işleme tekniklerinin etkili ve güvenilir bir yaklaşım sağladığını gösterdiğini bildirmişlerdir.

3. MATERYAL VE YÖNTEM

3.1. Materyal

3.1.1. Araştırma alanı

Çalışma, Tokat Gaziosmanpaşa Üniversitesi Tarımsal Uygulama ve Araştırma Merkezi bünyesindeki bir bağ alanında yürütülmüştür. Araştırma alanı görseli Şekil 3.1’de verilmiştir. Üzüm veriminin tahmin edilebilmesi için olgunlaşan üzümlerin hasat edilmeden önceki görüntüleri Şekil 3.2’de gösterilen bağ alanından toplanmıştır.



Şekil 3.1. Araştırma alanı



Şekil 3.2. Çalışmanın yürütüldüğü bağ alanı

3.1.2. Çalışmada kullanılan cihazlar

Görüntülerin alınmasında akıllı mobil telefon ve GoPro marka Hero 7 Black model kamera kullanılmıştır (Şekil 3.3). Görüntülerin alınmasında kullanılan GoPro Hero 7 Black kameranın özellikleri aşağıdaki gibidir:

- ✓ Görüntü İşlemcisi: GoPro GP1
- ✓ Sensör Tipi: CMOS
- ✓ Etkin Piksel: 12 MP
- ✓ Azami Çözünürlük: 4000×3000
- ✓ Görüntü Oranı: 4:3
- ✓ Sensör Formatı: 1/2.3 inç
- ✓ Sensör Boyutu (Genişlik): 6.17 mm
- ✓ Sensör Boyutu (Uzunluk): 4.62 mm
- ✓ En Düşük ISO: 100
- ✓ En Yüksek ISO: 6400



Şekil 3.3. GoPro Hero 7 Black kamera

Görüntüleri işlemek için iyi bir işlemci ve ekran kartına sahip bilgisayara gereksinim vardır. Algoritmalar çok çekirdekli işlemciler ve GPU'larda çalıştırarak hızlandırılabilir. Çalışmada en iyi sonuçları almak ve işlemleri daha hızlı yapabilmek için 12 GB RAM, 8 GB NVIDIA GeForce 920MX ekran kartı, Intel Core i5 işlemcili 4 çekirdekli 7. Nesil teknik özelliklerine sahip ASUS Marka bir bilgisayar kullanılmıştır. Görüntü işlemlerin doğruluğunu tespit etmek için salkımların hasat zamanı hassas tartı ile ağırlıklarını tartmak için Şekil 3.4'te gösterilen 1 gram hassasiyetli HMT marka SF-400 model hassas terazi kullanılmıştır.



Şekil 3.4. Hassas tartı

3.1.3. MATLAB

Görüntü işleme aşamalarında MATLAB R2022b paket programı kullanılmıştır. MATLAB, temel olarak nümerik hesaplama, grafiksel veri gösterimi ve programlamayı içeren teknik ve bilimsel hesaplamalar için yazılmış yüksek performansa sahip bir yazılımdır. Görüntü işleme MATLAB yazılımının Image Processing Toolbox modülü kullanılarak gerçekleştirilmiştir. Image Processing Toolbox görüntü işlemeyle ilgili tüm fonksiyon ve komutları içinde barındıran MATLAB araç kutusudur. MATLAB Image Processing Toolbox araç kutusu sayesinde yaygın görüntü işleme iş akışlarını otomatikleştirmeye olanak tanınmaktadır. Görüntü işleme üzerinde çalışma yapanlar için kodlar sınıflandırılmış ve düzenlenmiştir. Bu konuda çalışanlara çok büyük kolaylık sağlanmaktadır.

3.1.4. Çalışmada kullanılan üzüm çeşitleri

Michele Palieri (*Alphonse Lavallée X Red Malaga*)

Çalışmada kullanılan Michele Palieri üzümü, morumsu siyah renklidir. Büyük, yuvarlak tanelere sahip olup ortalama salkım ağırlığı 440 g'dır. Sofralık üzüm çeşididir. Yaz sonunda hasat edilir. Geçit bölgelerde yetiştiriciliğe uygundur. İtalya'dan ülkemize getirilmiş ülkenin iklimine uyum sağlamış bir çeşittir (Anonim, 2020c). Üzüm çeşit görseli Şekil 3.5'de verilmiştir.



Şekil 3.5. Michele Palieri üzüm çeşidi

İtalya (*Bicane X Hamburg Misketi*)

Çalışmada kullanılan İtalya üzümü, beyaz-sarı kehribar renklidir. Büyük, yuvarlak tanelere sahip olup ortalama salkım ağırlığı 500-800 g'dır. Sofralık üzüm çeşididir. Ağustos ayının 2. yarısında hasat edilmektedir. Nispeten yüksek yayla kesimlerinde yetiştirilmesi için uygun olmakla birlikte geçit bölgeleri ve kıyı bölgelerde de ekonomik olarak yetiştiriciliği uygundur. İtalya'dan ülkemize getirilmiş ülkenin iklimine uyum sağlamış bir çeşittir (Anonim, 2020c). Üzüm çeşit görseli Şekil 3.6'da verilmiştir.



Şekil 3.6. İtalya üzüm çeşidi

Mevlana (*Vitis vinifera* Mevlana)

Çalışmada kullanılan Mevlana üzümü, yeşil-sarı renklidir. Büyük, konik tanelere sahip olup ortalama salkım ağırlığı 470-700 g'dır. Sofralık üzüm çeşididir. Ağustos sonunda hasat edilmektedir. Çardak sisteminde yetiştiriciliğe daha uygundur (Anonim, 2020c). Üzüm çeşit görseli Şekil 3.7'de verilmiştir.



Şekil 3.7. Mevlana üzüm çeşidi

Geleneksel üzüm verimi hesaplama, genellikle üzüm bağlarında kullanılan temel bir ölçüm sürecini içermektedir. Bu süreçte öncelikle bağda bulunan üzüm salkımlarının sayısı tespit edilmektedir. Rastgele seçilen bitkilerden alınan salkım sayıları toplanarak ortalama bir salkım sayısı elde edilmektedir. Ardından, örnek olarak seçilen salkımların ağırlığı ölçülmektedir. Bu ölçümler, salkımların genel büyüklüğü ve ağırlığı hakkında bilgi sağlamaktadır. Elde edilen ortalama salkım ağırlığı, salkım sayısı ile çarpılarak toplam üzüm verimi hesaplanmaktadır.



3.2. Yöntem

3.2.1. Veri toplama

Bağ alanında, üzümler hasat döneminde omca ve salkım çeşidine göre ayrı numaralandırılarak etiketleme (Şekil 3.9) ve görüntü alma işlemleri (Şekil 3.10) yapılmıştır. Üzümler hasat edilmeden önce akıllı mobil telefon ve GoPro marka Hero 7 Black kamera yardımıyla Michele Palieri, İtalya ve Mevlana üzüm çeşitlerinin her birinden etiketlenen salkımlardan 4000x3000 çözünürlükte 500 fotoğraf çekilmiştir. Üç çeşit için toplamda 1500 salkım fotoğrafı elde edilmiştir. Görüntüler 29.08.2021 ve 30.08.2021 tarihlerinde alınmıştır. Veri toplama işlemlerinden sonra her çeşit için ayrı etiketlenen salkımlar hassas tartı ile tartılıp ağırlıkları kaydedilmiştir.



