T.C

TRAKYA ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

YAPAY ZEKA ÖRÜNTÜ TANIMA ALGORİTMASI KULLANARAK SINIFLANDIRMA OTOMASYONUNUN TASARIMI

Hayrettin TOYLAN

DOKTORA TEZİ

Makine Mühendisliği Anabilim Dalı

Yrd.Doç.Dr.Hilmi KUŞÇU

DANIŞMAN

2012

EDİRNE

T.C

TRAKYA ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

YAPAY ZEKA ÖRÜNTÜ TANIMA ALGORİTMASI KULLANARAK SINIFLANDIRMA OTOMASYONUNUN TASARIMI

Hayrettin TOYLAN

Doktora Tezi

Makine Mühendisliği Anabilim Dalı

Bu tez 26/04/2012 tarihinde aşağıdaki jüri tarafından kabul edilmiştir.

Prof.Dr.Selçuk ARIN	Yrd.Doç.Dr.Hilmi KUŞÇU	Doç.Dr.Yılmaz KILIÇASLAN
Jüri Başkanı	Danışman	Üye
Doç.Dr.Semiha ÖZTUNA		Yrd.Doç.Dr.Cenk MISIRLI
Üye		Üye

ÖZET

Doktora Tezi, Yapay Zeka Örüntü Tanıma Algoritması Kullanarak Sınıflandırma Otomasyonunun Tasarımı, T.C. Trakya Üniversitesi, Fen Bilimleri Enstitüsü, Makine Mühendisligi Anabilim Dalı.

Bu tez çalışmasında elma üreticilerinin elma sınıflandırma makinesinden beklentileri doğrultusunda, fonksiyonel bir elma sınıflandırma sistemi geliştirilmiştir. Geliştirilen elma sınıflandırma sisteminde, kullanıcının tercihine göre birbirinden bağımsız olarak çalıştırılabilen üç farklı sınıflandırma seçeneği sunulmuştur. Bunlar, elmaların renk ve boyuna göre sınıflandırılması, elmaların yüzey kalitesine göre sınıflandırılması ve elmanın kütlesine göre sınıflandırılmasıdır. Bu üç farklı sınıflandırma uygulaması için donanıma uygun olarak algoritma tasarlanmış ve gerçekleştirilmiştir.

Bu tez kapsamında özellikle elmaların renk/boyuna ve yüzey kalitesine göre sınıflandırılması işlemi üzerinde durulmuş ve bu iki sınıflandırma işlemini gerçekleştirmek üzere, gerçek zamanlı çalışan makine görme sistemi tasarlanmıştır. Bununla birlikte makine görme sisteminde bulunan kullanıcı tercihli bu iki yazılım, MATLAB GUI kullanılarak yazılan arayüz ile desteklenmiştir.

İlk yazılım, elmaları renk ve boylarına göre dört farklı sınıfa ayırmaktadır. Bu işlem görüntünün elde edilmesini takiben, çoklu renk uzayı kullanılarak, arka plan ayırma (maskeleme), elmanın renginin belirlenmesi ve elmanın boyunun belirlenmesi ile gerçekleştirilmiştir. Tasarlanan sistem ile Golden, Starking ve Jonagold türü elmalar renklerine göre iki (Kırmızı-Sarı) ve boylarına göre de iki (Normal-İri) olmak üzere toplamda dört sınıfa ayrılırlar. Bu sınıflandırma işlemi %100' e yakın bir başarı oranı ile bir dakikadan daha az bir sürede, 95 adet elma sınıflandırabilme başarısı göstermiştir.

İkinci yazılımda, starking türü elmaların yüzey kalitesine göre sınıflandırılmasını sağlayan, görüntü işleme temelli akıllı bir örüntü tanıma algoritması gerçekleştirilmiştir. Örüntü tanıma algoritması, arka plandan ayrılan elma görüntüsünün bölütlenmesi, örüntülerin özniteliklerinin çıkarılması, öznitelik seçimi ve örüntünün sınıflandırılması basamaklarından oluşur. Bu çalışmada, çoklu-renk uzayı kullanılarak, arka plandan ayrılan elma görüntüsünün bölütlenme işleminden sonra elde edilen örüntülerine ait istatistiksel, dokusal ve şekilsel özelliklerini içeren yirmi beş öznitelik çıkarılmıştır. Bu öznitelikler, Ardışık Geri Yönde Kayan Seçim (SBFS) öznitelik seçim yöntemi ile ayırt ediciliği daha yüksek on bir elemanlı öznitelik alt kümesine indirgenmiş ve bu öznitelikler alt kümesi, sınıflandırıcıya girdi sağlamıştır. Örüntüleri tanımlama aşamasında ise Destek Vektör Makineleri (DVM) ve k En Yakın Komşuluk (k-EYK) sınıflandırma algoritmaları test edilmiştir. Bu testler sonucunda, sınıflandırma hassasiyeti bakımından Gaussian Yarıçap Temelli Fonksiyon çekirdekli, DVM öne çıkarak, farklı eğitim ve test gruplarında en yüksek %90 doğruluk oranı ile örüntüleri,

kusurlar ve diğerleri (elma sapı, çiçek çukuru ve sağlıklı dokular) olarak iki gruba sınıflandırma başarısı göstermiştir. Sonuç olarak, elma yüzeyinde bulunan ve kusur olarak tanımlanan örüntülerin toplam alanına göre elmalar, Ekstra, Sınıf 1, Sınıf 2 ve Reddedilen şeklinde dört sınıfa ayrılmışlardır.

Bu tez çalışmasında, makine görme sisteminden bağımsız üçüncü bir elma sınıflandırma tercihi olarak kütle duyarlı elma sınıflandırma sistemi de geliştirilmiştir. Bu sistemde kütlesi belirlenmiş elmalar, Programlanabilir Mantıksal Denetleyici (PLC)'de yazılan algoritma yardımıyla, kütlenin oluşturduğu ağırlık kuvveti yük hücresi tarafından ölçülerek, dört farklı kütle sınıfına ayrılmışlardır.

Bu tez 2012 yılında yapılmıştır ve 124 sayfadan oluşmaktadır.

ANAHTAR KELİMELER: Makine görmesi, Elma sınıflandırma, Görüntü işleme, Örüntü tanıma, Destek Vektör Makineleri

ABSTRACT

PhD Thesis, Classification Automation Design Using An Artificial Intelligence Pattern Recognition Algorithm, T.R. Trakya University, Graduate School Of Natural And Applied Sciences, Department Of Machine Engineering.

As part of this thesis, a functional apple classification system has been developed, in line with the expectations that apple producers have of apple classification machines. In the apple classification system that was developed, three separate classification options are provided that may be operated independently of each other according to the user's preference. The options are the classification of apples by color and size, the classification of apples by surface quality, and the classification of apples by mass. For these three separate classifications, algorithms conforming to the hardware have been designed and implemented.

Within the scope of this thesis, the emphasis has been on classification of apples by color/size and surface quality, and a machine vision system operating in real-time has been designed. Additionally, these two software components of the machine vision system, which are user-selectable, have been supported with an interface developed using the MATLAB GUI.

The first software component classifies apples into four categories based on color and size. This process is accomplished, following image capturing, by background separation (masking), determining the apple's color using multi-color spaces, and by determining apple size. Using the designed system, Golden, Starking and Jonagold apples are separated into four categories, two per color (Red, Yellow) and two per size (Regular, Large). This classification process has been successful in classifying 95 apples in less than one minute with a success rate close to 100%.

The second software component implements an intelligent pattern recognition algorithm based on image processing that allows Starking apples to be classified per their surface quality. The pattern recognition algorithm is comprised of the steps for segmentation of the apple image that has been separated from the background, extraction of the attributes of the patterns, attribute selection, and classification of the pattern. In this study, twenty-five attributes have been extracted containing features relating to statistics, texture, and shape of the patterns obtained following the segmentation of the apple image separated from the background using multi-color spaces. Using the SBFS attribute selection method, these attributes have been reduced to an eleven-element sub-cluster with a higher distinguishing capability, and this attribute sub-cluster has been provided as an input to the classifier. In the pattern classification phase, the DVM and K-nearest-neighbor classification algorithms have been tested. As a result of these tests, the Gaussian Radial Basis Function (RBF) kernel DVM stood out in terms of precision of classification, and was successful in classifying patterns into two groups, faulty and others (apple stem, apple calyx, and healthy tissue), with a maximum success rate of 90% over diverse training and test groups. In

conclusion, apples have been classified into four categories, Extra, Grade 1, Grade 2, and Rejects, based on the total area on the surface of the apple of the patterns classified as faults.

In this thesis, an option for a third, mass-sensitive apple classification system, independent of the machine vision system, has also been developed. In this system, apples whose masses have been determined are then classified into four separate mass categories with the help of an algorithm developed for and running on the PLC, through measurements, using the load-cell, of the force of weight created by the mass.

This thesis is done in 2012 and consists of 124 pages.

KEYWORDS: Machine vision, Apple classification, Image processing, Pattern recognition, Support Vector Machine

TEŞEKKÜR

Doktora öğrenimim sırasında ve tez çalışmam boyunca bana yol gösteren, destek ve yardımlarını esirgemeyen çok değerli danışman hocam Yrd. Doç Dr. Hilmi KUŞÇU'ya en içten dileklerimle teşekkür ederim. Ayrıca tez izleme komitesinde yer alan Doç. Dr.Yılmaz KILIÇASLAN ve Yrd. Doç. Dr. Cenk MISIRLI'ya müteşekkir olduğumu belirtmek istiyorum.

Bu çalışmamda işyerlerini kullanımıma açan tüm Pınarhisar sanayi esnafına özellikle de Recep ustaya, bununla birlikte değerli arkadaşım Kaner'e, Müjdat Bey'e ve Cihat Bey'e teşekkürü borç bilirim.

Bu tez çalışmasını TUBAP 2010/140 nolu proje numarası ile destekleyen Trakya Üniversitesi Bilimsel Araştırma Projeleri (TÜBAP) birimine teşekkür ederim.

Ve son olarak tez çalışmam boyunca her türlü desteği sağlayan sevgili eşim Nilüfer'e teşekkür ederim.

