

**ANKARA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

YÜKSEK LİSANS TEZİ

**GÖRÜNTÜ İŞLEME TEKNİKLERİ KULLANILARAK BAZI MEYVELERİN
SINIFLANDIRILMASI**

Dilara GERDAN

**TARIM MAKİNALARI VE TEKNOLOJİLERİ MÜHENDİSLİĞİ ANABİLİM
DALI**

**ANKARA
2020**

Her hakkı saklıdır

ÖZET

Yüksek Lisans Tezi

GÖRÜNTÜ İŞLEME TEKNİKLERİ KULLANILARAK BAZI MEYVELERİN SINIFLANDIRILMASI

Dilara GERDAN

Ankara Üniversitesi
Fen Bilimleri Enstitüsü

Tarım Makinaları ve Teknolojileri Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Mustafa VATANDAŞ

Bu tez çalışmasında, meyvelerin boyut ve renk özelliklerine göre sınıflandırılması amacıyla bir görüntü işleme algoritması sınıflandırma düzeni geliştirilmiştir. Bu amaçla meyve çeşidi olarak, Starkrimson Delicious ve Golden Delicious elma çeşitleri, Washington Navel ve Valencia Midnight portakal çeşitleri ile Ekmek ve Eşme ayva çeşitlerinden 50'şer örnek seçilerek toplam 300 meyve denemeye alınmıştır. Kumpas ve spektrofotometre ile okunan boyut ve renk değerleri, geliştirilen görüntü işleme algoritmasına girilerek meyveleri doğru sınıflama başarısı belirlenmiştir. Görüntü işleme algoritmasının sınıflandırma ünitesi entegrasyonu, meyveleri boyutlarına göre sınıflandırma başarısı Starkrimson Delicious çeşidinde % 88, Golden Delicious elma çeşidinde % 100, Washington Navel çeşidinde % 96, Valencia Midnight çeşidinde % 82 bulunmuştur. Ayva sınıflandırma işleminde, TS 1817' de sınıflandırmanın ağırlıklara göre yapıldığı göz önüne alınarak her bir ayva hassas terazide tartılmış, boyutlar ile ağırlık arasındaki ilişkiler ortaya konulmuştur. Sınıflandırma işlemi, her iki çeşit için en küçük ve en büyük çap değerlerinin belirlenip, algoritmaya kumpasla okunan çap ölçülerinin alt ve üst limit değerleri girilerek yapılmıştır. Bu yöntemle, Ekmek ayva çeşidinde % 95, Eşme ayva çeşidinde ise sınıflama başarısı % 86 bulunmuştur. Her bir renk kanalı için, spektrofotometreden alınan alt ve üst limit değerleri algoritmaya girildiğinde elma çeşitlerinin birbirleri arasında renk bakımından sınıflara ayrılmasında başarı elma çeşitleri içinde % 100 bulunmuştur.

Diğer taraftan görüntü işleme algoritmasıyla meyvelerde okunan boyut ve renk değerleri, veri madenciliğinde kullanılan tahminleyici teknikler kullanılarak değerlendirilmiştir. Bu amaçla, K En Yakın Komşuluk (KNN), Karar Ağacı (DT), Naive Bayes sınıflandırma ve Çok Katmanlı Algılayıcı Sinir Ağı (MLP) algoritmalarından yararlanılmıştır. Algoritmalar 10-kez çapraz doğrulama yöntemi ile çalıştırılmıştır. Ayrıca üst öğrenme algoritmalarından Rastgele Orman (RO) yöntemi seçilmiştir. Yapay sınıflandırıcıların eğitilerek denenmesinde ise boyut ve renk ölçümlerinin doğru meyve sınıfını tahminleme başarısı, KNN için % 93,6, DT için % 90,3, Naive Bayes % 88,3, MLP % 92,6 ve RO için % 94,3 bulunmuştur.

Mayıs 2020, 154 sayfa

Anahtar kelimeler: Meyve sınıflandırma, Görüntü işleme, Veri madenciliği

ABSTRACT

Master Thesis

CLASSIFICATION OF SOME FRUITS BY USING IMAGE PROCESSING TECHNIQUES

Dilara GERDAN

Ankara University
Graduate School of Natural and Applied Sciences
Department of Agricultural Machinery and Technologies Engineering

Supervisor: Prof. Dr. Mustafa VATANDAŞ

In this thesis, an image processing algorithm and classification unit were developed to classify the fruits according to their size and color characteristics. For this purpose, a total of 300 fruits (50 fruit samples from each of the Starkrimson Delicious and Golden Delicious apple varieties, Washington Navel and Valencia Midnight orange varieties, Ekmek and Eşme quince varieties) were used in the experiments. The size and color values measured with a caliper and a spectrophotometer were entered in the developed image processing algorithm to determine the success rates of classifying the fruits. The integration of image processing algorithm with the classification unit classified 88% of the Starkrimson Delicious variety, 100% of the Golden Delicious apple variety, 96% of the Washington Navel variety, and 82% of the Valencia Midnight variety successfully. In the quince classification process, taking into consideration that the classification was made according to the weights in TS 1817 standard, each quince was weighed on a precision scale and the relationship between dimension and weight was determined. The smallest and largest diameters for both quince varieties were determined, then the highest and lowest diameters of each fruit were entered in the algorithm for classification. The success rates of classification with this method were found to be 95% for Ekmek and 86% for Eşme quince varieties, respectively. For each color channel, when the upper and lower limit values from the spectrophotometer were entered in the algorithm, the classification success was found to be 100% for the apple varieties.

On the other hand, the size and color values of fruits with image processing algorithm were also evaluated by using estimation techniques in data mining. For this purpose, K Nearest Neighbor (KNN), Decision Tree (DT), Naive Bayes classification and Multi-Layer Perceptron Neural Network (MLP) algorithms were used. The algorithms were run using 10-fold cross-validation method. In addition, Random Forest (RO) method was chosen from the meta learning algorithms. The successes of predicting the correct fruit class and color measurements in training and testing of artificial classifiers were 93.6% for KNN, 90.3% for DT, 88.3% for Naive Bayes, 92.6% for MLP and 94.3% for RO, respectively.

May 2020, 154 pages

Key Words: Fruit classification, Image processing, Data mining

TEŐEKKÖR

Bu alıŐmanın gerekleŐtirilmesinde destek olan, akademik hayatıma ıŐık tutan, araŐtırmalarımın her aŐamasında bilgi, tavsiye ve katkılarıyla yÖnlendiren, ÖĐrencisi olmaktan onur duyduĐum danıŐman hocam Sayın Prof. Dr. Mustafa VATANDAŐ'a (Ankara Öniversitesi Tarım Makinaları ve Teknolojileri MÖhendisliĐi ABD) sonsuz Őükranlarımı sunarım. Ayrıca beni "GÖrüntü İŐleme" konusuyla tanıştıran, alıŐmalarım sırasında Önemli katkılarda bulunan ve yÖnlendiren Sayın Do. Dr. Abdullah BEYAZ'a, (Ankara Öniversitesi Tarım Makinaları ve Teknolojileri MÖhendisliĐi ABD) teŐekkür ederim.

Dilara GERDAN
Ankara, Mayıs 2020

İÇİNDEKİLER

TEZ ONAY SAYFASI

ETİK.....	i
ÖZET.....	ii
ABSTRACT	iii
TEŞEKKÜR	iii
KISALTMALAR DİZİNİ	vi
ŞEKİLLER DİZİNİ	vii
ÇİZELGELER DİZİNİ	x
1. GİRİŞ	1
1.1 Dijital Görüntü İşleme.....	2
1.2 Biyolojik Materyalin Boyut ve Şekil Özelliklerinin Belirlenmesinde Kullanılan Yöntemler.....	5
2. KURAMSAL TEMELLER ve KAYNAK ÖZETLERİ	12
2.1 İnsan Görüşü ve Bilgisayarlı Görme	12
2.2 Görüntü İşlemede Temel Kavramlar	13
2.3 Görüntü Geliştirme Teknikleri.....	14
2.4 Görüntü Analizine İlişkin Kuramsal Temeller	20
2.5 Veri Madenciliği ve Sınıflandırma Teknikleri	23
3. MATERYAL ve YÖNTEM.....	45
3.1 Materyal	45
3.2 Sınıflandırma Ünitesi ve Ölçüm Cihazları.....	46
3.3 Yöntem	53
4. BULGULAR ve TARTIŞMA.....	59
4.1 Meyve Boyutuna Göre Sınıflandırma Bulguları	59
4.1 Meyve Rengine Göre Sınıflandırma Bulguları.....	83
5. SONUÇ.....	145
KAYNAKLAR	146
ÖZGEÇMİŞ.....	152

KISALTMALAR DİZİNİ

CART	Sınıflandırma ve Regresyon Ağaçları (Classification and Regression Trees)
CNN	Evrışimsel Sinir Ağı (Convolutional Neural Network)
DT	Karar Ağacı (Decision Tree)
EM	Elektromanyetik Spektrum (Electromagnetic Spectrum)
HSI	Renk tonu, Doygunluk, Yoğunluk (Hue, Saturation, Intensity)
KNN	K-En Yakın Komşuluk (K-Nearest Neighborhood)
LDA	Doğrusal Ayırma Analizi (Linear Discrimination Analysis)
MAVL	Çoğunluk Oylaması (Majority Voting)
MDL	Asgari açıklama uzunluğu (Minimum Description Length)
MLP	Çok katmanlı algılayıcı (Multilayer Perceptron)
MLR	Çoklu Doğrusal Regresyon (Multiple Linear Regression)
NIR	Yakın Kızılötesi (Near Infrared)
PCA	Temel Bileşen Analizi (Principal Component Analysis)
PLSDA	Kısmi En Küçük Kareler Ayırma Analizi (Partial Least Squares Discrimination Regression)
R-CNN	Bölgesel Tabanlı Evrışimsel Sinir Ağı (Region Based Convolutional Neural Network)
RMS-error	Kök ortalama kare hatası (Root Mean Square- error)
RO	Rastgele Orman (Random Forest)
ROI	İlgi bölgesi (Region of Interest)
SND	Standart Normal Dağılım
SVM	Destek Vektör Makinası (Support Vector Machine)
YSA	Yapay Sinir Ağları

ŞEKİLLER DİZİNİ

Şekil 1.1 1921'de özel bir telgraf yazıcı tarafından kodlanmış bir banttın üretilen dijital resim (Gonzales ve Woods 2002)	3
Şekil 1.2 Sinyallerin Atlantik'ten iki kez geçmesinden sonra 1922 yılında bir banttın alınan resim (Gonzales ve Woods 2002).....	4
Şekil 1.3 15 ton seviyesinde elde edilmiş gri resim (Gonzales ve Woods 2002).....	4
Şekil 1.4 Ranger 7 tarafından iletilen Ay'ın düzeltilmiş görüntüsü (Gonzales ve Woods 2002)	5
Şekil 1.5 Elma (A) ve patates (B) için şekil tanımlanmasında kullanılan standart kart örneği (Öztürk 1988)	7
Şekil 1.6 Yuvarlaklık ve küresellik karakteristikleri (Öztürk 1988).....	8
Şekil 1.7 Meyve ve sebzelerin ortalama projeksiyon alanlarının belirlenmesinde kullanılan kriter ve düzenek (Öztürk 1988)	11
Şekil 2.1 Görüntüyü yeniden yapılandırma işlemi (Ritter ve Wilson 2001)	15
Şekil 2.2 (a) Düşük zıtlık seviyesine sahip görüntü, (b) yüksek zıtlık seviyesine sahip görüntü.....	15
Şekil 2.3 Kivi meyvesinin ve dilimlenmiş kivi örneklerinin farklı histogram eşitlemesine ait sonuçlar	16
Şekil 2.4 Görüntü bozukluğunu giderme işlemi	17
Şekil 2.5 EM spektrum (Anonymous 2018)	18
Şekil 2.6 RGB renk modeli (Kurtulmuş 2012)	18
Şekil 2.7 HSI renk uzayının konik temsili (Kurtulmuş 2012)	19
Şekil 2.8 L*a*b renk uzayı (Kurtulmuş 2012).....	20
Şekil 2.9 Görüntünün genişletilmesi (dilatasyon) (Pratt 2007).....	20
Şekil 2.10 Görüntünün küçültülmesi (erozyon) (Pratt 2007).....	21
Şekil 2.11 Bir baskı devre kartının iskeletleştirilmesi (Pratt 2007)	21
Şekil 2.12 Görüntü özelliklerinin çıkarılması işlemleri (Nixon ve Aguado 2002)	22
Şekil 2.13 Görüntünün katmanlara ayrılması işlemi.....	22
Şekil 2.14 Zeytin çekirdeğinde yapılan işlemler (Beyaz 2014).....	23
Şekil 2.15 Kenar belirleme işlemi.....	23
Şekil 2.16 Örnek bir karar ağacı modeli	27
Şekil 2.17 Yapay sinir ağı örneği (Silahtaroglu 2016).....	29
Şekil 2.18 Rastgele orman modeli (Anonymous 2020b)	30
Şekil 2.19 Meyve sınıflandırma sistemi (Tonguç 2007).....	31

Şekil 2.20 Mantarlarda donma hasarını tespiti sistemin çalışma prensibi (Gowen vd. 2009)	32
Şekil 2.21 Greyfurtta RGB tekniğiyle belirlenen hastalık görüntüleri (Kim vd. 2009)	33
Şekil 2.22 Saha sunucuları ve feroman tuzakları (Fukatsu vd. 2012).....	34
Şekil 2.23 Sistemin çalışma algoritması (Fukatsu vd. 2012	34
Şekil 2.24 Görüntü işlemeyle şeftali meyvesini belirleme aşamaları (Kurtulmuş 2012)	35
Şekil 2.25 Lekeli yumurta tespiti (Özkan 2012)	35
Şekil 2.26 Balık tazeliğini belirleme aşamaları (Karagöz 2013)	36
Şekil 2.27 Görüntü işleme ile çalışan sınıflandırma makinesinin bölümleri (Örnek 2014).....	37
Şekil 2.28 Kurutulmuş hurmada görüntü işleme aşamaları (Al-Shekaili vd. 2016)	37
Şekil 2.29 Çalışmada kullanılan yerel zeytin çeşitleri (Beyaz ve Öztürk 2016).....	38
Şekil 2.30 Çalışmada kullanılan özel tasarlanmış kutu ve portakaldan alınan görüntü (Jhawar 2016)	39
Şekil 2.31 Şeker kamışı yaprağında görülen fungal kahverengi lekeler ve görüntü işleme tekniği ile lekelerin belirlenmesi (Patil ve Bodhe 2016).....	39
Şekil 2.32 NIR hiperspektral görüntüleme sisteminin şematik gösterimi (Erkinbaev vd. 2017).....	40
Şekil 2.33 Bitki ve hayvan zararlılarının sınıflandırılması (Dimilier ve Kırsal Ever 2018).....	41
Şekil 2.34 Çilek meyvelerinde kenar belirleme işlemi (Ishikawa vd. 2018)	41
Şekil 2.35 Elma sınıflandırma da (a) çürük elma görüntüsü, (b) sağlam elma görüntüsü (Li ve vd. 2019).....	42
Şekil 2.36 (a) Yüz algılama, (b) yüz tanıma işlemleri (Kuan ve vd. 2019)	42
Şekil 2.37 Görüntü işleme ile çilek yapraklarında külleme hastalığının belirlenmesi aşamaları (Shin ve vd. 2019).....	43
Şekil 2.38 Görüntü işleme ile çatlak yumurta tespiti aşamaları (Datta ve vd. 2019).....	44
Şekil 3.1 LabVIEW’da nesne türleri	46
Şekil 3.2 Dijital kumpas	47
Şekil 3.3 Denemelerde kullanılan spektrometre ve kalibrasyon plakaları.....	47
Şekil 3.4 Görüntü eldesinde kullanılan kamera ve tripod ünitesi	48
Şekil 3.5 Denemelerin yapıldığı bantlı götürücü sistemi	49
Şekil 3.6 Redüktörlü DC motor	49
Şekil 3.7 DC motor sürücüsü	50

Şekil 3.8 Çift etkili pnömatik silindirler	50
Şekil 3.9 NPN tip transistörler	50
Şekil 3.10 Selenoid valfler	51
Şekil 3.11 Kompresör	52
Şekil 3.12 Arduino Uno R3 geliştirme kartı	52
Şekil 3.13 Geliştirilen görüntü işleme algoritmasının iş akış diyagramı	55
Şekil 3.14 KNIME Analytics Platform yazılımı kullanılarak yapılan iş akışı.....	58
Şekil 4.1 Starkrimson Delicious çeşidine ait regresyon grafiği	80
Şekil 4.2 Golden Delicious çeşidine ait regresyon grafiği	80
Şekil 4.3 Washington Navel çeşidine ait regresyon grafiği	81
Şekil 4.4 Valencia Midnight çeşidine ait regresyon grafiği.....	81
Şekil 4.5 Ekmek ayva çeşidine ait regresyon grafiği	82
Şekil 4.6 Eşme ayva çeşidine ait regresyon grafiği.....	82
Şekil 4.7 Renge göre sınıflandırma işlemi	83

ÇİZELGELER DİZİNİ

Çizelge 1.1 Biyolojik materyalin fiziksel özellikleri (Öztürk 1988).....	6
Çizelge 2.1 İnsan görüşü ve bilgisayarlı görme arasındaki farklar (Jähne ve Haußecker 2000).....	13
Çizelge 3.1 Elmalarda sınıflara göre kabul edilen en küçük çap ölçüleri (Anonim 2007a).....	53
Çizelge 3.2 Turunçgil meyvelerinin boy özellikleri (Anonim 2007b).....	53
Çizelge 3.3 Delta E değerleri ve renk algısı arasındaki ilişkiler (Anonymous 2020a)...	54
Çizelge 3.4 Elmalarda renk özelliklerine göre izin verilen toleranslar (Anonim 2007a).....	55
Çizelge 4.1 Starkrimson Delicious elma çeşitlerinin boyut sınıflandırma.....	59
Çizelge 4.2 Golden Delicious çeşidine ait boyut sınıflandırma	61
Çizelge 4.3 Washington Navel çeşidine ait boyut sınıflandırma	64
Çizelge 4.4 Valencia Midnight çeşidine ait boyut sınıflandırma.....	70
Çizelge 4.5 Ekmek ayva çeşidine ait boyut sınıflandırma	76
Çizelge 4.6 Eşme ayva çeşidine ait boyut sınıflandırma.....	78
Çizelge 4.7 Starkrimson Delicious çeşidine ait renk değerleri	84
Çizelge 4.8 Golden Delicions'a ait renk değerleri	93
Çizelge 4.9 Washington Navel çeşidine ait renk değerleri	102
Çizelge 4.10 Valencia Midnight çeşidine ait renk değerleri	111
Çizelge 4.11 Ekmek ayva çeşidine ait renk değerler	120
Çizelge 4.12 Eşme çeşidine ait renk değerleri	129
Çizelge 4.13 Verilere ait tanımlayıcı istatistikler.....	138
Çizelge 4.14 KNN algoritmasına ait karışıklık matrisi ve doğruluk ölçütleri	140
Çizelge 4.15 Karar ağacı algoritmasına ait karışıklık matrisi ve doğruluk ölçütleri	141
Çizelge 4.16 Naive Bayes algoritmasına ait karışıklık matrisi ve doğruluk ölçütleri...	142
Çizelge 4.17 MLP algoritmasına ait karışıklık matrisi ve doğruluk ölçütleri.....	143
Çizelge 4.18 RO algoritmasına ait karışıklık matrisi ve doğruluk ölçütleri	144

1. GİRİŞ

Günümüz teknolojik gelişmeleri, Endüstri 4.0 ile tarım, gıda ve hayvancılık faaliyetlerini yeni bir seviyeye taşımıştır. Endüstriyel gelişmeler yüzyıllar boyunca devam etmiş ve sanayi devrimleri ortaya çıkmıştır. Bilindiği gibi, ilk sanayi devrimi buhar makinesinin icadı, ikinci sanayi devrimi elektrik enerjisinin kullanılması ve üçüncü sanayi devrimi ile dijital sistemlerin yoğun bir şekilde kullanılmasıyla başlamıştır (Yıldız 2018). Dördüncü sanayi devrimi olan Endüstri 4.0; akıllı robotlar, simülasyon, nesnelerin İnterneti, büyük veri işleme (Big Data), blok zinciri, yatay ve dikey sistem organizasyonu, M2M (Makineden Makineye), siber güvenlik, bulut bilişim, vb. öğeleri içermektedir. Bu teknolojik gelişmeler tarım sektöründe de diğer tüm alanlarda olduğu gibi ilerlemeler kaydedilmesine yardımcı olmaktadır.

Pazara sunulacak ürünlerde renk, boyut, dokusunda bulunan farklı kusurlar ve şekil gibi dış özellikler sınıflandırma ve derecelendirilmede önemli özelliklerdir. Meyve ve sebzelerde en önemli kalite özelliklerinden biri ise meyvenin görünüşüdür. Görünüm sadece ürünün pazar değerini, tercihlerini ve tüketicinin seçimini etkilemekle kalmamakta, aynı zamanda iç kalitesini de belirli bir ölçüde etkilemektedir. Taze meyve ve sebzelerin pazara sunulmadan önce sınıflanması, ambalajlanması ve depolanması gibi işlemlerden kaynaklanan problemler, pazar fiyat oluşumunu belirlemekte ve bunun sonucunda üretici gelirini etkilemektedir (Pezikoğlu vd. 2004). Meyvenin dış kalite kontrolünün elle yapılması zaman almakta ve yoğun emek gerektirmektedir. Bu nedenle, gıda ve tarım ürünlerinin otomasyona dayalı dış kalite kontrolü için, bilgisayarlı görme sistemlerinin yaygın kullanım olanakları bulunmaktadır. Günümüzde makine görüşündeki ilerlemeler, düşük maliyetli donanım ve yazılımların kullanılabilirliği nedeniyle, tahribatsız meyve sınıflandırmasında doğru, hızlı, objektif ve verimli sonuçlar üretebilmektedir (Naik ve Patel 2017).

Tarımsal Araştırmalar ve Politikalar Genel Müdürlüğü tarafından 2019 yılında yayımlanan Yaş Meyve ve Sebze Çalıştayı raporuna göre dünyada toplam meyve veriminde % 24,03, üretim alanında % 21,03 ve üretim miktarında % 50,11 artış yaşanmıştır. Ancak bu artış, hasat sonrası yapılan yanlış mekanizasyon uygulamaları

nedeniyle toplam üretimde yaklaşık % 30-40 kadar ürünün israf olmasına neden olmaktadır. Hasat sonrası teknolojilerin uygulamaları, taze meyve ve sebzelerin hasattan tüketime kadar olan kayıpların en aza indirilmesi, nicel ve nitel kayıpları azaltabileceği gibi, besin değeri, fiziksel görünüm ve duyuşsal özellikler gibi ürün kalitesini nihai tüketime kadar koruyabilmektedir. Bazı araştırmalar, gelişmekte olan ve gelişmiş ülkelerin hasat sonrası kayıpları arasında büyük farklılıklar olduğunu, tahmini kayıpların % 2 ve % 23 arasında olduğunu göstermektedir (Singh vd. 2014). Tam da bu noktada, hasat sonrası teknolojilerin geliştirilmesi için Endüstri 4.0 bileşenlerinin, geleneksel tarım uygulamalarının yerini alması gerekmektedir.

Bu tez çalışmasında, Endüstri 4.0 bileşenlerinden görüntü işleme ve veri madenciliği teknikleri kullanılarak elma, portakal ve ayva çeşitlerinin hem renk hem boyut bakımından sınıflandırılmasına yönelik bir sistem geliştirilmiştir.

1.1 Dijital Görüntü İşleme

Dijital görüntü, sayısallaştırma işlemiyle elde edilmektedir (Anonim 2018a). Dijital görüntü işlemede, dijital görüntülerin dijital bir bilgisayarla işlenmesi söz konusudur. Bir dijital görüntü sonlu sayıda elemandan oluşmaktadır ve her birinin belirli bir konumu ve değeri bulunmaktadır. Bu öğelere resim öğeleri, görüntü öğeleri veya piksel denmektedir. Piksel, dijital görüntünün unsurlarını tanımlamak için en yaygın kullanılan terimdir. Görme, insanın en gelişmiş duyuşlarından biri olmasına karşın görüntüleme makinelerinde elektromanyetik (EM) spektrumun bant genişliği insan görüşünden daha geniş olarak gama ışınlarından radyo frekans bölgesine kadar değişim göstermektedir. Bu nedenle görüntü işleme, insan görüşünün sınırlı olduğu görme alanı dışında da kendine geniş bir uygulama alanı bulabilmektedir. (Gonzales ve Woods 2002).

Görüntü işleme tekniklerinin amaçları genel olarak şu şekilde özetlenebilmektedir (Anonim 2018a):

1. Görüntü iyileştirme,

2. Görüntü düzeltme,
3. Görüntü sıkıştırma,
4. Görüntü analiz etme,
5. Görüntü tanıma.

Dijital görüntü işlemenin ilk uygulamalardan biri, bir gazete şirketinin bir görüntüyü Londra ve New York arasında, denizaltı kablosu aracılığıyla göndermesiyle başlamıştır. 1920'li yılların başlangıcında, görüntünün Atlas Okyanusu üzerinde gönderilme hızı bir haftadan 3 saate kadar düşürülmüştür. Alınan görüntüler özel baskı ekipmanlarınca yeniden yapılandırılarak iyileştirilmiştir. Örneğin Şekil 1.1'i elde etmek için kullanılan baskı yöntemi, telgraf terminalinde delinmiş bantlardan yapılmış fotoğraf üretmeye dayalı bir tekniktir. Fakat yanlış baskı tekniği ve renk yoğunluğunun dağılımı ile ilgili sorunlar görüntü kalitesinin iyi olmamasına sebep olmuştur. Bu yüzden bu baskı tekniği uygulaması 1921 yılında son bulmuştur. Şekil 1.2 bu yöntemi kullanarak elde edilen bir görüntüyü göstermektedir. Şekil 1.1 üzerindeki iyileştirmeler hem ton kalitesi hem de çözünürlük açısından daha belirgin olmaktadır (Gonzales ve Woods 2002).



Şekil 1.1 1921'de özel bir telgraf yazıcı tarafından kodlanmış bir banttan üretilen dijital resim (Gonzales ve Woods 2002)



Şekil 1.2 Sinyallerin Atlantik Okyanusundan iki kez geçmesinden sonra 1922 yılında bir banttan alınan resim (Gonzales ve Woods 2002)

1929 yılına gelindiğinde, görüntüler için 5 farklı gri seviyede kodlama yeteneğine sahip olan bu teknik 10 seviye daha eklenmesiyle 15 seviyeye yükseltilmiştir. Şekil 1.3'te 15 seviyede gri tonlamalı resim görülmektedir (Gonzales ve Woods 2002).



Şekil 1.3 15 ton seviyesinde elde edilmiş gri resim (Gonzales ve Woods 2002)

Dijital görüntü işleme alanındaki ilerlemeler, dijital bilgisayarların geliştirilmesiyle başlamıştır. Veri depolama, görüntüleme ve görüntülerin iletilmesini destekleyen teknolojilere gereksinim duymakla beraber, matematiksel işlemler de gerektirmektedir. İlk bilgisayar fikri 5000 yıldan daha eskilere kadar uzanmaktadır. Günümüzde kullandığımız bilgisayarların temeli 1940'lara dayanmaktadır. Bilgisayarlı resim işlemi John Von Neumann'ın oluşturduğu iki temele dayandırılmıştır (Gonzales ve Woods 2002). Bunlar;

1. Depolanan verileri ve programı saklayan bir bellek
2. Şartlı dallanmadır (program akışını başka bir noktaya kaydırmak amacıyla kullanılır).

Görüntü işleyerek anlamlı sonuçlar elde edilebilecek ilk bilgisayar 1960 yılında yapılmıştır. 1964 yılında Jet Propulsion Laboratuvarı'nda Ranger 7 tarafından iletilen Ay'ın görüntüleri ve görüntülerdeki çeşitli bozulmalar işlenerek düzeltilmiştir (Şekil 1.4) Dijital görüntü, 1970'li yılların başında astronomi ve tıp alanında bilgisayarlı tomografinin icadıyla yaygınlaşmıştır (Gonzales ve Woods 2002).