Şekil 3.8. Omca ve salkımların numara verilerek etiketlenmiş hali



Şekil 3.9. Omca ve salkımları etiketleme



Şekil 3.10. Görüntü alma


3.2.2. Veri seti oluşturma

Toplanan görüntüler bilgisayar ortamına aktarılmıştır. Aktarılan görüntüler bir klasörde ham görüntüler olarak depolanmıştır. Daha sonra her bir çeşit için ayrı bir klasör yapılarak veri seti oluşturulmuştur. Görüntü döndürme, ton kaydırma, yeniden boyutlandırma, gürültü giderme gibi bir dizi işlemler ile veri seti düzenlenip görüntüler işlenmeye hazır hale getirilmiştir.

3.2.3. Algoritma geliştirme

İşlenmeye hazır görüntüler MATLAB programının Image Processing Toolbox modülünde geliştirilen algoritmalar ile görüntü işleme aşamalarına tabi tutulmuştur. Algoritma adımları aşağıda verilmiştir:

Adım 1: Bağ alanından alınan üzüm görüntüleri “imread” komutu ile bir değişkene atanarak MATLAB “workspace” için tanımlanmıştır. Orijinal üzüm görüntüleri, (Şekil 3.11)’de gösterildiği gibi JPEG formatında RGB görüntüleridir.




Şekil 3.11. Orijinal görüntü

Adım 2: Programa girilen görüntülerin “rgb2gray” komutu ile parlaklığı korunurken ton ve doygunluk bilgilerini ortadan kaldırarak RGB görüntüleri gri tonlamaya dönüştürülmüştür (Şekil 3.12).



Şekil 3.12. Gri tonlamalı görüntü

Adım 3: Eşik değeri “threshold” komutu ile 100 olarak belirlenmiştir. Ardından gri tonlamalı görüntüdeki piksel değerlerinin belirlenen eşik değerinden büyük olanları seçtirilerek görüntü siyah ve beyaz olmak üzere ikili (binary) görüntüye (Şekil 3.13) çevrilmiştir.



Şekil 3.13. İkili (binary) görüntü

Adım 4: Bağlı bileşenler (nesneler) “bwlabel” komutu ile 2 boyutlu ikili (binary) görüntüde etiketlenmiştir.

Adım 5: Bir görüntüdeki her nesne (bağlı bileşen) için alan (area), merkez (centroid) ve sınırlayıcı kutu (boundingbox) gibi özellikleri ölçmeye yarayan “regionprops” komutu kullanılmıştır. Görüntüdeki nesnelerin hacimsel özelliklerini ölçmek için “Area” özelliği seçilmiştir.

Adım 6: Daha sonra nesne alanları hesaplatılıp belirlenen çarpan değeri ile çarpılarak her bir nesnenin gram değerleri çıkartılmıştır. İşlemeye tabi olan her bir görüntüdeki salkım üzerinde bulunan tane sayıları gerçek nesne sayısı olarak girilmiştir.

Adım 7: Algılanmış nesne sayısı ve gerçek nesne sayıları ekrana yazdırılmıştır.

Adım 8: Her bir nesnenin gram olarak bulunan ağırlıkları “sum” komutu kullanılarak toplam gram ağırlık elde edilmiştir.

Adım 9: Verim değeri, elde edilen toplam gram ağırlığının gerçek nesne sayısına bölünmesi ile bulunmuştur.

$$Salkım Verim = \frac{\text{Elde edilen toplam gram ağırlığı}}{\text{Gerçek nesne sayısı}}$$

Adım 10: Sonuç olarak her bir görüntünün işleme ile elde edilen verim değeri ekrana yazdırılmıştır.

Algoritama

```
>>image = imread('salkım.jpg');  
  
>> gray_image = rgb2gray(image);  
  
>> threshold = 100;  
  
>> binary_image = gray_image > threshold;  
  
>> labeled_image = bwlabel(binary_image);  
  
>> stats = regionprops(labeled_image, 'Area');  
  
>> nesne_alanlari_gram = [stats.Area] * 0.1;  
  
>> gercek_nesne_sayisi = 20;  
  
>> algılanmis_nesne_sayisi = length(nesne_alanlari_gram);  
  
>> algılanmis_nesne_sayisi = length(nesne_alanlari_gram);  
  
>> toplam_agirlik_gram = sum(nesne_alanlari_gram);  
  
>> verim_gram = toplam_agirlik_gram / gercek_nesne_sayisi;  
  
>> fprintf('Algılanan Nesne Sayısı: %d\n', algılanmis_nesne_sayisi);  
  
>> fprintf('Gerçek Nesne Sayısı: %d\n', gercek_nesne_sayisi);  
  
>> fprintf('Toplam Nesne Ağırlığı (gram): %.2f\n', toplam_agirlik_gram);  
  
>> fprintf('Verim (gram): %.2f\n', verim_gram);
```

3.2.4. Sonuların deęerlendirilmesi

Salkım verimi; toplam tane sayısı ve tane aęırlıęından da tahmin edilebilmektedir. Yapılan iřlemlerin doęruluęunu tespit etmek iin etiketlenen ve fotoęraflanan salkımların hasat zamanı hassas tartı ile aęırlıkları tartılmıřtır (řekil 3.14). Tartılan salkımların sonuları ile grnt iřleme yntemiyle elde edilen sonular karřılařtırılmıřtır.



řekil 3.14. Hasat zamanı hassas tartı ile zm aęırlıklarının tartımı

4. BULGULAR VE TARTIŞMA

Belirtilen yöntem kapsamında bağ alanında Michele Palieri üzüm, İtalya üzüm ve Mevlana üzüm çeşitlerinden alınan 267 adet salkım görüntüsü MATLAB ortamında geliştirilen algoritmalar ile görüntü işlemeye tabi tutulmuştur. Çalışma sonucunda elde edilen bulgular; her çeşit için geleneksel tartım sonucu, görüntü işleme ile olan verim sonuçları ve aralarındaki fark gram cinsinden aşağıdaki çizelgelerde verilmiştir.