İÇİNDEKİLER

ÖZET……i
ABSTRACT……iii
TEŞEKKÜR…… v
ŞEKİLLER TABLOSU……viii
ÇİZELGELER TABLOSU……..... xi
SİMGELER……. xii
1. GİRİŞ……... 1
2. LİTERATÜR TARAMASI……..…… 4
2.1. Donanımsal Gelişmeler……5
2.2. Yazılımsal Gelişmeler…… 7
2.2.1. Görüntünün bölütlenmesi ve anlamlandırılmasında kullanılan Yöntemler……7
2.2.2. Elmanın kalitesine göre sınıflandırılmasında kullanılan yöntemler…… 9
3. RENK ve RENK UZAYI……...……... 11
3.1. Renk……...…… 11
3.2. Renk Uzayı……12
3.1.1. RGB renk uzayı……...…... 13
3.1.2. HSV renk uzayı……...…... 15
3.1.3. CMY renk uzayı……..…... 17
3.1.4. CIE XYZ renk uzayı……..……19
3.1.5. CIE L*a*b* renk uzayı……...……..20
3.1.6. CIE L^*C^*h renk uzayı…… 21
4. MAKİNE GÖRME SİSTEMİ……..…… .23
4.1. Kamera ve Lens ……..…… 24
4.2. Aydınlatma Sistemi……26
5. ÖRÜNTÜ TANIMA……..… 27
5.1. Görüntü İşleme……28
5.1.1. Görüntü Maskeleme……... 29
5.1.2. Bölütleme (Segmentasyon)……..…….. 29
5.2. Öznitelik Çıkarımı……..…… 31
5.3. Öznitelik Seçimi……..……...33
5.4. Sınıflandırma……34
5.4.1. Denetimli sınıflandırma (Supervised Classification)……..…….. 34
5.4.1.1. Destek Vektör Makinesi (DVM)…….. 34
5.4.1.2. *k* En Yakın Komşuluk (*k*-EYK) ……..... 38
5.4.2. Denetimsiz sınıflandırma (Unsupervised Classification)……..40
6. MAKİNE GÖRME SİSTEMİ KULLANARAK GERÇEK ZAMANLI ELMA SINIFLANDIRMA OTOMASYONU…… 41
6.1. Elma Sınıflandırma Makine Görme Sistemi……..41
6.1.1. Kamera ve lens……..……42
6.1.2. Aydınlatma sistemi……45
6.1.3. Programlanabilir Mantıksal Denetleyici (PLC)…… 47
6.1.4. Sensör…… 48

6.1.5. Giriş/Çıkış kartı……. 49
6.1.6. Mekanik sistem tasarımı……..……51
6.1.6.1. Giriş birimi……51
6.1.6.2. Döner rulolu konveyör sistem…….……..51
6.1.6.2.1. Konveyör hız kontrolü……..54
6.1.6.3. Ayırıcı birim……..55
6.1.7. Makine görmesi ile elma sınıflandırma ara yüz yazılımı…….. 55
6.2. Elmaların Renk ve Boyunun Gerçek Zamanlı Çoklu-Renk Uzayı Kullanılarak Belirlenmesi……..……57
6.2.1. Çoklu-renk uzayı yardımı ile arka plan ayırma (Maskeleme)……57
6.2.1.1. RGB renk uzayından CIE XYZ renk uzayına dönüşüm…….. .58
6.2.1.2. XYZ_{D65} (D65 kaynak aydınlatma)'den XYZ_{D55} (D55 Hedef aydınlatma) dönüşüm……60
6.2.2. Elmaların renk ve boyunun belirlenmesi…….. 64
6.3. Yüzey Kalitesine Göre Elmaların Sınıflandırılması……66
6.3.1. Görüntü yakalama…… 67
6.3.2. Elma yüzey kusurlarının örüntü tanıma kullanılarak tanımlama…69
6.3.2.1. Arka plan ayırma (Maskeleme)…….……69
6.3.2.2. Elma görüntülerini bölütleme (Segmentasyon)…… 70
6.3.2.3. Öznitelik çıkarımı…… 72
6.3.2.4. Öznitelik seçimi…… 75
6.3.2.5. Sınıflandırma…… 80
6.3.2.5.1. Destek Vektör Makineleri (DVM)……..81
6.3.2.5.2. *k* En Yakın Komşuluk (*k*-EYK)……..84
7. KÜTLE DUYARLI ELMA SINIFLANDIRMA OTOMASYONU……..…. 86
7.1. Kütle Duyarlı Elma Sınıflandırma PLC Programı…… 87
7.2. SCADA…….. 89
7.3. Kütle Duyarlı Elma Sınıflandırma Sistemi Giriş/Çıkış Elamanları…….... 90
8. SONUÇ ve TARTIŞMA…….. 92
9. ÖNERİLER…….. 96
KAYNAKLAR…….. 97
EK-A: SEÇLEN 11 ÖZNİTELİĞİN İKİ BOYUTLU ÖZNİTELİK UZAYI…….. 102
EK-B: ELMA GÖRÜNTÜSÜNÜN RENK UZAYLARI BİLEŞENLERİ VE PİKSEL DAĞILIMLARI……..... 103
EK-C: PROGRAMLANABİLİR MANTIKSAL DENETLEYİCİ MERDİVEN PROGRAMI…… 107
EK-D: MAKİNE GÖRMESİ ELMA SINIFLANDIRMA SİSTEMİNİN MATLAB ORTAMINDA YAZILAN KODLARDAN BAZILARI…….. 115
EK-E: KAMERA ve LENS ÖZELLİKLERİ…… 123
ÖZGEÇMİŞ……...124

ŞEKİLLER TABLOSU

Şekil 1.1. 2009 verilerine göre Dünya'da elma üretimi……2
Şekil 1.2. Makine görme sistemi yazılımının temel basamakları……..3
Şekil 3.1. Bir RGB renk görüntüsündeki piksellerin üç bileşeninin gösterimi……14
Şekil 3.2. RGB renk küpü……....14
Şekil 3.3. HSV renk altıgeni ve renk konisi……... .15
Şekil 3.4. HSV renk uzayının çizimi……... ……16
Şekil 3.5. CMY renk uzayı…….. ……18
Şekil 3.6. 2.derece gözlemciye göre CIE XYZ renk uzayının CIE 1931 Renksellik diyagramı…….....19
Şekil 3.7. CIE L*a*b* renk uzayı……...20
Şekil 3.8. CIE L^*C^*h diagramı……22
Şekil 4.1. Makine görme sistemi…… 24
Şekil 5.1. Örüntü tanıma yapısı……... 28
Şekil 5.2. Maskelenmiş görüntü…….. 29
Şekil 5.3. Bölütleme teknikleri…… 31
Şekil 5.4. Doğrusal ayrılabilen veriler için hiper-düzlem……36
Şekil 5.5. Doğrusal ayrılamayan veriler için optimum hiper-düzlem…… 37
Şekil 6.1. Elma sınıflandırma makine görme sistemi……..42
Şekil 6.2. Kameranın USB bağlantı durumu……43
Şekil 6.3. Kamera konumu ve seçilen lense göre görüntüleme alanı …… 44
Şekil 6.4. Farklı aydınlatmaların görüntü maskeleme sonuçları…… 46
Şekil 6.5. Aydınlatma sistemi……..46
Şekil 6.6. PLC görünüşü……47
Şekil 6.7. Optik sensör bağlantısı……... 48
Şekil 6.8. Giriş/Çıkış kartı bağlantı şekli……49
Şekil 6.9. Gerilim dönüştürücü devre……50
Şekil 6.10. Gerilim dönüştürücü devre tasarımı ve bağlantı adresleri……50
Şekil 6.11. Giriş birimi……51

Şekil 6.12. Kauçuk oval rulo ve bağlantısı……..52
Şekil 6.13. Konveyör perspektif görünüş çizimi……53
Şekil 6.14. Konveyör görünüş…… 53
Şekil 6.15. Ayırıcı birim……..55
Şekil 6.16. Elma renk/boy'a göre sınıflandırma GUI ……56
Şekil 6.17. Elma yüzey kalitesine göre sınıflandırma GUI…… 57
Şekil 6.18. D55 aydınlatma koşulları ve Matlab hazır fonksiyonunun, CIE L*a*b* renk uzayı "a" bileşeni sonuçlarının karşılaştırılması……. 63
Şekil 6.19. D55 ayd. uyumlu yazılım ile Matlab hazır fonksiyon zaman karşılaştırması ……....63
Şekil 6.20. Sol tarafta orijinal görüntü, sağ tarafta maskelenen elma görüntüsü…… 64
Şekil 6.21. Elma renk/boy bulmada kullanılan renk uzayları bileşenleri ve eşikleme sonuçları……..... 65
Şekil 6.22. Starking elma renk analizi sonuçları…… 66
Şekil 6.23. Yarısı mavi renk ile boyanmış elmanın görüntüsü…… 68
Şekil 6.24. Kamera altından dönerek ilerleyen elmanın farklı yüzeylerinin görüntüsü……. 68
Şekil 6.25. Elma yüzey kusurlarının tanıma sisteminin mimarisi……... 69
Şekil 6.26. Elma görüntüsü üzerinde bölütleme örnekleri……...71
Şekil 6.27. Normalize edilmiş öznitelik haritası……..75
Şekil 6.28. SFFS öznitelik seçimi eğrisi……...76
Şekil 6.29. SBFS öznitelik seçimi eğrisi……. 77
Şekil 6.30. SFS öznitelik seçimi eğrisi…… 77
Şekil 6.31. SBS öznitelik seçimi eğrisi……78
Şekil 6.32. İki sınıf için " 4-5-23" numaralı öznitelik uzayında verilerin dağılımı…… 79
Şekil 6.33. İki sınıf için " 6-10-24" numaralı öznitelik uzayında verilerin dağılımı…… 79
Şekil 6.34. On farklı test kümesine göre DVM çekirdek fonksiyonlarının sınıflandırma başarı grafiği…… 83
Şekil 6.35. *k* En Yakın Komşuluk algoritmasının belirlenen *k* değerlerine göre on farklı test kümesindeki sınıflandırma başarı grafiği……. 85

Şekil 7.1. PLC akış diyagramı……88
Şekil 7.2. Kütlesine göre elma sınıflandırma SCADA ekranı…… 89
Şekil 7.3. Yük hücresi ve transmiter…….. 90
Şekil 7.4. Tartım sistemi……..91
Şekil 8.1. Elma yüzey kusurlarının örüntü tanıma ile belirlenmesi…….95

ÇİZELGELER TABLOSU

Çizelge 3.1. 3200 K'de her bir renk uzayı dönüşümü için bulunan en iyi özellik sayısı ve sınıflandırma sonuçları.....13
Çizelge 6.1. İnsan gözündeki koni hücreleri dalga boyları..... 61
Çizelge 6.2. Aydınlatmaya göre tristimulus değerleri..... 62
Çizelge 6.3. Bölütleme işlemi için gözlemlenen örnekler..... 71
Çizelge 6.4. Sıralanmış öznitelikler.....75
Çizelge 6.5. Öznitelik seçim yöntemleri ile seçilen öznitelik alt kümeleri sınıflandırma başarıları..... 78
Çizelge 6.6. Sınıflandırma işlemi için toplam örüntü miktarı.....80
Çizelge 6.7. Destek Vektör Makineleri'nde kullanılan temel çekirdek fonksiyonlarının sınıflandırma başarı oranları..... 82
Çizelge 6.8. Destek Vektör Makineleri'nde kullanılan temel çekirdek fonksiyonlarının kullanılan test kümelerine göre sınıflandırma başarı oranları.....83
Çizelge 6.9. *k* En Yakın Komşuluk yönteminde kullanılan farklı *k* değerlerinin kullanılan test kümelerine göre sınıflandırma başarı oranları.....84