Şekil 1.4 Ranger 7 tarafından iletilen Ay'ın düzeltilmiş görüntüsü (Gonzales ve Woods 2002)

1.2 Biyolojik Materyalin Boyut ve Şekil Özelliklerinin Belirlenmesinde Kullanılan Yöntemler

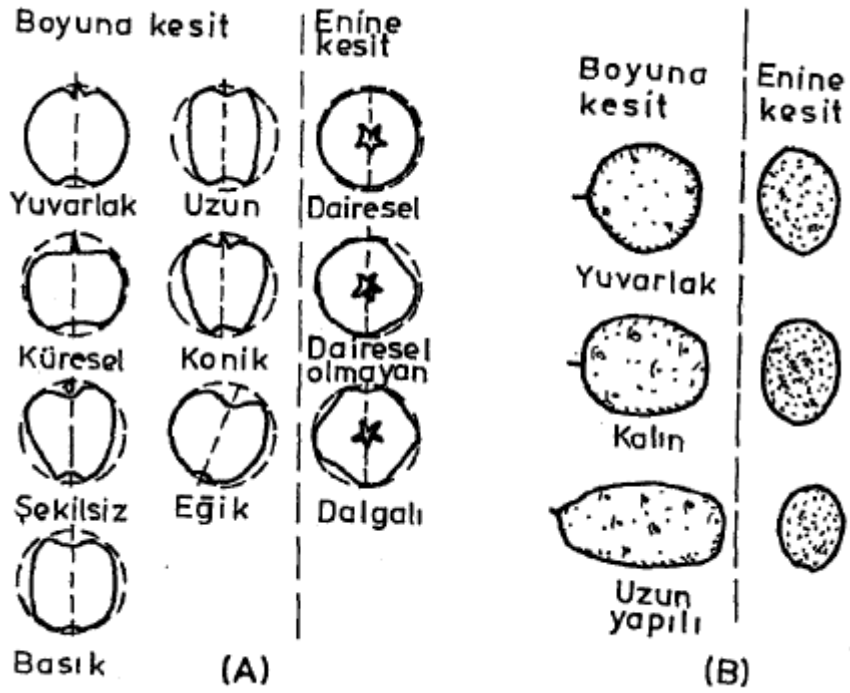
Sınıflandırma işlemi; yabancı maddelerden temizlenmiş ürünleri, türlerine, boyut özelliklerine ve kalitelerine göre ayırmak amacıyla yapılmaktadır (Öztürk 1988). Biyolojik materyalde sınıflandırma; fiziksel, kimyasal ve biyolojik özelliklerine göre yapılabilmektedir (Çizelge 1.1). Biyolojik materyalin fiziksel özelliklerine göre sınıflandırma işleminde; mekanik, termik, optik ve elektriksel özellikler esas alınarak ürünü ayırma işlemi gerçekleştirilmektedir. Kimyasal sınıflandırma işleminde; asit miktarı, şeker miktarı, tanen madde miktarı, karbondioksit miktarı ve pH değerleri hesaplanırken biyolojik sınıflandırma işlemlerinde; olgunlaşma derecesi, solunum,

koku, tat, biyokimyasal maddelere karşı davranış özellikleri incelenmektedir (Öztürk 1988).

Çizelge 1.1 Biyolojik materyalin fiziksel özellikleri (Öztürk 1988)

Biyolojik Materyalin Fiziksel Özellikleri			
Mekanik Özellikler	Termik Özellikler	Optik Özellikler	Elektriksel Özellikler
Temel boyutlar Geometrik Ölçüler Kütle Yoğunluk Ağırlık merkezi Kopma kuvveti Sertlik Sürtünme katsayısı Viskozite	Özgül ısı Isı iletkenliği Isıl genleşme Isı taşınım Isı yayımı	Renk Yansıma ve geçirgenlik yeteneği	İletkenlik Işıma yeteneği Yarı iletkenlik sayısı

Biyolojik materyalin boyut ve şekil özelliklerinin belirlenmesinde kullanılan yöntemler arasında en çok standart kartlar, geometrik şekillere benzetme yaklaşımı, ortalama projeksiyon alanının hesaplanması, yuvarlık ve küresellik değerlerinin bilinmesinden faydalanılmaktadır. Standart kartlar, biyolojik materyalin enine ve boyuna kesitleri, hazırlanmış standart kartlar çizelgesindeki şekillerle karşılaştırılmaktadır. Örneğin Şekil 1.5'te hazırlanan standart kartta elma ve patatese ilişkin veriler görülmektedir. Standart kartlar kullanılarak, ürünün şekline ait sayısal veriler ve tanımlayıcı terimler bulunabilmektedir.



Şekil 1.5 Elma (A) ve patates (B) için şekil tanımlanmasında kullanılan standart kart örneği (Öztürk 1988)

Yuvarlaklık (roundness), katı cisimlerin köşelerinin keskinliğinin bir ölçüsü olarak ifade edilmektedir. Yuvarlaklığın hesaplanmasında birkaç formül kullanılmaktadır (Mohsenin 1980). Bunlar sırasıyla şunlardır:

$$YO = \frac{r}{R} \quad (\text{Şekil 1.6.a})$$

YO: Yuvarlaklık oranı (faktörü),

r: En keskin köşenin eğrilik yarıçapı,

R: Cismin ortalama yarıçapıdır (Mohsenin 1980).

$$Y = \frac{Ap}{Ac} \quad (\text{Şekil 1.6.b})$$

Y: Yuvarlaklık,

Ap: Cismin doğal, hareketsiz pozisyonundaki en büyük projeksiyon alanı,

Ac: En küçük çevresel çemberin alanıdır (Mohsenin 1980).

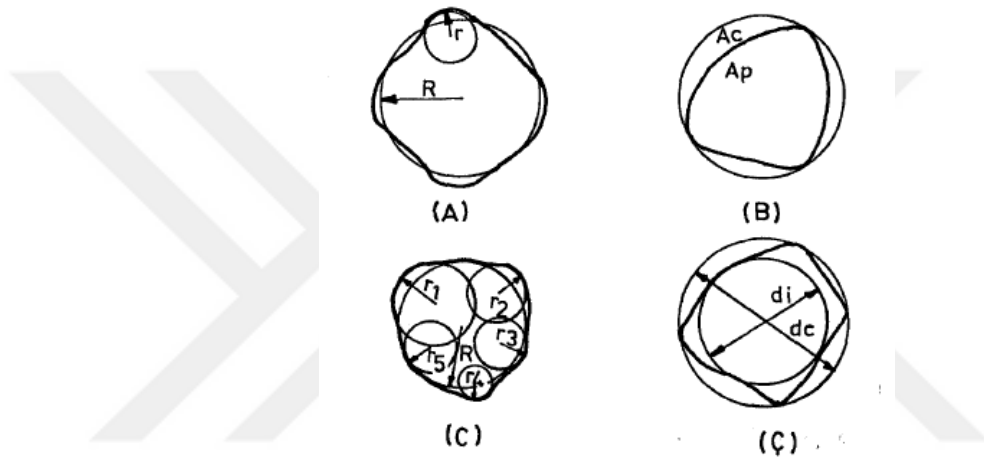
$$Y = \frac{\Sigma r}{NR} \quad (\text{Şekil 1.6 (c)})$$

Y: Yuvarlaklık,

Σr : Cismin eğrilik yarıçaplarının toplamı,

N: Yuvarlak çıkıntı sayısı

R: Cismin kesitine çizilebilecek en büyük içten teğet çemberin yarıçapıdır (Öztürk 1988).



Şekil 1.6 Yuvarlaklık ve küresellik karakteristikleri (Öztürk 1988)

Küresellik (sphericity) kavramının geometrik anlamı, cismin küreye ne oranda yaklaştığını belirlemektir. Küreselliğin belirlenmesinde üç formül kullanılmaktadır;

$$K = \frac{d_i}{d_c} \quad (\text{Şekil 1.6.ç})$$

Bu formülde, küresellik (K) bulunurken, en büyük iç (d_i) ve en büyük dış (d_c) çember çaplarının oranından yararlanılmaktadır (Öztürk 1988).

$$K = \frac{d_e}{d_c}$$

Bu formülde, küresellik (K) bulunurken, malzemeyle aynı hacme sahip olan küre çapının (d_e) malzemenin en büyük çapına (d_c) bölünmesiyle bulunmaktadır (Öztürk 1988).

$$K = \left[\frac{\left(\frac{\pi}{6}\right) * a * b * c}{\left(\frac{\pi}{6}\right) * a^3} \right]^{\frac{1}{3}} = \left(\frac{bc}{a^2}\right)^{\frac{1}{3}}$$

Bu formülde, küresellik (K) hesaplanırken, üç farklı uzunluktaki elips cismin hacmi, materyali çevreleyen kürenin hacmine oranlanmaktadır (Öztürk 1988).

Burada;

a: Uzun eksen boyu,

b: a eksenine dik uzun eksen boyu,

c: a ve b eksenlerine dik uzun eksen boyu (Öztürk 1988).

Bazı biyolojik materyallerde yüzey alanı ve hacmin hesaplanmasında aşağıdaki eşitliklerden yararlanılmaktadır;

1. Şekli limona benzeyen iki ucu uzatılmış elips şeklindeki meyve ve sebzeler için,

$$V = 4/3(\pi ab^2); \quad S = 2\pi b^2 + 2\pi \frac{ab}{\epsilon} \sin^{-1} \epsilon$$

2. Şekli greyfurta benzeyen kutupları yassılaştırılmış küreye benzeyen meyve ve sebzeler için,

$$V = 4/3(\pi a^2 b)$$

$$S = 2\pi a^2 + \frac{\pi b^2}{\epsilon} * \ln \frac{1 + \epsilon}{1 - \epsilon}$$

$$\epsilon = \left[a - \left(\frac{b}{a}\right)^2 \right]$$

Bu eşitliklerde;

V: Hacim,

S: Yüzey alanı,

a: Döner elipsin uzun eksen yarıları,

b: Döner elipsin kısa ekseninin yarıları,

ϵ : Eksantriklidir (Öztürk 1988).

3. Şekli salatalık ve havuca benzeyen kesik dik koni şeklindeki meyve ve sebzeler için;

$$V = \left(\frac{\pi}{3}\right) h (r_1^2 + r_1 * r_2 + r_2^2)$$

$$S = \pi(r_1 + r_2) [h^2 + (r_1 - r_2)^2]^{1/2}$$

r_1 : Taban yarıçapı,

r_2 : Üst yüzey yarıçapı,

h : Yüksekliktir (Öztürk 1988).

Ortama projeksiyon alanı yöntemi, Houston tarafından limon meyvelerinin sınıflandırılmasında kullanılan boyut kriterlerini tanımlamak için geliştirilmiştir. Bu teknikte, birbirine dik üç eksenenden alınan projeksiyon alanları, ortalama projeksiyon alanı olarak tanımlanmıştır. Boyut belirlemede kullanılan kriterler ve ölçüm düzeneği Şekil 1.7’de gösterilmiştir. Bu yöntemin geçerliliğini test etmek için gerçek projeksiyon alanı ile ürünün hacmi arasındaki ilişkiler belirlenmiştir. Buradan ürünün alana göre hesaplanan hacmi ile ölçülen hacmi karşılaştırılmıştır. Dış bükey cisimler teorisine göre aşağıdaki eşitlikten yararlanılmaktadır (Mohsenin 1980).

$$\frac{V^2}{S^3} \geq \frac{1}{36\pi}$$


Bu eşitlikte;

V : Konveks materyalin hacmi,

S : Konveks materyalin yüzey alanı (Öztürk 1988).

Konveks materyalde, ortalama projeksiyon alanı, yüzey alanının dörtte biri ($S=4A$) olarak da kullanılmaktadır.

$$A \leq \left(\frac{9\pi}{16}\right)^{\frac{1}{3}} V^{\frac{2}{3}}, \quad A \leq KV^{\frac{2}{3}}, \quad K = \left(\frac{9\pi}{16}\right)^{\frac{1}{3}} = 1.21$$



Şekil 1.7 Meyve ve sebzelerin ortalama projeksiyon alanlarının belirlenmesinde kullanılan kriter ve düzenek (Öztürk 1988)

2. KURAMSAL TEMELLER ve KAYNAK ÖZETLERİ

2.1 İnsan Görüşü ve Bilgisayarlı Görme

Çevredeki cisimlerden gelen ışınlar, şeffaf kornea gibi gözün çeşitli katmanlarından geçtikten sonra retinaya ulaşmaktadır. Retinada bulunan sarı nokta üzerine ters olarak düşen görüntü, görme sinirleri aracılığıyla beynin görme alanına iletilmektedir. Bu görüntü beyinde düzeltilmekte ve cisimlerin düzgün olarak algılanması sağlanmaktadır. Bu yolla görme olayı gerçekleşmektedir (MEGEP 2013). İnsanın görme sistemi üç bölümden oluşmaktadır: Bunlar; göz, sinir sistemi ve beyindir (Nixon ve Aguado 2002). Teknolojik görme ise (Machine vision) bazı fiziksel olayların ve aygıtların bir araya getirilmesiyle oluşan bir sistemle gerçekleştirilebilmektedir. Bilgisayarlı görme (Computer Vision) adı da verilen bu sistemlerin bileşenleri aşağıda verilmiştir.

1. Işınım: Cisimlerden yansıyan radyasyon enerjisidir. Makine görüşü yönünden radyasyon yaymayan nesnelere görülmemekte ve buna bağlı olarak da üzerlerinde herhangi bir işlem yapılamamaktadır. Bu nedenle, doğal yollardan radyasyon yaymayan nesnelere için uygun yapay aydınlatma tekniklerinin uygulanması gerekmektedir (Jähne ve Haußecker 2000).

2. Kamera: Genel anlamıyla görüntüleri kaydetmeye yarayan aygıtlar kamera olarak adlandırılmaktadır. Kameraların görüntü almasında kullanılan en önemli bölümleri optik merceklerdir (Jähne ve Haußecker 2000).

3. Sensör: Nesnelere veya görüntü üzerinden alınan ışığa ilişkin akı yoğunluğunu, ileri bir işlem için uygun bir sinyale dönüştüren aygıttır. Bir görüntüleme sisteminde radyasyonun uzaysal dağılımını elde etmek için 2 boyutlu bir dizi sensör gerekmektedir. Bazı durumlarda uygun bir tarama sistemi ile tek bir sensör veya bir dizi sensör yeterli olabilmektedir (Jähne ve Haußecker 2000).

4. Görüntü işleme ünitesi: Yüksek boyutlu verilerin işlendiği, nesne özelliklerini ölçmek ve bunları sınıflara ayırmak için kullanılabilecek uygun özellikleri içeren aygıtlardır. İşleme üniteleri genellikle üzerinde işlem yapılan görüntülerin kaydedilebildiği bir belleğe de sahip olabilmektedir (Jähne ve Haußecker 2000).

5. Aktuatör: Görüntü içerisinde aranan cisimi algıladıktan sonra oluşan elektriksel sinyallere tepki verilmesini sağlayan ünedir. İnsan görüşü ve bilgisayarlı görme arasındaki farklar Çizelge 2.1’de özetlenmiştir.

Çizelge 2.1 İnsan görüşü ve bilgisayarlı görme arasındaki farklar (Jähne ve Haußecker 2000)

Görev	İnsan Görüşü	Bilgisayarlı Görme
Görüntüleme	Işığın opak (mat) yüzeylerden yansımaları ile görme gerçekleşir	Elektromanyetik veya akustik radyasyon kullanarak kontrollü aydınlatma ile görüntüleme gerçekleşir
Görüntü oluşumu	Işığın kırılmasına dayalı optik sistem	Çeşitli teknik sistemler
Işınımın kontrolü	Gözbebeği	Ayarlanabilir filtreler
Odaklanma	Odak uzunluğunun değişimi	Çeşitli mesafe ölçüm prensiplerine dayanan otomatik odaklama sistemleri
Işınım duyarlılığı	Logaritmik duyarlılık	Doğrusal duyarlılık, logaritmik duyarlılık
Takip etme	Hareketli göz küresi	Hareketli kameralar
Görüntüyü işleme ve analiz	Organlar arası hiyerarşi	Teknolojik olarak seri işlemler

2.2 Görüntü İşlemede Temel Kavramlar

Görüntü işlemede söz konusu olan temel kavramlar şu şekilde sıralanabilmektedir. Bunlar;

1. Piksel (pixel): Görüntünün en küçük birimi olarak adlandırılır. (Anonim 2018b).

2. Görüntü: X ve Y düzleminde belirli koordinatları olan ve her koordinat çiftinin (x, y) genliği, yoğunluğu ile rengi olan, $f(x, y)$ iki boyutlu bir fonksiyon olarak tanımlanabilmektedir (Gonzales ve Woods 2002).

3. Yeğlilik (Intensity): x - y koordinat düzleminde bulunan piksele ait parlaklık değerini gösterir (Anonim 2018b)

4. Sayısallaştırma (Digitizing): Analog parlaklık değerinin sayısal sistemde ki ayrık seviyelerde ki ifadesidir (Anonim 2018b).


5. Çözünürlük (Resolution): Görüntünün kaç pikselle temsil edildiğini göstermektedir. Çözünürlüğün arttıkça, görüntüdeki ayrıntılar belirginleşmektedir (Anonim 2018b).

6. Uzaysal Frekanslar (Spatial Frequencies): Parlaklık değerinin değişim sıklığını ifade etmektedir (Anonim 2018b).

2.3 Görüntü Geliştirme Teknikleri


Görüntü geliştirmenin temel amacı, görüntüyü ilk halinden uzaklaştırarak işlenebilmesi için uygun hale getirmektir (Gonzales ve Woods 2002). Diğer bir deyişle görüntünün insan veya makine tarafından yorumlanabilmesi için daha uygun bir formata getirilmesidir. Görüntüyü yeniden yapılandırma, görüntüdeki bozuklukları giderme, renkli görüntü geliştirme ile görüntülerin koyulaştırılması veya açık hale getirilmesi gibi işlemler şeklinde uygulanmaktadır. Çok sayıda görüntü geliştirme tekniği olmasına rağmen, her görüntünün iyileştirilmesinde aynı yöntemler kullanılmamaktadır. Bu, tüm görüntüler için genel bir görüntü kalitesi standardının olmamasından kaynaklanmaktadır (Ritter ve Wilson 2001). Dijital görüntü işleme sistemlerinde genellikle fiziksel bir görüntünün uzaysal örnekleme noktalarından elde edilen sayı dizileri işlenmektedir. İşlemeden sonra, başka bir sayı dizisi üretilmekte ve bu sayılar daha sonra görüntüyü yeniden oluşturmak için kullanılmaktadır. Görüntü örnekleri (örneğin görüntü koyuluğu veya fotoğrafik yoğunluğun ölçümleri gibi), sürekli bir görüntü alanının bazı fiziksel ölçümlerini temsil etmektedir. Ölçümlerin geçerliliğini ortaya koymak ve ölçüm hatalarını azaltmak için düzeltmelerin yapılması önem taşımaktadır. Bir görüntüyü doğrudan ölçmek genellikle mümkün olamamaktadır. Bunun yerine, istenen görüntü alanı ile ilgili bazı fonksiyonlar yardımıyla ölçümler yapılmakta ve bu fonksiyonlar

istenen görüntü alanını elde etmek için tersine çevrilmektedir. Görüntü geliştirme tekniklerinden biri olan görüntüyü yeniden yapılandırma işleminin amacı, çeşitli bozukluklara sahip olan resim için orijinal görüntüyü tahminleme ve elde etme işlemidir (Ritter ve Wilson 2001). (Şekil 2.1)



Şekil 2.1 Görüntüyü yeniden yapılandırma işlemi (Ritter ve Wilson 2001)

Görüntü geliştirme tekniklerinden bir diğeri olan zıtlık düzenlemede (contrast manipulation), normal veya elektronik görüntülerin en yaygın sorunlarında biri, azaltılmış ve doğrusal olmayan görüntü genliği aralığından kaynaklanan zayıf kontrast düzeyidir (Pratt 2007). Zıtlık terimi, hem analog hem de dijital görüntülerdeki çeşitli görüntü özellikleri arasında bulunan renk veya gri tonlamalı farklılaşma miktarını ifade etmektedir. Daha yüksek zıtlık seviyesine sahip görüntüler genellikle daha düşük karşıt olanlardan daha fazla renk veya gri tonlamalı varyasyon göstermektedir. Zıtlığı artırılmış görüntülerde ki nesne ve renkler daha belirgin biçimde olurken, düşük zıtlıkta renk tonları birbirine daha yakın olmaktadır (Kurtulmuş 2012). Şekil 2.2.'de düşük ve yüksek düzeyde zıtlığa sahip aynı cismin iki farklı görüntüsü yer almaktadır.



Şekil 2.2 (a) Düşük zıtlık seviyesine sahip görüntü, (b) yüksek zıtlık seviyesine sahip görüntü

Histogram eşitlemede (histogram equalization) tekniğinde ise amaç, görüntüdeki parlaklık seviyesi hakkında bilgi vermekte ve görüntü zıtlığı ile parlaklık seviyeleri aralarındaki farkın ölçülmesidir. Histogram, parlaklık seviyesine göre belirli bir parlaklık seviyesine sahip piksel sayısını göstermektedir. 8 bitlik pikseller için, parlaklık 0 (siyah) ile 255 (beyaz) arasında değişmektedir. Histogram eşitlemesi, bir görüntüyü tüm seviyelerin eşdeğer olduğu bir sonuç görüntüsü elde edecek şekilde düzenleme olanağı vermektedir (Nixon ve Aguado 2002). Şekil 2.3’de kivi meyvesinin ve dilimlenmiş kivi örneklerinin farklı histogram eşitlemesine ait sonuçlar gösterilmiştir.




Şekil 2.3 Kivi meyvesinin ve dilimlenmiş kivi örneklerinin farklı histogram eşitlemesine ait sonuçlar

Görüntüde ki süreksizlik ile keskin tonlama içeren görüntülerdeki değişikliklerini bulma işleminde ise görüntü bozukluğunu giderme yöntemi kullanılmaktadır (Anonim 2018b). Bu amaçla uygulanan bazı teknikler arasında şeffaflaştırma, kırmızı göz giderme, saydamlaştırma, keskinleştirme vb. sayılabilmektedir. Şekil 2.4’de görüntü bozukluğu giderme işlemi uygulanmış bir resim görülmektedir.



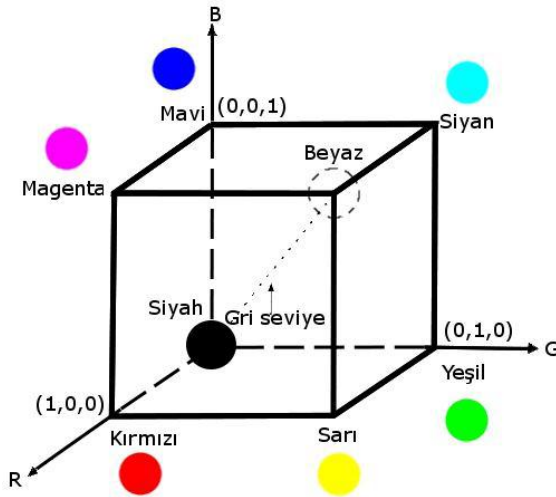
Şekil 2.4 Görüntü bozukluğunu giderme işlemi

Renkli görüntü geliştirmede ise renk uzaylarından faydalanılmaktadır. Renk, ışık olarak adlandırılan spektrumun görünür bölgesinde belirli bir dalga boyuna sahip elektromanyetik radyasyondur. Görünür ışık bölgesi hava veya vakum altında, elektromanyetik spektrumun 360 nm ve 760 nm arasındaki dalga boyu aralığı olarak belirlenmektedir. Işık, gözdeki retinal reseptörleri uyarmakta ve görme olayı denilen rengin algılanmasına neden olmaktadır (Sharma 2003). Renk, ilk olarak frekansa göre algılanmakta ve düşük frekanslı radyasyon göz tarafından görülememektedir. Göz, yeterince parlak bir ışık kaynağını donuk bir kırmızı şeklinde algılamakta; frekans arttıkça algılanan bu renk kademeli olarak kırmızıdan turuncuya, sarıdan yeşile veya maviden mora doğru dönüşüm göstermektedir. Mor renkli ışıklar insan gözü tarafından çok iyi algılanamamaktadır. Görünür ışık dalgaları, kızılötesi radyasyon, ultraviyole radyasyon, X-ışınları gibi bir elektromanyetik (EM) radyasyon şeklidir. Genel olarak, görünür ışık çoğu insan gözünün görebildiği dalga boyları olarak tanımlanmaktadır. EM radyasyonu dalga veya parçacıklarda farklı dalga boylarında ve frekanslarda iletilmekte, bu geniş dalga boyu aralığı elektromanyetik spektrum olarak bilinmektedir. Bu spektrum, azalan dalga boyu ve artan enerji ve frekans sırasına göre tipik olarak yedi bölgeye ayrılmaktadır (Anonymous 2018). Görünür ışık, kızılötesi (IR) ve ultraviyole (UV) arasındaki EM spektrumu aralığında yer almaktadır. Şekil 2.5'te elektromanyetik spektrumun görüntüsü yer almaktadır.



Şekil 2.5 EM spektrum (Anonymous 2018)


Geçmişten günümüze kadar birçok renk uzayı kullanılmış ve geliştirilmiştir. Bunlardan biri olan RGB renk modeli, geniş bir renk dizisi oluşturmak için kırmızı, yeşil ve mavi ışığın çeşitli şekillerde bir araya getirildiği, kartezyen koordinat sistemini esas alan bir renk uzayıdır (Kurtulmuş 2012) (Şekil 2.6). Şekildeki birim küp 0-255 arasındaki değerleri bulunmakla birlikte, toplam tek bir renk örneği (örneğin sadece mavi) için 256 renk bulunmaktadır. Toplamda ise $256 \times 256 \times 256 = 16.777.216$ olası renk bulunmaktadır.



Şekil 2.6 RGB renk modeli (Kurtulmuş 2012)

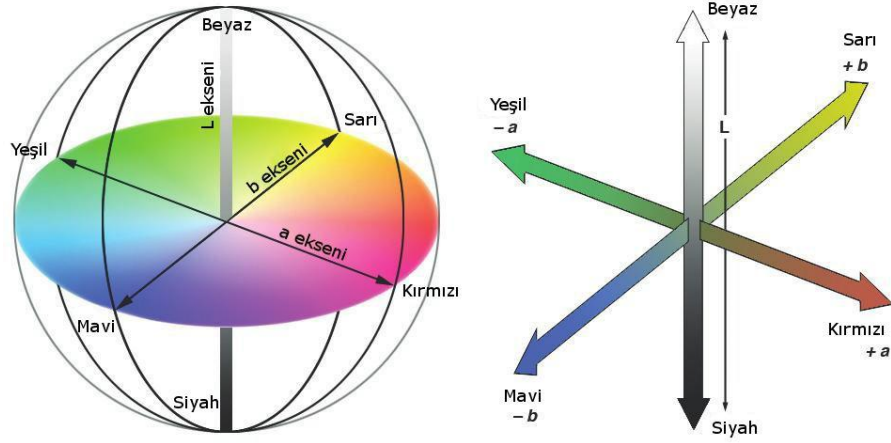
HSI (HSV) renk uzayında, silindirik ya da konik koordinat uzaylarında temsil edilebilen bu model geliştirilmiştir. HSV, HSL, HSB ve HLS gibi birçok gösterimi mevcuttur. Bu

gösterimler arasında parlaklık değerinin hesaplanmasında matematiksel açıdan küçük farklılıklar olmasına rağmen, anlatımda kolaylık olması bakımından bu renk modelleri genellikle aynı başlık altında incelenmektedir. HSI teriminin açılımı renk tonu (hue)-doygunluk (saturation) -yoğunluk (intensiti) şeklindedir. Renk modelinin son teriminde ye alabilen; ‘V’ harfi değer (value), ‘L’ ışınsal aydınlık (lightness ya da luminance), ‘B’ parlaklık (brightness) anlamına gelmektedir. Bu renk modeli 1970’lerde bilgisayarlı grafik uygulamaları için geliştirilmiştir. RGB ve bunun öncesinde kullanılan renk uzaylarına alternatif olarak geliştirilmiştir. Şekil 2.7 ’de bu renk modelinin konik uzayda temsili görülmektedir (Kurtulmuş 2012).