Çizelge 4.1. Michele Palieri üzüm çeşidi için sonuçlar

Michele Palieri			
Etiketi	Geleneksel Tartım Ağırlığı(g)	Görüntü İşleme İle Belirlenen Ağırlık(g)	Fark(g)
1-Omca-1. Salkım	1605	1606.73	1.73
1-Omca-2. Salkım	1566	1567.40	1.40
1-Omca-3. Salkım	615	615.54	0.54
1-Omca-4. Salkım	1290	1295.12	5.12
1-Omca-5. Salkım	751	752.52	1.52
1-Omca-6. Salkım	1455	1450.86	-4.14
1-Omca-7. Salkım	827	829.58	2.58
1-Omca-8. Salkım	239	237.57	-1.43
1-Omca-9. Salkım	640	642.11	2.11
1-Omca-10. Salkım	413	407.95	-5.05
1-Omca-11. Salkım	1347	1347.05	0.05
1-Omca-12. Salkım	419	411.90	-7.10
1-Omca-13. Salkım	210	211.35	1.35
1-Omca-14. Salkım	358	351.56	-6.44
1-Omca-15. Salkım	157	154.26	-2.74
1-Omca-16. Salkım	221	220.67	-0.33
1-Omca-17. Salkım	667	660.26	-6.74
1-Omca-18. Salkım	322	323.12	1.12
1-Omca-19. Salkım	1007	1007.14	0.14
1-Omca-20. Salkım	380	386.45	6.45
2-Omca-1. Salkım	950	943.73	-6.27
2-Omca-2. Salkım	555	547.22	-7.78
2-Omca-3. Salkım	141	146.03	5.03
2-Omca-4. Salkım	124	122.68	-1.32
2-Omca-5. Salkım	600	604.64	4.64
2-Omca-6. Salkım	997	993.28	-3.72
2-Omca-7. Salkım	165	166.54	1.54
2-Omca-8. Salkım	409	415.82	6.82
2-Omca-9. Salkım	150	147.50	-2.50
2-Omca-10. Salkım	539	536.27	-2.73
2-Omca-11. Salkım	782	781.11	-0.89
2-Omca-12. Salkım	557	567.62	10.62

3-Omca-1. Salkım	397	404.71	7.71
3-Omca-2. Salkım	551	549.84	-1.16
3-Omca-3. Salkım	598	594.74	-3.26
3-Omca-4. Salkım	600	602.63	2.63
3-Omca-5. Salkım	1024	1031.07	7.07
3-Omca-6. Salkım	533	539.91	6.91
3-Omca-7. Salkım	344	348.87	4.87
3-Omca-8. Salkım	336	339.95	3.95
3-Omca-9. Salkım	460	466.624	6.624
3-Omca-10. Salkım	277	277.90	0.90
3-Omca-11. Salkım	260	265.68	5.68
3-Omca-12. Salkım	289	289.92	0.92
3-Omca-13. Salkım	196	193.52	-2.48
3-Omca-14. Salkım	359	353.97	-5.03
3-Omca-15. Salkım	230	230.86	0.86
3-Omca-16. Salkım	724	722.91	-1.09
3-Omca-17. Salkım	582	591.48	9.48
3-Omca-18. Salkım	1470	1476.08	6.08
3-Omca-19. Salkım	1460	1459.59	-0.41
3-Omca-20. Salkım	392	382.19	-9.81
3-Omca-21. Salkım	733	731.48	-1.52
3-Omca-22. Salkım	510	513.25	3.25
4-Omca-1. Salkım	708	715.22	7.22
4-Omca-2. Salkım	310	301.42	-8.58
4-Omca-3. Salkım	383	383.20	0.20
4-Omca-4. Salkım	540	546.82	6.82
4-Omca-5. Salkım	150	148.80	-1.20
4-Omca-6. Salkım	226	225.04	-0.96
4-Omca-7. Salkım	117	117.00	0.00
5-Omca-1. Salkım	1805	1811.27	6.27
5-Omca-2. Salkım	1040	1042.30	2.30
5-Omca-3. Salkım	726	731.84	5.84
5-Omca-4. Salkım	315	313.95	-1.05
5-Omca-5. Salkım	730	733.72	3.72
5-Omca-6. Salkım	558	550.93	-7.07
5-Omca-7. Salkım	778	769.35	-8.65
5-Omca-8. Salkım	732	728.43	-3.57
5-Omca-9. Salkım	1444	1434.60	-9.40
5-Omca-10. Salkım	546	550.77	4.77
5-Omca-11. Salkım	717	713.87	-3.13
5-Omca-12. Salkım	434	438.59	4.59
5-Omca-13. Salkım	596	603.45	7.45
5-Omca-14. Salkım	210	209.97	-0.03
5-Omca-15. Salkım	5200	5193.93	-6.07
5-Omca-16. Salkım	755	757.12	2.12
5-Omca-17. Salkım	504	501.99	-2.01
5-Omca-18. Salkım	469	475.18	6.18
5-Omca-19. Salkım	536	528.23	-7.77

5-Omca-20. Salkım	1338	1336.82	-1.18
5-Omca-21. Salkım	267	273.54	6.54
5-Omca-22. Salkım	713	717.00	4.00
5-Omca-23. Salkım	800	799.03	-0.97

Michele Palieri üzüm çeşidinden alınan 84 adet salkım görüntüsü MATLAB Image Processing Toolbox modülü ile görüntü işleme tekniği kullanılarak her salkımdaki tane sayısına bağlı olarak verim belirlenmiştir. Hasat zamanı ayrı etiketlenen salkımlar geleneksel yöntemlerle hassas tartı ile tartılmış ve ağırlıkları kaydedilmiştir. Geleneksel tartım sonuçları ile görüntü işleme ile yapılan tahmin sonuçları karşılaştırıldığında, görüntü işleme ile bulunan tahmin sonuçları geleneksel tartım sonuçlarına kıyasla 42.13 g ile yüksek çıkmıştır. Her iki sonuç karşılaştırıldığında birbirlerine çok yakın değerler bulunmuştur (Çizelge 4.1).



Şekil 4.1. Michele Palieri üzüm çeşidinin görüntü işlemeyle elde edilen ağırlık ile geleneksel tartım sonucu arasındaki ilişki

Grafik, ölçümle belirtilen iki değişken arasındaki doğrusal ilişkinin kuvveti ve yönü hakkında bilgi vermiştir. Bu bağlamda grafikteki noktalar Michele Palieri üzüm çeşidinin 84 adet salkım görüntüsünü temsil etmektedir. En küçük kareler yöntemine göre geleneksel tartım (bağımlı değişken) sonuçları ile görüntü işleme (bağımsız değişken) sonucunun değerlendirmesi arasındaki regresyon katsayısı $R^2=0.998$, $p<0.01$; Pearson korelasyon katsayısı: $r=0.999$, $p<0.01$ çok kuvvetli ilişki olarak belirlenmiştir. Görüntü işleme yöntemi ile hesaplanan regresyon denkleminin verilere uyum düzeyi 4.86 olarak bulunmuştur.