SİMGELER

S_λ	Aydınlatıcının Spektral Gücü	(λ dalgaboyunda)
x_λ, y_λ, z_λ	Renk Eşleştirme Fonksiyonları	(λ dalgaboyunda)
d_λ	Spektral Reflektans	(λ dalgaboyunda)
k	Sabit (Normalizasyon çarpanı)	
L*	Açıklık-Koyuluk Ekseni Değeri	
a*	Kırmızı-Yeşil Ekseni Değeri	
b*	Sarı-Mavi Ekseni Değeri	
C*	Kroma (Renk Doygunluğu)	
h	Renk Açısı (Ton açısı)	
X, Y, Z	Rengin Tristimulus Değerleri	
Xn, Yn, Zn	Aydınlatıcının Tristimulus Değerleri	
sn	Saniye	
mm	Milimetre	
nm	Nanometre	
μ	Ortalama	
σ	Standart Sapma	

Kısaltmalar

CCD	Charge Coupled Device (Yüklenme Eşleşmiş Cihaz)
CIE	Commission Internationale de l'Eclairage (Uluslararası Aydınlatma Komisyonu)
CMOS	Complemantary Metal-oxide Oxide Semiconductor (Bütünleyici Metal Oksit Yarıiletken)
CMYK	Cyan-Magenta-Yellow-Black (Camgöbeği-Eflatun-Sarı-Siyah)

CNC	Computer Numerical Control (Bilgisayarlı Nümerik Kontrol)
DA	Doğru Akım
DVM	Destek Vektör Makineleri
Fps	Frame Per Second (Saniyedeki Görüntü Sayısı)
GRD	Ground (Toprak)
GUI	Graphical User Interface (Grafiksel Kullanıcı Arayüzü)
HSI	Hue-Saturation-Intensity (Renk tonu-Doygunluk-Yoğunluk)
HSV	Hue-Saturation-Value (Renk tonu-Doygunluk-Değer)
k-EYK	*k*-En Yakın Komşuluk (*k*-nearest-neighbor-*k*-NN)
LED	Light Emmitting Diode (Işık Yayan Diyot)
MPI	Multi-Point Interface
PLC	Programmable Logic Controller (Programlanabilir Mantıksal Denetleyici)
RGB	Red-Green-Blue (Kırmızı-Yeşil-Mavi)
RTU	Remote Terminal Unit (Uzak Terminal Birim)
SBFS	Sequential Floating Backward Selection (Ardışık Geri Yönde Kayan Seçim)
SBS	Sequential Backward Search (Ardışık Geri Yönde Seçim)
SCADA	Supervisory Control And Data Acquistions (Denetsel Kontrol ve Veri Kazanımı Sistemi)
SFFS	Sequential Forward Foating Selection (Ardışık İleri Yönde Kayan Seçim)
SFS	Sequential Forward Search (Ardışık İleri Yönde Seçim)
SOM	Self-Organizing Map (Özörgütlemeli Harita)
TSE	Türk Standartları Enstitüsü
USB	Universal Serial Bus (Evrensel Dizisel Araç)
YIQ	Luma-Inphase-Quadrature (Parlaklık-Faz-Evre farkı)
YTF	Yarıçap Temelli Fonksiyon (Radial Basis Function –RBF)
YUV	Luma-Chrominance (Parlaklık-Renk tonu)

BÖLÜM 1

GİRİŞ

Son yıllarda makine görmesi, teknolojinin gelişimi ile birlikte büyük önem kazanmıştır. Makine görme sistemi; biyoloji, medikal (kanserli hücrelerin belirlenmesi), savunma sanayi (hedef belirleme), trafik kontrol ve endüstriyel alanların otomatik denetlenmesi gibi pek çok farklı alanda otomatik olarak şeklin tanınması ve sınıflandırılması problemlerine çözüm aramaktadır. Bu sistemin tarım ürünlerinin sınıflandırılması için pratik ve kullanışlı bir araç olduğu da bilinmektedir.

Günümüzde tarımsal ürünlerin kalitesini tanımlayan çeşitli faktörler (renk, boyut, şekil ve kusur miktarı vb), makine görme sistemi ile değerlendirilmektedir. Bu çalışmada makine görmesi, elmaları yüzey kalitelerine veya renk ve boylarına göre sınıflandırmak amacı ile kullanılmıştır.

Dünyada elma üretimi 2009 verilerine göre 71.286.632 tondur. Türkiye; Çin ve ABD'den sonra 2.782.370 ton olan elma üretim kapasitesi ile Dünya'da elma üretiminde üçüncü sırada yer almaktadır (http://faostat.fao.org Erişim tarihi:31.10.2011). Üretilen elmalar tüketiciler tarafından türü, rengi, boyu ve kusurlu olma durumlarına göre talep edilmektedir. Bununla birlikte, elma pazarlamasında en önemli etkenlerden biri de standardizasyondur. Bu nedenle TSE (Türk Standartları Enstitüsü) tarafından hazırlanan elma standartları, meyve özellikleri dikkate alınarak elmayı; renklerine göre gruplara, botanik bakımından yapılarına göre çeşitlere, kalite özelliklerine göre sınıflara ve iriliklerine göre de boylara ayırmaktadır. Bu beklentiler doğrultusunda, üreticilerin kaliteli ürün yetiştirme yanında bir sonraki aşamada ürünlerin sınıflandırma işlemlerini de etkin bir şekilde gerçekleştirmesi gerekmektedir.

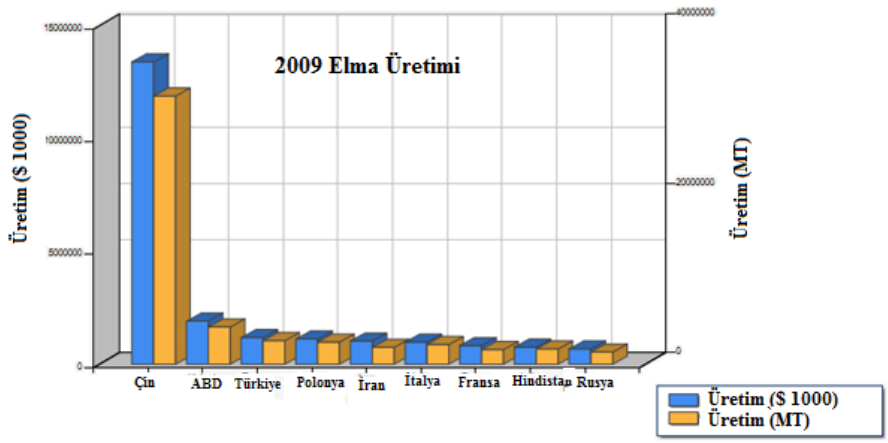

Şekil 1.1. 2009 verilerine göre Dünya'da elma üretimi (http://faostat.fao.org Erişim tarihi:31.10.2011)

Ülkemizde üretimi yapılan meyve sınıflandırma sistemleri, genellikle sadece boyut ve kütle esas alınarak çalışmaktadır. "Kütle esas alınan makineler hassas tartı düzeneğine sahip olmalıdırlar. Bu yöntemde meyveler bantlı götürücüler ile tartı düzenine getirilir. Meyveler kendi kütlesine uygun karşı kütleyi ya da direnci yendiği anda ait oldukları ağırlık sınıfına düşerler. Bu yöntemi kullanan makinelerin verimleri 2000kg/h civarındadır. Meyvelerin boyutlarına göre sınıflandırılmasında, elle kullanılan değişik çaplı çemberler ya da mastar görevini yapan delikli tahta tablalar kullanılır. Bu aletlerle bir kişi saatte 100-200 kg meyve sınıflandırabilir. Mekanik yollarla meyveleri boyutlarına göre sınıflandıran makineler 5 ana grupta toplanabilir; ayırıcı silindirli bantlı götürücü tip, elek sistemli tip, yatay silindirli tip, aralıkları değişen, bant, kayış ya da konik silindirli tip ve delik çapları değişen (orifisli) tiptir" (Tekin, 1995). Bunlara ek olarak merkezkaç kuvveti prensibine göre çalışan boylama makineleri de ülkemizde yaygın olarak kullanılmaktadır.

Ancak günümüzde bu tür sistemler pazardaki aktörler tarafından yetersiz görülmektedir. Öte yandan sadece boyut ve kütle esaslı meyve sınıflandırma sistemleri, ürünlerin pazara açılmasında yeterli değildir. Özellikle dış pazarlarda satılabilecek elmaların TSE standartlarına göre yüzey kalitesi göz önüne alınırsa; Ekstra, Sınıf I ve Sınıf II olmak üzere üç kalite sınıfına ayrılması gerekmektedir. Dünya'daki görüntü işleme, endüstriyel otomasyon sistemleri ve yapay zeka alanlarındaki teknolojik gelişmeler son derece hızlı bir şekilde gelişirken, bunların takip edilmesi ve aynı zamanda uygulanması ülkemizin ekonomik çıkarları göz önüne alındığında, dışa bağımlılığı en aza indirgemekle birlikte pazarda da beklentileri karşılayabilecektir.

Bu nedenle tez kapsamında, makine görme sistemi kullanarak gerçek zamanlı çalışan elma sınıflandırma sistemi geliştirilmiştir. Öncelikle tasarlanan döner rulolu konveyör bantı sayesinde dönerek ilerleyen elmaların özel olarak aydınlatılmış ortamda endüstriyel renkli kamera yardımı ile görüntüleri elde edilmiştir. Bu görüntüler üzerinde algoritma işleyişi aşağıda verilmiştir.