Şekil 2.7 HSI renk uzayının konik temsili (Kurtulmuş 2012)


L^*a^*b renk uzayı ise, geometrik olarak HSI yaklaşımına benzeyen model küresel bir yapıyla açıklanmaktadır. Burada L, gri seviye eksenini yani ışınsal aydınlık (lightness ya da luminance) temsil ederken, a ve b renk ve doygunluk (saturation) birlikte tanımlayan ortogonal eksenlerdir. Şekil 2.8’de L^*a^*b renk uzayı ve koordinat sistemi görülmektedir. Şekilde a ekseninin yeşil (+a) ile kırmızı (-a) arasındaki geçişi, b ekseninin ise sarı (+b) ile mavi (-b) arasındaki geçişi temsil ettiği görülmektedir (Kurtulmuş 2012).




Şekil 2.8 L*a*b renk uzayı (Kurtulmuş 2012)

2.4 Görüntü Analizine İlişkin Kuramsal Temeller

Bu bölümde görüntü analizinde kullanılan morfolojik görüntü işleme, görüntü özelliklerinin çıkarılması, görüntünün katmanlara ayrılması, örüntü tanılama ve kenar belirleme yöntemleri ele alınmıştır. Morfolojik görüntü işleme, bir görüntünün içindeki nesnelerin yapısının değiştirildiği bir görüntü işleme türüdür. Burada; genişletme (dilatation) (Şekil 2.9), erozyon (erosion) (Şekil 2.10) ve iskeletleme (skeletonization) (2.11) üç temel morfolojik işlem olarak uygulanmaktadır. Genişletme ile bir nesne mekansal ölçekte tekdüze büyütülürken, erozyonla tekdüze küçültülmektedir. İskeletlemede ise bir nesnenin çubuklar şeklinde gösterimini ifade etmektedir (Pratt 2007).



Şekil 2.9 Görüntünün genişletilmesi (dilatasyon) (Pratt 2007)




Şekil 2.10 Görüntünün küçültülmesi (erozyon) (Pratt 2007)




Şekil 2.11 Bir baskı devre kartının iskeletleştirilmesi (Pratt 2007)

Bir görüntünün özelliklerinin elde edilmesi (Feature Extraction), bir görüntülerden yüksek düzeyde renk ve şekil gibi bilgilerin çıkarılmasına ilişkin faaliyetleri içermektedir. Bu amaçla uygulanan işlemlerde düşük ve yüksek düzeyli özellik özütleme (Low And High Level Feature Extraction) işlemleri yapılabilmektedir. Bu işlemlerin esası yoğunluk farkından kaynaklanan görüntü özelliklerine bağlı olarak gölge belirleme, kenar belirleme, zıtlık belirleme, hareket algılama, eğim algılama ve hareketlerin ardışıklığın belirlenmesine dayanmaktadır (Nixon ve Aguado 2002). Şekil 2.12’de görüntü özelliklerinin çıkarılması işlemlerine ait görseller bulunmaktadır.



Şekil 2.12 Görüntü özelliklerinin çıkarılması işlemleri (Nixon ve Aguado 2002).


Görüntü veya video bölütlemesi (Image-Video Segmantation), bir görüntüden özel bilgi çıkarmayı amaçlayan, görüntü analizinin önemli bir bölümünü oluşturmaktadır Diğer bir deyişle görüntüleri, o görüntüyü oluşturan parçalara ayrıştırma işlemidir. Görüntülerde yer alan nesnelere arka plandan ve diğer nesnelere ayırma işlemi de bu kısımda gerçekleştirilmektedir (Zhang 2006). Şekil 2.13'e, renkli görüntünün arka plandan arındırılarak katmanlara ayırma işlemi uygulanmış görüntüsü yer almaktadır.



Şekil 2.13 Görüntünün katmanlara ayrılması işlemi

Örüntü tanılama (Pattern Recognition), görüntüden çıkarılan bilgilerin sınıflandırma ve nesne tanılama amaçlarına dönük olarak uygulanan işlemleri içermektedir (Anonim 2018d). Şekil 2.14 (a)'da görülen orijinal görüntülen katmanlara ayırma işlemi ve

çekirdek topoğrafyasına ilişkin örüntü tanınarak cisim çıkartılarak Şekil 2.14 (b) ‘deki görüntü elde edilmiş, bu görüntü daha sonra arka plan değiştirme işlemiyle ölçeklendirilmiştir (Şekil 2.14(c)).



Şekil 2.14 Zeytin çekirdeğinde yapılan örüntü tanılama işlemi (Beyaz 2014)

Kenar belirleme (Edge Detection), görüntü içerisinde tanınması istenen bölüme ait kenarların belirgin ve matematiksel olarak işlenebilir olarak ifade edilmesidir (Zhang 2006). Şekil 2.15’de orijinal görüntüde yer alan ayçiçeği tablasının taç yaprakları etrafında kenar belirleme işlemi uygulanmış hali görülmektedir.



Şekil 2.15 Kenar belirleme işlemi

2.5 Veri Madenciliği ve Sınıflandırma Teknikleri

“Büyük veri tabanlarından bilgi keşfi olarak da bilinen veri madenciliği, bilgisayar bilimlerinde büyük verilerde yer alan ilginç, yararlı ve keşfedilmemiş örüntüler ve ilişkilerin tespit edilmesi” olarak tanımlanmaktadır (Köse 2018). Veri madenciliği

teknikleri ile keşfedilen bilgi daha iyi kararlar vermeyi, daha gelişmiş bir planlamayı, daha yüksek doğrulukla tahmin etme olanaklarını sağlayarak süreçlerin etkin ve verimli kullanılmasına yardımcı olmaktadır (Kalikov 2006, Abu-Oda ve El-Halees 2015). Veri madenciliği, fazla verinin olduğu büyük veri tabanlarındaki keşfedilmemiş bilgileri, istatistik ve yapay zekâ kullanarak analiz etmektedir. Veri madenciliği konuları, tıpkı istatistik biliminde olduğu gibi, tahmin edici ve tanımlayıcı olarak incelenmektedir (Zhong ve Zhou 1999, Özekes 2003, Köse 2018). Veri madenciliği modelleri işlevlerine göre üç gruba ayrılmaktadır:

1. Sınıflama ve regresyon,
2. Kümeleme,
3. Birliktelik Kuralları (Özekes 2003, Coşlu 2013).

Sınıflama, veri setindeki önemli verileri ele alarak gelecek veri eğilimlerini tahmin edebilen modelleri kuran tahminsel veri analiz yöntemleridir. Verilerin ortak özelliklere göre gruplara ayrıştırılmasına sınıflandırma, herhangi bir değişkenin, bir veya daha fazla farklı değişkenler arasındaki ilişkinin matematiksel olarak ifade edilmesine ise regresyon denilmektedir (Silahtaroglu 2016, Köse 2018). Sınıflamada kategorik değerler tahmin edilirken, regresyonda süreklilik gösteren değerler tahmin edilmektedir. Gözetimli sınıflandırma algoritmalarının kullanımında, genellikle verinin 2/3'ü eğitim, 1/3'ü test için kullanılmaktadır. Bu oranlar değişmekle birlikte verinin bölünmediği durumlarda olabilmektedir. Veri setinin parçalanmasındaki amaç makineyi test tahmin etme söz konusudur. Buna gözetimli öğretim (supervised learning) denmektedir. Tanımlamaların yapılmadığı, yani herhangi çeşit etiketin bulunmaması, verilerin kendi içinde ayrılması yani kümeleme (clustering) işlemi gibi durumlarda, tüm verilerin makinaya bırakılması ise gözetimsiz öğrenme (unsupervised learning) olarak adlandırılmaktadır. Eğer nominal (yazılı) değer tahmin edilmeye çalışılıyorsa buna sınıflandırma (classification) adı verilmektedir (Şeker ve Erdoğan 2018). Sınıflandırma (classification) yöntemi genel olarak kural tabanlı öğrenme (rule based learning) ile de çalışmaktadır (Şeker ve Erdoğan 2018). Örneğin; boyut değeri 6,5 cm renk değeri 140 (R), 50 (G), 110 (B) 40 olan veriler için elma etiketi verildiğinde, bu veri setinde benzer değerler doğru sonuçlar çıkabilmekte, fakat farklı değerlere sahip yeni üyeler sınıflandırmaya girdiğinde başarısız olma ihtimali yükselebilmektedir.

Kümeleme, muhtemel benzerliklerin söz konusu olduğu veri gruplarının, belirlenecek unsurlara göre hangi verinin hangi sınıfa dâhil olacağını gösteren tanımlayıcı analiz yöntemidir. Kümeleme analizi uygulanacak veriyi tanımaya yardımcı olan yöntemdir. (Köse 2018). İlk başta herhangi bir sınıfı bulunmayan veriler gruplar halinde kümelere ayrılmaktadır. Sınıflama çalışmalarından önce, kümeleme analizleri verileri anlamada önişlem gibi kullanılabilir (Özekes 2003).

Birliktelik kuralları ve ilişki analizi, nesnelere arasındaki gizli ilişkilerin ortaya çıkarılmasında kullanılmaktadır. Veri tabanındaki nesnelere birbirleri arasındaki bağıntıları açıklamakla birlikte, bir nesnenin kaydının varlığı ile başka diğer bir hangi kaydın olma olasılığını analiz etmektedir. Örnek olarak AIS, SETM, Apriori, AprioriTid algoritmaları birliktelik analizlerini göstermekte kullanılan algoritmalar olarak ifade edilmektedir (Silahtaroglu 2016).

Bu tez çalışmasında sınıflandırma amaçlı kullanılan algoritmalarından biri Karar Ağacı'dır. Karar Ağaçları (Decision Tree), nesnelere özellikleri ile değerleri arasındaki ilişkileri temsil eden bir tahmin modelidir. Bu yöntem sürecinde öğrenilen nesne özelliklerini modellemek için kullanılan denetimli bir yöntemdir. Veri madenciliği yöntemleri içinde çok sık kullanılmaktadır. Hem sayısal hem de sınıfsal verilerin işlenmesinde kullanılabilir. Tahmin (prediction) sayısal veriler üzerinde çalışırken sınıflandırma (classification) ise etiket (label) tahmininde bulunmaktadır. Tahminden kastedilen ve bulunmaya çalışılanlar sayısal değerlerdir. Bu bakımdan karar ağaçları (Decision Tree), sınıflar üzerinde etiketlendirme yapmaktadır (Şeker ve Erdoğan 2018). Bir karar ağacındaki her düğüm, sınıflandırılacak örnekteki bir özelliği temsil etmektedir. Karar ağaçları, verilerden çıkarılan kuralları öğrenerek gelecek verilerin değerini tahminleyecek bir model oluşturmaktır (Rokach ve Maimon 2008, Abu-Oda ve El-Halees 2015). Sınıflandırma modellerini oluşturmak için ağaç yapısını kullanan yöntem, veri kümesini daha küçük alt kümelere ayırmaktadır (Şekil 2.16).

Geliştirilen ilk Karar Ağacı algoritması olarak bilinen ID3 algoritması, her örneğin özneteliğini, hedef sınıflarına göre ne kadar iyi ayırdığını bilgi kazancı ve entropiyi (düzensizlik) kullanarak değerlendirmektedir. Entropisi en az olan, ayırt edici öznetelik

seçilmekte ve ağacın kök düğümünde test olarak kullanılmaktadır. Entropi, bilgi teorisinde yaygın olarak kullanılan ve örneklerin homojenliğini karakterize eden bir ölçüdür. Verilerin birbirinden farklılığı yani entropi ölçüsü ne kadar fazla ise, o verilerle bulunan sonuçlar da bir o kadar belirsiz ve kararsız olmaktadır (Silahtaroglu 2016; Köse 2018). Kısaca ID3 algoritmasıyla anlaşılır, küçük ve sade ağaçlar oluşturulmaktadır (Köse 2018). Bütün nesnelere aynı sınıfta olması durumunda entropi sıfır olmaktadır. Entropi, aşağıda verilen eşitlikle hesaplanmaktadır:

$$Entropi(N_j) = \sum_{i=1}^c \frac{|N_i|}{|N_j|} \log_2 \frac{|N_i|}{|N_j|}$$

Burada;

N_j : Nitelik kümesi içerisindeki N niteliğinin toplam kayıt sayısı,

N_i : N niteliğinin i 'inci seçeneğinin kayıt sayısını ifade etmektedir (Köse 2018).

Örneklerin ayırt edici niteliğe göre düğüm ve dallanmaları oluşturması aşamasında doğru sınıflandırmanın yapılabilmesi adına bu özelliğe göre oluşan farklılıklar, bilgi kazanımı olarak adlandırılmaktadır. Kazanım bilgisi, her bir alt bölümün entropilerinin ağırlıklı toplamları arasındaki farklar hesaplanarak elde edilmektedir (Silahtaroglu 2016). Kazanım formülü aşağıda verilmiştir:

$$D = H(D) - \sum_{i=1}^n P(D_i) H(D_i)$$

Burada;

D : Kazanım,


H : Entropi,

P : Olasılık (Ağırlık)'tır (Silahtaroglu 2016).

C4.5 algoritması, ID3 ağacının geliştirilmiş hali olarak yaygın kullanılan algoritmalar arasında yer almaktadır. Tıpkı ID3 algoritması gibi entropi ve bilgi kazancına dayalı bir algoritmadır. ID3 algoritmasından farklı olarak hem ayrık hemde sürekli veri türlerini desteklemektedir ve budama işlemleri yapılmaktadır. Uygulaması kolay, anlaşılabilir kuralları ortaya çıkarması ve gürültülü verilerde başarılı olması bu ağacın ID3

algoritmasına göre üstünlükleri olarak sıralanabilmektedir (Köse 2018). Bu nedenle çalışmada, C4.5 algoritması kullanılmıştır.

Karar ağaçlarında karar düğümleri, dallar ve yapraklar bulunmaktadır. Ağacın en üstündeki düğüm kök düğümüdür. Her bir düğüm ayırt edici karar olurken, her bir dal nihai kararı verilmekte ve yaprakla sonuçlanmaktadır. Hiçbir dal başka bir dal ile devam etmemektedir. Örneklerin sınıflandırılması, kök düğümünden başlamakta ve yukarıdan aşağıya doğru veriler sınıflanmaktadır (Pandya ve Pandya 2015, Köse 2018).



Şekil 2.16 Örnek bir karar ağacı modeli

Kullanılan bir diğer algoritma olan K-en yakın komşuluk (KNN) algoritması, sınıflama ve regresyon işlevi grubunda bulunan parametrik olmayan bir yöntemdir. Bu algorithma, veri örneklerinin birbirlerine olan noktasal uzaklık bilgisini kullanarak yeni örneklerin sınıflandırılması için en kısa mesafeler kullanılmaktadır. "En yakın" terimi, hâlihazırda sınıflandırılmış örneklerin bazılarının yeni örneklerle benzer özelliklere sahip olduğu gerçeğini temsil etmektedir (Marinakos ve Daskalaki 2016). Noktasal uzaklık bilgisini yani mesafe hesaplama işleminde, genellikle Öklid uzaklığı ve ya Manhattan uzaklığı gibi mesafe hesaplama yöntemleri kullanılmaktadır (Silahtaroglu 2016). Öklid uzaklığı aşağıdaki eşitlikten hesaplanmaktadır:

$$d(i,j)=\sqrt{(x_{i1}-x_{j1})^2+(x_{i2}-x_{j2})^2+\dots+(x_{in}-x_{jn})^2}$$

Manhattan uzaklık ölçüsü ise aşağıdaki formül ile hesaplanmaktadır:

$$d(i, j) = |x_{i1} - x_{j1}| + |x_{i2} - x_{j2}| + \dots + |x_{in} - x_{jn}|$$

Sınıflandırma amaçlı kullanılan diğer bir yöntem ise Naive-Bayes'tir. Bu yöntem, özellikle fazla verinin olduğu ikili ve çok sınıflı sınıflandırma problemlerini çözmek için kullanılan bir algoritmadır (Caruana ve Niculescu-Mizil 2006, Lonita ve Lonita 2018). Bu yöntemde, genelde kelimelerin ve sınıfların birleşik olasılıklarının belirlenmesinde, özellikle ise metin madenciliği alanında kullanılmaktadır (Amasyalı vd., 2006). Verilerin etiketlenmesi ve sınıflandırılması için kullanımı kolay bir sınıflandırma algoritmasıdır. Bayes teoremini kullanarak, her kriterin sonuca olan etkilerinin olasılık değerlerinin hesaplanması ve hangi verinin hangi sınıfın üyesi olduğunu hesaplama amacıyla kullanılmaktadır (Çalış vd. 2013). Naive Bayes sınıflandırma tekniği, koşul değiştirme durumunu analiz etmektedir. Örneğin B'nin gerçekleştiği durumda A'nın olma olasılığı tahmin edilmeye çalışılmaktadır. Aynı zamanda bu A'nın gerçekleştiği durumda B'nin olma olasılığı olarak da sorgulanabilmektedir (Şeker ve Erdoğan 2018).

Bu yöntemin eğitimi ve sonuç işlemleri çok hızlı fakat karmaşık sınıflandırma problemlerini çözmede ise yetersiz kalabilmektedir. Bayes teoremi aşağıdaki formül ile hesaplanmaktadır.

$$\rho(A/B) = (\rho(B/A) * \rho(A))/\rho(B)$$

Formülde;

$P(A)$: A olayının öncel olasılığı,

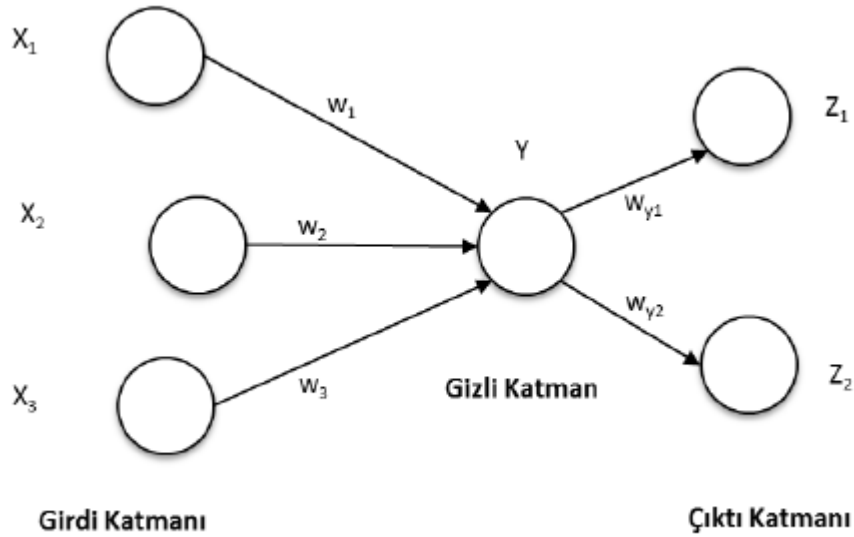
$P(B)$: B olayının ardıl olasılığı,

$P(B/A)$: A olayı olduğunda B olayının olasılığı,

$P(A/B)$: B olayı olduğunda A olayının olasılığıdır (Çalış vd. 2013).

Sınıflandırma amaçlı kullanılan yöntemlerden sonuncusu ise Yapay sinir ağları (YSA)'dır. YSA, 1980 yılından itibaren bilgisayar bilimlerindeki gelişmeler sayesinde ilerleme sağlamıştır. Sınıflandırma işlemlerinin yanı sıra kümeleme ve örüntü tanımlama işlemlerinde de kullanılmaktadır (Silahtaroglu 2013). YSA, tıpkı biyolojik


sinir sistemine benzeyen insan beyninin öğrenme fonksiyonunu gerçekleştiren bilgisayar sistemleridir. Biyolojik sinir hücrelerinin aralarında iletişim kurması ve işlenen bilginin yine diğer hücelere gönderilmesi işlemi yapay sinir ağlarında benzer şekilde gerçekleştirilmektedir. Yapay sinir hücrelerinin dışardan gelen bilgileri toplaması, bu bilgileri işlemesi ve diğer hücelere iletilmesi söz konusudur. Biyolojik sinir hücresinde ağ oluşumu işlenen bilginin akson'lar ile diğer hücelere bağlanarak iletilmesiyle oluşturulurken, yapay sinir ağlarının oluşumunda işlenen bilgiler aktivasyon fonksiyonundan proses elemanlarına (yapay sinir hücreleri) geçerek oluşmaktadır. Her bağlantının bir ağırlık değeri bulunmaktadır. Bu ağırlık değerlerinin sahip olduğu saklı bilgi de ağ üzerinde yayılmaktadır. Proses elemanları birbirlerine paralel olarak girdi katmanı, ara veya gizli katmanlar ve çıktı katmanının bir araya gelmesiyle bir ağ oluşturmaktadırlar. Bilgiler ağa girdi katmanından alınarak, ara katmanlarda ağa gelen bilgilerin ağırlık değerleri alınarak işlenir ve oradan çıktı katmanına iletilirler (Şekil 2.17). Ağın doğru sonuçlar verebilmesi için girdiye doğru ağırlık değerlerinin verilmesi, doğru ağırlıkların bulunmasında ise ağın eğitilmesi gerekmektedir (Öztemel 2012).



Şekil 2.17 Yapay sinir ağı örneği (Silahtaroglu 2016)

Çalışmada sınıflandırma yöntemlerinin yanında, veri madenciliğinde kullanılan üst öğrenme algoritmalarından Rastgele Orman (Random Forest) algoritması da kullanılmıştır. Leo Bieman tarafından geliştirilen rastgele orman algoritması, bir soruyu

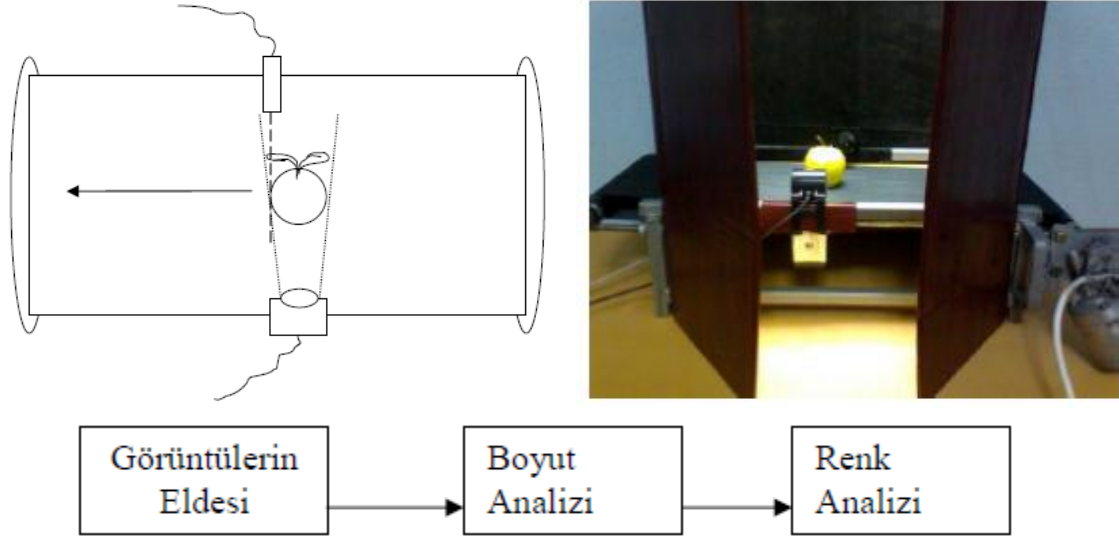
çözmek için birden fazla ağaç üretmekte ve farklı karar ağaçları oluşturmaktadır. RO, sınıflandırma ve regresyon ağaçları içerisinde yer alan bir algoritmadır. Rastgele Orman, verilerin alt kümelerine dayalı olarak birçok ağacın oluşturulduğu CART algoritmasının gelişmiş bir versiyonudur. Çok sayıda karar ağacından gelen tahminlerin toplanmasına dayanan anlaşılması ve uygulaması yönünden basit, hızlı sonuç veren popüler öğrenme yöntemlerinden biridir (Şekil 2.18) (Mitchell 2011).



Şekil 2.18 Rastgele orman modeli (Anonymous 2020b)


Biyolojik materyallerin sınıflandırma işlemleriyle ilgili çalışmalar, kaynak özetleri şeklinde aşağıda sunulmuştur.

Tonguç (2007) sarı, kırmızı ve yeşil renkli elmaların boyutsal (edge detection, feature extraction) ve renksel ayrımı (color detection) için görüntü işleme tekniklerini kullanmıştır. Çalışma, öncelikle sabit bir platform üzerinde gerçekleştirildikten sonra hareketli sisteme taşınmıştır. Kapalı bir kutu içinde bandın üzerinden ilerleyen meyveler kamera ve renk sensörü tarafından algılanarak görüntüler elde edilmiştir. Bu yüksek çözünürlükteki görüntüler C# dili ile hazırlanan program tarafından işlenmiştir. Sistem, kamera önüne gelen meyve görüntüsünü işleyerek, boyut ve renk ile ilgili sayısal ve görsel bilgi sunmaktadır. Şekil 2.19'da meyve sınıflandırma sistemine ait görüntüler ve çalışma prensibi verilmiştir.




Şekil 2.19 Meyve sınıflandırma sistemi (Tonguç 2007)

Gowen vd. (2009) mantarlarda donma hasarının erken tespiti için hiperspektral görüntüleme de (HSI) kullanımını araştırmışlardır. Mantar örnekleri için, 400 ile 1000 nm dalga boyunda hiperspektral görüntüleme cihazı kullanılmış ve her mantar örneğinden gelen yansıma spektrumları Standart Normal Dağılım (SNV) dönüşümü kullanılarak ön değerlendirmeye tabi tutulmuştur. Araştırmacılar, depolama süresince ağırlıkları kaydedilen mantarlarda, çözülme işleminin erken aşamalarında donmuş numunelerde ağırlık yönünden bir farklılık bulunmasa da 24 saat sonra donmuş hasarlı mantarlarda önemli değişiklikler olduğunu belirtmişlerdir. Temel Bileşen Analizi (PCA) ve Doğrusal Ayırma Analizi (LDA) ile hasarsız mantarların % 100'ünün, donmuş hasarlı numunelerin % 97,9'unun doğru şekilde sınıflandırıldığını vurgulanmıştır. Ayrıca donma-çözülme etkilerinin mantar üzerinde gözle görülür bir şekilde belirgin olmadığını da belirtmişlerdir. Şekil 2.20'de mantarlarda donma hasarını tespit eden sistemin çalışma prensibi şematik olarak gösterilmiştir.




Şekil 2.20 Mantarlarda donma hasarı tespit sistemin çalışma prensibi (Gowen vd. 2009)

Kim vd. (2009) bir RGB kamera kullanarak, greyfurt meyvesinin kabuklarında görülen 5 yaygın hastalık çeşidini renk ve doku özelliklerinden yola çıkarak özellik özütleme (Feature Extraction) ile belirlemiştir. Hastalıklı olmayan ve 5 farklı hastalık çeşidi bulunduran greyfurtlardan elde edilen toplam 39 adet RGB görüntülerden HSI, HS ve I renk uzayı oluşturulmuştur. Bu amaçla, araştırmacılar sınıflandırma modellerini, renk ve doku özelliklerini kullanarak ayırmışlardır. Sonuçta HSI renk uzayında en iyi sınıflandırma doğruluğu (% 96,7) sağlayarak, narenciye kabuğu hastalıklarını ayırt etmek için kullanılabileceğini belirtmişlerdir. Şekil 2.21’de greyfurtta görülen hastalıklara ilişkin görsel verilmiştir.