Çizelge 4.2. İtalya üzüm çeşidi için sonuçlar

İtalya			
Etiketi	Geleneksel Tartım Ağırlığı(g)	Görüntü İşleme İle Belirlenen Ağırlık(g)	Fark(g)
1-Omca-1. Salkım	1482	1487.78	5.78
1-Omca-2. Salkım	329	332.48	3.48
1-Omca-3. Salkım	402	399.65	-2.35
1-Omca-4. Salkım	421	411.76	-9.24
1-Omca-5. Salkım	399	391.83	-7.17
1-Omca-6. Salkım	222	226.29	4.29
1-Omca-7. Salkım	862	859.07	-2.93
1-Omca-8. Salkım	720	712.83	-7.17
1-Omca-9. Salkım	360	368.39	8.39
1-Omca-10. Salkım	870	873.84	3.84
1-Omca-11. Salkım	421	425.46	4.46
1-Omca-12. Salkım	376	374.20	-1.80
1-Omca-13. Salkım	361	353.93	-7.07
1-Omca-14. Salkım	357	362.74	5.74
1-Omca-15. Salkım	1092	1096.51	4.51
1-Omca-16. Salkım	982	988.99	6.99
1-Omca-17. Salkım	713	711.79	-1.21
1-Omca-18. Salkım	274	277.52	3.52
1-Omca-19. Salkım	275	276.30	1.30
1-Omca-20. Salkım	383	388.50	5.50
1-Omca-21. Salkım	616	614.38	-1.62
1-Omca-22. Salkım	572	571.13	-0.87
1-Omca-23. Salkım	254	253.27	-0.73
2-Omca-1. Salkım	617	617.98	0.98
2-Omca-2. Salkım	211	211.11	0.11
2-Omca-3. Salkım	463	464.27	1.27
2-Omca-4. Salkım	218	220.12	2.12
2-Omca-5. Salkım	160	158.77	-1.23
2-Omca-6. Salkım	575	578.41	3.41
2-Omca-7. Salkım	618	619.57	1.57
2-Omca-8. Salkım	467	472.95	5.95
2-Omca-9. Salkım	293	294.97	1.97
2-Omca-10. Salkım	391	384.05	-6.95
2-Omca-11. Salkım	276	275.19	-0.81
2-Omca-12. Salkım	94	96.12	2.12
2-Omca-13. Salkım	847	848.62	1.62
2-Omca-14. Salkım	464	465.90	1.90
2-Omca-15. Salkım	269	271.82	2.82
3-Omca-1. Salkım	1954	1951.79	-2.21
3-Omca-2. Salkım	415	419.43	4.43
3-Omca-3. Salkım	300	307.60	7.60

3-Omca-4. Salkım	428	424.48	-3.52
3-Omca-5. Salkım	220	222.80	2.80
3-Omca-6. Salkım	698	697.15	-0.85
3-Omca-7. Salkım	625	618.70	-6.30
3-Omca-8. Salkım	284	283.15	-0.85
3-Omca-9. Salkım	876	874.45	-1.55
3-Omca-10. Salkım	386	389.60	3.60
3-Omca-11. Salkım	349	350.20	1.20
3-Omca-12. Salkım	701	698.36	-2.64
3-Omca-13. Salkım	397	393.95	-3.05
3-Omca-14. Salkım	396	394.61	-1.39
3-Omca-15. Salkım	240	233.34	-6.66
3-Omca-16. Salkım	158	161.96	3.96
3-Omca-17. Salkım	520	516.02	-3.98
3-Omca-18. Salkım	561	564.83	3.83
3-Omca-19. Salkım	788	793.58	5.58
3-Omca-20. Salkım	2957	2960.36	3.36
3-Omca-21. Salkım	311	305.73	-5.27
3-Omca-22. Salkım	368	369.03	1.03
3-Omca-23. Salkım	230	224.40	-5.60
3-Omca-24. Salkım	567	566.93	-0.07
3-Omca-25. Salkım	730	725.45	-4.55
3-Omca-26. Salkım	599	602.03	3.03
3-Omca-27. Salkım	796	792.05	-3.95
3-Omca-28. Salkım	1192	1196.89	4.89
3-Omca-29. Salkım	190	187.35	-2.65
3-Omca-30. Salkım	243	239.52	-3.48
4-Omca-1. Salkım	374	372.79	-1.21
4-Omca-2. Salkım	280	278.00	-2.00
4-Omca-3. Salkım	744	739.37	-4.63
4-Omca-4. Salkım	1022	1024.81	2.81
4-Omca-5. Salkım	357	360.67	3.67
4-Omca-6. Salkım	602	600.14	-1.86
4-Omca-7. Salkım	294	294.81	0.81
4-Omca-8. Salkım	334	337.08	3.08
4-Omca-9. Salkım	480	481.80	1.80
4-Omca-10. Salkım	277	270.44	-6.56
4-Omca-11. Salkım	269	268.83	-0.17
4-Omca-12. Salkım	767	770.82	3.82
4-Omca-13. Salkım	675	678.65	3.65
4-Omca-14. Salkım	392	386.37	-5.63
4-Omca-15. Salkım	614	616.10	2.10
4-Omca-16. Salkım	995	992.56	-2.44
4-Omca-17. Salkım	569	568.73	-0.27
4-Omca-18. Salkım	351	350.59	-0.41
4-Omca-19. Salkım	768	765.11	-2.89
4-Omca-20. Salkım	319	315.65	-3.35
5-Omca-1. Salkım	476	480.54	4.54

5-Omca-2. Salkım	595	598.04	3.04
5-Omca-3. Salkım	657	662.03	5.03
5-Omca-4. Salkım	156	151.62	-4.38
5-Omca-5. Salkım	161	163.02	2.02
5-Omca-6. Salkım	324	322.33	-1.67
5-Omca-7. Salkım	414	414.38	0.38
5-Omca-8. Salkım	635	641.85	6.85
5-Omca-9. Salkım	627	629.44	2.44
5-Omca-10. Salkım	1029	1021.76	-7.24
5-Omca-11. Salkım	502	495.31	-6.69
5-Omca-12. Salkım	298	295.21	-2.79
5-Omca-13. Salkım	159	158.11	-0.89
5-Omca-14. Salkım	254	260.54	6.54
5-Omca-15. Salkım	536	535.40	-0.60
5-Omca-16. Salkım	281	282.28	1.28
5-Omca-17. Salkım	767	764.69	-2.31
5-Omca-18. Salkım	397	396.74	-0.26
5-Omca-19. Salkım	880	877.59	-2.41
5-Omca-20. Salkım	173	173.83	0.83
5-Omca-21. Salkım	680	689.08	9.08
5-Omca-22. Salkım	415	408.94	-6.06
5-Omca-23. Salkım	319	318.52	-0.48

İtalya üzüm çeşidinden alınan 111 adet salkım görüntüsü MATLAB Image Processing Toolbox modülü ile görüntü işleme tekniği kullanılarak her salkımdaki tane sayısına bağlı olarak verim belirlenmiştir. Hasat zamanı ayrı etiketlenen salkımlar geleneksel yöntemlerle hassas tartı ile tartılmış ve ağırlıkları kaydedilmiştir. Geleneksel tartım sonuçları ile görüntü işleme ile yapılan tahmin sonuçları karşılaştırıldığında, görüntü işleme ile bulunan tahmin sonuçları geleneksel tartım sonuçlarına kıyasla 15.80 g ile yüksek çıkmıştır. Her iki sonuç yukarıda verilen çizelgede karşılaştırıldığında birbirlerine çok yakın değerler bulunmuştur (Çizelge 4.2).



Şekil 4.2. İtalya üzüm çeşidinin görüntü işlemeyle elde edilen ağırlık ile geleneksel tartım sonucu arasındaki ilişki

Grafik, ölçümle belirtilen iki değişken arasındaki doğrusal ilişkinin kuvveti ve yönü hakkında bilgi vermiştir. Bu bağlamda grafikteki noktalar İtalya üzüm çeşidinin 111 adet salkım görüntüsünü temsil etmektedir. Görüntü işleme sonuçları ile geleneksel tartım sonucunun değerlendirmesi arasındaki regresyon katsayısı $R^2=0.997$, $p<0.01$; Pearson korelasyon katsayısı: $r=0.998$, $p<0.01$ çok kuvvetli ilişki olarak belirlenmiştir. Görüntü işleme yöntemi ile hesaplanan regresyon denkleminin verilere uyum düzeyi 4.00 olarak bulunmuştur.