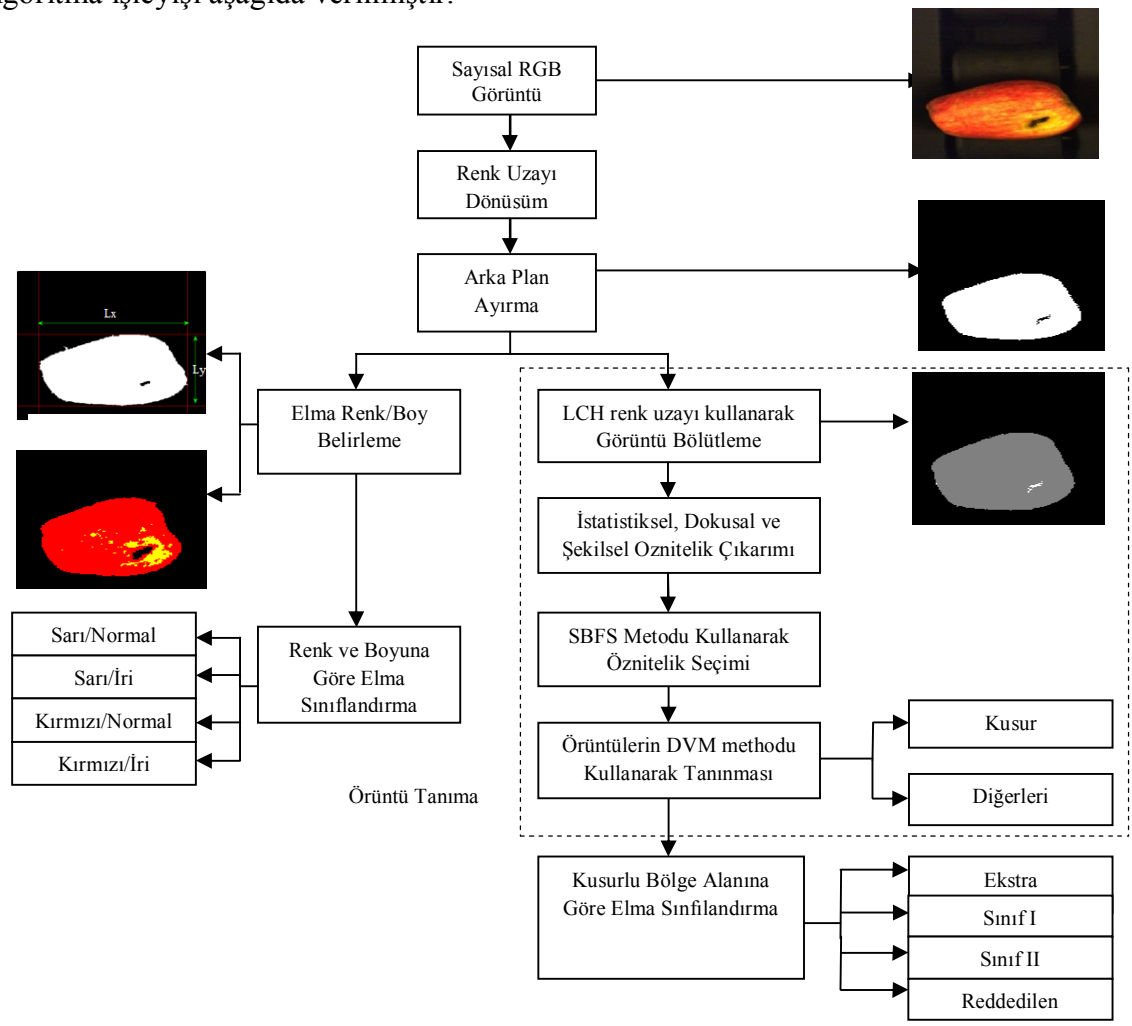

Şekil 1.2. Makine görme sistemi yazılımının temel basamakları

Bu tez çalışmasında, yapay zeka örüntü tanıma algoritması kullanılarak, elmaların dış yüzeylerinde kusur olarak tanımlanan bölgelerin toplam alanına (mm^2) göre Ekstra, Sınıf I, Sınıf II ve Reddedilen Sınıf olmak üzere dört kalite grubuna ayrılmasına ve elmaların renk/boyuna göre sınıflandırılmasına öncelik verilmiştir. Böylece bu çalışma, alandaki söz konusu boşluğun giderilmesi ve bundan sonra yapılacak çalışmalara ışık tutması açısından önem taşımaktadır.

BÖLÜM 2

LİTERATÜR TARAMASI

Makine görme sistemleri veya görüntü işleme teknikleri farklı tipli gıda ürünlerinde araştırmacılar tarafından kullanılmıştır (Blasco v.d., 2007). Kullanılan farklı gıda ürün tipleri; Şeftali (Miller ve Delwiche, 1991), mısır (Panigrahia v.d., 1998), zeytin (Diaz v.d., 2004), portakal (Ruiz v.d., 1996; Kondo v.d., 2000), patates (Muir v.d., 1982), dolmalık biber (Shearer ve payne, 1990), pizza (Due ve Sun, 2005) fıstık (Pearson, 1995), mantar (Heinemann v.d., 1994), pirinç (Wan v.d., 2002) ve elma (Leemans ve Destain, 2004; Li v.d., 2002; Wen ve Tao, 1999; Kavdır ve Guyer, 2008; Unay ve Gosselin, 2007) olarak sayılabilir.

Marketlerde bulunan elmalar; şekline, rengine, boyuna ve yüzeyinde varsa kusurların görünümüne göre sınıflandırılmaktadır (Leemans ve Destain, 2004). Makine görmesinin endüstriyel gıda makinelerinde kullanılmasıyla birlikte, elma dış yüzeyinin yüksek çözünürlüklü kameralar yardımı ile renk, boy ve kusurlarının belirlenmesi mümkün kılınmıştır.

Günümüzde makine görmesi veya görüntü işleme teknikleri ile elmanın özelliklerini belirlemek veya onları sınıflandırmak, birçok araştırmacı için çalışma konusu olmuştur. Bu konu üzerinde yapılan çalışmalar incelendiğinde, araştırmacıların bir kısmı sistemlerin yazılım bazında gelişmesini sağlamak için çaba harcamış, bir kısmı da hem donanımsal hem de yazılımsal gelişmeler üzerinde durmuştur. Aşağıda söz konusu bu gelişmeler açıklanmıştır.

2.1. Donanımsal Gelişmeler

Makine görme sisteminin başarılı bir şekilde çalışabilmesi yazılım ve donanım unsurlarının doğru ve uyumlu olmasını gerektirmektedir. Bazı araştırmacılar meyve sınıflandırmasında makine görme sistemlerinin performansını artırabilmek için farklı donanımlar denemişler ve yazılımlarını bu donanımlara göre geliştirmişlerdir. Ele alınan bölümde yapılan bu araştırmalar üzerinde durulmuştur.

Üzerinde çalışılan meyvenin doğru incelenebilmesi için elde edilen görüntülerin, meyvenin tüm yüzeyini kapsaması gerekmektedir. Bunu başarabilmek için araştırmacılar farklı yöntemler denemişlerdir. Wen ve Tao rulolar üzerine yerleştirilen elmaların dönerek taşındığı konveyör sistemini gerçekleştirmişler, fakat bu durumda dönme ekseninin karşı yüzeylerine yakın noktaları gözleyememişlerdir (Wen ve Tao, 1998; Leemans ve Destain, 2004). Guedalia ip üzerinde serbestçe yuvarlanan meyveleri gözlemleyen 3 kamera kullanmıştır (Guedalia, 1997; Leemans ve Destain, 2004). Li ve diğerleri elmaların alt ve üst kısımlarını gözleyen 2 kamera ve aynı zamanda yan yüzeylere de 2 ayna yerleştirerek tüm yüzeyin görülmesini amaçlamışlardır (Li v.d., 2002). Leemans ve Destain dönen elmaları gözlemlemek için 45 derecelik açılarla yerleştirilmiş 2 kamera ile bu işlemi gerçekleştirmişlerdir (Leemans ve Destain, 2004). Bennedsen ve Peterson kullandıkları sistemde, dönerek ilerleyen elmaları her 30 derece döndüğünde fotoğraflamış ve bu şekilde altı fotoğrafta elmanın yarı yüzeyini görmeyi amaçlamışlardır (Bennedsen ve Peterson, 2005). Molto ve diğerleri çalışmasında 2 robot kolu kullanmışlardır. Bu çalışma ile elde edilen 4 resim ile şeftali, narenciye ve elma yüzeyinin %80'nini gözlemlemişlerdir. Bu şekilde görüntülemede her bir resmin işlem zamanının 500ms'nin altında olduğu sonucuna varmışlardır (Molto v.d., 1998). Üzerinde çalışılan meyvenin tüm yüzeyinin görüntülenmesi istenirken, birim zamanda incelenecek meyve sayısının da göz ardı edilmemesi gerekmektedir.

Meyvenin kalitesinin ilk değerlendirmesini yapmak için renk kullanılır. Kontrol sistemlerinin çoğu görüntüyü bölütlemek için yalnızca bu özelliği kullanırlar (J.Blasco v.d., 2007). Böylelikle sağlıklı doku ve kusurlar arasında yüksek zıtlık yaratılır (Leemans ve Destain, 2004). Bu durumu sağlamak da etkin bir aydınlatma ile gerçekleştirilebilir. Yang elmaların sap ve çiçek çukurlarını açıkça görebilmek için bir dağıtılır aydınlatma sistemi ile kombine edilmiş, yapılandırılmış aydınlatma sistemini

kullanmıştır (Yang, 1993; Leemans ve Destain, 2004). Leemans ve Magain çalışmalarında sınıflandırma hattı boyunca uzatılmış araçlar kullanarak, ortamda aynı parlaklığı sağlamak için reflektörler ve aydınlatma tüplerini kullanmışlardır (Leemans ve Magain, 1998). Molto ve diğerleri yaptıkları çalışmada yarı küresel bir aydınlatma haznesi tanımlayarak, meyveleri haznenin merkezine yerleştirmişler ve böylece dairesel tüpten gelen ışık, haznenin iç duvarları tarafından dağıtılmıştır (Molto ve diğerleri, 1998; Leemans ve Destain, 2004). Blasco ve diğerleri farklı dalga boylarında ışık elde etmek için floresan tüp (gün ışığı), actinic floresan tüp ve kızılötesi lamba ile yapmış olduğu aydınlatma sistemini portakal ve mandalinaların görüntüsünü elde etmek için kullanmışlardır (Blasco v.d. 2007). Makine görme sistemlerinde akkor flamanlı, floresan, lazer, kızıl ötesi ve X-ray tüpleri gibi farklı aydınlatma kaynakları bulunabilmektedir (Brosnan ve Sun, 2004).