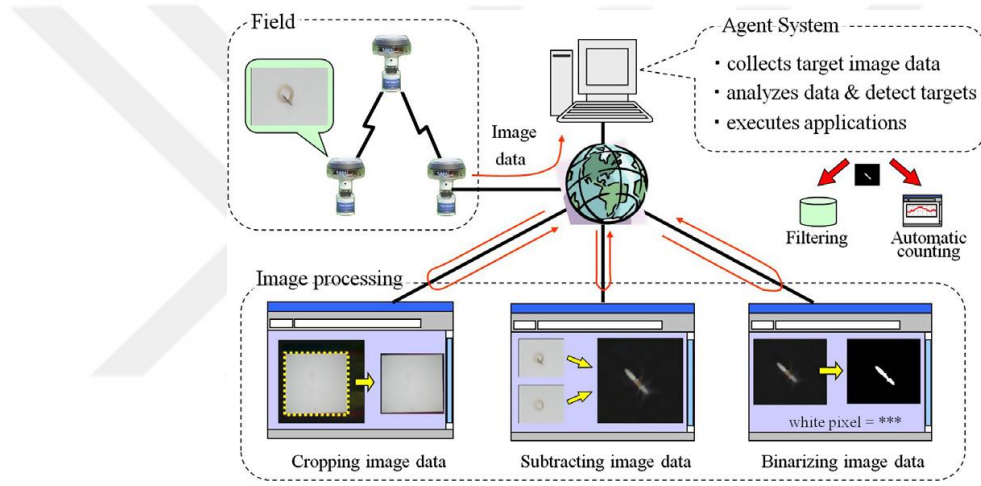


Şekil 2.21 Greyfurtta RGB tekniğiyle belirlenen hastalık görüntüleri (Kim vd. 2009)

Fukatsu vd. (2012) feromon tuzaklarında etkili böcek sayımını gerçekleştirmek için, uzaktan izlenebilen sensör ve ağ sistemine dayalı bir görüntü işleme sistemi geliştirmişlerdir. Çeltik zararlısı olan *Leptocorisa chinensis*'in sayılabilmesi için araziye yerleştirilen sunucu ve yüksek çözünürlüklü kamera yardımıyla alınan veriler her 5 dakikada bir kablosuz internet aracılığıyla monitöre aktarılmıştır. Sırasıyla, görüntü işleme algoritması; görüntüyü kırpma, arka planı kaldırma ve ikili görüntü elde etme tekniklerinin kullanıldığı sistemin % 97 doğrulukla çalıştığını belirtmişlerdir. Şekil 2.22'de çalışmada kullanılan saha sunucuları ve feromon tuzaklarına ait görsel, Şekil 2.23'te ise sistemin çalışma algoritması verilmiştir.



Şekil 2.22 Saha sunucuları ve feroman tuzakları (Fukatsu vd. 2012)



Şekil 2.23 Sistemin çalışma algoritması (Fukatsu vd. 2012)

Kurtulmuş (2012) şeftali meyvesinde verim haritalamasına yönelik olarak yaptığı çalışmada, görüntü işleme tekniklerinden yararlanarak doğal koşullarda alınmış şeftali görüntülerinin renk, doku ve şekil gibi bilgilerden özellik çıkarma yöntemini kullanarak algoritmalar geliştirmiştir. Araştırmacı geliştirdiği algoritmaların bazılarının % 85 düzeyinde meyveyi belirleme başarısı ortaya koyduğunu bildirmiştir. Şekil 2.24'te görüntü işlemeyle şeftali meyvesinin belirlenme aşamaları verilmiştir.




Şekil 2.24 Görüntü işlemeyle şeftali meyvesini belirleme aşamaları (Kurtulmuş 2012)

Özkan (2012) MATLAB yazılımını kullanarak tavuk yumurtalarında kirlilik tespiti ve yumurta hacmini hesaplayan bir kalite kontrol uygulaması gerçekleştirmiştir. Araştırmacı, kalite derecesinin belirlenmesinde bulanık mantık algoritmasını kullanmıştır. Elde edilen sonuçlara göre geliştirilen algoritmanın % 98 doğrulukla çalıştığını belirtmiştir. Şekil 2.25’de geliştirilen kalite kontrol uygulamasına ait ekran görüntüsü verilmiştir.




Şekil 2.25 Lekeli yumurta tespiti için kullanılan yazılıma ait ekran görüntüsü (Özkan 2012)

Karagöz (2013) balık tazeliğini ölçmek için cep telefonunun kamera özelliğinden yararlanarak alınan görüntüleri MATLAB yazılımında işlemiştir. Balık tazeliğini belirleyen yöntemler için sadece şekille ilgili bilgilerden % 90 başarılı sonuç ve renk bilgisinin katılmasıyla da balıkların başarılı bir şekilde sınıflandırılabilirdiğini vurgulamıştır. Bu sonuçlara göre araştırmacı, görüntü işleme teknikleriyle başarılı bir şekilde balık tazeliğinin ölçülebileceğini belirtmiştir. Şekil 2.26’da balık tazeliğini belirleme aşamaları verilmiştir.



Şekil 2.26 Balık tazeliğini belirleme aşamaları (Karagöz 2013)

Örnek (2014) çalışmasında enine ve boyuna merdaneli tip mekanik havuç sınıflandırma makineleri ile geliştirdikleri gerçek zamanlı görüntü işleme sisteminin sınıflandırma etkinliği araştırmıştır. Kullandığı sınıflandırma makinası redüktörlü bir motor ile hız ayarı yapılabilen bir bant üzerinde bulunan havuçların görüntülenmesi ve bu görüntülerin analizi esasına dayanmaktadır. Elde edilen sonuçlara göre enine merdaneli, boyuna merdaneli ve gerçek zamanlı sınıflandırma makinesinde hatalı bölüme düşen havuçların oranı sırasıyla % 0,65 - % 99,33, % 18,39 - % 88,90 ve % 5,42 - % 9,03 arasında bulunmuştur. Şekil 2.27’de görüntü işleme ile çalışan sınıflandırma makinesinin bölümleri verilmiştir.



Şekil 2.27 Görüntü işleme ile çalışan sınıflandırma makinesinin bölümleri (Örnek 2014)

Al-Shekaili vd. (2016) Suudi Arabistan'ın çeşitli bölgelerinde yetişen hurma çeşitlerini sertliklerine göre sınıflandırmışlardır. Kurutulmuş meyvelerin kalitesini belirlemede kullanılan geleneksel pahalı ve zaman alıcı yöntemler yerine geliştirdikleri bilgisayarlı görme sisteminde 1800 adet örneğin tek renkli görüntülerinden histogram ve doku özelliklerini çıkararak yapay sinir ağı (YSA) ve doğrusal ayırım analizi (LDA) yöntemlerini kullanmışlardır. Araştırmacılar kurutulmuş meyveleri yumuşak, yarı sert ve sert olarak sınıflara ayırmışlardır. Sonuçlar LDA için % 84 YSA için ise % 77 oranında başarılı bulunmuştur. Histogram özelliklerini kullanmanın doku özelliklerine göre sertliğe dayalı hurma sınıflandırmasında daha fazla etkili bulunduğunu ve bilgisayarlı görme tekniğinin, kuru meyveler için çevrimiçi kalite izleme sistemleri geliştirmek için büyük bir potansiyele sahip olduğunu vurgulamışlardır. Şekil 2.28'de kurutulmuş hurmada görüntü işleme aşamaları gösterilmiştir.



Şekil 2.28 Kurutulmuş hurmada görüntü işleme aşamaları (Al-Shekaili vd. 2016)

Beyaz ve Öztük (2016) çalışmalarında, 11 çeşit yerel zeytinden 10 tanesini çekirdek görüntülerinden tanılamışlardır (Şekil 2.29). 2896×1944 piksel ve 300 dpi çözünürlükte

çekilen zeytin görüntüleri bir DSLR kamera ile çekilmiş ve piksel dağılımları değerlendirilmiştir. Bu amaçla MATLAB v2012 ve Image j yazılımını kullanmışlardır. Elde edilen veriler ışığında, zeytin çeşitlerini tanılamak için varyans analizi ve Duncan testi kullanılmış, gözlenen tüm zeytin çeşitlerinin $P < 0,05$ düzeyinde belirlenmiştir.




Şekil 2.29 Çalışmada kullanılan yerel zeytin çeşitleri (Beyaz ve Öztürk 2016)

Jhavar (2016) çalışmasında, 160 adet portakal görüntüleri üzerinden örüntü tanılama (pattern recognition) yöntemini kullanarak sınıflandırmıştır. Tasarlanan sınıflandırma sistemi; veri toplama ve işleme, görüntüden özellik çıkarma (feature extraction) ve karar verme (making decision) basamaklarından oluşmuştur. Görüntüler, 430 lüks ışık ile aydınlatılmış özel bir kutu içerisinde dijital bir kamerayla 640×480 piksel çözünürlükte alınmıştır. Çalışma sonucuna göre portakalların sınıflandırılmasında % 90 ve % 98 başarı elde edilmiştir. Şekil 2.30'da çalışmada kullanılan özel tasarlanmış kutu ile portakaldan alınan görüntüye yer verilmiştir.



Şekil 2.30 Çalışmada kullanılan özel tasarlanmış kutu ve portakaldan alınan görüntü (Jhawar 2016)


Patil ve Bodhe (2016) çalışmalarında şeker kamışında fungal hastalıkların neden olduğu yaprak lekelerini görüntü işleme tekniği ile belirlemişlerdir. Deneme sonuçlarına göre fungal hastalıkları belirlemede % 98,60 oranında başarı elde etmişler ve pestisit kullanımının azaltılması amacıyla yapraklardaki lezyonların tespiti ve miktarları hakkında bilgi vermek için bu yöntemin hızlı ve yüksek doğruluklu olarak kullanılabileceğini vurgulamışlardır. Şekil 2.31'da şeker kamışı yaprağında mantar enfeksiyonu etkisiyle görülen kahverengi lekeler ve görüntü işleme tekniği ile lekelerin belirlenmesine ilişkin görseller verilmiştir.



Şekil 2.31 Şeker kamışı yaprağında görülen fungal kahverengi lekeler ve görüntü işleme tekniği ile lekelerin belirlenmesi (Patil ve Bodhe 2016)


Erkinbaev vd. (2017) çalışmalarında hiperspektral yakın kızılötesi görüntüleme tekniğini kullanarak glutensiz yulaf tanelerini arpa, buğday ve çavdardan ayırmışlardır. Çok değişkenli veri analizi ile birleştirilmiş 900-1700 nm dalga boyunda NIR hiperspektral görüntüleme kullanılarak altı çeşide ait taneleri (yulaf, kavuzundan ayrılmış yulaf, arpa, kavuzundan ayrılmış arpa, buğday ve çavdar) sınıflandırmak için PCA (Temel Bileşen Analizi) ve PLSDA (Kısmi En Küçük Kareler Ayırma Analizi)

yöntemlerini kullanmışlardır. Çalışma, kavuzundan ayrılmış yulaf için % 99 doğrulukla sonuçlanmıştır. Sonuç olarak araştırmacılar, NIR hiperspektral görüntülemenin, çevrimiçi yulaf tanesinin kalite kontrol ve muayenesinde uygulama potansiyeline sahip olduğunu belirtmişlerdir. Şekil 2.32’de NIR hiperspektral görüntüleme sisteminin şematik gösterimi verilmiştir.



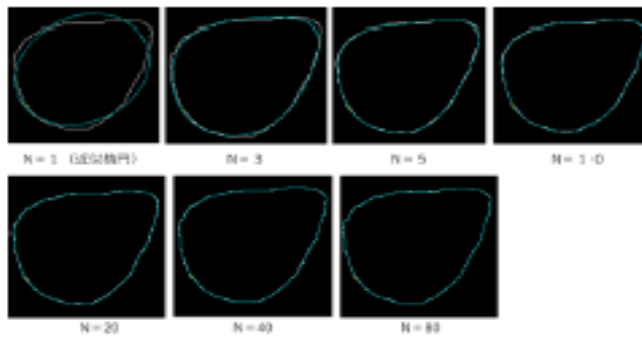
Şekil 2.32 NIR hiperspektral görüntüleme sisteminin şematik gösterimi (Erkinbaev vd. 2017)

Dimilier ve Kirsal Ever (2018) akıllı sınıflandırma sistemiyle bitki ve hayvan zararlılarını, yapay sinir ağı ve görüntü işleme tekniğinden faydalanarak sınıflandırmışlardır. Zararlıların tespiti ve bu zararlılar için uygun ilacın kullanımına yönelik yapılan çalışmada, araştırmacılar öncelikle görüntülerdeki ayırt edici geometrik desenler (pattern recognition) işlenmiştir. Sistemin başarılı bir şekilde sınıflandırma yaptığını bildirmişlerdir. Şekil 2.33’te çalışmada kullanılan bitki ve hayvan zararlılarına ait görseller verilmiştir.



Şekil 2.33 Bitki ve hayvan zararlılarının görüntü analiziyle sınıflandırılması (Dimilier ve Kirsal Ever 2018)


Ishikawa vd. (2018) çalışmalarında, dijital görüntüler üzerinden alınan şekil bilgisinden yararlanarak çilekleri sınıflandırmışlardır. SHAPE yazılımını kullanarak, toplam 2969 adet fotoğraftan elde edilen meyve uzunluğu, genişliği, projeksiyon alanı ve meyve sınır çizgileri verilerini sınıflandırma amacıyla kullanmışlardır. Dokuz farklı şekle sahip olan çilek meyvelerini tanılamada makine öğrenmesi (machine learning) yöntemin başarılı olduğunu vurgulamışlardır. Şekil 2.34'te farklı şekillere sahip çilek meyvelerinin sınır çizgilerinin belirlenmesine ilişkin görseller verilmiştir.



Şekil 2.34 Çilek meyvelerinde kenar belirleme işlemi (Ishikawa vd. 2018)

Li ve vd. (2019) çalışmalarında, hasat sonrası elmalarda iç ve dış kalitenin hızlı bir şekilde belirlenmesi için çevrimiçi optik ve spektroskopik esaslı bir sistem geliştirmişlerdir. Dış kalite tespit mekanizması ve iç kalite tespit mekanizmasından

oluşan çevrimiçi algılama sisteminde, elmanın tüm yüzey bilgisini içeren görüntüsünün belirlenebilmesi için yeni bir görüntü bölütleme yöntemi geliştirilmiştir (Şekil 2.35). Çalışmada, meyve dış kalite değerlendirme oranının % 96,76, boyut ölçümünde korelasyon katsayısı 0,9763, kök-ortalama-kare hatası (RMS error) 1,3243 mm olarak tespit edilmiştir. Şekil 2.39’da çürük ve sağlam elmalara ilişkin görsel verilmiştir.



Şekil 2.35 Elma sınıflandırma da (a) çürük elma görüntüsü, (b) sağlam elma görüntüsü (Li ve vd. 2019)

Kuan ve vd. (2019) süt ineklerinde meydana gelen sıcaklık stresinin, süt veriminde ciddi bir düşüşe yol açması nedeniyle ineklerde beslenme davranışının izlenmesi için derin öğrenmeye dayalı bir görüntüleme sistemi geliştirmişlerdir. Sistem; temassız, süt ineklerinin beslenme davranışını izleyebilen gömülü sistemde, inek yüzü görüntüleri elde etmek için besleme alanının önüne sabitlenmiş kameraları içermekte ve bireysel inek yüzlerini tanılamak için Evrişimsel Sinir Ağı (CNN) yöntemi kullanılmıştır (Şekil 2.36). Çalışma sonucunda, inek yüzü tanılamada başarı % 0,971 bulunmuştur.

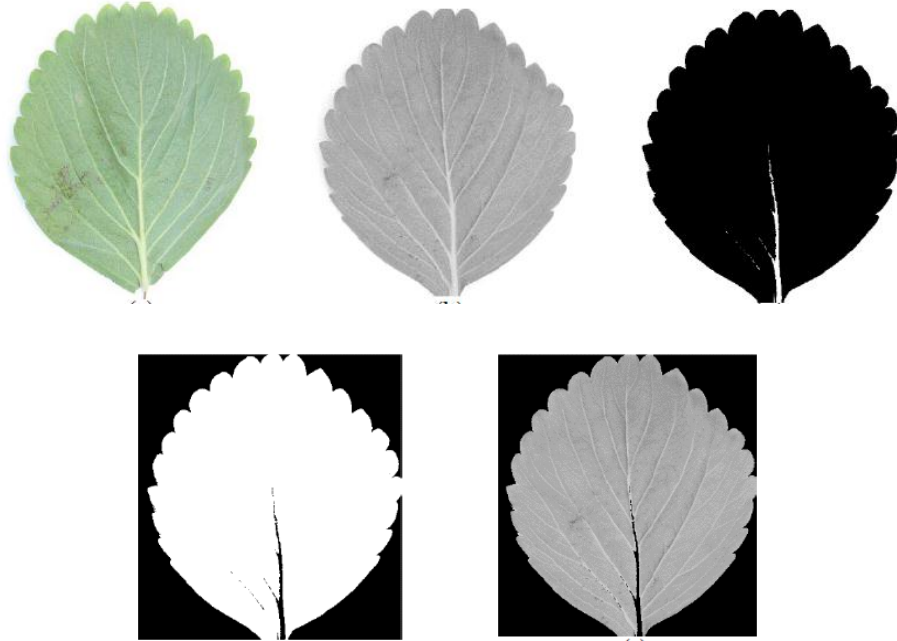


Şekil 2.36 (a) Yüz algılama, (b) yüz tanıma işlemleri (Kuan ve vd. 2019)

Canizo vd. (2019) çalışmalarında şarap menşei bilgisini tahmin edebilecek sınıflandırma modelleri oluşturmuşlar ve veri madenciliği algoritmaları ile karşılaştırmışlardır. Üzümdeki 29 elementin belirlenmesinde MLR, K-NN, SVM ve RO algoritmaları kullanılmıştır. En iyi sonuçlar SVM ve RO algoritmalarıyla sırasıyla % 84 ve % 88,9 doğrulukta tahmin edilmiştir.


H'ng ve Loh (2019) çalışmalarında, çeşitli morfolojik özelliklerin yaprağın mekanik özellikleri üzerindeki etkisini araştırmışlar, ardından veri madenciliği tekniklerini kullanarak yeni bir yaprak mekanik özellikleri tahmin modeli geliştirmişlerdir. Doğrusal Regresyon, KStar, Karar Tabloları ve M5P algoritmaları kullanımıyla yapılan çalışmada tahmin için WEKA yazılımından yararlanılmıştır. Elde edilen sonuçlara göre yaprakta yırtılma kuvveti ve yırtılma dayanımını, M5P algoritması en iyi tahminde bulunmuştur.

Shin ve vd. (2019) çilekte görülen külleme hastalığının erken tespiti için üç görüntü işleme tekniği ve iki gözetimli makine öğrenmesi tekniğinden yararlanmışlardır. Yapay Sinir Ağları ve Destek Vektör Makinası kullanılarak yapılan tahminde % 90,38'lik başarı ile en yüksek doğruluk YSA kullanımıyla tespit edilmiştir. Şekil 2.37'de çalışmada kullanılan yapraklara ait görüntü işleme ile külleme hastalığının belirlenmesi aşamaları verilmiştir.



Şekil 2.37 Görüntü işleme ile çilek yapraklarında külleme hastalığının belirlenmesi aşamaları (Shin vd. 2019)

Datta vd. (2019) çatlak yumurtaları tespit edebilmek için görüntü işleme ve Bölge Tabanlı Evrişimsel Yapay Sinir Ağı (R-CNN) kullanmışlardır (Şekil 2.38). Test verilerinde hasar tespitinin performansı, ortalama hassasiyet (MAP) değeri kullanılarak değerlendirilmiştir. Ağ % 75'ten daha büyük bir ortalama hassasiyet vermiştir ve bölgelerin çoğunu hasarlı olarak tespit edebilmiştir.



Şekil 2.38 Görüntü işleme ile çatlak yumurta tespiti aşamaları (Datta ve vd. 2019)

3. MATERYAL ve YÖNTEM

3.1 Materyal

Çalışmada, biyolojik materyal olarak elma, portakal ve ayva çeşitleri kullanılmıştır. Rosaceae familyasının *Malus* cinsi üyesi olan elmaların çok sayıda türleri bulunmaktadır. Türkiye, dünyada önemli elma üreticisi ülkeler arasında yer almaktadır. FAO (2016) verilerine göre 2 925 828 ton ile Türkiye, dünya ülkelerinden ise Çin, Amerika ve Polonya'dan sonra dördüncü sırada bulunmaktadır (FAO 2018). TÜİK verilerine göre 2017 yılı için Türkiye'de toplam meyve üretimi 20 580 293 ton, elma üretimi ise 3 032 164 tondur (TÜİK 2018). Çalışmada, 50'şer adet Starkrimson Delicious ve Golden Delicious elma çeşitleri kullanılmıştır.

TÜİK (2017) verilerine göre Türkiye'de 4 769 726 ton turunçgil üretimi içinde önemli bir paya sahip olan portakalın (*Citrus sinensis*) 1 950 000 ton üretimi yapılmıştır (TÜİK 2018). FAO (2016) verilerine göre dünya ülkeleri içerisinde ise Türkiye, 1 850 000 ton portakal üretimi ile 10. sırada yer almaktadır (FAO 2018). Çalışmada, materyal olarak 50'şer adet Washington Navel ve Valencia Midnight çeşidi kullanılmıştır.

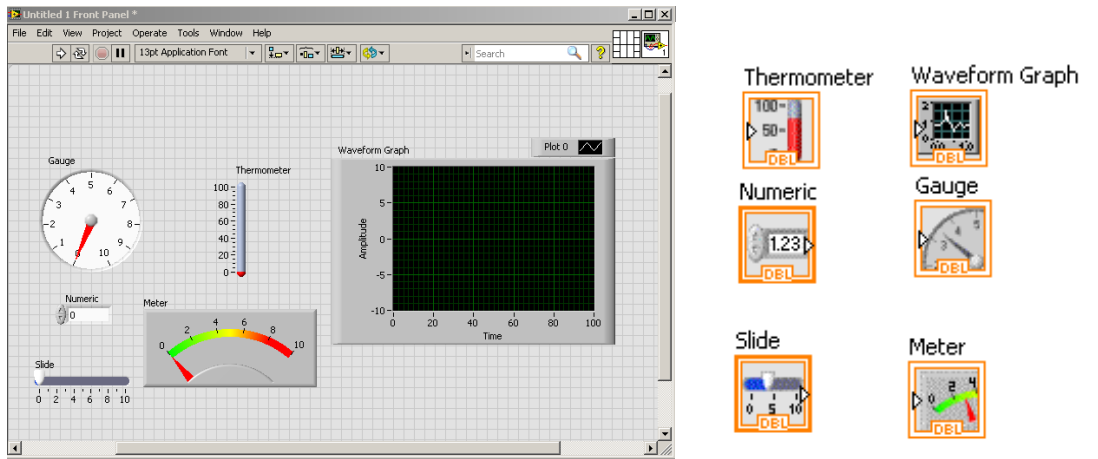
Anavatanı İran'ın kuzeyi, Türkmenistan ve Kafkasya olan ayva, Rosaceae familyasının *Cydonia* cinsi üyesidir. Ilıman iklim meyve türü olmakla birlikte kış soğuklarına (-25°C) dayanıklıdır. FAO (2016) verilerine göre Türkiye 126 400 ton ayva üretimi ile dünyada Özbekistan'dan sonra 2.sırada yer almaktadır (FAO 2018). Çalışmada, 50'şer adet Eşme ve Ekmek ayva çeşidi materyal olarak kullanılmıştır.

Meyvelerin görüntü işleme teknikleri kullanılarak sınıflandırılmasına ilişkin olarak yapılan çalışmalarda görüntüsü alınan örnek büyüklüğünün sayısı 43 ile 948 değerleri arasında değişim görülmektedir (Örnek 2014; Yabanova ve Yumurtacı 2018). Bu değerlerin yanında istatistiksel değerlendirme prensipleri ve veri madenciliği çalışmaları için tavsiye edilen asgari sayılar göz önüne alınarak her bir çeşit için örnek büyüklüğü 50 adet meyve olarak belirlenmiştir.

3.2 Sınıflandırma Ünitesi ve Ölçüm Cihazları

Çalışmada LabVIEW yazılımı kullanılmıştır. LabVIEW (Laboratory Virtual Instrument Engineering Workbench), grafiksel ikonlar ile bu ikonlar arasında veri akışına yardımcı hatların birleştirilmesiyle oluşturulan akış diyagramları için programlama ortamını hazırlayan bir paket programdır. Bu yazılım C, C++, Java, vs. gibi geleneksel dillerden farklı olan nesne odaklı (object oriented) bir grafiksel programlama dilidir (graphical programming language). LabVIEW yazılımı, test, ölçme ve kontrol sistemlerinde sık kullanılmaktadır.

LabVIEW iki kısımdan oluşmaktadır. Bunlardan ilki, sanal enstrümanların kontrol edildiği kullanıcı ara yüzü olan ön panel, diğeri ise sanal enstrümanların çalıştığı asıl işlemlerin gerçekleştiği blok diyagramdır. LabVIEW’da kullanılan üç tür nesne bulunmaktadır. İkonların yerleştirildiği ön panelde göstergeler ve kontroller yer almaktadır. Bu iki nesne doğrudan blok diyagram bağlantılı olmakla birlikte ön panelde eklenen kontrol veya gösterge grubunun fonksiyonu blok diyagrama doğrudan geçmektedir (Şekil 3.1). Ön panelde bulunmayan matematiksel operatörler, zamanlama, vb. gibi fonksiyonlar ise asıl işlemlerin gerçekleştirildiği Blok diyagramda bulunmaktadır (Beyaz 2017).



Şekil 3.1 LabVIEW’da nesne türleri

Ölçüm cihazı olarak, meyve çap değerlerinin ölçülmesinde dijital kumpas kullanılmıştır (Şekil 3.2). Dijital kumpaslar, diğer klasik kumpas çeşitlerine göre kullanıcının olası okuma hatasına izin vermeden, daha kolay ve daha hassas ölçüm yapma imkânı sağlamaktadır. Çalışmada kullanılan dijital kumpas 1/100 mm duyarlılıkta okuma yapabilmektedir.



Şekil 3.2 Dijital kumpas

Meyvelerden renk verilerini elde etmek için Xrite Ci60 model taşınabilir spektrofotometre kullanılmıştır. Kullanılan spektrofotometre, 400 – 700 nm dalga boyu aralığındaki renk değerlerini birden fazla renk uzayında belirleyebilmekte olup, bu çalışmada L*a*b* renk uzayında ölçümler yapılmıştır. Spektrofotometre, ölçüm yapılan yüzeye, bünyesinde bulunan tungsten lamba aracılığıyla ışın göndermekte ve geri yansıyan ışınların spektral analizleri mavi yanıtı yüksek silikon fotodiyotlar kullanılarak çözümlenmektedir (Şekil 3.3).



Şekil 3.3 Denemelerde kullanılan spektrofotometre ve kalibrasyon plakaları


Çalışmada, meyvelerin görüntülerinin elde etmede Logitech C930E model web cam kullanılmıştır (Şekil 3.4). Kamera boyutları 29 x 94 x 24 mm olup, 1920 x 1080 piksel

özünürlüğe kadar görüntü alabilmektedir. Kamera, dizüstü bilgisayarlar, LCD veya CRT monitörlere uygun olarak çalışabilmektedir. Kullanılan kamera, sınıflandırma düzeneğini üstten görebilecek şekilde tripoda yerleştirilmiştir.




Şekil 3.4 Görüntü eldesinde kullanılan kamera ve tripod ünitesi

Sınıflandırma düzeneğinin en önemli bileşeni olan bantlı götürücü, paslanmaz özellikte krom sac ve alüminyum malzemeden imal edilmiştir. Taşıyıcı bant, genişliği 88 mm, kalınlığı 2 mm, 650 - 700 mm arasında olan ve siyah renkte olup elektrostatik etkiyi yok edebilen özellikte bir banda sahiptir. Bantlı götürücünün bağlantı elemanlarının tümü paslanmaz özellikte malzemelerden yapılmıştır. Tahrik silindiri dış çapı 32 mm olmakla birlikte silindirin her iki ucunda 25 mm derinliğinde ve 8 mm çapında delikler bulunmaktadır. Tahrik silindirinin bir ucu 14 mm, diğer ucu 17 mm çapındadır ve yataklarının paslanmaması için alüminyumdan imal edilmiştir. Şekil 3.5'te bantlı götürücünün genel görüntüsü verilmiştir.