Çizelge 4.3. Mevlana üzüm çeşidi için sonuçlar

Mevlana			
Etiketi	Geleneksel Tartım Ağırlığı(g)	Görüntü İşleme İle Belirlenen Ağırlık(g)	Fark(g)
1-Omca-1. Salkım	255	257.14	2.14
1-Omca-2. Salkım	407	403.90	-3.10
1-Omca-3. Salkım	599	604.33	5.33
1-Omca-4. Salkım	511	516.35	5.35
1-Omca-5. Salkım	266	269.99	3.99
1-Omca-6. Salkım	150	149.71	-0.29
1-Omca-7. Salkım	552	550.82	-1.18
1-Omca-8. Salkım	240	236.12	-3.88
1-Omca-9. Salkım	189	185.26	-3.74
1-Omca-10. Salkım	220	225.77	5.77
1-Omca-11. Salkım	199	196.92	-2.08
1-Omca-12. Salkım	321	317.61	-3.39

1-Omca-13. Salkım	252	259.72	7.72
1-Omca-14. Salkım	207	207.76	0.76
1-Omca-15. Salkım	84	89.84	5.84
2-Omca-1. Salkım	556	552.55	-3.45
2-Omca-2. Salkım	446	452.44	6.44
2-Omca-3. Salkım	136	135.93	-0.07
2-Omca-4. Salkım	266	262.74	-3.26
2-Omca-5. Salkım	75	75.32	0.32
2-Omca-6. Salkım	177	177.79	0.79
2-Omca-7. Salkım	449	446.70	-2.30
2-Omca-8. Salkım	87	80.70	-6.30
2-Omca-9. Salkım	159	156.06	-2.94
2-Omca-10. Salkım	214	215.21	1.21
2-Omca-11. Salkım	308	307.85	-0.15
2-Omca-12. Salkım	106	106.81	0.81
2-Omca-13. Salkım	171	171.78	0.78
3-Omca-1. Salkım	1132	1131.58	-0.42
3-Omca-2. Salkım	220	219.79	-0.21
3-Omca-3. Salkım	422	424.98	2.98
3-Omca-4. Salkım	203	201.30	-1.70
3-Omca-5. Salkım	470	469.18	-0.82
3-Omca-6. Salkım	383	385.94	2.94
3-Omca-7. Salkım	133	133.47	0.47
3-Omca-8. Salkım	262	266.00	4.00
3-Omca-9. Salkım	371	367.45	-3.55
3-Omca-10. Salkım	318	317.62	-0.38
3-Omca-11. Salkım	62	62.49	0.49
3-Omca-12. Salkım	265	263.46	-1.54
4-Omca-1. Salkım	154	155.50	1.50
4-Omca-2. Salkım	418	420.18	2.18
4-Omca-3. Salkım	165	164.25	-0.75
4-Omca-4. Salkım	78	82.69	4.69
4-Omca-5. Salkım	97	98.35	1.35
4-Omca-6. Salkım	203	204.56	1.56
4-Omca-7. Salkım	130	134.27	4.27
4-Omca-8. Salkım	147	145.24	-1.76
4-Omca-9. Salkım	85	82.89	-2.11
4-Omca-10. Salkım	252	254.45	2.45
4-Omca-11. Salkım	199	198.94	-0.06
4-Omca-12. Salkım	425	425.22	0.22
4-Omca-13. Salkım	302	305.84	3.84
4-Omca-14. Salkım	487	489.01	2.01
4-Omca-15. Salkım	432	427.91	-4.09
4-Omca-16. Salkım	189	189.66	0.66
4-Omca-17. Salkım	401	399.70	-1.30
4-Omca-18. Salkım	276	276.83	0.83
4-Omca-19. Salkım	283	282.91	-0.09
4-Omca-20. Salkım	48	48.03	0.03

4-Omca-21. Salkım	99	95.20	-3.80
4-Omca-22. Salkım	269	271.53	2.53
4-Omca-23. Salkım	222	221.98	-0.02
5-Omca-1. Salkım	180	179.34	-0.66
5-Omca-2. Salkım	78	74.95	-3.05
5-Omca-3. Salkım	103	102.39	-0.61
5-Omca-4. Salkım	262	264.01	2.01
5-Omca-5. Salkım	130	129.24	-0.76
5-Omca-6. Salkım	80	78.81	-1.19
5-Omca-7. Salkım	200	199.99	-0.01
5-Omca-8. Salkım	74	74.45	0.45
5-Omca-9. Salkım	575	570.19	-4.81


Mevlana üzüm çeşidinden alınan 72 adet salkım görüntüsü MATLAB Image Processing Toolbox modülü ile görüntü işleme tekniği kullanılarak her salkımdaki tane sayısına bağlı olarak verim belirlenmiştir. Hasat zamanı ayrı etiketlenen salkımlar geleneksel yöntemlerle hassas tartı ile tartılmış ve ağırlıkları kaydedilmiştir. Geleneksel tartım sonuçları ile görüntü işleme ile yapılan tahmin sonuçları karşılaştırıldığında, görüntü işleme ile bulunan tahmin sonuçları geleneksel tartım sonuçlarına kıyasla 18.89 g ile yüksek çıkmıştır. Her iki sonuç yukarıda verilen çizelgede karşılaştırıldığında birbirlerine çok yakın değerler bulunmuştur.



Şekil 4.3. Mevlana üzüm çeşidinin görüntü işlemeyle elde edilen ağırlık ile geleneksel tartım sonucu arasındaki ilişki

Grafik, ölçümle belirtilen iki değişken arasındaki doğrusal ilişkinin kuvveti ve yönü hakkında bilgi vermiştir. Bu bağlamda grafikteki noktalar Mevlana üzüm çeşidinin 72 adet salkım görüntüsünü temsil etmektedir. En küçük kareler yöntemine göre geleneksel tartım (bağımlı değişken) sonuçları ile görüntü işleme (bağımsız değişken) sonucunun değerlendirilmesi arasındaki regresyon katsayısı $R^2=0.996$, $p<0.01$; Pearson korelasyon katsayısı: $r=0.997$, $p<0.01$ çok kuvvetli ilişki olarak belirlenmiştir. Görüntü işleme yöntemi ile hesaplanan regresyon denkleminin verilere uyum düzeyi 2.88 olarak bulunmuştur.

Çizelgelerde incelendiğinde görüntü işleme ile elde edilen sonuçlar ile tartım sonuçları karşılaştırılmış ve birbirine çok yakın değerler bulunmuştur. Ölçümleri yapılmış olan salkımların 3 çeşidin toplam regresyon grafiği Şekil 4.4'te gösterilmiştir.