Donanım özelliklerini tamamlayan bir diğer önemli nokta da kamera seçimidir. Bir meyvenin çapı, çevresi ve alanı gibi tüm bu özellikler gri görüntüden elde edilebilir. Fakat yüzey kusurları ve renk bilgisi için renklere ihtiyaç vardır (Aleixos v.d., 2002). Literatür incelendiğinde, araştırmacıların uygulamalarında farklı kamera ve filtre tercihleri yaptıkları görülmüştür. Wen ve Tao yaptıkları çalışmada, 700 nm uzun geçişli bir filtre ile birleştirilen siyah-beyaz kamera kullanmışlardır (Wen ve Tao, 1998). Unay ve Gossalin farklı dalga boylarında geçirgenliğe sahip 450, 500, 750 ve 800 nm geçişli filtrelerle elma görüntülerini incelemiş ve bunları bölütleme uygulamalarında kullanmıştır. Sonuçta 750 nm geçişli filtre ile diğer filtre çeşitlerine göre eşit veya daha yüksek başarı elde edilmiştir (Unay ve Gosselin, 2007). İnsan gözünden farklı olarak makine görmesi, elektromanyetik spektrum bölgesini görmek için sınırlı değildir. Bazı araştırmacılar belirli dalga boylarını farklı tip kamera (UV kamera, Kızıl ötesi kamera) ve filtreler yardımı ile birbirinden ayırmışlardır. Bu araştırmacılara göre insan gözünün görebildiği spektrum bölgesi ile yakın kızılötesi bileşimi meyvedeki hataların belirlenmesinde kullanılabilir (Aleixos v.d., 2002). Wen ve Tao yakın kızılötesi kamera ile orta kızılötesi kamerayı elmanın kök ve sapını bulabilmek için kombine etmiştir (Wen ve Tao, 2000). Molto, Blasco ve Aleixos ise çalışmalarında renkli ve yakın kızılötesi kamerayı kombine etmişlerdir (Molto v.d., 2000; Leemans ve Destain, 2004).

Elmayı dışsal kalitesine göre sınıflandıran makine görme sistemlerinde, farklı aydınlatma kaynaklarının, filtrelerin ve kameraların kullanılma amacı; sağlıklı

dokuların, kusurların, elma sap ve çiçek çukurlarının birbirlerinden etkin bir şekilde ayrılmasıdır. Bu amaca ulaşmak için araştırmacılar insan gözünün görebildiği veya göremediği farklı spektrum dalga boylarında elde ettikleri görüntüler üzerinde bu ayrımı yüksek başarı ile elde etmeye çalışırlar.

Bununla birlikte renk, boy, şekil ve yüzey kusurları gibi dışsal özellikler renkli, siyah beyaz ve kızılötesi kameralar ile elde edilebilir. Fakat içsel yapılarında bulunan kusurların bu cihazlarla belirlenmesi zordur. Bu durumlarda özel görüntü yakalama tekniklerinin kullanılması gereklidir. Ultrasonik, manyetik rezonans görüntüleme, bilgisayarlı tomografi, elektriksel tomografi yaygın kullanılan görüntüleme tekniklerindendir (Du ve Sun, 2004).

2.2. Yazılımsal Gelişmeler

Elma sınıflandırma uygulamalarında araştırmacıların yoğunlaştığı yazılım çalışmaları iki kısımda incelenebilir. İlki elde edilen elma görüntüsü üzerindeki elmanın sapı, çiçek çukuru ve kusurlu alanlarını oluşturan piksellerin gruplandırılması (bölütleme) ve bunların tanınmasıdır. İkincisi uzman kişiler tarafından yapılan elmaların kalitelerine göre sınıflandırılma işleminin yapay zeka algoritmaları kullanılarak otomatikleştirilmesidir.

2.2.1. Görüntünün bölütlenmesi ve anlamlandırılmasında kullanılan yöntemler

Elma sınıflandırma yazılım çalışmalarının en büyük problemlerinden biri de elmanın sapını, çiçek çukurunu ve kusurlarını oluşturan bölgelerin birbirinden ayrılmasıdır. Bu bölgelerin belirlenmesi iki amaca hizmet eder. Öncelikle, elmanın sapını ve çiçek çukurunu oluşturan iki bölgeyi birleştiren eksene dikey gelen en geniş ekvatoral çap, elmanın çapı olarak tanımlanır. İkinci olarak da yüzey kusurları ile

elmanın sap ve çiçek çukurlarının birbirlerinden ayırt edilmesi sağlanarak, elma yüzeyindeki çürük miktarının artırılmaması sağlanır. Bu işlem için elma yüzeyine bölütleme işlemi uygulanır ve bölütleme işlemi sonunda elde edilen bölgelerin öznitelikleri çıkartılır. Bu özniteliklere göre bölgelerin hangi kümeye ait oldukları belirlenir.

Elmanın yüzey değerlendirmesini yapmak için renk önemli bir özelliktir. Kontrol sistemlerinin çoğu görüntüyü bölütlemek için yalnızca bu özelliği kullanırlar (J.Blasco v.d., 2007). Bu özellik sayesinde, elma görüntüsünde bulunan elmanın sap, çiçek çukuru ve kusurlarını oluşturan bölgelerin birbirinden ayrılmasını sağlamak için araştırmacılar farklı yöntemler kullanmışlardır. Yang, elma görüntüsünün bölütleme işleminde kusurların, elmanın sap ve çiçek çukurunun sağlıklı dokulardan daha koyu olduğunu belirtmiş, eşikleme ve arka plan çıkarma gibi teknikleri öne sürmüş ve bu işlemleri Golden Delicious ve Granny Smith türü elmalar üzerinde denemiştir (Yang, 1994). Nakano ise çalışmasında, elmanın yüzeyindeki pikselleri yapay sinir ağları kullanarak ve bu pikselleri beş sınıfa ayırarak bölütleme işlemi uygulamıştır (Nakano, 1997).

Kleynen ve diğerleri benzer model eşleştirme algoritması kullanarak, elmanın sap ve çiçek çukurunun tanınmasını sağlamışlardır. Gerçekleştirdikleri algoritma ile verilen kaynak görüntü sayesinde, model elmanın sap ve çiçek çukuru görüntüsündeki her bir nokta arasındaki benzerliklere bakarak aralarındaki ilişkiyi bulmaya çalışmışlardır. Bunun sonucunda korelâsyon eşleştirme metodunun elma saplarını tanıma başarısı %91, çiçek çukurlarını tanıma başarısı ise %92 olarak bulunmuştur (Kleynen v.d., 2005).

Wen ve Tao elma görüntülerinde bulunan kusurların tanımlanmasını dört adımda gerçekleştirmiştir. Bu adımlar; kusur çıkarımı, öznitelik çıkarımı, kural tabanlı yapı ve tanımadır. Kusur çıkarımı işlemini, uyarlamalı küresel dönüşüm kullanarak gerçekleştirmiş bununla birlikte yapısal kural temelli ikili karar ağacı yapısını, kusur öznitelikleri çıkarımı ve analizini kullanarak belirlemişlerdir. Sonuçta kusurlu elmalar üzerinde yapılan çalışmalarda elmanın sap ve çiçek çukurunu tanıma başarısı sırasıyla %94.92 ve %93.53 olarak elde edilmiştir. İyi elmalar üzerinde yapılan çalışmalarda ise bu oran %81.40 ve %87.93 olarak bulunmuştur (Wen ve Tao, 1999). Leemans ve diğerleri çalışmalarında, kusurları belirlemek için denetimsiz görüntü bölütleme

yöntemini sunmaktadırlar. Yazarlar, golden elmaların ortalama değeri ve piksellerin renginden mahalanobis mesafesini hesaplamış ve bu mesafeye eşik uygulayarak kusurları belirlemişlerdir (Leemans v.d., 1998). Bennedsen ve Peterson, elmanın sap ve çiçek çukurunu ayırmak için yapay sinir ağlarını ve denetimsiz öznitelik çıkarımını kullanarak %98,4 başarı elde etmişlerdir (Bennedsen ve Peterson, 2004). Unay ve Gosselin yaptıkları çalışmada görüntüleri eşikleme yöntemi ile bölütlemiştir. Bölütleme işlemi sonucunda elde edilen örüntülerin istatistiksel, dokusal ve şekilsel özniteliklerinin çıkarılmasından sonra denetimli sınıflandırma algoritmaları kullanılarak, (doğrusal diskriminant, en yakın komşuluk, bulanık en yakın komşuluk, destek vektör makineleri) elmanın sap, çiçek çukuru ve kusurları yüksek başarı ile birbirinden ayrıştırılmıştır (Unay ve Gosselin, 2007). Li ve diğerleri, eşikleme yöntemi ile elmanın yüzeyini bölütlemek için fraktal boyut hesaplamış ve bunu öznitelik olarak kullanıp, ileri beslemeli geri yayılımlı yapay sinir ağına verilmesini sağlamışlardır. Böylece elmanın sap, çiçek çukuru ve kusurunu %93 başarı oranı ile sınıflandırma sonucuna ulaşmışlardır (Li v.d., 2002).

2.2.2. Elmanın kalitesine göre sınıflandırılmasında kullanılan yöntemler

Uzman kişiler tarafından yapılan elmaların kalitesine göre sınıflandırılma işlemi, bu kişiler yerine karar verebilen algoritmalar sayesinde yapılabilir. Bu konuda yapılan çalışmalar, daha çok elma yüzeyinden elde edilen özelliklere göre elmanın yüzey kalitesini belirlemek üzerinedir. Leemans ve Destain'in yaptıkları çalışmada, elma üzerindeki her bir kusur renk, doku ve şekil özniteliklerine göre karakterize edildikten sonra, bir veri tabanı oluşturmuşlardır. Çalışmada, elde edilen dinamik tablo şeklindeki veri tabanını statik tabloya dönüştürerek, kuadratik diskriminant analiz yöntemini kullanmışlardır. Bu yöntem sonucunda Jonagold türü elmaları Sınıf I ve Sınıf II (Sınıf I:Az kusurlu, kabul edildi; Sınıf II: Reddedildi) olmak üzere %73 sınıflandırma başarısı ile ayırabilmişlerdir (Leemans ve Destain, 2004). Başka bir çalışmada elmalar, 11 parametre ile yapay sinir ağları kullanılarak, beş kalite sınıfına ayrılmıştır. Söz konusu çalışmada, doğru sınıflandırma oranı %33,3'ten %95'e doğru giden bir artışla değişmiştir (Nakano, 1997). Öte yandan Xiaobo ve diğerleri 17 renk öznitelik

parametresini her bir elma için elde etmişlerdir. Bu öznitelikleri şekil tanıma işlemine sokmadan önce normalize etmişler ve genetik algoritma tabanlı organizasyon özellik parametreleri yöntemini kullanmışlardır. Elmanın rengini belirlemek için ise "adım karar ağacı" uygulamışlardır. Böylece sınıflandırma oranında "ekstra" ve "reddedilen" sınıflandırma grubunda yüksek ancak "sınıf I" ve "sınıf II" grubunda yüksek olmamakla birlikte, dört sınıfa ayırabilme başarısını elde etmişlerdir. Xiaobo ve diğerleri, bu yöntemi Nakano'nun Yapay Sinir Ağları yöntemi ile karşılaştırarak bu yöntemle daha doğru sonuçlar elde edildiğini ifade etmişlerdir (Xiaobo v.d., 2007).