Şekil 3.5 Denemelerin yapıldığı bantlı götürücü

Bantlı götürücüyü çalıştıran DC motorun mili ile götürü tahrik silindirine direk geçme yöntemiyle bağlanmıştır. DC motorun redüktör çıkış devri 90 min^{-1} ve motorun çalışma gerilimi 24V DC'dir (Şekil 3.6).




Şekil 3.6 Redüktörlü DC motor

Bandın hızı sisteme eklenen bir DC motor sürücü kullanarak ayarlanabilmektedir (Şekil 3.7). Sisteme eklenen motor sürücüsü, 5 – 30 Volt aralığında çalışan motorları kontrol edebilme özelliğine sahiptir.




Şekil 3.7 DC motor sürücüsü


Sınıflandırma düzeneğinde, asıl ayırma işini yapan iki adet pnömatik çift etkili silindir kullanılmıştır (Şekil 3.8). Pistonların kontrolünü sağlayan selenoidlerin tetiklenmesi amacıyla NPN tipi transistör kullanılmıştır (Şekil 3.9). Sisteme pistonları kumanda eden bir çift selenoid valf (Şekil 3.10) ve gerekli basınçlı havayı üreten maksimum 6,8 bar kapasiteli bir kompresör bağlanmıştır (Şekil 3.11).



Şekil 3.8 Çift etkili pnömatik silindirler



Şekil 3.9 NPN tip transistörler



Şekil 3.10 Selenoid valfler



Şekil 3.11 Kompresör

Bant sistemi üzerinde bulunan pnömatik pistonların kontrolü için Arduino geliştirme kartı kullanılmıştır. Arduino Uno, Mikrodenetleyici (ATmega328) kullanan, çeşitli kartlarla ve diğer devrelere bağlanabilen dijital 14 dijital giriş - çıkış pini ve 6 analog giriş pini bulunduran bir geliştirme kartıdır (Şekil 3.12).



Şekil 3.12 Arduino Uno R3 geliştirme kartı

3.3 Yöntem

Ölçümlerin ilk aşamasında, hasat sonrası kasalardan tesadüfi olarak seçilen elma, ayva ve portakal çeşitleri sap çukuru yapılandırılan etiketlerle numaralandırılmış, ardından kumpasla meyvelerin çiçek çukuru ile sap çukuru arasındaki en geniş mesafe ölçülüp kaydedilmiştir. Toplamda 300 adet ölçüm elde edilmiştir. Algoritma tarafından gerçekleştirilen ölçümlerde ise boyut okumaları, öncelikle meyvelerden alınan RGB görüntülerin gri tonlamalı görüntülere çevrilip sınırlarının belirlenmesi (edge detection), ardından ise en uzun kenarlarının ilgi alanı (ROI, region of interest) sınırlarından ne kadar uzak mesafede olduğu bilgisi elde edilerek belirlenmiştir. Meyvelerin altına yerleştirilen bir platform ile en geniş kısımlarının kamera tarafından ölçülmesi sağlanmıştır. Kamera altına meyveler çiçek çukuru altta kalacak şekilde yerleştirilmiştir. Gerçekleştirilen ölçümler TSE standartlarında belirtilen sınıflama değerlerine göre yapılmıştır. Çizelge 3.1’de TS 100’ün elma için belirlediği en küçük çap değerleri, Çizelge 3.2’de ise yine TS 34’ün belirlediği portakalın boy özellikleri verilmiştir. Geliştirilen algoritmanın elmalar için iri boy ve normal boy, portakallar için sınıf numarası 0...13 arasındaki gruplardan hangilerinde yer aldığı ön panelde boy göstergelerinde belirtilmiş ve bandın üzerinde ayırma işlemini yapan pistonların açılmasıyla sınıflandırılmıştır.

Çizelge 3.1 Elmalarda sınıflandırılmasında kabul edilen küçük çap ölçüleri (Anonim 2007a)

	Ekstra	Sınıf I	Sınıf II
İri boy (L), mm	65	60	60
Normal boy (N), mm	60	55	50

Çizelge 3.2 Turunçgil meyvelerinin boy özellikleri (Anonim 2007b)

Boy No	0	1	2	3	4	5	6
Portakal (mm)	92-110	87-100	84 - 96	81 - 92	77 - 88	73 - 84	70 - 80
Boy No	7	8	9	10	11	12	13
Portakal (mm)	67 - 76	64 - 73	62 - 70	60 - 68	58 -66	56 - 63	53 - 60

Boyut okumaları gerçekleştirildikten sonra çap değerleri belirlenen meyvelerde, Xrite Ci60 spektrofotometre ile meyvelerin sap çukuru çevresinden belirlenen üç yüzey üzerinden renk okumaları gerçekleştirilmiş ve ortalamaları alınarak üç renk kanalı (L, a, b) elde edilmiştir. Alınan Lab renk değerleri formülle RGB renk uzayına dönüştürülmüştür. Renk yönetiminde çok önemli bir araç, iki örnek arasındaki renk farkını tek bir sayı ile belirleyebilme yeteneğidir. Bu amaçla Delta E, renk farkının bir ölçüsü olarak kullanılmaktadır ve Lab uzayındaki iki örnek arasındaki Öklid mesafesini kullanarak belirlenmektedir. Delta E değeri 0 ile 100 arasında değer almaktadır. Renkli görüntü kalitesinin, görüntüleri alan kamera vb. cihazların özelliklerine, görüntü üzerinde yapılan sıkıştırma, restorasyon, yeniden düzenleme, görüntünün iletimi gibi birçok faktöre bağlı olduğu ifade edilmektedir (Ouni vd. 2008). Bu nedenle spektrofotometre ile görüntü işleyerek alınan renk değerlerinin arasındaki renk farklılığını belirtmek için Delta E değeri de verilmiştir. Delta E değeri aşağıdaki formülle hesaplanmaktadır.

$$\Delta E_{ab}^* = \sqrt{(L_2^* - L_1^*)^2 + (a_2^* - a_1^*)^2 + (b_2^* - b_1^*)^2}$$

Formüldeki 1. ve 2. olarak belirtilen renk kanalları, renk ölçümü yapan cihaz veya kameradan alınan değerleri içermektedir. Formülle hesaplanan değer ne kadar küçükse renk farklılığı o kadar az olmaktadır. Delta E değerlerinin yorumları Çizelge 3.3'te verilmiştir.

Çizelge 3.3 Delta E değerleri ve renk algısı arasındaki ilişkiler (Anonymous 2020a)


Delta E değeri	Renk algısı
<= 1,0	Renk farklılığı algılanamaz.
1 - 2	Yakın gözlemlerle farklılık algılanabilir.
2 - 10	İlk gözlemlerle farklılık algılanabilir.
11 - 49	Renkler zıt olmayıp, birbirine benzerdir.
100	Renkler tamamen birbirinin zıttıdır.

Renk okuması yapılan yüzeyler daha sonra kameranın görebileceği konumda yerleştirilmiş, geliştirilen görüntü işleme algoritmasının aynı yüzey üzerinde gerçek zamanlı gerçekleştirdiği ölçüm sonuçları ise Excell dosyasına kaydedilmiştir. Renk değerleri sadece elmalar için TS 100'ün belirlediği standart çerçevesinde sınıflara ayrılmıştır. Çizelge 3.4'te elmalarda izin verilen renk özelliklerine ait bilgiler görülmektedir.

Çizelge 3.4 Elmalarda renk özelliklerine göre izin verilen toleranslar (Anonim 2007a)

Sınıflar	Grup A	Grup B	Grup C	Grup D
	Meyve yüzeyinin toplam kırmızı alanı, en az,	Meyve yüzeyinin toplam kırmızı alanı, en az	Meyve yüzeyinin toplam çizgili kırmızı alanı, en az	Renklilik oranı dikkate alınmaz
Ekstra	3/4	1/2	1/3	
Sınıf I	1/2	1/3	1/10	
Sınıf II	1/4	1/10	Renklilik oranı dikkate alınmaz	

Daha sonra kumpas ve spektrofotometre ile okunan boyut ve renk değerleri, geliştirilen görüntü işleme algoritmasına girilerek meyveleri doğru sınıflama başarısı belirlenmiştir. Meyvelerin boyut ve renk özelliklerine göre sınıflandırılması için geliştirilen görüntü işleme akış diogramı Şekil 3.13'de verilmiştir.




Şekil 3.13 Geliştirilen görüntü işleme algoritmasının iş akış diyagramı

Algoritma tarafından gerçekleştirilen okumalarda, elma, portakal ve ayvaya ait boyut ve renk değerlerinden sayısal dört nitelikli (meyve çapı, R renk kanalı, G renk kanalı ve B renk kanalı) üç yüz adet nesnenin bulunduğu bir veri tabanı oluşturulmuştur. Veri tabanında nitelikleri belirlenen meyvelerin sınıf atamaları (label) yapılmıştır. KNIME Analytics Platform yazılımı kullanılarak, tanımlayıcı istatistik yöntemleri ile veriler tanıtılmış ardından veri madenciliğinde kullanılan sınıflandırma teknikleri ile analiz edilmiştir. Etiket değerlerinin tahmin edilmeye çalışıldığı sınıflandırmada, KNN, karar ağacı, Naive Bayes sınıflandırma ve MLP kullanılmış, üst öğrenme algoritmalarından ise Random Forest (Rastgele Orman) yöntemi seçilmiştir (Şekil 3.14). Karar ağacı oluşturmada kalite ölçüsü olarak bilgi kazanımı (gain information) esas alınmış, budama

yöntemi olarak ise asgari açıklama uzunluğu (MDL) kullanılmıştır. Ayrıca algoritmalar, sınıflandırma teknikleri için eğitim ve test kısımlarını bölmede on kez katlamalı çapraz doğrulama yöntemi ile çalıştırılmıştır. Bu yöntemde, veri setini on parçaya ayırılıp her bir parçanın test, geri kalan dokuz parçanın ise eğitim kümesi olarak kullanılması esasına dayanmaktadır. Sistemin genel hata ve başarı oranlarını, on sonucun ortalaması alınarak hesaplanmaktadır.





Şekil 3.14 KNIME Analytics Platform yazılımı kullanılarak yapılan iş akışı

4. BULGULAR ve TARTIŞMA

4.1 Meyve Boyutuna Göre Sınıflandırma Bulguları

Meyvelerin sınıflandırılması için geliştirilen algoritmanın, kumpas ve gerçek zamanlı boyut okuma karşılaştırmaları Çizelge 4.1, 4.2, 4.3 ve 4.4 'te verilmiştir. 50 adet Starkrimson Delicious çeşidi için sınıflandırma düzeneğinde yapılan denemelerde 6 adet yanlış sınıflandırma yapılmıştır. TS 100'e göre yapılan sınıflandırmada; Ekstra sınıfı için 1. piston, 2.sınıf elmalar için 2. piston tetiklenmiştir. 1. kalite sınıfa giren elmalarda ise pistonlar tetiklenmeyip, bant üzerinden doğrudan geçiş sağlanmıştır. Starkrimson Delicious elma çeşidinde sınıflandırmada başarısı % 88'dir. 50 adet Golden Delicious elma çeşidinde ise boyutlara göre sınıflandırma başarısı % 100 olarak elde edilmiştir. Er vd. (2013) "gerçek zamanlı otomatik elma tasnifleme" çalışmalarında, elma çeşitlerinin bantlı götürücü üzerinde gerçek zamanlı olarak görüntü işleme ile renk, boyut parametreleriyle birlikte boyut ve alan değerlerinden tahmin edilen meyve ağırlıklarıyla sınıflandırma işlemini yapmışlar ve sistemin çalışma başarısının % 95,5 olduğunu belirtmişlerdir. Bul vd. (2005) görüntü işleme tekniklerini kullanarak iyi ve kötü kalitedeki fasulyelerin sınıflandırılmasına yönelik yaptıkları çalışmada, iki DC motorla hareketlendirilen bant üzerindeki fasulyelerin gerçek zamanlı olarak işlenmesi ve sınıflandırılmasında % 87 başarı elde etmişlerdir.

Çizelge 4.1 Starkrimson Delicious elma çeşitlerinin boyut sınıflandırma

Meyve No	Kumpasla ölçülen boyut (mm)	Meyve Sınıfı	Görüntü İşlemeyle ölçülen boyut (mm)	Meyve Sınıfı	Tetikleme
1	57	1. Sınıf	57,6	1. Sınıf	Serbest
2	65	Ekstra	65,3	Ekstra	1. Piston
3	55,5	1. Sınıf	56	1. Sınıf	Serbest
4	52	2. Sınıf	53	2. Sınıf	2. Piston
5	63,1	Ekstra	63,2	Ekstra	1. Piston
6	60	Ekstra	62	Ekstra	1. Piston
7	59,6	1. Sınıf	63	Ekstra	1. Piston
8	65	Ekstra	68,1	Ekstra	1. Piston

Çizelge 4.1 Starkrimson Delicious elma çeşitlerinin boyut sınıflandırma (devam)

9	62	Ekstra	64,2	Ekstra	1. Piston
10	59,1	1. Sınıf	62,5	Ekstra	1. Piston
11	61,4	Ekstra	62,1	Ekstra	1. Piston
12	60,7	Ekstra	65,1	Ekstra	1. Piston
13	63	Ekstra	62,4	Ekstra	1. Piston
14	58,8	1. Sınıf	61,5	1. Sınıf	Serbest
15	60,7	Ekstra	62,4	Ekstra	1. Piston
16	61,5	Ekstra	61,4	Ekstra	1. Piston
17	57,1	1. Sınıf	59,2	1. Sınıf	Serbest
18	60,9	Ekstra	63,6	Ekstra	1. Piston
19	61,3	Ekstra	64,4	Ekstra	1. Piston
20	60,4	Ekstra	60,8	Ekstra	1. Piston
21	61,2	Ekstra	64,7	Ekstra	1. Piston
22	54,9	2. Sınıf	54,6	2. Sınıf	2. Piston
23	60,4	Ekstra	61,4	Ekstra	1. Piston
24	59,7	1. Sınıf	64,3	Ekstra	1. Piston
25	63,4	Ekstra	61,6	Ekstra	1. Piston
26	56,4	1. Sınıf	61,5	Ekstra	1. Piston
27	64,2	Ekstra	66,8	Ekstra	1. Piston
28	60,3	Ekstra	61,5	Ekstra	1. Piston
29	61,5	Ekstra	62,9	Ekstra	1. Piston
30	62,2	Ekstra	64,4	Ekstra	1. Piston
31	50,7	2. Sınıf	50,1	2. Sınıf	2. Piston
32	62,1	Ekstra	64,2	Ekstra	1. Piston
33	62,3	Ekstra	62,8	Ekstra	1. Piston
34	62,1	Ekstra	64,2	Ekstra	1. Piston
35	66,3	Ekstra	66,8	Ekstra	1. Piston
36	57,5	1. Sınıf	59,7	1. Sınıf	Serbest
37	63,8	Ekstra	64,2	Ekstra	1. Piston
38	61,2	Ekstra	62,6	Ekstra	1. Piston
39	62,3	Ekstra	67,7	Ekstra	1. Piston

Çizelge 4.1 Starkrimson Delicious elma çeşitlerinin boyut sınıflandırma (devam)

40	62,8	Ekstra	62,4	Ekstra	1. Piston
41	62,1	Ekstra	60,3	Ekstra	1. Piston
42	61,7	Ekstra	60,4	Ekstra	1. Piston
43	64,9	Ekstra	65,9	Ekstra	1. Piston
44	62,2	Ekstra	62,4	Ekstra	1. Piston
45	62,6	Ekstra	65,6	Ekstra	1. Piston
46	61,3	Ekstra	62,7	Ekstra	1. Piston
47	62,4	Ekstra	63,1	Ekstra	1. Piston
48	62,6	Ekstra	66,8	Ekstra	1. Piston
49	64,6	Ekstra	69,1	Ekstra	1. Piston
50	60,9	Ekstra	62,6	Ekstra	1. Piston

Çizelge 4.2 Golden Delicious çeşidine ait boyut sınıflandırma

Meyve No	Kumpasla ölçülen boyut (mm)	Meyve Sınıfı	Görüntü İşlemeyle ölçülen boyut (mm)	Meyve Sınıfı	Tetikleme
1	72,9	Ekstra	80,2	Ekstra	1. Piston
2	76,6	Ekstra	85,4	Ekstra	1. Piston
3	75,5	Ekstra	86,5	Ekstra	1. Piston
4	70,3	Ekstra	80,1	Ekstra	1. Piston
5	63,4	Ekstra	65,8	Ekstra	1. Piston
6	68,8	Ekstra	74,8	Ekstra	1. Piston
7	62,3	Ekstra	67,2	Ekstra	1. Piston
8	76,5	Ekstra	87,2	Ekstra	1. Piston
9	79,2	Ekstra	89,8	Ekstra	1. Piston
10	75,6	Ekstra	87,4	Ekstra	1. Piston
11	69,7	Ekstra	79,2	Ekstra	1. Piston
12	50,5	2. Sınıf	50,9	2. Sınıf	2. Piston
13	74,7	Ekstra	86,7	Ekstra	1. Piston
14	73,8	Ekstra	84,7	Ekstra	1. Piston
15	62,1	Ekstra	66,5	Ekstra	1. Piston
16	65,3	Ekstra	69,8	Ekstra	1. Piston
17	72,3	Ekstra	82,7	Ekstra	1. Piston
18	77,6	Ekstra	87,3	Ekstra	1. Piston
19	74,4	Ekstra	84,9	Ekstra	1. Piston

Çizelge 4.2 Golden Delicious çeşidine ait boyut sınıflandırma (devam)

20	64,6	Ekstra	70,4	Ekstra	1. Piston
21	72,1	Ekstra	81,6	Ekstra	1. Piston
22	68,6	Ekstra	75,2	Ekstra	1. Piston
23	64,6	Ekstra	68,4	Ekstra	1. Piston
24	69,5	Ekstra	74,7	Ekstra	1. Piston
25	73,2	Ekstra	84,8	Ekstra	1. Piston
26	75,7	Ekstra	86,4	Ekstra	1. Piston
27	68,8	Ekstra	77,3	Ekstra	1. Piston
28	66,7	Ekstra	73,4	Ekstra	1. Piston
29	62,5	Ekstra	65,8	Ekstra	1. Piston
30	60,3	Ekstra	62,2	Ekstra	1. Piston
31	64,1	Ekstra	71,8	Ekstra	1. Piston
32	66,4	Ekstra	70,8	Ekstra	1. Piston
33	61,3	Ekstra	64,8	Ekstra	1. Piston
34	67,1	Ekstra	72,4	Ekstra	1. Piston
35	50,1	2. Sınıf	50,7	2. Sınıf	2. Piston
36	62,3	Ekstra	66,2	Ekstra	1. Piston
37	67,5	Ekstra	73,1	Ekstra	1. Piston
38	74,7	Ekstra	84,1	Ekstra	1. Piston
39	64,7	Ekstra	67,9	Ekstra	1. Piston
40	69,8	Ekstra	69,9	Ekstra	1. Piston
41	67,8	Ekstra	74,8	Ekstra	1. Piston
42	76,2	Ekstra	89,2	Ekstra	1. Piston
43	76,5	Ekstra	86,2	Ekstra	1. Piston
44	77,4	Ekstra	89,4	Ekstra	1. Piston
45	72,6	Ekstra	82,5	Ekstra	1. Piston
46	70,4	Ekstra	89,4	Ekstra	1. Piston
47	75,9	Ekstra	87,4	Ekstra	1. Piston
48	66,8	Ekstra	73,9	Ekstra	1. Piston
49	75	Ekstra	81,1	Ekstra	1. Piston
50	77,3	Ekstra	92,4	Ekstra	1. Piston

Portakal sınıflandırma işlemi yine TS 34'ün belirttiği sınıf numaralarına göre gerçekleştirilmiştir. 0...2 grubu için 1. piston, 3...6 grubu için 2. Piston tetiklendirilmiş, 7...13 grubunda ise pistonlar tetiklendirilmeyip serbest geçişe izin verilmiştir. Portakal çeşitlerinde, meyve çapı bakımından aynı anda birden fazla gruba girme olasılığı olduğundan; 0...2 ve 3...6 grubunda bulunan bir meyvenin bir alt grupta (3...6), 3...6 ve 7...13 grubunda bulunan meyvenin ise yine bir alt grupta olduğu (7...13) varsayılarak sınıflandırılmasına karar verilmiştir. Çizelge 4.3 ve 4.4. incelediğinde, Washington Navel çeşidi için boyutlara göre sınıflandırma başarısı % 96, Valencia Midnight çeşidine göre ise % 82 olarak bulunmuştur. Jhavar (2016) çalışmasında, 160 adet portakaldan alınan fotoğraflar üzerinden örüntü tanılama yöntemini kullanarak portakalların sınıflandırılmasında % 90 ve % 98 başarı elde edilmiştir.

Çizelge 4.3 Washington Navel çeşidine ait boyut sınıflandırma

Washington																		
Meyve no	Ölçümler		Boy no													Tetikleme	Sınıflama	
			0	1	2	3	4	5	6	7	8	9	10	11	12			13
			92 - 110	87 - 100	84 - 96	81 - 92	77 - 88	73 - 84	70 - 80	67 - 76	64 - 73	62 - 70	60 - 68	58 - 66	56 - 63			53 - 60
1	Kumpas	64,70																
	Görüntü İşleme	66,70																
2	Kumpas	58,80																
	Görüntü İşleme	60,80																
3	Kumpas	62,90																
	Görüntü İşleme	65,80																
4	Kumpas	88,15																
	Görüntü İşleme	93,90																
5	Kumpas	62,90																
	Görüntü İşleme	65,80																
6	Kumpas	65,25																
	Görüntü İşleme	67,80																
7	Kumpas	61,90																
	Görüntü İşleme	66,10																

Çizelge 4.3 Washington Navel çeşidine ait boyut sınıflandırma (devam)

8	Kumpas	56,30															Serbest	Başarılı
	Görüntü İşleme	58,80																
9	Kumpas	84,40															2.piston	Başarılı
	Görüntü İşleme	87,10																
10	Kumpas	59,60															Serbest	Başarılı
	Görüntü İşleme	62,90																
11	Kumpas	61,80															Serbest	Başarılı
	Görüntü İşleme	65,30																
12	Kumpas	58,70															Serbest	Başarılı
	Görüntü İşleme	62,70																
13	Kumpas	84,55															2.piston	Başarılı
	Görüntü İşleme	87,30																
14	Kumpas	63,90															Serbest	Başarılı
	Görüntü İşleme	66,90																
15	Kumpas	60,95															Serbest	Başarılı
	Görüntü İşleme	64,00																
16	Kumpas	61,55															Serbest	Başarılı
	Görüntü İşleme	66,80																
17	Kumpas	62,20															Serbest	Başarılı
	Görüntü İşleme	67,00																

Çizelge 4.3 Washington Navel çeşidine ait boyut sınıflandırma (devam)

	İşleme																	
18	Kumpas	60,95																
	Görüntü İşleme	64,40															Serbest	Başarılı
19	Kumpas	91,80																
	Görüntü İşleme	95,40															1.piston	Başarısız
20	Kumpas	55,45																
	Görüntü İşleme	57,90															Serbest	Başarılı
21	Kumpas	62,20																
	Görüntü İşleme	65,90															Serbest	Başarılı
22	Kumpas	62,80																
	Görüntü İşleme	67,70															Serbest	Başarılı
23	Kumpas	93,15																
	Görüntü İşleme	97,70															1.piston	Başarılı
24	Kumpas	62,45																
	Görüntü İşleme	65,90															Serbest	Başarılı
25	Kumpas	61,65																
	Görüntü İşleme	64,70															Serbest	Başarılı
26	Kumpas	104,30																
	Görüntü İşleme	107,30															1.piston	Başarılı

Çizelge 4.3 Washington Navel çeşidine ait boyut sınıflandırma (devam)

27	Kumpas	53,95															Serbest	Başarılı
	Görüntü İşleme	56,30																
28	Kumpas	66,60															Serbest	Başarılı
	Görüntü İşleme	71,60																
29	Kumpas	81,85															2.piston	Başarılı
	Görüntü İşleme	84,80																
30	Kumpas	55,20															Serbest	Başarılı
	Görüntü İşleme	56,90																
31	Kumpas	62,70															Serbest	Başarılı
	Görüntü İşleme	67,70																
32	Kumpas	61,40															Serbest	Başarılı
	Görüntü İşleme	63,30																
33	Kumpas	95,10															1.piston	Başarılı
	Görüntü İşleme	98,10																
34	Kumpas	58,20															Serbest	Başarılı
	Görüntü İşleme	60,90																
35	Kumpas	56,90															Serbest	Başarılı
	Görüntü İşleme	57,20																
36	Kumpas	63,70															Serbest	Başarılı
	Görüntü İşleme	66,90																

Çizelge 4.3 Washington Navel çeşidine ait boyut sınıflandırma (devam)

	İşleme																	
37	Kumpas	62,55																
	Görüntü İşleme	65,80															Serbest	Başarılı
38	Kumpas	56,90																
	Görüntü İşleme	60,50															Serbest	Başarılı
39	Kumpas	63,90																
	Görüntü İşleme	67,30															Serbest	Başarılı
40	Kumpas	57,10																
	Görüntü İşleme	61,10															Serbest	Başarılı
41	Kumpas	58,90																
	Görüntü İşleme	63,30															Serbest	Başarılı
42	Kumpas	63,30																
	Görüntü İşleme	68,30															Serbest	Başarılı
43	Kumpas	61,70																
	Görüntü İşleme	64,30															Serbest	Başarılı
44	Kumpas	63,60																
	Görüntü İşleme	67,60															Serbest	Başarılı
45	Kumpas	56,60																
	Görüntü İşleme	60,60															Serbest	Başarılı
46	Kumpas	85,10															2.piston	Başarılı

Çizelge 4.3 Washington Navel çeşidine ait boyut sınıflandırma (devam)

	Görüntü İşleme	89,20																
	Kumpas	62,15																
47	Görüntü İşleme	65,60															Serbest	Başarılı
	Kumpas	59,95																
48	Görüntü İşleme	62,30															Serbest	Başarılı
	Kumpas	81,40																
49	Görüntü İşleme	85,40															2.piston	Başarılı
	Kumpas	53,50																
50	Görüntü İşleme	53,90															Serbest	Başarılı

Çizelge 4.4 Valencia Midnight çeşidine ait boyut sınıflandırma

Valencia Midnight																		
Meyve no	Ölçümler		Boy no													Tetikleme	Sınıflama	
			0	1	2	3	4	5	6	7	8	9	10	11	12			13
			92 - 110	87 - 100	84 - 96	81 - 92	77 - 88	73 - 84	70 - 80	67 - 76	64 - 73	62 - 70	60 - 68	58 - 66	56 - 63			53 - 60
1	Kumpas	84,75															2. Piston	Başarılı
	Görüntü İşleme	88,40																
2	Kumpas	83,60															2. Piston	Başarılı
	Görüntü İşleme	85,60																
3	Kumpas	92,10															1. Piston	Başarılı
	Görüntü İşleme	97,70																
4	Kumpas	82,60															2. Piston	Başarılı
	Görüntü İşleme	84,90																
5	Kumpas	81,90															2. Piston	Başarılı
	Görüntü İşleme	84,20																
6	Kumpas	79,20															2. Piston	Başarılı
	Görüntü İşleme	84,10																
7	Kumpas	84,70															2. Piston	Başarılı
	Görüntü İşleme	86,30																

Çizelge 4.4 Valencia Midnight çeşidine ait boyut sınıflandırma

8	Kumpas	79,90																2. Piston	Başarılı
	Görüntü İşleme	82,90																	
9	Kumpas	80,85																2. Piston	Başarılı
	Görüntü İşleme	83,00																	
10	Kumpas	88,50																1. Piston	Başarısız
	Görüntü İşleme	93,80																	
11	Kumpas	83,70																2. Piston	Başarılı
	Görüntü İşleme	87,10																	
12	Kumpas	87,25																2. Piston	Başarılı
	Görüntü İşleme	90,70																	
13	Kumpas	85,80																2. Piston	Başarılı
	Görüntü İşleme	89,30																	
14	Kumpas	93,90																1. Piston	Başarılı
	Görüntü İşleme	96,10																	
15	Kumpas	91,70																1. Piston	Başarısız
	Görüntü İşleme	96,60																	
16	Kumpas	83,80																2. Piston	Başarılı
	Görüntü İşleme	84,80																	
17	Kumpas	79,30																2. Piston	Başarılı
	Görüntü İşleme	81,20																	

Çizelge 4.4 Valencia Midnight çeşidine ait boyut sınıflandırma

	Görüntü İşleme	102,90																		
28	Kumpas	91,40																		
	Görüntü İşleme	96,60																	1. Piston	Başarısız
29	Kumpas	92,85																		
	Görüntü İşleme	98,20																	1. Piston	Başarılı
30	Kumpas	87,20																		
	Görüntü İşleme	88,30																	2. Piston	Başarılı
31	Kumpas	85,40																		
	Görüntü İşleme	90,60																	2. Piston	Başarılı
32	Kumpas	91,80																		
	Görüntü İşleme	96,80																	1. Piston	Başarısız
33	Kumpas	88,10																		
	Görüntü İşleme	91,80																	2. Piston	Başarılı
34	Kumpas	93,20																		
	Görüntü İşleme	97,50																	1. Piston	Başarılı
35	Kumpas	82,20																		
	Görüntü İşleme	84,20																	2. Piston	Başarılı
36	Kumpas	73,80																		
	Görüntü İşleme	75,10																	Serbest	Başarılı

Çizelge 4.4 Valencia Midnight çeşidine ait boyut sınıflandırma

	İşleme																		
47	Kumpas	93,70																1.piston	Başarılı
	Görüntü İşleme	101,60																	
48	Kumpas	83,80																2.piston	Başarılı
	Görüntü İşleme	86,80																	
49	Kumpas	84,95																2.piston	Başarılı
	Görüntü İşleme	85,90																	
50	Kumpas	83,05																2.piston	Başarılı
	Görüntü İşleme	88,40																	

Ayva sınıflandırma işleminde, TS 1817' ye göre boyut ve renk bakımında bir sınıflandırma olmadığı, sınıflandırmanın ağırlıklara göre yapıldığı göz önüne alınarak her bir ayva hassas terazide tartılmış, boyutlar ile ağırlık arasındaki ilişkiler ortaya konulmuştur (Anonim 2007c). Buna göre Ekmek ayva çeşidinde, kumpas ile okunan meyve çap değeri ve ağırlık arasındaki kolerasyon katsayısının 0,7 görüntü işleme ile elde edilen çap değeri ve ağırlık arasındaki kolerasyon ise 0,77 bulunmuştur. Eşme ayva çeşidinde ise bu değerler sırasıyla 0,86 ve 0,88 bulunmuştur. Sınıflandırma işlemi, her iki çeşit için en küçük ve en büyük çap değerlerinin belirlenip, algoritmaya kumpasla okunan çap ölçülerinin alt ve üst limit değerleri girilerek yapılmıştır (Çizelge 4.5, 4.6). Her iki ayva çeşidinde de doğru sınıflama için 1. piston, hatalı sınıflamalarda ise 2. piston tetiklenmiştir. Bu yöntemle, Ekmek ayva çeşidinde 5 adet hatalı okuma ile sistem başarısı % 95, Eşme ayva çeşidinde ise 7 hatalı okuma ile % 86 bulunmuştur.