Şekil 4.4. Görüntü işlemeyle elde edilen ağırlık ile geleneksel tartım sonucu arasındaki ilişki

Verilen grafikte geleneksel tartım sonucu ve görüntü işleme tekniği ile belirlenen ağırlık değerlerini karşılaştırınca birbirine çok kuvvetli ilişki olduğu ve doğrusal bir grafik oluşturduğu görülmektedir. Grafikteki noktalar 267 adet salkım görüntüsünü temsil etmektedir. Görüntü işleme sonuçları ile geleneksel tartım sonucunun değerlendirilmesi arasındaki regresyon katsayısı $R^2=0.998$, $p<0.01$; Pearson korelasyon katsayısı: $r=0.999$, $p<0.01$ olarak belirlenmiştir. Görüntü işleme yöntemi ile hesaplanan regresyon denkleminin verilere uyum düzeyi 4.04 olarak bulunmuştur.

Grafikler genel olarak incelediğinde, Mevlana üzümün diğer çeşitlerden daha iyi tahmin değeri elde ettiği görülmüştür. Tüm üzüm çeşitleri birlikte değerlendirildiğinde sonuçların geleneksel tartım yöntemine çok yakın değerler elde edilmiştir. Görüntü işleme yönteminin başarı ile üzüm veriminin tahmin edilmesinde kullanılabileceği sonucuna varılmıştır.

Çalışmada elde edilen sonuçlar literatürde bulunan üzüm veriminin tahmin edilmesi için görüntü işleme yaklaşımları ile karşılaştırılmış ve farklı yöntemlerin verim tahmini üzerindeki etkisi değerlendirilmiştir. Liu ve ark. (2013) üzüm salkımlarının ağırlığını tahmin etmek amacıyla görüntü analizi ve özellik çıkarımı kullanarak bir doğrusal regresyon yaklaşımı geliştirmişlerdir. Bu yöntem, tane sayısı, salkım çevresi, salkım alanı ve tahmini salkım hacmi gibi özellikleri kullanarak ideal koşullarda %5.3'lük bir doğruluk elde etmiştir. Diago ve ark. (2014) ise üzüm küme verim bileşenlerini görüntü analizi ile belirlemek için Canny ve logaritmik görüntü işleme algoritmalarını kullanmışlardır. Bu çalışma, farklı üzüm küme verileri ve asma çeşitleri üzerinde gerçekleştirilmiştir. Sonuçlar, görüntü analizine dayalı olarak meyve ağırlığının %84 doğrulukla tahmin edilebildiğini göstermektedir. Nuske ve ark. (2014) bağlardaki üzüm verimini yüksek çözünürlüklü görüntülerle otomatik olarak tahmin etmişlerdir. Bu çalışmada, renk, doku ve şekil özellikleri kullanılarak güçlü bir sınıflandırıcı geliştirilmiş ve büyük veri kümeleri üzerinde deneyler yapılmıştır. Sonuçlar, mekânsal verim varyansının %75'ine kadar ve toplam verimin %3 ila %11'i arasında bir ortalama hata ile verim tahmin edilebildiğini göstermektedir. Bu çalışmalar, üzüm yetiştiriciliği ve bağcılık alanında görüntü analizi ve özellik çıkarma potansiyelini ortaya koymaktadır. Ancak, farklı çalışmaların sonuçları arasındaki farklılıkların yöntem farklılıkları, veri farklılıkları, donanım ve yazılım farklılıkları, veri miktarı ve çeşitliliği, güncel teknoloji ve algoritmalar gibi bir dizi faktörden kaynaklandığı göz önüne alınmalıdır. Sonuç olarak, görüntü işleme yönteminin üzüm verim tahmini için güçlü bir araç olabilmesi için tutarlı bir performansın sağlanması kritik öneme sahiptir. İstenen bu performansın sağlanabilmesi için görüntüleme araçları, algoritma sağlamlığı, aydınlatma ve görüntüleme koşulları gibi diğer faktörler optimize edilmelidir.

Literatürde çeşitli tarım ürünlerinin verim tahminini gerçekleştirmeyi amaçlayan bir dizi çalışmada bulunmaktadır. Bu çalışmalar, farklı ürün türlerine (örneğin üzüm, çilek, elma, biber vb.) odaklansa da temel hedefleri, hasat öncesi veya sonrası dönemlerde verim tahminlerini yapmak ve bu bilgiyi yönetim kararlarını desteklemek olarak öne çıkmaktadır. Bu amaç doğrultusunda, görüntü işleme teknikleri kullanılarak bitki veya meyve görüntüleri analiz edilmekte ve elde edilen analizler aracılığıyla verim tahminleri yapılmaktadır. Görüntülerin

renk, şekil ve dokusu gibi özellikleri, bu tahminlerin temel belirleyicileri olarak öne çıkmaktadır.

Her bir çalışma, farklı görüntü işleme teknikleri ve makine öğrenme algoritmalarını benimsemiştir. Bazı çalışmalar özel olarak tasarlanmış modelleri (örneğin CNN-RNN) kullanırken, diğerleri popüler algoritmaları (örneğin YOLO, Faster-RCNN) tercih etmiştir. Bu farklı model ve algoritmaların kullanımı, verim tahmini hatalarının ve başarı oranlarının değişmesine yol açmaktadır. Bu çalışmalarda, farklı veri setleri kullanılmıştır. Görüntüler farklı zaman aralıklarında toplanmış olabileceği gibi, farklı bitki aşamalarına ait görüntüleri de içerebilmektedir. Bazı çalışmaların amacı, elde edilen verim tahmin sonuçlarını tarımsal kararlar için kullanmak iken, diğerleri özellikle robotik hasat veya işgücü yönetimi gibi belirli uygulama alanlarına odaklanmıştır.

5. SONUÇ VE ÖNERİLER

Son yıllarda hızlı gelişen teknolojik ilerlemeler ile birlikte tarımsal alanda, bitki tanıma ve sınıflandırma, hasat ve kalite kontrolü, yabancı ot tespiti, mahsul tahmini ve verim analizi gibi birçok işlemin hızlı ve otomatik olarak gerçekleştirilmesi için görüntü işleme teknikleri yaygın olarak kullanılmaktadır. Bu çalışmada ise, görüntü işleme yöntemi kullanılarak üç farklı üzüm çeşidinde üzüm verimi belirlenmiştir. Çalışmada, üzüm salkımlarının boyutu, rengi, yaprak sağlığı gibi faktörler dikkate alınarak ve görüntü işleme yönteminin yanında makine öğrenmesi yöntemlerinin de eklenmesi ile üzüm veriminin tahmini daha yüksek başarı ile belirlenebilmesi mümkündür. Bu sayede, çiftçilere hasat zamanlamasını optimize etme, kaynakları daha verimli kullanma ve üzüm üretimini artırma vb. konularda önemli bir avantaj sağlamaktadır. Bu bağlamda, görüntü işleme ile üzüm veri tahmini, modern tarımın sürdürülebilirlik ve verimlilik hedeflerine ulaşmasında önemli bir adım olarak öne çıkmaktadır.