BÖLÜM 3

RENK VE RENK UZAYI

3.1. Renk

Renk önemli bir görsel bilgi olarak tanımlanır. Bir nesneden yansıyan ışık görsel sistemimizin konik hücreleri tarafından emilir ve sonuçta bir rengin algılanmasını sağlar. İnsanın görme sisteminde rengin algılanabilmesi için, renk hassasiyetlerine göre üç tür konik sınıflama bulunur. Bunlar, kısa dalga boylarında hassasiyete sahip "S" konisi, orta dalga boylarında hassasiyete sahip "M" konisi ve uzun dalga boylarında hassasiyete sahip "L" konisidir. Nesneden yansıyan ışık, insanın gözündeki koniklerin emilim miktarının üç sınıfta farklılaşmasını sağlar. Sinir sistemimiz tarafından konik emilimlerin yorumlanması renk algımızın temelini oluşturur. Bu nedenle renk, bir nesnenin yüzey yansımasının algısal temsilidir (Acharya ve Ray, 2005).

Bununla birlikte renk, örüntü tanıma, görüntü eşleştirme, içerik temelli görüntü kurtarma, makine görmesi, renkli görüntü sıkıştırma ve bunun gibi birçok görüntü işleme uygulamasında başarılı bir şekilde kullanılan önemli bir özelliktir. Renk bilimi halen günümüzde makine görmesi ve sayısal görüntü işleme çalışmalarında iddialı bir çalışma alanı olmaya devam etmektedir (Acharya ve Ray, 2005). Renklerin matematiksel olarak üç boyutlu gösterimine renk uzayı denilir. Bölüm 3.2'de renk uzayları konusuna açıklık getirilmiştir.

3.2. Renk Uzayı

Renk uzayları, üç boyutlu olarak tasarlanır ve bütün renkleri temsil edecek şekilde oluşturulur. En çok kullanılan renk uzayları RGB (Red, Green, Blue; Kırmızı, Yeşil, Mavi), YIQ (Luma, Inphase, Quadrature; Parlaklık, Faz, Evre farkı), YUV (Luma, Chrominance; Parlaklık, Renk tonu) ve CMYK (Cyan, Magenta, Yellow, Black; Camgöbeği, Eflatun, Sarı, Siyah) olarak bilinir. Ancak, bu renk uzaylarının hiçbiri parlaklık, doygunluk ve rengin sezgisel kavramı ile ilgili değildir. Bu nedenle bunlara ek olarak HSV (Hue, Saturation, Value; Renk tonu, Doygunluk, Değer), HSI (Hue Saturation, Intensity; Renk tonu, Doygunluk, Yoğunluk) gibi farklı renk uzayları da bulunmaktadır (Jack, 1995). Renk uzayları iki grupta toplanabilir. İlki cihaz bağımlı renk uzayları ki burada cihazın özellikleri ön plandadır (RGB, HSV, YUV). İkincisi ise cihaz bağımsız renk uzayları CIE (Commission Internationale de L.Eclairage: Uluslararası Aydınlatma Komisyonu) tarafından getirilen renk uzaylarıdır. Cihaz bağımsız renk uzaylarının içerisinde CIE XYZ, CIE L*a*b* ve CIE L^*C^*h renk uzayları gösterilebilir.

Renk modelleri veya renk uzayları belirli bir renk koordinat sistemine sahiptir ve renk uzayındaki her nokta sadece bir rengi temsil eder. Renk görüntüleri sayısal görüntüleme sistemi tarafından üretilir ve RGB görüntü olarak isimlendirilen Kırmızı (R), Yeşil (G), Mavi (B) şeklinde temsil edilir (Acharya ve Ray, 2005).

Renk uzayı dönüşümleri yüzeyi oluşturan farklı sınıflar arasındaki ayrılabilirliği ve aynı sınıflar arasındaki benzerliği artırmak, bununla birlikte farklı aydınlatma koşulları altında güçlü bir performans sağlamak için örüntü tanıma ve sınıflandırma uygulamalarında etkin bir şekilde kullanılır (Shin v.d., 2002).

Sınıflandırmada kullanılacak renk uzayı seçimi, kullanılacak uygulama ve donanıma göre çeşitlilik gösterir (Bruce v.d., 2000). Yong ve diğerleri 3200 K sıcaklığına sahip halojen lambalarla aydınlatılmış ortamda, renkli kamera ile elde etmiş oldukları 56 adet çeşitli kusur (yağ, çizgi ve kir gibi) görüntülerinin, özniteliklerinin çıkarılmasında ve sınıflandırmasında beş farklı renk uzayını karşılaştırmışlar (Çizelge 3.1) ve en iyi sonuçları RGB renk uzayı ile elde etmişlerdir (Yong v.d., 2009).

Çizelge 3.1. 3200 K'de her bir renk uzayı dönüşümü için bulunan en iyi özellik sayısı ve sınıflandırma sonuçları (Yong v.d., 2009)

Renk Uzayları	Öznitelik Sayısı	Bileşenlere Göre Öznitelik Sayısı			Sonuçlar
RGB	7	5 R	0 G	2 B	81.1 %
XYZ	10	4 X	4 Y	2 Z	79.2 %
CIELab	12	7 L	3 a	2 b	78.8 %
CIELuv	17	13 L	3 u	1 v	80.6 %
GREY	6	-	-	-	76.7 %

Mendoza ve diğerleri eğri yüzeylere sahip gıdaların ölçülebilmesi için en iyi renk uzayı olarak CIE L*a*b* sistemini önermektedir (Mendoza v.d., 2006). Öte yandan Du ve Sun, pizza üzerinde bulunan malzemeleri, HSV renk uzayı ile DVM sınıflandırıcıyı kombine ederek sınıflandırmış ve %97 sınıflandırma başarısı elde etmiştir (Du ve Sun, 2005). Yapılan başka bir çalışmada, portakal ve mandalinanın yüzeyinde bulunan farklı kusurları ve sapı diskriminant analiz yöntemi ile sınıflandırmak üzere, beş farklı renk uzayını karşılaştırmış ve sonuçta HSI renk uzayı ile %87 en yüksek başarıyı elde etmişlerdir (Blasco v.d., 2007).

Elmaların sınıflandırmasında en uygun performansı elde etmek için farklı renk uzaylarından sistemimize en uygun olanı bulmak gerekmektedir. Bu amaçla bu renk uzaylarını tanımak ve aralarındaki dönüşümleri doğru bir şekilde gerçekleştirmek önemlidir.

3.2.1. RGB renk uzayı

Genellikle kamera tarafından çekilen renkli görüntüler üç boyutlu RGB (Red, Green, Blue) renk uzayında kaydedilir (Du ve Sun, 2005). RGB renk görüntüsü renk piksellerinin MxNx3 sıralamasından oluşur. Her renk pikseli özel uzaysal bir bölgede RGB görüntülemenin Kırmızı (R), Yeşil (G) ve Mavi (B) bileşenleri ile uyumlu bir üçleme şeklindedir (Şekil 3.1). Renk monitörüne kırmızı, yeşil ve maviyi verdiğinde

ekranda bir renk görüntüsü üretilir. Standart olarak üçlü görüntüyü şekillendiren RGB renk görüntüsü kırmızı, yeşil ve mavi bileşen görüntüsü olarak isimlendirilir.

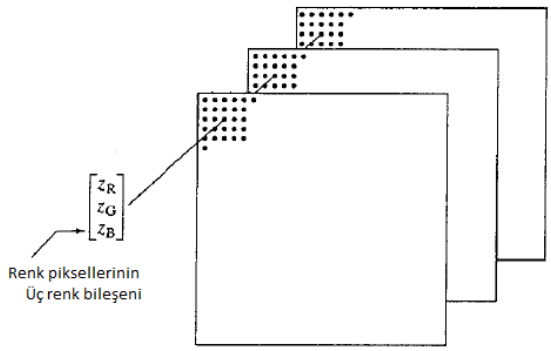

Şekil 3.1. Bir RGB renk görüntüsündeki piksellerin üç bileşeninin gösterimi (Gonzalez ve Woods, 2002)

Bileşen görüntüsünün veri sınıfı onların değer aralıklarını belirler. Eğer RGB görüntü iki sınıfsa, değer aralığı [0, 1] dir. Benzer şekilde 8 bitlik işaretsiz tamsayı (uint8) veya 16 bitlik işaretsiz tamsayı (uint16) sınıfının RGB görüntüleri için değer aralığı sırasıyla [0, 255] veya [0, 65535] dir. RGB bileşenlerinin farklı oranlarda bir araya gelmesi ile diğer renkler ve tonlar oluşur. Bu durumda 24 bitlik (8 bit x 3 bant) görüntülerde her piksel, 0-255 arasında bir değer alabilmekte ve sonuçta 16.777.216 (256 x 256 x256 veya 2^{24}) farklı birleşim (renk) oluşmaktadır. RGB renk uzayı şekil 3.2'de verildiği üzere bir RGB renk küpü şeklinde grafiksel olarak gösterilebilir (Gonzalez ve Woods, 2002).

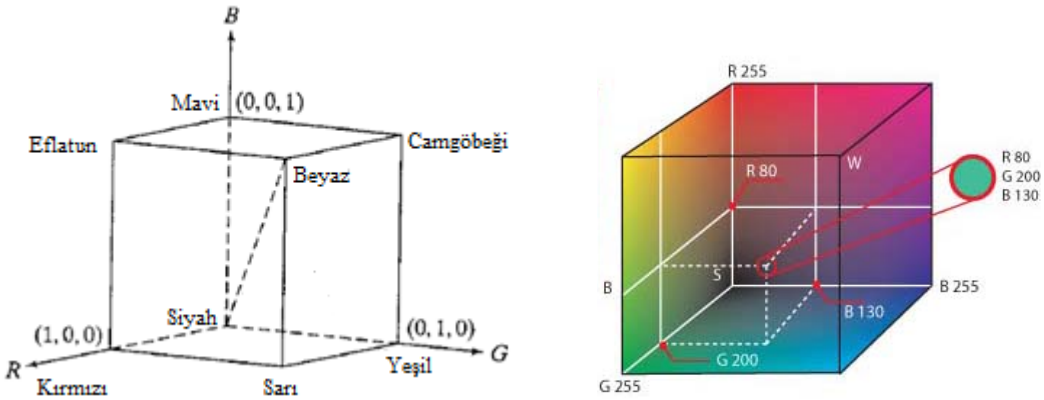

Şekil 3.2. RGB renk küpü

RGB bileşenlerinin değerleri gelen ışık ve duyarlılık fonksiyonlarının toplamıdır.

$$R = \int_{300}^{830} S(\lambda)R(\lambda)d\lambda \quad (3.1)$$

$$G = \int_{300}^{830} S(\lambda)G(\lambda)d\lambda \quad (3.2)$$

$$B = \int_{300}^{830} S(\lambda)B(\lambda)d\lambda \quad (3.3)$$

R(λ), G(λ), B(λ) ise R, G, B algılayıcılarının sırasıyla duyarlılık fonksiyonlarıdır (Tkalcic ve Tasic, 2003).