Çizelge 4.5 Ekmek ayva çeşidine ait boyut sınıflandırma

Meyve No	Kumpasla ölçülen boyut (mm)	Görüntü İşlemeyle ölçülen boyut (mm)	Sınıflandırma	Tetikleme
1	77,60	82,70	Başarılı	1. Piston
2	69,90	70,60	Başarılı	1. Piston
3	68,40	70,30	Başarılı	1. Piston
4	77,15	81,20	Başarısız	2. Piston
5	72,80	76,50	Başarılı	1. Piston
6	73,20	77,70	Başarısız	2. Piston
7	76,30	78,30	Başarısız	2. Piston
8	65,95	65,70	Başarılı	1. Piston
9	66,40	66,20	Başarılı	1. Piston
10	73,30	75,20	Başarılı	1. Piston
11	71,90	72,20	Başarılı	1. Piston
12	70,30	72,10	Başarılı	1. Piston
13	74,50	74,80	Başarılı	1. Piston
14	75,35	74,40	Başarılı	1. Piston
15	73,85	82,30	Başarısız	2. Piston
16	76,60	76,80	Başarılı	1. Piston
17	70,45	70,10	Başarılı	1. Piston

Çizelge 4.5 Ekmek ayva çeşidine ait boyut sınıflandırma (devam)

18	73,55	72,40	Başarılı	1. Piston
19	74,25	74,50	Başarılı	1. Piston
20	72,90	69,60	Başarılı	1. Piston
21	72,20	71,60	Başarılı	1. Piston
22	71,30	70,20	Başarılı	1. Piston
23	65,80	68,90	Başarılı	1. Piston
24	66,55	69,10	Başarılı	1. Piston
25	71,65	74,80	Başarılı	1. Piston
26	67,65	71,10	Başarılı	1. Piston
27	66,45	69,30	Başarılı	1. Piston
28	71,60	70,60	Başarılı	1. Piston
29	66,20	65,30	Başarılı	1. Piston
30	70,50	70,60	Başarılı	1. Piston
31	73,85	75,20	Başarılı	1. Piston
32	70,30	70,20	Başarılı	1. Piston
33	72,95	71,60	Başarılı	1. Piston
34	67,60	68,80	Başarılı	1. Piston
35	72,75	76,60	Başarılı	1. Piston
36	68,90	69,10	Başarılı	1. Piston
37	63,85	66,70	Başarılı	1. Piston
38	75,20	78,60	Başarısız	2. Piston
39	70,45	72,50	Başarılı	1. Piston
40	65,65	67,40	Başarılı	1. Piston
41	71,85	76,90	Başarılı	1. Piston
42	69,55	72,30	Başarılı	1. Piston
43	65,60	65,10	Başarılı	1. Piston
44	69,40	72,30	Başarılı	1. Piston
45	70,65	73,60	Başarılı	1. Piston
46	72,85	71,90	Başarılı	1. Piston
47	71,80	68,50	Başarılı	1. Piston
48	66,20	68,70	Başarılı	1. Piston
49	70,15	69,60	Başarılı	1. Piston
50	69,75	69,60	Başarılı	1. Piston


Çizelge 4.6 Eşme ayva çeşidine ait boyut sınıflandırma

Meyve No	Kumpasla ölçülen boyut (mm)	Görüntü İşlemeyle ölçülen boyut (mm)	Sınıflandırma	Tetikleme
1	91,50	96,70	Başarılı	1. Piston
2	89,70	95,10	Başarılı	1. Piston
3	90,60	94,30	Başarılı	1. Piston
4	96,20	102,80	Başarısız	2. Piston
5	94,10	103,10	Başarısız	2. Piston
6	97,70	93,20	Başarılı	1. Piston
7	88,65	91,20	Başarılı	1. Piston
8	85,40	88,20	Başarılı	1. Piston
9	82,30	87,50	Başarılı	1. Piston
10	84,90	89,40	Başarılı	1. Piston
11	91,90	93,80	Başarılı	1. Piston
12	89,20	90,40	Başarılı	1. Piston
13	81,75	85,30	Başarılı	1. Piston
14	91,80	96,20	Başarılı	1. Piston
15	93,70	97,40	Başarılı	1. Piston
16	83,85	93,60	Başarılı	1. Piston
17	89,95	96,50	Başarılı	1. Piston
18	84,55	88,70	Başarılı	1. Piston
19	100,40	105,30	Başarısız	2. Piston
20	88,10	89,10	Başarılı	1. Piston
21	90,80	96,30	Başarılı	1. Piston
22	87,70	93,80	Başarılı	1. Piston
23	91,75	94,30	Başarılı	1. Piston
24	90,25	93,80	Başarılı	1. Piston
25	89,15	93,20	Başarılı	1. Piston
26	94,10	99,80	Başarılı	1. Piston
27	89,55	95,70	Başarılı	1. Piston
28	89,65	90,40	Başarılı	1. Piston
29	95,30	101,80	Başarısız	2. Piston
30	96,80	102,90	Başarısız	2. Piston

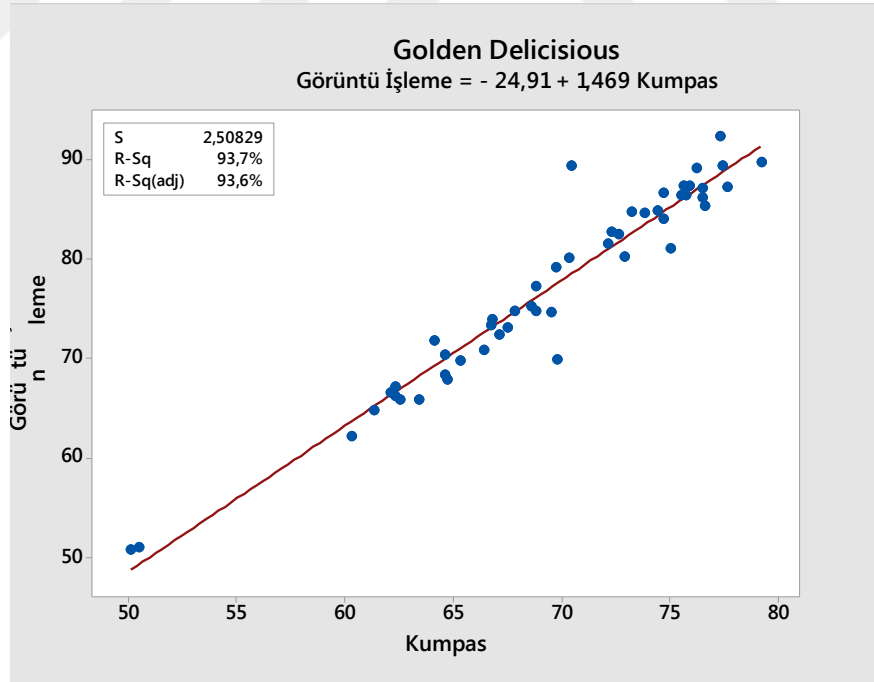
Çizelge 4.6 Eşme ayva çeşidine ait boyut sınıflandırma (devam)

31	86,50	89,70	Başarılı	1. Piston
32	95,40	98,20	Başarılı	1. Piston
33	95,60	96,90	Başarılı	1. Piston
34	95,10	100,60	Başarısız	2. Piston
35	92,55	94,40	Başarılı	1. Piston
36	89,80	94,30	Başarılı	1. Piston
37	89,35	92,30	Başarılı	1. Piston
38	89,20	94,10	Başarılı	1. Piston
39	83,50	85,60	Başarılı	1. Piston
40	91,85	90,10	Başarılı	1. Piston
41	85,55	87,40	Başarılı	1. Piston
42	93,35	101,30	Başarısız	2. Piston
43	82,55	86,20	Başarılı	1. Piston
44	67,65	73,60	Başarılı	1. Piston
45	93,60	98,70	Başarılı	1. Piston
46	92,85	97,30	Başarılı	1. Piston
47	71,10	70,40	Başarılı	1. Piston
48	93,50	96,90	Başarılı	1. Piston
49	89,25	94,10	Başarılı	1. Piston
50	91,90	95,30	Başarılı	1. Piston

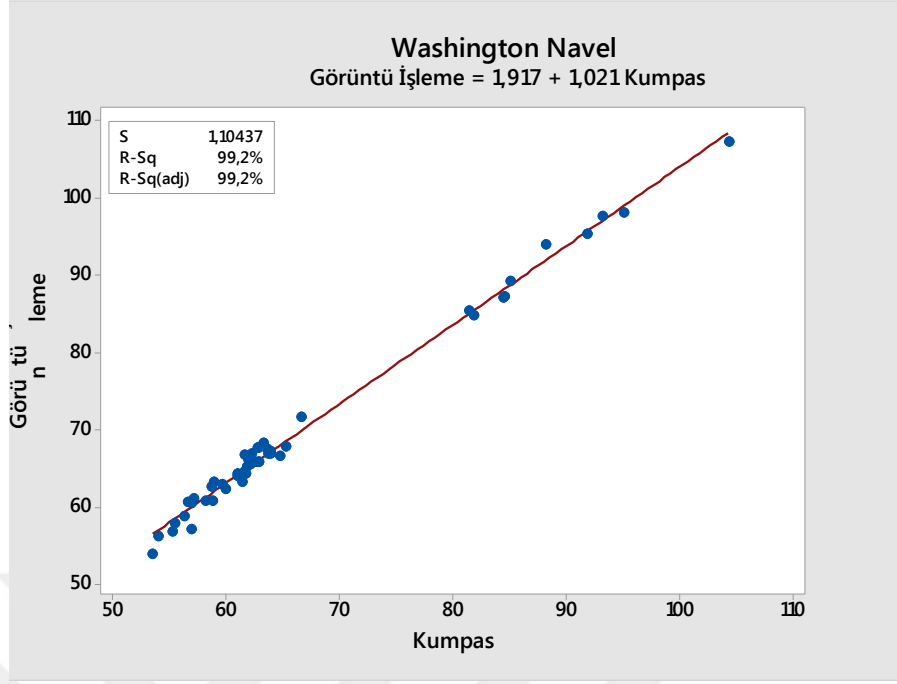
Starkrimson Delicious, Golden Delicious, Washington Novel, Valencia Midnight, Ekmek ve Eşme ayva çeşitlerinde kumpas ve gerçek zamanlı görüntü işleme ile bulunan boyutlar arasındaki ilişki sırasıyla Şekil 4.1 – 4.6’de grafikler halinde verilmiştir.




Şekil 4.1 Starkrimson Delicious çeşidine ait kumpas ölçümü (mm) ve görüntü işleme ölçümü (mm) arasındaki regresyon grafiği



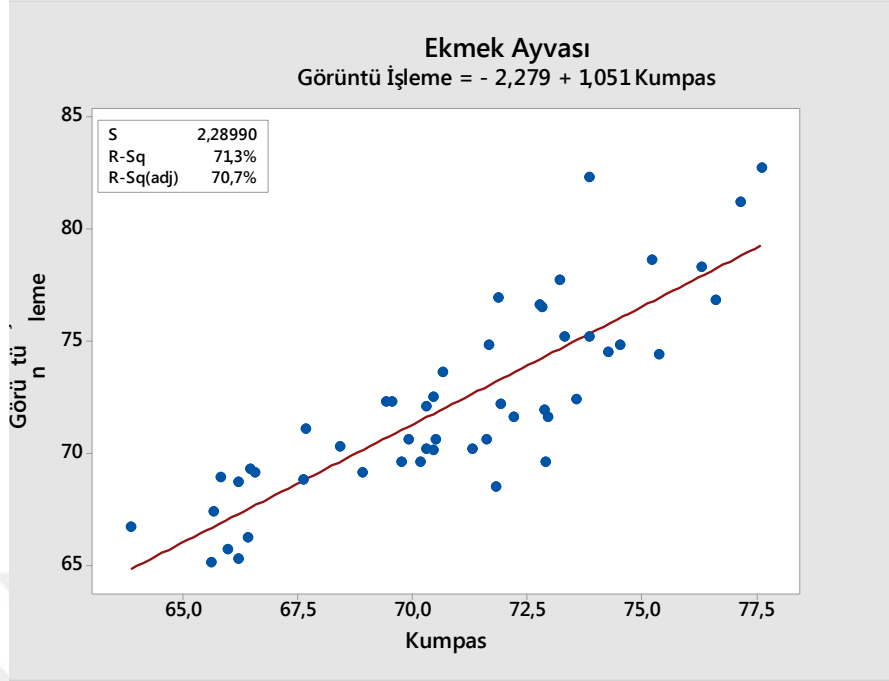
Şekil 4.2 Golden Delicious çeşidine ait kumpas ölçümü (mm) ve görüntü işleme ölçümü (mm) arasındaki regresyon grafiği




Şekil 4.3 Washington Navel çeşidine ait kumpas ölçümü (mm) ve görüntü işleme ölçümü (mm) arasındaki regresyon grafiği



Şekil 4.4 Valencia Midnight çeşidine ait kumpas ölçümü (mm) ve görüntü işleme ölçümü (mm) arasındaki regresyon grafiği



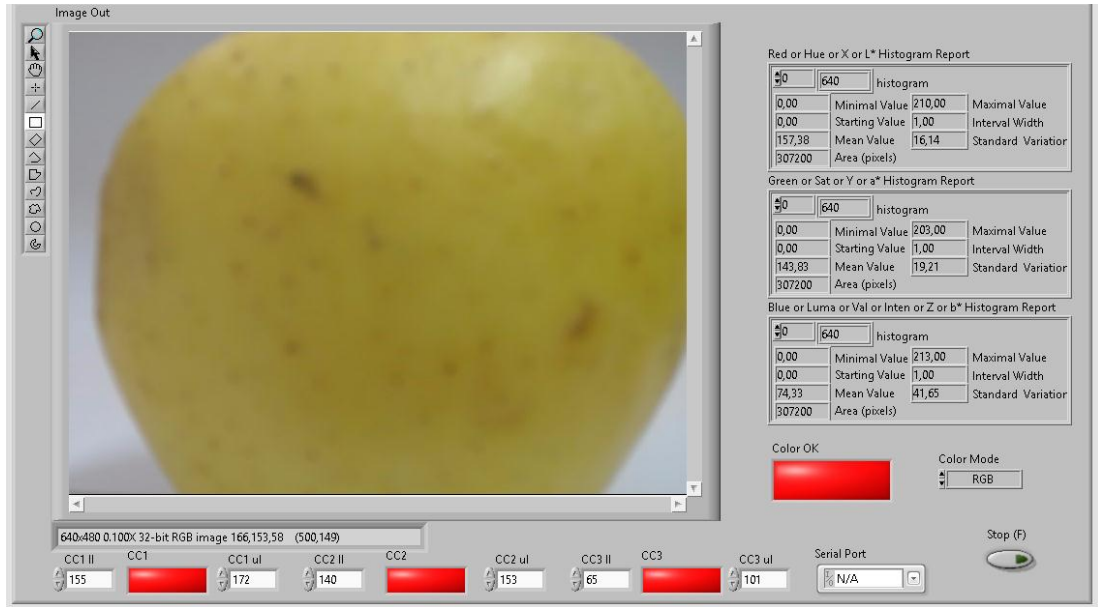
Şekil 4.5 Ekmek ayva çeşidine ait kumpas ölçümü (mm) ve görüntü işleme ölçümü (mm) arasındaki regresyon grafiği



Şekil 4.6 Eşme ayva çeşidine ait kumpas ölçümü (mm) ve görüntü işleme ölçümü (mm) arasındaki regresyon grafiği


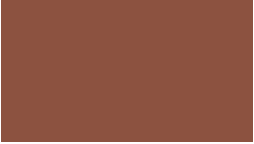



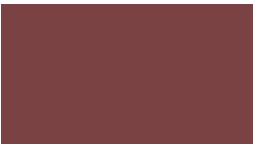




4.1. Meyve Rengine Göre Sınıflandırma Bulguları

Spektrofotometreden alınan R, G, B renk kanalları değerleri ile görüntü işleme sonucu elde edilen veriler arasında yüksek düzeyli bir regresyon ilişkisi bulunamamıştır. Her bir renk kanalı için, spektrofotometreden alınan alt ve üst limit değerleri algoritmaya girildiğinde elma çeşitlerinin birbirleri arasında renk bakımından sınıflara ayrılmasında başarı %100 bulunmuştur (Şekil 4.7). Fakat portakal ve ayva çeşitleri kendi içerisinde renk bakımından anlamlı farklılıkları bulunmadığından renge göre sınıflandırmada başarılı olunamamıştır. Renge göre sınıflandırma yapılamayan çeşitlerde algoritma meyve boyutuna göre sınıflandırmaya devam etmiştir. Görüntü işleme ve spektrofotometreden alınan renk değerleri Çizelge 4.7 – 4.12’de sırasıyla incelenen meyveler için renk kartları hazırlanarak verilmiş ve spektrofotometre ile görüntü işlemeden alınan renklerin birbirinden ne oranda farklı olduğunu belirtmek için renk farklılığı (Delta E) değerleri verilmiştir. Beyaz vd. (2010) tarafından yapılan çalışmada Starkrimson ve Golden Delicious elma çeşitlerinde renk ölçer ve görüntü işleme ile elmalardan alınan renk değerleri arasındaki farklılık (ΔE) değerlerini sırasıyla 7,441 ve 23,483 bulmuşlardır.















Şekil 4.7 Renge göre sınıflandırma işlemi








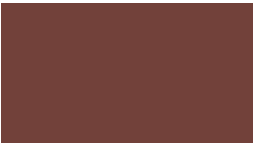




Çizelge 4.7 Starkrimson Delicious çeşidine ait renk analizi değerleri

Görüntü İşleme				Spektrofotometre				Renk Farklılığı
R	G	B	Renk Kartı	R	G	B	Renk Kartı	Delta E
158,71	63,61	56,27		139,67	82,07	64,87		17,47
168,42	78,08	78,95		123,22	72,48	63,78		18,78
167,05	69,77	69,54		123,20	65,68	67,31		19,88
171,06	76,83	85,98		118,45	63,31	62,23		19,59
155,84	65,23	56,73		129,67	77,21	61,54		17,73


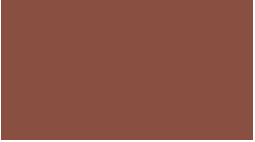

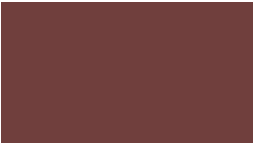








Çizelge 4.7 Starkrimson Delicious çeşidine ait renk analizi değerleri (devam)

166,36	60,37	96,24		124,03	67,15	56,88		28,41
151,73	75,06	67,29		135,74	71,20	62,24		6,14
133,00	83,78	93,46		133,41	68,60	63,07		14,55
154,31	89,75	84,91		118,24	69,08	63,01		11,90
163,91	70,28	97,67		124,45	70,09	65,49		22,10
170,32	85,54	82,39		121,39	64,63	60,95		16,72













Çizelge 4.7 Starkrimson Delicious çeşidine ait renk analizi değerleri (devam)

149,57	95,47	91,57		130,48	68,98	63,28		11,06
156,81	96,98	62,37		123,27	64,71	66,62		23,49
161,70	69,23	89,59		125,04	71,31	63,25		20,59
157,22	44,06	69,53		114,05	65,01	58,46		27,89
160,16	87,59	62,14		134,39	75,95	64,85		12,86
164,42	66,20	92,63		135,23	70,92	61,68		21,29












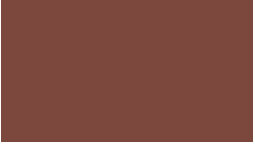
Çizelge 4.7 Starkrimson Delicious çeşidine ait renk analizi değerleri (devam)

153,15	85,97	80,51		137,45	78,51	63,79		7,09
171,00	68,00	61,58		112,48	63,36	60,66		27,41
179,00	55,00	68,00		146,50	86,11	75,63		27,28
160,20	84,56	98,12		141,44	79,74	70,85		17,19
162,23	54,86	56,41		139,92	78,25	64,89		20,44
160,91	62,86	60,54		156,73	96,37	66,61		20,76



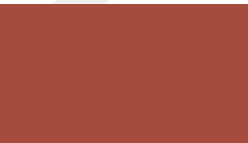
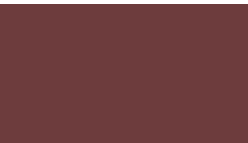








Çizelge 4.7 Starkrimson Delicious çeşidine ait renk analizi değerleri (devam)

159,96	74,63	81,97		144,30	95,24	64,28		23,67
157,95	95,26	91,38		136,16	79,56	67,36		8,77
164,86	57,24	63,53		131,38	76,18	67,25		23,08
164,85	78,73	59,13		124,91	65,44	64,82		20,30
167,96	70,74	86,51		116,14	67,13	60,16		23,21
162,37	54,00	53,57		152,59	80,63	67,27		16,94











Çizelge 4.7 Starkrimson Delicious çeşidine ait renk analizi değerleri (devam)

165,52	69,44	93,17		116,30	64,47	63,52		22,11
147,43	69,66	86,56		126,76	72,67	62,68		16,58
160,70	59,98	64,87		110,51	59,24	60,87		23,52
158,89	50,65	77,61		114,60	65,77	65,11		26,05
163,59	57,35	87,94		123,60	82,06	64,72		33,27
157,44	65,77	63,52		124,18	72,50	62,46		18,30




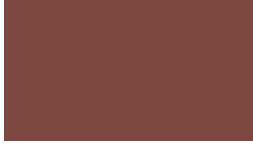

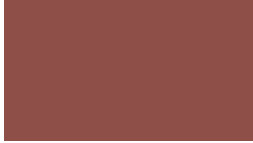


Çizelge 4.7 Starkrimson Delicious çeşidine ait renk analizi değerleri (devam)

157,83	58,00	64,55		111,74	62,94	66,27		23,95
165,87	76,49	62,58		109,45	59,85	61,34		25,24
171,88	59,62	96,53		142,04	91,59	64,64		37,44
161,33	66,89	56,17		126,15	65,10	63,57		19,01
161,25	49,78	84,59		124,86	62,86	65,02		22,59
158,52	82,40	79,56		147,58	80,21	68,58		5,86

Çizelge 4.7 Starkrimson Delicious çeşidine ait renk analizi değerleri (devam)











156,34	68,36	58,12		111,92	61,44	59,30		21,02
148,75	79,70	72,37		105,77	63,96	60,29		16,17
156,00	54,12	81,51		119,75	60,65	56,85		21,37
151,07	73,01	83,58		124,65	68,73	65,24		12,01
155,88	71,82	67,37		121,11	76,68	70,86		18,95

Çizelge 4.7 Starkrimson Delicious çeşidine ait renk analizi değerleri (devam)













149,91	63,56	63,98		136,09	72,45	70,93		10,73
135,72	55,40	73,51		124,79	72,40	64,30		16,91
138,91	49,18	68,73		142,08	78,84	73,07		16,80
154,04	76,4	51,56		126,86	66,72	63,62		17,74

*Renk kartları https://www.w3schools.com/colors/colors_rgb.asp sitesinden yararlanılarak yapılmıştır (Anonymous 2020c).