Çalışmada, farklı üzüm çeşitleri arasındaki salkım morfolojisindeki büyük değişkenlik, farklı koşullara uyarlanmış farklı çeşitler için özelleştirilmiş modellerin oluşturulmasının temelini oluşturmuştur. Çalışma, görüntü işleme yöntemi ile üzüm verim tahmininde etkili bir yol olduğunu ortaya koymuştur. Ayrıca bu yöntem düşük maliyeti, yüksek doğruluk ve hızı ile mevcut manuel ölçümlere göre daha iyi bir alternatif sunmaktadır.

Çalışma sonucunda görüntü işleme ile verim tahmini, otomatik veri odaklı olmasının yanı sıra zamandan, insan iş gücünden bağımsız tahmin değerleri sağlamıştır. Bu çalışma elde edilen verim tahminleri hasat dönemini ve ürün pazarlamasını planlamayı, tarım kaynaklarının daha etkin ve verimli bir şekilde yönetilmesi ile bağcılara bilgi sağlaması düşünülmektedir.

Gerçek yetiştirme ortamında çalışılmasından kaynaklı aydınlatma gücü, aydınlatma dağıtımı ve asma yapraklarından kaynaklanan yansımalar gibi bir dizi faktör, görüntü yakalamada önemli zorluklar oluşturmuştur. Kameranin değişken pozisyonu, pozlama süresine bağlı hareket bulanıklığı, görüntü çözünürlüğü ve meyve tespiti için gereken net görüntü kalitesi gibi faktörler bu zorlukların ana nedenlerindendir. Belirli bir platform kurularak bu faktörlerden kaynaklanan hatalar en aza indirgenmesi sağlanabilir.

Üzüm veriminin görüntü işleme veya makine öğrenmesi yöntemleri ile otomatik olarak belirlenmesi ve sonrasında hasat işlemlerinin de otomatik olarak robotlar tarafından yapılması mümkündür. Bu amaçla tarımsal üretim alanlarında kullanılan sensör ağları verilerinin görüntü işleme teknikleriyle entegre edilerek, hasat robotları için verimli bir sistem oluşturulabilir. Bu

yaklaşım, robotların sahadaki çevreyi daha iyi anlamasına ve daha doğru tahminler yapabilmesine olanak tanırken, tarım endüstrisinin daha verimli ve bilinçli kararlar almasına yardımcı olabilmektedir. Geliştirilen yöntem veya sistemlerin performansını artırmak amacıyla, optimal ışık koşullarında ve yüksek kaliteli lenslerle elde edilen görüntülerin kullanılması, analiz sonuçlarının kesinliğini artırabilmektedir. Bu, görüntüleme sistemlerinin sahadaki veri toplama yeteneklerini optimize ederek, sonuçların güvenilirliğini artırabilir. Gelecekteki çalışmalar, genel bir yaklaşım benimseyerek daha kapsamlı sonuçlar sunabilmek adına daha geniş ve çeşitli veri setlerinin toplanmasına odaklanabilir. Bu veri setleri, farklı mevsimler, iklim koşulları ve üzüm çeşitleri gibi değişkenleri içermelidir. Bu şekilde, elde edilen tahmin modelleri çeşitli senaryolara daha iyi adapte olabilme ve daha genel sonuçlar üretebilme potansiyeline sahip olacaktır.



6. KAYNAKLAR

- Abd-Elrahman, A., Wu, F., Agehara, S. ve Britt, K., 2021. Improving Strawberry Yield Prediction By Integrating Ground-Based Canopy Images in Modeling Approaches. ISPRS Int. J. Geo-Inf. 10(4), 239. Doi: <https://doi.org/10.3390/ijgi10040239>.
- Alibabaei, K., Gaspar, P. D. ve Lima, T. M., 2021. Crop Yield Estimation Using Deep Learning Based on Climate Big Data and Irrigation Scheduling. Energies, 14(11), 3004. Doi: <https://doi.org/10.3390/en14113004>.
- 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 Yanar, Y., 2019. Bitki Hastalık ve Zararlı Düzeylerinin Belirlenmesinde Görüntü İşleme Tekniklerinin Kullanımı: Şeker Pancarı Yaprak Leke Hastalığı Örneği. International Erciyes Agriculture, Animal Food Sciences Conference 24-27.
- Anonim, 2020a. Üzüm Değerlendirme Raporu. <https://www.tarimorman.gov.tr>. (Erişim Tarihi: 21.05.2023).
- Anonim, 2020b. Görüntü İşleme Nedir ve Nerelerde Kullanılır?. <https://www.ceyrekmuhendis.com/goruntu-isleme-nedir-ve-nerelerde-kullanilir/>. (Erişim Tarihi: 18.05.2023).
- Anonim, 2020c. Sofralık ve Şaraplık Üzüm Çeşitleri. <https://isparta.tarimorman.gov.tr/>. (Erişim tarihi:03.08.2023).
- Anonim, 2022. Tarım Ürünleri Piyasaları. <https://arastirma.tarimorman.gov.tr/>. (Erişim Tarihi: 04.08.2023).
- Anonim, 2023. Üzüm İstatistikleri. <https://www.statagri.com/uzum-istatistikleri/>. (Erişim Tarihi:04.08.2023).
- Anonim, 2019. <https://www.tarimorman.gov.tr> (Erişim Tarihi: 21.05.2023).
- Ataç, Ş. ve Kayabaşı, A., 2023. Görüntü İşlemeye Dayalı Yapay Zekâ Teknikleri Kullanılarak Rekolte Tahmini: Elma Ağacı Uygulaması. Karamanoğlu Mehmetbey Üniversitesi, Mühendislik ve Doğa Bilimleri Dergisi, 5(1), 67-84.
- Bashimov, G., 2017. Türkiye’de Üzüm Üretimi ve İhracat Performansı. Uludağ Üniversitesi Ziraat Fakültesi Dergisi, Cilt 31, Sayı 2, 57-68.
- Behrooz-Khazaei, N. ve Maleki, M. R., 2017. A Robust Algorithm Based On Color Features for Grape Cluster Segmentation. Computers and Electronics in Agriculture 142 (2017) 41–49.
- Bhookya, N. N., Malmathanraj, N. ve Palanisamy, P., 2020. Yield Estimation of Chilli Crop Using Image Processing Techniques. 6th International Conference on Advanced Computing and Communication Systems (ICACCS). Coimbatore, Hindistan. Doi: 10.1109/ICACCS48705.2020.9074257.
- Binici, T., Gürsöz, S., Odabaşıoğlu, M. İ. ve Palabıçak, M. A., 2021. Trc3 Bölgesi’nde Bağcılığın Geliştirilmesi Raporu. Dicle Kalkınma Ajansı, Mardin.
- Diago, M. P., Tardaguila, J., Aleixos, N., Millan, B., Prats-Montalban, J.M., Cubero, S. ve Blasco, J., 2014. Assessment of Cluster Yield Components By Image Analysis. DOI 10.1002/jsfa.6819.
- Dorj, U. O., Lee, M. ve Yun, S. S., 2017. An yield estimation in citrus orchards via fruit detection and counting using image processing. Computers and Electronics in Agriculture 140 (2017) 103–112. Doi: <https://doi.org/10.1016/j.compag.2017.05.019>.