3.2.2. HSV renk uzayı

HSV (Hue, Saturation, Value), bir renk tekerleğinden veya paletinden renkleri seçmek için, insanlar tarafından kullanılan çeşitli renk sistemlerinden biridir. Renkleri sırasıyla renk tonu, doygunluk ve parlaklık olarak tanımlar. Bu sistem insan deneyimlerine ve insanların renk algılamalarına RGB sisteminden daha yakındır.

HSV renk uzayı, gri ekseni (dikey eksen) boyunca RGB renk küpüne bakarak formüle edilir. Bu sonuçlar şekil 3.3(a)'da altıgen renk paletinde gösterilmektedir. Şekil 3.3(b)'de dikey eksen boyunca hareket ettikçe, eksen değişikliklerine dikey olan altıgen düzlemin boyutu, şekilde tasvir edilen hacmi (Value) verir (Gonzalez ve Woods, 2002).

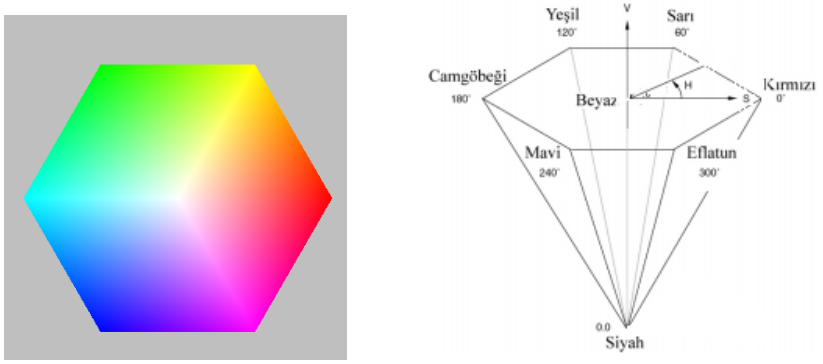

(a) (b)

Şekil 3.3. HSV renk altıgeni ve renk konisi

Ton (H) değerinin sıfırdan bire doğru değişmesi, rengin kırmızıdan sarı, yeşil, yeşilimsi mavi, mavi ve morumsu kırmızıya ve nihayetinde de kırmızının değişmesi anlamına gelir ki bu durumda kırmızı değeri gerçekte 0 ve 1.0 değerini almaktadır. Doygunluk (S) değerinin sıfırdan bire değişmesi, renklerin doygun olmayan formdan (gri ton) tam doygunluğa (beyaz bileşen içermemesi) erişmesi anlamına gelmektedir. Parlaklık (V) değerinin sıfırdan bire değişmesi ise renklerin artan ölçüde parlak hale gelmesini ifade etmektedir (MathWorks, 2002).

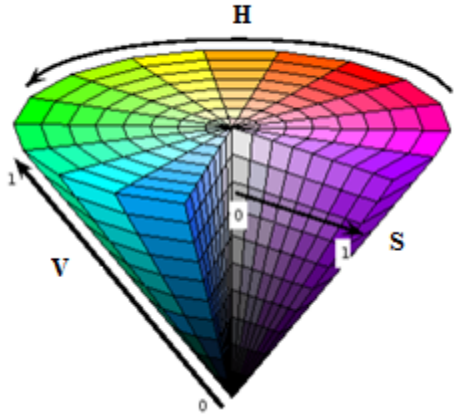

Şekil 3.4. HSV renk uzayının çizimi

RGB değerlerinden HSV değerlerinin hesaplanması (Tkalcic ve Tasic, 2003);

$$S = 1 - \left(\frac{\min(R,G,B)}{\text{maks}(R,G,B)} \right) \tag{3.4}$$

$$\text{Değer}(V) = \text{maks}(R,G,B) \tag{3.5}$$

Renk adının (H) bulunabilmesi için öncelikle R', G', B' değerlerinin aşağıdaki gibi hesaplanması gerekir.

$$R' = \frac{\text{maks}(R,G,B) - R}{\text{maks}(R,G,B) - \min(R,G,B)} \tag{3.6}$$

$$G' = \frac{\text{maks}(R,G,B) - G}{\text{maks}(R,G,B) - \min(R,G,B)} \tag{3.7}$$

$$B' = \frac{\text{maks}(R,G,B) - B}{\text{maks}(R,G,B) - \min(R,G,B)} \tag{3.8}$$

Eğer S=0 ise Doygunluk (H) belirlenemez. Diğer taraftan;

$$\begin{aligned}
&H = 5 + B' \quad R = \text{maks}(R,G,B), G = \min(R,G,B)\\
&H = 1 - G' \quad R = \text{maks}(R,G,B), G \neq \min(R,G,B)\\
&H = R' + 1 \quad G = \text{maks}(R,G,B), B = \min(R,G,B)\\
&H = 5 - B' \quad G = \text{maks}(R,G,B), B \neq \min(R,G,B)\\
&H = 3 + G' \quad B = \text{maks}(R,G,B)\\
&\text{Diğer durumlarda } H = 5 - R' \text{ olarak belirlenir.}
\end{aligned} \tag{3.9}$$

H değeri bulunduktan sonra 60 ile çarpılarak dereceye dönüştürülür.

“H” ve “S” diğerlerinin diğer bir hesaplama ile (Gonzalez ve Woods, 2002);

$$H = \begin{cases} \theta & \text{Eğer } B \le G \\ 360 - \theta & \text{Eğer } B > G \end{cases} \tag{3.10}$$

$$\theta = \cos^{-1}\left(\frac{0.5(\text{R} - \text{G}) + (\text{R} - \text{B})}{\sqrt{(\text{R} - \text{G})^2 + (\text{R} - \text{B})(\text{G} - \text{B})}} \right) \tag{3.11}$$

$$S = 1 - \left(\frac{3}{R+G+B} \right) \min(R,G,B) \quad \text{olarak bulunur.} \tag{3.12}$$

3.1.3. CMY renk uzayı

Renkli yazıcılar ya da çoğaltıcıları içeren çıkış araçlarının çoğu CMYK renk modelini kullanır. RGB den CMY dönüşüm de 0 ile 1 arasında normalleştirilmiş renk

değerlerini RGB temsil eder. Camgöbeği, eflatun ve sarı CMY renk uzayının eksenleridir. CMY renk uzayı RGB renk uzayının tamamlayıcısıdır.

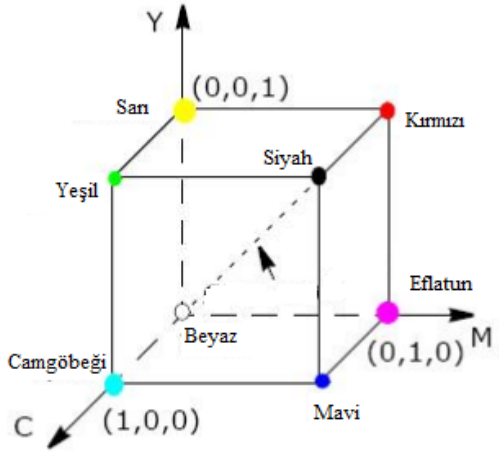

Şekil 3.5. CMY renk uzayı

RGB renk uzayından CMY renk uzayına dönüşüm aşağıdaki bağlantıyla sağlanır (Tkalcic ve Tasic, 2003).

$$C = 1 - R \tag{3.13}$$

$$M = 1 - G$$

$$Y = 1 - B$$

CMY'den CMYK renk uzayına dönüşüm ise (Tkalcic ve Tasic, 2003);

$$K = \min(C, M, Y) \tag{3.14}$$

$$C = \frac{C - K}{1 - K}$$

$$M = \frac{M - K}{1 - K}$$

$$Y = \frac{Y - K}{1 - K}$$

3.2.4. CIE XYZ renk uzayı

CIE XYZ renk uzayı insan gözünü esas aldığından dolayı tüm renk yönetim sistemleri için temel oluşturur ve bünyesinde tüm algılanabilir renkleri içerir. Bu renk uzayı CIE tarafından 1931 yılında standart aydınlatıcı (A, B, C, D50, D55, D65, E, F) ve standart gözlemciye (2^0, 10^0) göre belirlenmiştir. Bunun nedeni CIE XYZ renk uzayının en önemli özelliğinin cihazdan bağımsız olmasıdır. Üçboyutlu CIE XYZ renk uzayının iki boyutlu bir gösterimi aşağıda verilmişidir (Şekil 3.6).