Çizelge 4.8 Golden Delicians'a ait renk analizi değerleri

Görüntü İşleme				Spektrofotometre				Renk Farklılığı
R	G	B	Renk Kartı	R	G	B	Renk Kartı	DeltaE
167,66	149,07	80,67		213,23	181,28	101,54		14,92
163,24	147,13	77,26		227,70	198,96	110,69		21,93
167,22	148,91	84,95		204,73	180,89	97,18		15,26
164,30	150,05	82,70		222,39	195,23	101,90		21,67
159,15	144,90	81,59		216,05	189,91	96,69		22,65













Çizelge 4.8 Golden Delicions'a ait renk analizi değerleri (devam)

158,94	146,29	83,42		215,34	189,75	102,44		20,96
157,29	148,69	86,12		203,38	192,43	107,06		19,04
160,84	148,58	84,37		202,05	165,97	89,42		14,97
172,34	144,91	76,80		198,33	158,23	64,06		15,11
167,57	148,40	75,67		217,40	179,82	82,18		19,19
157,08	143,24	73,48		185,18	141,60	54,18		17,38

Çizelge 4.8 Golden Delicions'a ait renk analizi değerleri (devam)

161,71	148,76	90,83		209,68	177,33	91,51		20,14
166,05	148,20	86,26		215,57	179,10	87,18		20,97
165,22	150,41	81,79		205,72	179,97	88,44		16,47
163,52	149,79	83,58		194,43	183,20	92,57		16,24
158,61	148,76	90,87		206,60	193,13	111,16		19,75
160,99	140,31	84,00		192,40	161,24	68,66		20,16













Çizelge 4.8 Golden Delicions'a ait renk analizi değerleri (devam)

170,67	147,50	65,27		208,44	167,92	79,97		12,02
164,18	150,63	81,61		200,62	178,57	83,20		16,74
166,56	145,83	80,27		219,23	191,18	114,22		17,98
162,65	149,90	75,28		216,06	188,02	85,84		20,64
155,82	150,89	86,64		210,52	191,66	99,25		21,40
159,05	151,67	92,82		187,95	178,26	85,26		18,98













Çizelge 4.8 Golden Delicions'a ait renk analizi değerleri (devam)

160,83	151,77	87,77		209,92	193,36	106,64		18,98
163,37	148,20	89,84		219,51	193,75	110,98		21,12
158,16	143,67	85,06		187,36	159,30	69,65		17,97
162,90	149,25	82,24		197,81	184,93	89,52		18,14
159,65	150,96	88,35		195,97	182,97	90,52		18,42
159,29	149,59	86,04		197,86	182,27	100,01		15,25













Çizelge 4.8 Golden Delicions'a ait renk analizi değerleri (devam)

158,13	145,64	87,84		212,29	191,05	106,28		21,53
163,38	147,87	83,75		215,59	196,67	111,93		20,12
160,49	148,77	82,30		214,48	191,66	94,74		22,02
161,44	148,87	77,74		205,82	186,32	96,03		16,77
159,44	149,08	92,28		207,04	191,83	105,77		20,96
157,99	152,85	100,75		192,31	184,03	94,01		21,63

Çizelge 4.8 Golden Delicions'a ait renk analizi değerleri (devam)





158,49	151,24	94,74		202,49	190,00	103,62		20,24
161,15	146,80	83,34		213,19	193,30	100,08		22,00
164,03	151,09	91,98		199,80	176,71	78,61		21,71
157,43	149,79	90,55		199,25	184,60	100,20		17,94
160,05	150,11	89,11		208,46	190,86	96,58		22,00
166,79	145,99	77,54		216,00	178,22	80,37		20,40

Çizelge 4.8 Golden Delicions'a ait renk analizi değerleri (devam)

166,64	142,90	65,43		226,61	173,78	53,93		26,94
166,33	148,49	79,63		196,58	165,74	84,43		11,17
168,09	145,87	76,94		223,97	189,17	90,70		22,05
156,23	149,43	86,71		213,71	181,81	89,51		22,81
163,04	146,15	71,97		207,01	180,65	85,00		16,93
157,29	147,54	91,12		215,55	190,63	92,90		26,63











100

Çizelge 4.8 Golden Delicions'a ait renk analizi değerleri (devam)

156,34	149,84	91,51		215,05	188,31	99,71		23,04
162,71	147,59	92,84		218,10	186,43	89,92		26,29
159,74	144,38	75,90		209,20	174,46	87,35		17,61

*Renk kartları https://www.w3schools.com/colors/colors_rgb.asp sitesinden yararlanılarak yapılmıştır (Anonymous 2020c).

Çizelge 4.9 Washington Navel çeşidine ait renk analizi değerleri

Görüntü İşleme (Renk Değerleri)				Spektrofotometre				Renk Farklılığı
R	G	B	Renk Kartı	R	G	B	Renk Kartı	Delta E
185,09	96,02	26,87		226,67	128,42	42,99		14,93
181,43	92,33	29,05		216,86	125,95	44,37		14,73
177,86	92,27	26,86		221,46	129,64	43,76		16,85
190,29	100,12	35,70		224,86	122,05	42,93		12,81
192,24	96,92	29,51		213,04	114,79	45,23		7,05

Çizelge 4.9 Washington Navel çeşidine ait renk analizi değerleri (devam)

185,59	92,92	32,50		219,10	117,25	44,95		11,57
191,58	104,39	30,35		226,89	126,71	42,69		11,71
181,25	99,17	33,78		219,72	117,26	42,44		12,65
186,78	94,12	42,40		218,48	122,51	49,26		14,02
176,67	97,17	37,51		226,28	122,40	42,85		18,59
181,73	95,99	29,49		220,32	121,57	42,31		13,18

Çizelge 4.9 Washington Navel çeşidine ait renk analizi değerleri (devam)

183,84	117,15	61,30		178,81	110,41	51,67		3,18
184,59	98,24	24,27		237,67	138,70	37,23		20,28
186,77	92,46	28,25		223,00	119,82	42,65		12,67
175,45	91,19	30,96		224,94	123,27	42,68		18,05
188,31	103,94	23,44		221,77	138,46	51,70		12,85
186,66	96,03	33,03		221,82	120,68	39,97		13,40

Çizelge 4.9 Washington Navel çeşidine ait renk analizi değerleri (devam)

186,86	104,30	28,27		227,62	130,95	39,84		14,35
189,85	102,16	38,33		226,28	122,40	42,85		13,36
191,26	102,52	27,39		220,16	121,60	44,75		8,84
185,28	97,05	19,31		215,96	124,16	46,66		10,42
187,87	101,73	25,12		207,11	124,85	48,14		8,73
188,37	100,96	29,71		218,11	123,19	33,99		12,02

Çizelge 4.9 Washington Navel çeşidine ait renk analizi değerleri (devam)

187,21	93,89	26,04		216,96	123,39	51,38		10,92
185,92	102,99	31,81		221,26	139,09	38,59		17,15
184,68	95,20	31,28		210,82	122,52	52,99		10,53
183,39	91,36	34,71		213,64	116,49	44,27		12,07
187,88	97,29	23,96		222,31	138,38	44,24		16,84
187,02	98,89	30,34		220,91	125,83	42,16		12,58

Çizelge 4.9 Washington Navel çeşidine ait renk analizi değerleri (devam)

183,75	94,87	34,78		219,56	117,29	44,83		12,54
187,14	110,28	32,69		217,05	123,97	27,64		12,82
187,23	93,63	25,39		188,77	117,28	60,98		15,61
182,75	106,37	47,44		201,21	119,69	40,56		10,54
185,05	93,24	29,40		186,81	105,74	52,31		9,43

Çizelge 4.9 Washington Navel çeşidine ait renk analizi değerleri (devam)

186,72	109,89	45,28		229,01	139,31	33,20		21,31
187,06	98,11	25,37		218,23	118,17	44,67		9,40
184,32	115,36	41,47		187,85	116,87	77,88		17,15
184,42	102,14	40,92		224,18	128,40	42,34		16,72
184,34	97,45	31,85		217,21	118,98	39,62		12,03
184,36	91,07	25,52		223,60	124,14	42,50		14,58

Çizelge 4.9 Washington Navel çeşidine ait renk analizi değerleri (devam)











187,78	90,93	22,04		204,72	117,38	47,96		10,33
187,27	92,82	26,82		211,54	113,10	46,43		8,02
192,24	97,20	32,78		215,49	110,39	46,86		6,91
189,09	99,39	27,89		216,73	119,07	46,84		8,64
189,04	105,93	39,76		215,28	115,56	39,62		10,41
195,40	107,06	33,95		211,53	122,40	43,89		6,09

Çizelge 4.9 Washington Navel çeşidine ait renk analizi değerleri (devam)













193,77	108,82	37,09		220,48	121,54	39,79		9,64
188,47	96,90	24,03		205,66	112,30	45,85		6,46
190,15	103,78	23,14		212,14	117,38	46,42		7,09
187,31	101,29	16,22		215,28	115,56	39,62		8,48

*Renk kartları https://www.w3schools.com/colors/colors_rgb.asp sitesinden yararlanılarak yapılmıştır (Anonymous 2020c).













Çizelge 4.10 Valencia Midnight çeşidine ait renk analizi değerleri

Görüntü İşleme				Spektrofotometre				Renk Farklılığı
R	G	B	Renk Kartı	R	G	B	Renk Kartı	Delta E
184,86	98,28	26,10		203,76	117,54	58,49		9,59
186,89	90,65	29,61		208,89	114,84	46,14		9,18
188,11	102,25	20,86		221,40	125,14	54,05		10,39
185,88	106,92	21,14		222,31	129,31	49,53		10,79
193,52	98,37	20,22		203,81	113,85	33,44		6,53













Çizelge 4.10 Valencia Midnight çeşidine ait renk analizi değerleri (devam)

186,53	95,59	22,60		214,38	120,71	41,78		9,77
189,36	106,44	27,47		221,66	120,70	42,48		10,50
183,03	97,92	18,31		221,66	120,70	42,48		11,85
182,66	98,65	25,54		234,57	135,47	55,31		16,31
193,85	107,89	18,85		234,57	135,47	55,31		12,28
188,32	96,56	22,64		223,54	123,52	60,70		11,89

Çizelge 4.10 Valencia Midnight çeşidine ait renk analizi değerleri (devam)

188,91	106,73	21,59		217,96	123,21	36,77		9,03
184,77	102,46	20,80		215,56	119,90	44,36		9,30
181,08	114,89	27,39		226,72	144,43	54,47		14,08
181,76	103,53	22,15		211,36	124,14	42,50		8,90
188,83	107,71	21,31		223,44	124,17	44,98		10,44
192,51	109,01	23,83		211,45	118,14	39,10		5,54













Çizelge 4.10 Valencia Midnight çeşidine ait renk analizi değerleri (devam)

186,54	104,32	26,03		208,29	124,09	50,53		7,88
183,25	104,58	19,17		218,20	127,48	41,82		10,66
194,25	111,90	16,58		219,14	122,40	39,61		8,17
188,94	101,41	25,70		224,06	124,06	34,47		12,67
190,86	111,31	21,95		230,08	138,57	39,46		13,20
188,44	101,21	16,83		199,61	111,50	47,46		8,10













Çizelge 4.10 Valencia Midnight çeşidine ait renk analizi değerleri (devam)

184,95	103,95	19,84		217,48	123,30	44,43		9,59
186,14	102,25	25,23		199,79	111,47	45,28		5,69
190,51	99,41	22,16		213,47	116,52	46,57		7,47
190,26	101,87	22,04		212,14	117,38	46,42		7,12
186,00	96,98	20,00		213,30	116,55	48,81		8,79
190,00	104,78	30,44		227,46	130,98	42,50		12,83











Çizelge 4.10 Valencia Midnight çeşidine ait renk analizi değerleri (devam)

185,53	97,65	22,85		210,22	113,98	46,28		7,49
191,68	101,64	31,79		221,66	120,70	42,48		10,15
183,45	95,64	28,41		217,64	123,27	41,97		12,46
188,87	104,08	28,45		215,42	124,25	53,45		8,34
186,76	99,91	33,50		222,66	129,26	44,70		13,81
192,94	118,89	26,12		212,95	116,61	53,14		13,06









Çizelge 4.10 Valencia Midnight çeşidine ait renk analizi değerleri (devam)

191,15	100,61	25,24		212,31	117,35	44,11		6,60
193,26	121,48	31,41		212,31	131,91	62,38		9,46
194,31	113,47	28,07		223,13	128,58	56,45		9,30
188,15	104,82	31,58		216,56	119,10	46,84		9,01
185,25	101,44	28,45		213,59	125,73	41,47		10,89
190,44	84,74	17,50		206,07	111,60	56,50		13,07

Çizelge 4.10 Valencia Midnight çeşidine ait renk analizi değerleri (devam)











191,72	115,59	24,88		214,96	115,62	44,42		11,11
187,05	106,18	35,70		209,65	123,29	50,66		6,95
185,75	95,51	22,51		208,29	110,56	46,13		7,11
184,14	110,63	20,84		216,13	124,13	44,27		10,29
194,41	117,63	32,91		222,09	125,02	44,81		10,08

Çizelge 4.10 Valencia Midnight çeşidine ait renk analizi değerleri (devam)

189,70	94,18	20,83		217,51	127,59	51,41		12,71
187,33	119,14	24,88		210,01	123,23	46,11		9,75
195,01	108,91	29,34		217,31	123,33	46,81		6,61
181,39	98,52	24,27		217,06	119,01	42,11		11,23

*Renk kartları https://www.w3schools.com/colors/colors_rgb.asp sitesinden yararlanılarak yapılmıştır (Anonymous 2020c).

Çizelge 4.11 Ekmek ayva çeşidine ait renk analizi değerleri

Görüntü İşleme				Spektrofotometre				Renk Farklılığı
R	G	B	Renk Kartı	R	G	B	Renk Kartı	Delta E
197,01	173,57	57,74		228,74	195,15	82,51		9,56
195,24	165,14	59,55		223,61	186,49	68,82		10,21
204,31	176,57	68,97		227,45	192,60	78,85		7,36
203,86	179,58	61,80		216,55	181,17	72,89		6,41
205,58	181,60	59,14		220,61	183,77	66,08		6,08

Çizelge 4.11 Ekmek ayva çeşidine ait renk analizi değerleri (devam)

207,71	172,85	77,23		230,16	195,37	83,81		9,97
191,24	161,19	69,52		225,49	189,33	80,85		13,01
196,88	168,48	77,31		225,94	192,76	90,01		10,66
198,73	168,46	59,79		227,13	189,15	66,63		10,38
201,68	170,24	76,51		225,20	189,36	83,09		9,17
199,09	167,54	70,14		229,34	191,97	76,63		11,81

Çizelge 4.11 Ekmek ayva çeşidine ait renk analizi değerleri (devam)

193,11	174,12	76,19		227,73	192,57	76,52		13,40
212,74	189,58	86,90		228,60	195,53	94,78		5,17
197,64	176,07	72,70		226,87	192,66	83,40		9,24
202,17	182,78	77,48		218,99	187,83	80,25		6,03
209,27	186,28	81,84		217,86	180,60	75,27		6,63
211,29	190,80	79,98		231,75	191,27	69,53		10,89

Çizelge 4.11 Ekmek ayva çeşidine ait renk analizi değerleri (devam)

206,82	184,55	76,89		223,07	186,54	73,59		7,06
199,77	175,93	71,38		228,01	192,54	74,15		10,39
197,95	169,16	82,36		223,59	189,96	82,99		12,00
189,48	160,54	57,91		226,12	193,17	76,41		13,36
189,61	168,26	82,55		223,88	189,93	80,75		14,97
196,32	166,85	74,89		212,26	179,04	67,77		9,64

Çizelge 4.11 Ekmek ayva çeşidine ait renk analizi değerleri (devam)

204,87	172,55	72,84		222,27	187,06	66,23		10,27
200,59	179,24	78,77		230,55	187,90	64,35		15,27
196,04	166,07	75,04		230,45	195,34	81,53		14,39
202,69	173,66	77,71		226,52	185,29	71,46		11,24
196,84	172,27	77,17		221,11	183,72	61,03		14,35

Çizelge 4.11 Ekmek ayva çeşidine ait renk analizi değerleri (devam)

191,94	166,98	84,17		226,28	196,63	88,09		15,89
200,48	173,94	85,45		224,74	189,84	73,82		14,22
200,50	171,80	73,73		218,41	180,54	70,68		7,55
190,42	163,56	74,35		227,16	192,63	81,14		14,93
199,05	168,68	76,63		230,15	191,88	69,40		16,31
192,79	163,75	72,74		223,12	190,44	73,71		14,42







Çizelge 4.11 Ekmek ayva çeşidine ait renk analizi değerleri (devam)

203,83	185,16	74,50		231,22	198,76	88,61		8,08
196,14	166,02	72,09		230,74	195,31	79,22		14,49
198,78	169,56	82,19		232,35	194,71	79,33		15,90
203,38	179,27	82,15		223,28	189,99	85,21		7,09
202,52	178,88	72,80		223,59	189,96	82,99		6,35
200,23	172,10	59,70		227,52	185,18	61,53		10,13

Çizelge 4.11 Ekmek ayva çeşidine ait renk analizi değerleri (devam)











193,85	175,28	71,66		227,39	189,13	78,58		11,10
208,70	184,03	91,15		226,26	192,73	87,84		7,62
208,55	178,50	80,39		231,02	195,28	76,87		10,56
203,44	171,52	77,55		229,89	191,91	71,86		13,89
202,29	180,68	62,44		225,54	193,23	81,04		7,61
210,95	185,48	67,02		220,35	183,80	68,51		4,52

Çizelge 4.11 Ekmek ayva çeşidine ait renk analizi değerleri (devam)

208,30	175,19	71,72		225,70	185,82	63,97		9,73
205,47	182,44	62,58		223,67	190,38	68,87		6,14
200,83	171,89	72,33		219,27	184,34	63,46		10,43
199,64	176,25	53,66		229,89	191,91	71,86		8,96

*Renk kartları https://www.w3schools.com/colors/colors_rgb.asp sitesinden yararlanılarak yapılmıştır (Anonymous 2020c).

Çizelge 4.12 Eşme çeşidine ait renk analizi değerleri

Görüntü İşleme				Spektrofotometre				Renk Farklılığı
R	G	B	Renk Kartı	R	G	B	Renk Kartı	Delta E
193,87	174,55	74,41		211,44	171,81	57,23		11,58
200,44	178,21	50,96		227,62	181,23	58,98		11,50
196,17	188,16	72,67		213,08	171,19	57,93		16,06
200,83	178,65	97,29		206,51	169,78	59,90		15,62
202,36	174,92	64,05		221,47	187,14	73,48		5,83

Çizelge 4.12 Eşme çeşidine ait renk analizi değerleri (devam)

209,80	180,28	66,79		202,42	163,39	66,50		9,48
202,72	175,40	74,08		230,95	191,36	76,74		10,27
209,66	179,68	75,16		213,76	174,57	67,78		4,58
198,52	173,92	68,32		218,75	173,13	47,45		13,27
206,05	181,72	85,36		227,45	192,60	78,85		10,05
205,37	179,68	75,24		212,85	185,91	71,34		4,91

Çizelge 4.12 Eşme çeşidine ait renk analizi değerleri (devam)

203,60	178,01	71,62		227,52	185,18	61,53		11,54
202,88	176,15	67,42		232,00	191,25	67,02		11,08
204,94	182,87	83,81		212,85	185,85	88,45		2,61
206,63	183,44	85,01		229,24	195,47	90,47		7,37
200,66	173,96	89,29		211,54	186,40	86,22		7,85
201,49	174,93	86,18		222,97	190,02	87,39		9,16

Çizelge 4.12 Eşme çeşidine ait renk analizi değerleri (devam)

203,83	172,71	86,78		220,03	190,75	95,83		7,35
203,16	173,32	82,47		205,04	181,03	85,30		4,10
206,01	179,09	80,43		221,66	190,59	85,11		5,74
203,28	175,89	67,81		224,26	182,50	61,30		9,62
200,60	179,90	77,74		214,47	189,12	88,83		4,01
211,45	183,18	79,00		190,46	156,23	71,70		12,73

Çizelge 4.12 Eşme çeşidine ait renk analizi değerleri (devam)

199,33	175,52	74,27		195,19	158,24	72,22		10,45
201,98	171,96	75,61		214,41	185,69	77,51		7,00
199,51	176,44	74,24		229,62	191,94	74,27		11,63
202,55	180,01	67,13		218,99	187,83	80,25		5,17
206,56	186,34	80,51		220,26	183,37	82,34		7,16
203,18	182,81	79,26		226,34	189,24	73,93		9,92

Çizelge 4.12 Eşme çeşidine ait renk analizi değerleri (devam)

194,94	191,53	82,41		218,99	187,83	80,25		12,36
203,61	178,74	80,42		226,06	189,27	76,28		9,50
202,37	179,68	74,49		202,37	166,81	79,76		10,28
200,98	178,05	70,55		230,58	198,82	93,01		8,97
200,77	177,65	79,45		226,61	189,21	71,55		11,78
202,02	176,41	79,94		230,58	198,82	93,01		9,92







Çizelge 4.12 Eşme çeşidine ait renk analizi değerleri (devam)

199,55	176,93	74,38		221,31	186,73	87,03		6,51
203,53	181,69	89,55		223,66	193,42	94,21		6,86
192,67	174,62	80,11		216,03	185,10	86,40		7,57
197,39	175,27	78,92		218,99	187,83	80,25		8,58
197,45	176,88	88,01		224,17	189,90	78,48		13,62
200,31	177,34	85,47		226,95	196,13	94,70		9,02

Çizelge 4.12 Eşme çeşidine ait renk analizi değerleri (devam)

195,72	172,34	77,77		197,16	161,85	56,65		8,26
188,74	171,75	91,55		217,93	184,48	75,44		16,77
195,09	174,40	82,00		223,99	193,39	92,08		9,56
194,46	178,22	87,25		222,63	193,52	100,50		8,73
201,06	175,02	80,46		220,61	187,23	80,35		8,12
197,72	174,51	81,46		224,31	193,36	89,92		8,76

Çizelge 4.12 Eşme çeşidine ait renk analizi değerleri (devam)

197,69	174,81	81,43		213,22	174,63	72,37		8,44
206,43	183,97	76,70		217,76	177,15	60,81		10,11
177,86	161,51	96,12		217,93	184,48	75,44		23,91

*Renk kartları https://www.w3schools.com/colors/colors_rgb.asp sitesinden yararlanılarak yapılmıştır (Anonymous 2020c).

Görüntü işleme algoritmasıyla meyvelerden okunan boyut ve renk değerleri, veri madenciliğinde kullanılan tahmine dönük teknikler kullanılarak değerlendirilmiştir. Bu amaçla, k en yakın komşuluk (KNN), karar ağacı (DT), Naive Bayes sınıflandırma ve çok katmanlı algılayıcı sinir ağı (MLP) algoritmaları kullanılmıştır. Algoritmalar 10-kez çapraz doğrulama yöntemi ile çalıştırılmıştır. Ayrıca üst öğrenme algoritmalarından Rastgele Orman (RO) yöntemi seçilmiştir. Analize başlamadan önce "Statistics" düğümü bağlanmış, verilere ait temel tanımlayıcı istatistikler Çizelge 4.13'te verilmiştir. Veriler içerisinde kayıp değerler bulunmamaktadır.

Çizelge 4.13 Verilere ait tanımlayıcı istatistikler

	Min	Ortalama	Maks	Standart Sapma	Kayıp veri
Boyut	50,1	77,679	107,3	13,3571	0
R	105,7731	190,2051	237,6705	30,4832	0
G	59,2384	138,7537	198,96	42,9613	0
B	16,58	62,8926	114,2186	23,9376	0

Boyut ve renk ölçümlerinin doğru meyve sınıfını tahmin etme başarısı, K En Yakın Komşuluk (KNN) % 93,667, Karar Ağacı (DT) % 90,333, Naive Bayes sınıflandırmada % 88,333, Çok Katmanlı Algılayıcı Sinir Ağı % 92,667 ve Random Forest için % 94,333 doğrulukla bulunmuştur. Sabancı vd. (2016) Golden Delicious, Granny Smith ve Starking Delicious elma çeşitlerinin sınıflandırılması amacıyla görüntü işleme teknikleri ile aldıkları değerleri Bayes Net, Naive Bayes, K Star, SMO, RBF Network, RBF Classifier, MLP Classifier, J48, Random Tree ve Random Forest algoritmalarını kullanarak yaptıkları sınıflandırmasında % 95,56 başarı ile J48 algoritması, renk sınıflandırma da ise MLP Classifier algoritmasından % 97,78 başarı elde etmişlerdir. Küçükönder vd. (2015) KStar, Rastgele Orman ve C4.5 algoritmalarıyla domatesten alınan renk verilerini sınıflandırmaya tabi tutarak, algoritmaların başarılarını karşılaştırmışlardır. Yapılan karşılaştırma sonucunda Kstar, Karar ağacı (C4.5), ve Rastgele Orman algoritmalarının doğruluk oranlarını sırasıyla % 100, % 70,74 ve % 98,30 olarak bulmuşlardır. Al-Shekaili vd. (2016) Suudi Arabistan'ın çeşitli

bölgelerinde yetişen hurma çeşitlerini sertliklerine göre sınıflandırdıkları araştırmada 1800 adet örneğin tek renkli görüntülerinden histogram ve doku özellikleri çıkarılarak yapay sinir ağı (YSA) ve doğrusal ayırım analizi (LDA) yöntemlerini kullanarak LDA için % 84 YSA için ise % 77 oranında başarı elde etmişlerdir. Kurutulmuş meyveleri yumuşak, yarı sert ve sert olarak sınıflara ayrıldığı çalışmada LDA için % 84 YSA için ise % 77 oranında başarılı bulunmuştur. Ataş (2016) Siirt fıstığı ile ilgili yaptığı çalışmada, gürbüz özneliklerin çıkarılması amacıyla görüntü işlemeden yararlanmış, alınan mekanik verileri gözetimli makine öğrenmesi algoritmalarından NB, YSA ve DVM ile sınıflandırmıştır. En yüksek sınıflandırma başarısına % 83,33 doğrulukla YSA olduğunu belirtmiştir. Solak ve Altınışık (2017) çalışmalarında fındık meyvelerinin tespit ve sınıflandırılması amacıyla görüntü işleme teknikleri ve ortalama tabanlı sınıflandırma ile K-means kümeleme yöntemlerinin kullanmışlardır. Görüntü işleme ile fındık meyvesi tespiti % 100 başarı ile tespit edilirken, kullanılan diğer algoritmalarla sırasıyla sınıflandırma başarısı % 90 ve % 100 oranında elde etmişlerdir. Beyaz vd. (2017) İspanya’da yetişen bazı zeytin çeşitlerinden görüntü işleme ile belirlenen uzunluk, genişlik ve renk verilerini YSA ile analiz etmişlerdir. Araştırmacılar, YSA ile meyve boyutlarında % 90 doğrulukla tanılama yapılabildiğini bildirmişlerdir. Yabanova ve Yumurtacı (2018) dinamik olarak tartımı yapılan yumurtaların destek vektör makineleri ile sınıflandırmışlardır. Yapılan uygulamada 11 adet giriş verisine kadar eğitim ve test başarısını % 100 bulmuşlardır. Tüm algoritmalara ait karışıklık matrisi ve doğruluk ölçütleri Çizelge 4.14 – 4.18’da verilmiştir.