- Gennaro, S.F.D., Toscano, P., Cinat, P., Berton, A. ve Matese, A., 2019. A Low-Cost and Unsupervised Image Recognition Methodology for Yield Estimation in a Vineyard. Doi: 10.3389/fpls.2019.00559.
- Gözener, B., Kaya, Y. ve Sayılı, M., 2014. Erzincan İli Üzümlü İlçesinde Cimin Üzümü Üretimi ve Pazarlama Durumu. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 9, 74-80.
- Haki, S., Wang, L. ve Archontoulis, S.V., 2020. A CNN-RNN Framework for Crop Yield Prediction. *Computational Genomics* Cilt 10. Doi: <https://doi.org/10.3389/fpls.2019.01750>.
- Kahya, E. (2022), Robotik Hasat İçin Örnek Görüntü İşleme Uygulamaları. Türkiye’de Sürdürülebilir Tarım Uygulamaları: Zorluklar ve Potansiyeller, Editörler: M. F. Baran. K. Bellitürk. A. Çelik. İksadyayinevi, Türkiye, 190-227. Kaya, Y., Polat, N., 2021. Sulu ve Kuru Tarım Alanlarında Buğday Verim Tahmininde Bitki Örtüsü İndekslerinin Kullanımı. *Türk Tarım ve Doğa Bilimleri Dergisi* 8(3): 736–746.
- Kaya, Y. ve Polat, N., 2021. Sulu ve Kuru Tarım Alanlarında Buğday Verim Tahmininde Bitki Örtüsü İndekslerinin Kullanımı. *Türk Tarım ve Doğa Bilimleri Dergisi* 8(3), 736–746.
- Kaymak, A.M., Örnek, M.N ve Kahramanlı, H., 2019. Görüntü İşleme Teknolojilerinin Elma Bahçelerine Yönelik Kullanım Örneği. *Uluborlu Mesleki Bilimler Dergisi* 2 (1), 17-26.
- Kılıç, D., 2021. Bursa İlinde Farklı Ekolojilerde Yetiştirilen Alphonse Lavallée Üzüm Çeşidinde Verim ve Kalite Özelliklerinin Belirlenmesi. *Uludağ Üniversitesi, Fen Bilimleri Enstitüsü, Bahçe Bitkileri Anabilim Dalı, Yüksek Lisans Tezi, Bursa.*
- Liu, S., Marden, S. ve Whitty, M., 2013. Towards Automated Yield Estimation in Viticulture. *Proceedings of Australasian Conference on Robotics and Automation*, University of New South Wales, Sydney Australia.
- MathWorks, 2008. MATLAB for Image Processing. The MathWorks Training Services. By The MathWorks, Inc.
- Millan, B., Velasco-Forero, S., Aquino, A. and Tardaguila, J., 2018. On-the-Go Grapevine Yield Estimation Using Image Analysis and Boolean Model. *Hindawi Journal of Sensors*. Volume 2018, Article ID 9634752, 14 pages. <https://doi.org/10.1155/2018/9634752>.
- Nuske, S., Achar, S., Bates. T., Narasimhan. S. ve Singh. S., 2011. Yield Estimation in Vineyards By Visual Grape Detection. *IEEE/RSJ International Conference on Intelligent Robots and Systems*.
- Nuske, S., Wilshusen, K., Achar, S., Yoder, L., Narasimhan. S. ve Singh. S., 2014. Automated Visual Yield Estimation in Vineyards. *Journal of Field Robotics* 31(5), 837–860. Doi: 10.1002/rob.21541.
- 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. ve Yanar, Y., 2022. The Technology Uses in The Determination of Sugar Beet Diseases. In V., Misra, S., Srivastava ve A. K., Mall (Editörler), *Sugar beet cultivation, management and processing*. Springer, Singapore. https://doi.org/10.1007/978-981-19-2730-0_30
- Ozguven, M.M., 2023. *The Digital Age in Agriculture*. CRC Press Taylor & Francis Group LLC. ISBN 978-103-23-8577-8
- Özgüven, M.M., 2018. Hassas Tarım. Akfon Yayınları, Sayfa Sayısı: 334, Ankara.
- Özgüven, M. M., Türker, U., Akdemir, B., Çolak, A., Acar, A. İ., Öztürk, R. ve Eminoğlu, M. B., 2020. Tarımda Dijital Çağ. Türkiye Ziraat Mühendisliği IX. Teknik Kongresi, Ankara, Türkiye, 13 - 17 Ocak 2020, cilt.1, ss.55-78.
- Özgüven, M.M., 2023. Bahçe Bitkileri Yetiştiriciliğinde Kullanılan Dijital Tarım Teknolojileri. *Tarım Makinaları Bilimi Dergisi*. (Basımda).

- Perihanoğlu, G. M., 2015. Dijital Görüntü İşleme Teknikleri Kullanılarak Görüntülerden Detay Çıkarımı. İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Geomatik Mühendisliği Anabilim Dalı, Yüksek Lisans Tezi, İstanbul.
- Semerci A, Kızıltuğ T, Çelik AD, Kiracı MA, 2015. Türkiye Bağcılığının Genel Durumu. Mustafa Kemal Üniversitesi, Ziraat Fakültesi Dergisi, 20 (2): 42-51.
- Teker, T., 2017. Üzümde Rekolte Tahmini Eğitimi. Manisa Bağcılık Araştırma Enstitüsü Müdürlüğü. İzmir Bölge Eğitimi.
- Terzi, İ., Özgüven, M.M. ve Yağcı, A., 2023. Derin Öğrenme Teknikleri ile Bazı Üzüm Çeşitlerinin Tespiti. Türk Tarım – Gıda Bilim ve Teknoloji Dergisi, 11(1), 125-130.
- TÜİK, 2023. Bitkisel Üretim İstatistikleri. http://www.tuik.gov.tr/PreTablo.do?alt_id=1001. (Erişim tarihi:04.08.2023).
- Wang, J., Zhang, Z., Luo, L., Zhu, W., Chen, J. and Wang, W., 2021. SwinGD: A Robust Grape Bunch Detection Model Based on Swin Transformer in Complex Vineyard Environment. Horticulturae, 7, 492. <https://doi.org/10.3390/horticulturae7110492>.
- Wevers, M. ve Smits, T., 2019. The Visual Digital Turn: Using Neural Networks To Study Historical Images. Oxford University. Digital Scholarship in the Humanities, Vol. 35, No. 1.
- Yaşar, G., 2017. İyi Tarım Uygulamaları: Migros Ticaret Anonim Şirketi Örneği, KSBD, 9(2): 503-524.
- Yılmaz, H.M., Mutluoğlu, Ö., Ulvi, A., Yaman, A. ve Bilgilioğlu, S.S., 2018. İnsansız Hava Aracı İle Ortofoto Üretimi Ve Aksaray Üniversitesi Kampüsü Örneği, Geomatik Dergisi, 3,2,103-110.
- Yılmaz, M., 2016. Görüntü İşleme Teknikleri İle Zirai Tuzaklardaki Böcek Adedi Tespiti. Maltepe Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı, Yüksek Lisans Tezi, İstanbul.

7.ÖZGEÇMİŞ