Çizelge 4.14 KNN algoritmasına ait karışıklık matrisi ve doğruluk ölçütleri

Karışıklık Matrisi	Golden Delicious	Starkrimson Delicious	Washington Navel	Valencia Midknight	Ekmek Ayva	Eşme Ayva	Doğruluk (%)	Hata oranı (%)
Golden Delicious	38	0	0	0	5	7	93,667	6,333
Starkrimson Delicious	0	50	0	0	0	0		
Washington Navel	0	0	50	0	0	0		
Valencia Midknight	0	0	0	50	0	0		
Ekmek Ayva	2	0	0	0	47	1		
Eşme Ayva	2	0	0	0	2	46		
Doğruluk Ölçütleri	F Ölçütü	Hatırlama	Kesinlik	Duyarlılık	Doğru Pozitif	Hatalı Pozitif	Doğru Negatif	Hatalı Negatif
Golden Delicious	0,826	0,905	0,905	0,76	38	4	246	12
Starkrimson Delicious	1	1	1	1	50	0	250	0
Washington Navel	1	1	1	1	50	0	250	0
Valencia Midknight	1	1	1	1	50	0	250	0
Ekmek Ayva	0,904	0,87	0,87	0,94	47	7	243	3
Eşme Ayva	0,885	0,852	0,852	0,92	46	8	242	4

Çizelge 4.15 DT algoritmasına ait karışıklık matrisi ve doğruluk ölçütleri

Karışıklık Matrisi	Golden Delicious	Starkrimson Delicious	Washington Navel	Valencia Midknight	Ekmek Ayva	Eşme Ayva	Doğruluk (%)	Hata oranı (%)
Golden Delicious	40	0	1	0	3	6	90,333	9,667
Starkrimson Delicious	0	50	0	0	0	0		
Washington Navel	0	0	47	3	0	0		
Valencia Midknight	0	0	1	49	0	0		
Ekmek Ayva	4	0	0	0	46	0		
Eşme Ayva	9	0	0	0	2	39		
Doğruluk Ölçütleri	F Ölçütü	Hatırlama	Kesinlik	Duyarlılık	Doğru Pozitif	Hatalı Pozitif	Doğru Negatif	Hatalı Negatif
Golden Delicious	0,777	0,8	0,755	0,8	40	13	237	10
Starkrimson Delicious	1	1	1	1	50	0	250	0
Washington Navel	0,949	0,94	0,959	0,94	47	2	248	3
Valencia Midknight	0,961	0,98	0,942	0,98	49	3	247	1
Ekmek Ayva	0,911	0,02	0,902	0,92	46	5	245	4
Eşme Ayva	0,821	0,78	0,867	0,78	39	6	244	11

Çizelge 4.16 Naive Bayes algoritmasına ait karışıklık matrisi ve doğruluk ölçütleri

Karışıklık Matrisi	Golden Delicious	Starkrimson Delicious	Washington Navel	Valencia Midknight	Ekmek Ayva	Eşme Ayva	Doğruluk (%)	Hata oranı (%)
Golden Delicious	47	0	1	0	0	2	88,333	11,667
Starkrimson Delicious	0	50	0	0	0	0		
Washington Navel	1	0	49	0	0	0		
Valencia Midknight	0	0	2	48	0	0		
Ekmek Ayva	17	0	0	0	33	0		
Eşme Ayva	10	0	0	0	2	38		
Doğruluk Ölçütleri	F Ölçütü	Hatırlama	Kesinlik	Duyarlılık	Doğru Pozitif	Hatalı Pozitif	Doğru Negatif	Hatalı Negatif
Golden Delicious	0,752	0,94	0,627	0,94	47	28	222	3
Starkrimson Delicious	1	1	1	1	50	0	250	0
Washington Navel	0,961	0,98	0,942	0,98	49	3	247	1
Valencia Midknight	0,98	0,96	1	0,96	48	0	250	2
Ekmek Ayva	0,776	0,66	0,943	0,66	33	2	248	17
Eşme Ayva	0,844	0,76	0,95	0,76	38	2	248	12

Çizelge 4.17 MLP algoritmasına ait karışıklık matrisi ve doğruluk ölçütleri

Karışıklık Matrisi	Golden Delicious	Starkrimson Delicious	Washington Navel	Valencia Midknight	Ekmek Ayva	Eşme Ayva	Doğruluk (%)	Hata oranı (%)
Golden Delicious	38	0	1	0	3	8	92,667	7,333
Starkrimson Delicious	0	50	0	0	0	0		
Washington Navel	0	0	48	2	0	0		
Valencia Midknight	0	0	0	50	0	0		
Ekmek Ayva	4	0	0	0	46	0		
Eşme Ayva	1	0	0	0	3	46		
Doğruluk Ölçütleri	F Ölçütü	Hatırlama	Kesinlik	Duyarlılık	Doğru Pozitif	Hatalı Pozitif	Doğru Negatif	Hatalı Negatif
Golden Delicious	0,817	0,76	0,884	0,76	38	5	245	12
Starkrimson Delicious	1	1	1	1	50	0	250	0
Washington Navel	0,97	0,96	0,98	0,96	48	1	249	2
Valencia Midknight	0,98	1	0,962	1	50	2	248	0
Ekmek Ayva	0,902	0,92	0,885	0,92	46	6	244	4
Eşme Ayva	0,885	0,92	0,852	0,92	46	8	242	4

Çizelge 4.18 RO algoritmasına ait karışıklık matrisi ve doğruluk ölçütleri

Karışıklık Matrisi	Golden Delicious	Starkrimson Delicious	Washington Navel	Valencia Midknight	Ekmek Ayva	Eşme Ayva	Doğruluk (%)	Hata oranı (%)
Golden Delicious	42	0	1	0	3	4	94,333	5,667
Starkrimson Delicious	0	50	0	0	0	0		
Washington Navel	0	0	50	0	0	0		
Valencia Midknight	0	0	0	50	0	0		
Ekmek Ayva	4	0	0	0	46	0		
Eşme Ayva	3	0	0	0	2	45		
Doğruluk Ölçütleri	F Ölçütü	Hatırlama	Kesinlik	Duyarlılık	Doğru Pozitif	Hatalı Pozitif	Doğru Negatif	Hatalı Negatif
Golden Delicious	0,848	0,84	0,857	0,84	42	7	243	8
Starkrimson Delicious	1	1	1	1	50	0	250	0
Washington Navel	0,99	1	0,98	1	50	1	249	0
Valencia Midknight	1	1	1	1	50	0	250	0
Ekmek Ayva	0,911	0,92	0,902	0,92	46	5	245	4
Eşme Ayva	0,909	0,9	0,918	0,9	45	4	246	5

5. SONUÇ

Çalışmada, meyvelerin boyut ve renk özelliklerine göre sınıflandırılması amacıyla bir görüntü işleme algoritması geliştirilmiş ve bir sınıflandırma ünitesine entegre edilerek denemelerde kullanılmıştır. Diğer taraftan görüntü işleme yazılımıyla meyvelerde okunan boyut ve renk değerleri, veri madenciliğinde kullanılan tahminleyici teknikleriyle de değerlendirilmiştir. 10-kez çapraz doğrulama yöntemi ile çalıştırılan algoritmalar yüksek doğrulukta sonuçlar vermiştir. Denemeye alınan meyveler için hem çevrimiçi (online) hem de çevrimdışı (offline) sınıflandırma yöntemleri başarılı olmuştur.

Görüntü işleme ve analiz teknikleri çeşitli alanlarda, özellikle askeri alanda başlamış, daha sonra çok çeşitli mühendislik alanlarına yayılmıştır. Uzun yıllar bu tekniklerle birlikte çalışmaların doğruluk düzeyleri üzerinde araştırmalar yapılmış ve çeşitli sonuçlar ortaya konulmuştur. Görüntü işleme tekniklerinin tahribatsız muayenede üstünlüğe sahip olması nedeniyle bu gelişmelerin artarak devam edeceği tahmin edilmektedir. Söz konusu gelişmeler özellikle yazılım geliştirme konusunda artan bir öneme sahip olacaktır. Tarım kesiminde ise teknolojinin tarıma giriş hızının artmasıyla da görüntü işleme tekniklerinin kullanılmasında daha fazla yaygınlık beklenmektedir. Özellikle biyolojik materyal özelliklerinin tanılanması ve tanılanan bu özelliklerin tarım makinaları ve otomasyonu uygulamalarında kullanılması yaygın hale gelecektir.

KAYNAKLAR

- Abu-Oda, G. S., El-Halees, A. M. 2015. Data Mining in Higher Education: University Student Dropout Case Study. *International Journal of Data Mining & Knowledge Management Process*, 5(1), 15.
- Al-Shekaili, N.H., Manickavasagan, A., Al-Mezeini, N.K., Rahman, M.S., Guizani, N. 2016. Computer vision technique to classify dates based on hardness. *Journal of Agricultural and Marine Sciences Vol. 22 (1): 36-41.*
- Amasyalı, M. F., Diri, B., Türkoğlu, F. 2006. Farklı Özellik Vektörleri ile Türkçe Dokümanların Yazarlarının Belirlenmesi. *The Fifteenth Turkish Symposium on Artificial Intelligence and Neural Networks (TAINN'2006)*, Muğla, Turkey, 21-24 June, 2006.
- Anonim, 2007a. Elma Standardı. TS 100. Türk Standartları Enstitüsü, Ankara.
- Anonim, 2007b. Turunçgil Standardı. TS 34. Türk Standartları Enstitüsü, Ankara.
- Anonim, 2007c. Ayva Standardı. TS 1817. Türk Standartları Enstitüsü, Ankara.
- Anonim, 2018a. Web Sitesi:
http://yzgrafik.ege.edu.tr/~ugur/12_13_Spring/CI/ImageProcessing.pdf, Erişim Tarihi: 15.09.2018.
- Anonim, 2018b. Web Sitesi: http://web.firat.edu.tr/iaydin/bmu357/Bolum_1.pdf, Erişim Tarihi: 15.09.2018.
- Anonymous, 2018. Web Sitesi: <https://www.slideshare.net/thelawofscience/light-em-spectrum-12842021>, Erişim Tarihi: 15.09.2018.
- Anonymous, 2020a. Web Sitesi: <http://zschuessler.github.io/DeltaE/learn/>, Erişim Tarihi: 01.04.2020.
- Anonymous, 2020b. Web Sitesi:
<https://devhunteryz.wordpress.com/2018/09/20/rastgele-ormanrandom-forest-algoritmasi/>, Erişim Tarihi: 01.04.2020.
- Anonymous, 2020c. Web Sitesi: https://www.w3schools.com/colors/colors_rgb.asp, Erişim Tarihi: 01.04.2020.
- Ataş, M. 2016. Fıstık Sınıflandırma Sistemi İçin Siirt Fıstığı İmgelerinden Gürbüz Özniteliklerin Çıkarılması. *Dicle Üniversitesi Mühendislik Fakültesi Dergisi*, Cilt: 7, Sayı: 1 (93-102).
- Beyaz, A. 2014. Görüntü İşleme Teknikleri Kullanılarak Zeytin Varyetelerinin Tanımlanması. Doktora Tezi, Ankara Üniversitesi, Fen Bilimleri Enstitüsü, Tarım Makinaları Anabilim Dalı, Ankara.
- Beyaz, A. 2017. Real-Time Video Analysis in Agriculture by Using LabVIEW Software. In *Colorimetry and Image Processing*. IntechOpen.

- Beyaz, A., Özkaya, M.T., İçen, D. 2017. Identification of some spanish olive cultivars using image processing techniques. *Scientia Horticulturae*, Volume 225, Pages 286-292.
- Beyaz, A., Öztürk, R. (2016). Identification of olive cultivars using image processing techniques. *Turkish Journal of Agriculture and Forestry*, 40(5), 671-683.
- Beyaz, A., Öztürk, R., Turker, U. (2010). Assessment of mechanical damage on apples with image analysis. *Journal: Food, Agriculture & Environment (JFAE)*, 8(3&4), 476-480.
- Bul, E., Gelen, G., Altun, H. 2005. Görüntü İşlemeye Dayalı Tarımsal Ürün Sınıflandırma. 11. Ulusal Elektrik- Elektronik- Bilgisayar Mühendisliği Kongresi, 22-25 Eylül 2005, Şişli-İstanbul.
- Canizo, B. V., Escudero, L. B., Pellerano R. G., Rodolfo, G. W. 2019. Data mining approach based on chemical composition of grape skin for quality evaluation and traceability prediction of grapes. *Computers and Electronics in Agriculture* 162 (2019) 514–522.
- Caruana, R., Niculescu-Mizil, A. 2006, An empirical comparison of supervised learning algorithms. In: *Proceedings of the 23rd international conference on Machine learning*, ACM, pp. 161-168.
- Coşlu, E. 2013. Veri Madenciliği. *Akademik Bilişim 2013 – XV. Akademik Bilişim Konferansı Bildirileri*, 23-25 Ocak 2013 – Akdeniz Üniversitesi, Antalya.
- Çalış, K., Gazdağı, O., Yıldız, O. 2013. Reklam İçerikli Epostaların Metin Madenciliği Yöntemleri ile Otomatik Tespiti. *Bilişim Teknolojileri Dergisi*, Cilt: 6, Sayı: 1, Ocak 2013.
- Datta, A. K., Botta, B., Gattam, S. S. R. (2019, July). Damage detection on chicken eggshells using Faster R-CNN. In *2019 ASABE Annual International Meeting* (p. 1). American Society of Agricultural and Biological Engineers.
- Dimilier, K., Kirsal Ever, Y. 2018. Planning pesticides usage for herbal and animal pests based on intelligent classification system with image processing and neural networks. *ITM Web of Conferences* 16, 01004.
- Er, O., Cetişli, B., Sofu, M. M., Kayacan, C. 2013. Gerçek Zamanlı Otomatik Elma Tasnifleme. *Süleyman Demirel Üniversitesi, Fen Bilimleri Enstitüsü Dergisi*, 17(2), 31-38, 2013.
- Erkinbaev, C., Henderson, K., Paliwal, J. 2017. Discrimination of gluten-free oats from contaminants using near infrared hyperspectral imaging technique. *Food Control*, Volume 80, Pages 197-203.
- FAO, 2018. Web Sitesi: <http://www.fao.org/faostat/en/#data/QC/visualize>, Erişim Tarihi: 15.09.2018.
- Fukatsu, T., Watanabe, T., Hu, H., Yoichi, H., Hirafuji, M. 2012. Field monitoring support system for the occurrence of *Leptocorisa chinensis* Dallas (Hemiptera: Alydidae) using synthetic attractants, Field Servers, and image analysis. *Computers and Electronics in Agriculture* 80 (2012) 8–16.

- Gonzales, R.C., Woods, R.E. 2002. Digital image processing. Prentice-Hall, Inc. Upper Saddle River, New Jersey.
- Gowen, A.A., Taghizadeh, M. O'Donnell, C.P. 2009. Identification of mushrooms subjected to freeze damage using hyperspectral imaging. Journal of Food Engineering, Volume 93, Issue 1, Pages 7-12.
- H'ng, C. W., Loh, W.P. 2019. A prediction of leaf mechanical properties with data mining. Computers and Electronics in Agriculture 162 (2019) 669–676.
- Ishikawa, T., Hayashi, A., Nagamatsu, S., Kyutoku, Y., Dan, I., Wada, T., Oku, K., Saeki, Y., Uto, T., Tanabata, T., Isobe, S., Kochi, N. 2018. Classification of Strawberry Fruit Shape by Machine Learning. International Archives of the Photogrammetry, Remote Sensing & Spatial Information Sciences, 42(2).
- Jähne, B., Haußecker, H. 2000. Computer Vision and Applications A Guide for Students and Practitioners, Academic Press, p:702, USA.
- Jhavar, J. 2016. Orange Sorting by Applying Pattern Recognition on Colour Image. Procedia Computer Science 78 (2016) 691 – 697.
- Kalikov, A., 2006, Veri Madenciligi ve Bir E-Ticaret Uygulaması, Yüksek Lisans Tezi, Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Elektronik-Bilgisayar Eğitimi Anabilim Dalı, Ankara.
- Karagöz, A. 2013. Fish Freshness Detection By Digital Image Processing. Yüksek Lisans Tezi, Dokuz Eylül Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik ve Elektronik Mühendisliği Anabilim Dalı, İzmir.
- Kim, D.G., Burks, T.F., Qin, J., Bulanon, D.M. 2009. Classification of grapefruit peel diseases using color texture feature analysis. Int J Agric & Biol Eng, Vol. 2 No.3, 41-50p.
- Köse, İ. 2018. Veri Madenciligi Teori Uygulama ve Felsefesi. Papatya Yayıncılık Eğitim, 280 s., İstanbul, Türkiye.
- Kuan, C-Y., Tsai, Y-C., Hsu, J-T., Ding, S-T., Lin, T-T. 2019. An Imaging System Based on Deep Learning for Monitoring the Feeding Behavior of Dairy Cows. An ASABE Meeting Presentation, DOI: <https://doi.org/10.13031/aim.201901469>, Paper Number: 1901469.
- Kurtulmuş, F. 2012. Olgunlaşmamış Şeftali Meyvesini Doğal Bahçe Koşullarında Alınmış Görüntülerde Görüntü İşleme Teknikleri Ve Yapay Sınıflandırıcılarla Saptayarak Sayan Algoritmaların Geliştirilmesi. Doktora Tezi, Uludağ Üniversitesi, Fen Bilimleri Enstitüsü, Tarım Makinaları Anabilim Dalı, Bursa.
- Küçükönder, H., Vursavuş, K. K., Üçkardeş, F. 2015. K-Star, Rastgele Orman ve Karar Ağacı (C4.5) Sınıflandırma Algoritmaları ile Domatesin Renk Olgunluğu Üzerinde Bazı Mekanik Özelliklerin Etkisinin Belirlenmesi. Türk Tarım – Gıda Bilim ve Teknoloji Dergisi, 3(5): 300-306, 2015.
- Li, L., Peng, Y., Li, Y., Liu, Y. 2019. A nondestructive on-line detection system of apple internal and external parameters based on optical technique. An ASABE

Meeting Presentation, DOI: <https://doi.org/10.13031/aim.201900783>, Paper Number: 1900783.

Lonita, I., Lonita, L. 2018. Classification Algorithms of Data Mining Applied for Demographic Processes. BRAIN – Broad Research in Artificial Intelligence and Neuroscience, Volume 9, Issue1 (February, 2018), ISSN 2067-8957.

Marinakos, G., Daskalaki S. 2016. Viability prediction for retail business units using data mining techniques: a practical application in the Greek pharmaceutical sector. Int. J. Computational Economics and Econometrics, Vol. 6, No. 1, 2016.

MEGEP, 2013. Web Sitesi: http://megep.meb.gov.tr/mte_program_modul/moduller_pdf/Kulak%20Burun%20Bo%20C4%9Faz%20Ve%20G%C3%B6z%20Cerrahisinde%20Bak%20C4%B1m.pdf, Erişim Tarihi: 15.09.2018.

Mitchell, M. W. 2011. Bias of the Random Forest Out-of-Bag (OOB) Error for Certain Input Parameters. Open Journal of Statistics, 2011, 1, pp: 205-211 doi:10.4236/ojs.2011.13024.

Mohsenin, N. N. 1980. Physical Properties of Plant and Animal Materials. Gordon and Breach Science Publishers, One Park Avenue, New York 10016, p: 742, USA.

Naik, S., Patel, B. 2017. Machine vision based fruit classification and grading-a review. International Journal of Computer Applications, 170(9), 22-34.

Nixon, M. S., Aguado, A. S. 2002. Feature Extraction and Image Processing. Newnes, p: 360, UK.

Ouni, S., Zagrouba, E., Chambah, M., Herbin, M. 2008. A New Generic Colour Full Reference Metric. ISIVC 2008.

Örnek, M.N. 2014. Havuç Sınıflandırmada Gerçek Zamanlı Görüntü İşleme Makinası Tasarımı ve Bazı Mekanik Sınıflandırma Makinaları ile Boylama Etkinliklerinin Karşılaştırılması. Doktora Tezi, Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Tarım Makinaları Anabilim Dalı, Konya.

Özekes, S. 2003. Veri Madenciliği Modelleri ve Uygulama Alanları. İstanbul Commerce University Journal of Science, 3 (3), pp: 65-82.

Özkan, H. 2012. Hayvansal Üretim Endüstrisinde Görüntü İşleme Tabanlı Gerçek Zamanlı Bir Kalite Kontrol Uygulaması. Yüksek Lisans Tezi, Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Elektronik ve Bilgisayar Eğitimi Anabilim Dalı, Konya.

Öztemel, E. 2012. Yapay Sinir Ağları. 3. Basım, Papatya Yayıncılık, İstanbul.

Öztürk, R. 1988. Bazı Meyve ve Sebzelere Uygun Kombine Tip Boylama Makinelerinin Yapısal Karakteristikleri, Doktora Tezi, Ankara Üniversitesi, Fen Bilimleri Enstitüsü, Tarımsal Mekanizasyon Anabilim Dalı, Ankara.

Pandya, R., Pandya, J. 2015. C5.0 Algorithm to Improved Decision Tree with Feature Selection and Reduced Error Pruning International Journal of Computer Applications (0975 – 8887) 117(16), pp: 18 – 21.

- Patil, S.P., Bodhe, S.P. 2016. Leaf Disease Severity Measurement Using Image Processing. International Journal of Engineering and Technology Vol.3 (5), 2011, 297-301p.
- Pezikoğlu, F., Ergun, M. E., Erkal, S. 2004. Taze meyve-sebze pazarlama zincirinde modern perakendecilerin durumu. Bahçe, 33(1).
- Pratt, W.K. 2007. Digital Image Processing. John Wiley & Sons, p:807, U.S.A.
- Ritter, G. X., Wilson J. N. 2001. Handbook of Computer Vision Algorithms in Image Algebra. CRC Press, p: 425, USA.
- Rokach, L., Maimon, O. Z. 2008. Data Mining with Decision Trees: Theory and Applications, World Scientific Co. Ltd. vol. 69.
- Sabancı, K., Ünlerşen, M. F., Dilay, Y. 2016. Karaman Yöresinde Yetiştirilen Elma Çeşitlerinin Sınıflandırma Parametrelerini Görüntü İşleme Teknikleri Kullanarak Belirlenmesi. Tarım Makinaları Bilimi Dergisi 2016, 12 (2), 133-139.
- Sharma, G. 2003. Color fundamentals for digital imaging, In: Digital Color Imaging Handbook, CRC Press, p: 764, Florida 33431, USA.
- Shin, J., Chang, Y. K., Nguyen-Quang, T., Heung, B., Ravichandran, P. 2019. Optimizing parameters for image processing techniques using machine learning to detect powdery mildew in strawberry leaves. In 2019 ASABE Annual International Meeting (p. 1). American Society of Agricultural and Biological Engineers.
- Silahtaroglu, G. 2016. Veri Madenciliği Kavram ve Algoritmaları. 3. Basım, 304 s., Papatya Yayıncılık, İstanbul.
- Singh, V., Hedayetullah, M., Zaman, P., Meher, J. 2014. Postharvest technology of fruits and vegetables: An overview. Journal of Postharvest Technology, 2(2), 124-135.
- Solak, S., Altınışık, U. 2017. Görüntü İşleme Teknikleri Ve Kümeleme Yöntemleri Kullanılarak Fındık Meyvesinin Tespit Ve Sınıflandırılması. Sakarya Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 22 (1), 56-65.
- Şeker, Ş. E., Erdoğan, D. 2018. KNIME İle Uçtan Uca Veri Bilimi. 1. Basım, 440 s., Demet Erdoğan Yayınevi.
- Tonguç, G. 2007. Görüntü İşleme Teknikleri Kullanılarak Meyve Tasnifi. Yüksek Lisans Tezi, Süleyman Demirel Üniversitesi, Fen Bilimleri Enstitüsü, Makine Eğitimi Anabilim Dalı, Isparta.
- TÜİK, 2018. Web Sitesi: <https://biruni.tuik.gov.tr/medas/?kn=104&locale=tr>, Erişim Tarihi: 15.09.2018.
- Yabanova, İ., Yumurtaçı, M. 2018. Classification Of Dynamic Egg Weight Using Support Vector Machine. Journal of the Faculty of Engineering and Architecture of Gazi University 33:2 (2018) 393-402.

- Yıldız, A., 2018. Endüstri 4.0 ve akıllı fabrikalar. Sakarya University Journal of Science, 22(2), 546-556.
- Zhang, Yu-Jin. 2006. Advances in Image and Video Segmentation. IRM Press, p: 437, U.S.A.
- Zhong, N., Zhou, L. 1999. Methodologies for Knowledge Discovery and Data Mining. Third Pacific-Asia Conference, Proceedings, Springer Verlag, April 26-28, 1999, Pakdd-99, Beijing, China.



ÖZGEÇMİŞ

Adı Soyadı : Dilara GERDAN

Doğum Yeri : Ankara

Doğum Tarihi : 19.05.1993

Medeni Hali : Bekâr

Yabancı Dili : İngilizce

Eğitim Durumu (Kurum ve Yıl)

Lise : Ankara Kurtuluş Lisesi (2011)

Lisans : Ankara Üniversitesi Ziraat Fakültesi Tarım Makinaları ve Teknolojileri Mühendisliği Bölümü (2017)

Yüksek Lisans : Ankara Üniversitesi Fen Bilimleri Enstitüsü Tarım Makinaları ve Teknolojileri Mühendisliği Anabilim Dalı (Eylül 2017 – Mayıs 2020)

Yayınlar (SCI)

1. Beyaz, A., **Gerdan D.** 2021. Meta-learning Based Prediction of Different Corn Cultivars from Colour Feature Extraction. Journal of Agricultural Sciences, 2021/27/1.
2. Beyaz, A., Dağtekin, M., Çilingir, İ., **Gerdan, D.** 2017. Evaluation of Droplet Size Spectra for Agricultural Pesticide Applications Using Water Sensitive Paper and Image Analysis Techniques, Fresenius Environmental Bulletin, vol. 26, no. 12A, pp. 7717–7723.

Uluslararası Kongre Sunum

1. Dursun, İ., Dursun, E., Beyaz, A., **Gerdan, D.** 2018. Kesişen Hat Yönteminden Yararlanılarak Bitki Yüzey Artığı Kaplama Yüzdesinin Belirlenmesi. International Eurasian Conference on Science, Engineering and Technology, EurasianSciEnTech 2018. (Tam metin bildiri)

2. Beyaz, A., **Gerdan, D.** 2018. Color-Based Filled Bottle Detection System Using LabVIEW. IX International Scientific Agriculture Symposium “AGROSYM 2018”, Book of Abstracts, pp: 374. (Özet bildiri)
3. Beyaz, A., **Gerdan, D.** 2018. A Tractor Mounted Auger Drill Stress Analysis by Using Autodesk Inventor Nastran In Cad Module. IX International Scientific Agriculture Symposium “AGROSYM 2018”, Book of Abstracts, pp: 375. (Özet bildiri)
4. Dursun, İ., Dursun, E., Beyaz, A., **Gerdan, D.** 2018. Determination of Percent Crop Residue Cover by Drone and Image Processing Method in Wheat Field After Harvesting, International Congress On Engineering and Life Science, 26-29 April 2018, Kastamonu/TURKEY. (Tam metin bildiri)
5. Beyaz, A., Çilingir, İ., Dağtekin, M., **Gerdan, D.** 2018. Evaluation of Droplet Size Spectra for Agricultural Pesticide Applications Using Water Sensitive Paper and Image Analysis Techniques, AGME 13th International Congress On Mechanization and Energy in Agriculture & International Workshop On Precision Agriculture. 13-15 September, İzmir/TURKEY. (Özet bildiri)

Ulusal ve Uluslararası Hakemli Dergiler

1. **Gerdan, D.**, Koç., C., Vatandaş, M. 2020. Gıda Ürünlerinin İzlenebilirliğinde Blok Zinciri Teknolojisinin Kullanımı. Tarım Makinaları Bilimi Dergisi (Accepted).
2. Beyaz, A., Özlü, S., **Gerdan, D.** 2020. Experimental Recognition System for Dirty Eggshell by Using Image Analysis Technique. Turkish Journal of Agriculture - Food Science and Technology, 8(5): 1122-1126, 2020 DOI: <https://doi.org/10.24925/turjaf.v8i5.1122-1126.3308>.
3. **Gerdan, D.**, Beyaz, A., Vatandaş, M. 2020. Classification of Apple Fruit Varieties: Comparison of Ensemble Learning and Naive Bayes in H2O Framework. Journal of Agricultural Faculty of Gaziosmanpasa University, 37 (1), 9-16, doi:10.13002/jafag4646.

4. Beyaz, A., **Gerdan, D.** 2019. Computer-aided Stress Analysis of a Model of Tractor Mounted Auger Drill. Agricultural Science Digest.2019.(39):90-95.

5. Beyaz, A., Beyaz, R., **Gerdan, D.** 2015. “Farklı Model Traktör Kullanımının Verdiği Güven Düzeyinin Galvanik Deri Tepkisi Sensörü Kullanılarak Belirlenmesi,” Süleyman Demirel Üniversitesi Mühendislik Bilimleri ve Tasarım Dergisi, vol. 3, no. 3, pp. 133–139.

Yazılan Ulusal/Uluslararası Kitaplar veya Kitaplardaki Bölümler:

1. Koç, C., Eminoğlu M. B., Yegül, U, **Gerdan, D.** 2020. Türkiye 'nin Tarım Ve Tarımsal Sanayinde Ar-Ge Çalışmalarında Mevcut Durumu ve Geleceği. In book: Ziraat, Orman ve Su Ürünleri Alanında Akademik Çalışmalar, Publisher: Gece Kitaplığı, pp: 77-96.

Projeler

1. Sağım Sistemleri için Pulsasyon Görüntüleme Ünitesi Tasarımı (TÜBİTAK – Bursiyer), Göreve başlangıç tarihi: 01/08/2019 – 01/04/2020.
2. İnsansız Hava Aracı (Drone) ve Görüntü İşleme Tekniğini Kullanarak Bitki Yüzey Artığı Kaplama Yüzdesinin Ölçülmesi (BAP- Araştırmacı), 03.07.2017 – 03.07.2018.