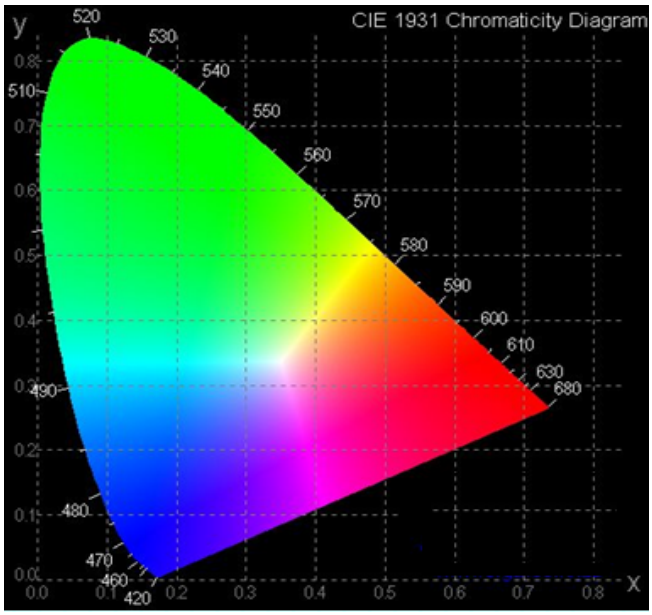

Şekil 3. 6. 2.derece gözlemciye göre CIE XYZ renk uzayının CIE 1931 renksellik diyagramı (*http://www.efg2.com/Lab/Graphics/Colors/Chromaticity.htm*\ Erişim tarihi:10.10.2011)

CIE renk sisteminde (λ) dalga boyunda tristimulus değerleri belirlenirse (Westland ve Ripamonti, 2004);

$$X = k \int S(\lambda)P(\lambda)x(\lambda)d\lambda \quad (3.15)$$

$$Y = k \int S(\lambda)P(\lambda)y(\lambda)d\lambda \quad (3.16)$$

$$Z = k \int S(\lambda)P(\lambda)z(\lambda)d\lambda \quad (3.17)$$

İnsan gözü yaklaşık 380nm ile 780nm arasındaki dalga boylarına duyarlıdır. Şekil 3.6'da sol alt köşede mavi, sağ üst köşede kırmızı, ortada ise yeşil renk hakimdir. CIE XYZ renk uzayında X, Y ve Z değerleri üç ana rengi (kırmızı, yeşil, mavi) algılayan sinirlerin beyne yolladıkları sinyallerin toplamıdır. Her üç uyarının ayrı ayrı toplam uyarı miktarına olan oranı rengi tanımlar (Yılmaz, 2002).

$$x = \frac{X}{X+Y+Z}, \quad y = \frac{Y}{X+Y+Z}, \quad z = \frac{Z}{X+Y+Z}$$

$$x + y + z = 1 \tag{3.18}$$

3.2.5. CIE L*a*b* renk uzayı

CIE, 1976'da yapısal eşitlik uzayı sağlamak için iki adet (CIE L*a*b* ve CIE L*u*v*) renk uzayı önermiştir. Bu renk uzaylarının insanın görsel algısı ile güçlü bir ilişkisi vardır. Bileşenleri "L" (Işık) , yeşilden kırmızıya oranı "a", maviden sarıya oranı "b" bileşenleri verir.

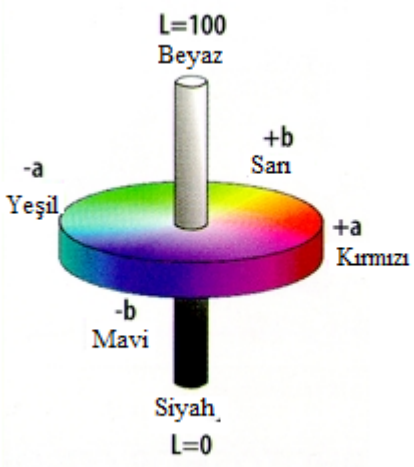

Şekil 3.7. CIE L*a*b* renk uzayı (http://www.hamradio.si/~s51kq/V-CIV.HTM Erişim tarihi: 10.10.2011)

CIE L*a*b* renk uzayının bileşenlerinin bulunabilmesi CIE XYZ renk uzayı ile mümkündür. X,Y ve Z değerlerinin bulunmasında kullanılan standart aydınlatıcı ve gözlemci bu bileşenlerin değerlerini de doğrudan etkiler.

CIE XYZ uzayından CIE L*a*b* renk uzayına dönüşüm aşağıdaki eşitlikten bulunabilir (Mendoza v.d, 2006).

$$L^* = 116f\left(\frac{Y}{Y_n}\right)^{\frac{1}{3}} - 16 \tag{3.19}$$

$$a^* = 500\left[f\left(\frac{X}{X_n}\right)^{\frac{1}{3}} - f\left(\frac{Y}{Y_n}\right)^{\frac{1}{3}}\right] \tag{3.20}$$

$$b^* = 200\left[f\left(\frac{Y}{Y_n}\right)^{\frac{1}{3}} - \left(\frac{Z}{Z_n}\right)^{\frac{1}{3}}\right] \tag{3.21}$$

$$f(q) = \begin{cases} q & \text{eğer } q>0{,}008856 \\ 7.787q + 16/116 & \text{değilse} \end{cases} \tag{3.22}$$

$q \in \left\{\frac{X}{X_n}, \frac{Y}{Y_n}, \frac{Z}{Z_n}\right\}$ Olarak belirlenir.

3.2.6. CIE L* C*h Renk uzayı

CIE L*C*h değerleri CIE L*a*b* değerlerinden yararlanılarak hesaplanmasıyla birlikte parlaklık, doygunluk ve hue açısının koordinatlarını kullanmaktadır.

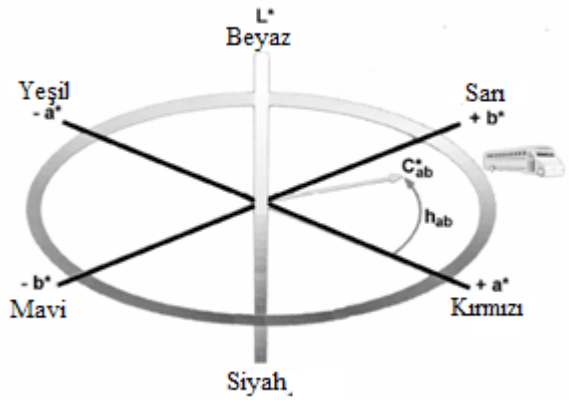

Şekil 3.8. CIE L*C*h diagramı (www.hunterlab.com, Erişim tarihi:11.10.2011)

Doygunluk ve Hue açısı aşağıdaki formül ile elde edilir (www.hunterlab.com, Erişim tarihi:11.10.2011).

$$C^* = \sqrt{a^{*2} + b^{*2}} \tag{3.23}$$

$$h = \arctan \frac{b^*}{a^*} \tag{3.24}$$

BÖLÜM 4

MAKİNE GÖRME SİSTEMİ

Makine görmesi, ürünlerin ve süreçlerin güvenliğini, sürecin verimliliğini, kalitenin gelişimini, hataların belirlenmesini sağlayan üretim sürecindeki doğal nesneleri ve materyalleri belirlemek için birleştirilmiş mekanik, optik, elektronik, yazılım sistemlerinin mühendisliği ile ilgilidir (Graves ve Batchelor, 2004). Diğer bir ifade ile makine görmesi, mekanik sistemlerin, sensörlerin, görüntüleme cihazlarının ve görüntü işleme algoritmalarının entegrasyonu olarak tanımlanabilir. Bununla birlikte makine görmesi örüntü tanıma ve yapay zeka gibi bir çok alanla da doğrudan ilişkilidir.

Makine görme sisteminin amacı, insanlar tarafından rahatlıkla uygulanabilen görüntüyü algılama davranışının makineler tarafından başarılmasıdır. İnsanlarda görüntüyü algılama olayı karmaşık bir süreçtir. Genel olarak ifade edilirse, ışık kaynağından gelen veya nesne üzerinden yansıyan, insanın görebileceği yaklaşık 380nm ile 780nm dalga boyu arasında olan ışık ışınlarının, ışığa duyarlı hücreler tarafından elektriksel sinyallere dönüştürülerek beyne iletilmesidir (Westland ve Ripamonti, 2004). Beyin gelen elektriksel sinyalleri yorumlayarak, görme olayını gerçekleştirir. Makine görme sisteminin temel mantığı bunun üzerine kurulmuştur. Burada görüntüleme cihazı (kamera, tarayıcı) tarafından yakalanan görüntü sayısal sinyale dönüştürülür ve yazılıma gönderilir. Görme olayını veya tanıma işlemini gerçekleştirecek olan yazılımdır. Görme olayı sonucunda yapılması gereken bir hareket varsa, yazılım bunu mekanik ve elektronik sistemler yardımı ile gerçekleştirir.

Son yıllarda, makine görme sistemleri imalat sürecinde otomasyonu sağlamak için sıklıkla kullanılmaktadır. Bununla birlikte bu sistemler savunma sanayi, güvenlik, trafik kontrol, denetleme, medikal gibi çok çeşitli alanlarda da kullanılmaktadır. Çünkü görüntüleme sistemleri, karmaşık ve veri akışının yüksek olmasına rağmen kusur sınıflandırma uygulamaları için hesaplama avantajı sağlamaktadırlar (Yong v.d., 2009).

Makine görme sistemleri, mekanik, optik, elektronik, yazılım sistemlerinin bir arada çalışmasını gerektirir. Bu çalışmada kullanılan makine görme sisteminin bileşenleri şekil 4.1.'de gösterilmektedir. Makine görme sistemi bünyesinde temel olarak; bilgisayar ve yazılım, aydınlatma sistemi, kamera ve lens, mekanik sistem, PLC (Programlanabilir Lojik Kontrolör), giriş/çıkış kartı ve pnömatik elemanlar bulunmaktadır.

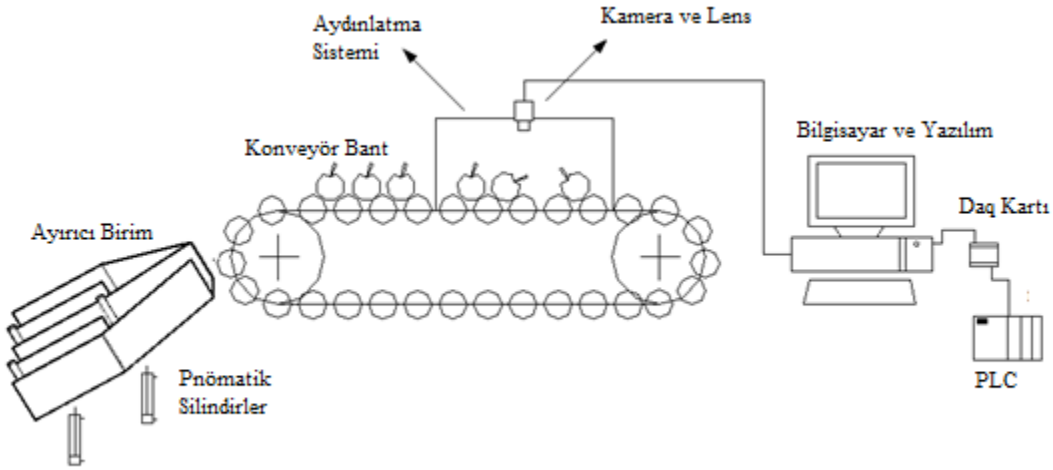

Şekil 4.1. Makine görme sistemi

4.1. Kamera ve Lens

Bir görüntünün kalitesi, parlaklık oranı ve piksel sayısı ile doğrudan ilgili olup, görüntü çözünürlüğü olarak adlandırılır. Bir görüntünün her bir piksel değeri, görüntüleme cihazının, görüntülenen nesneden yansıyan ışığın spektrumuna vermiş olduğu cevaba göre şekillenir. Bu nedenle kaliteli bir görüntü için kamera ve lensin seçimi ve uyumu çok önemlidir.

Kameralarda CMOS (Complementary Metal Oxide Semiconductor- Bütünleyici metal oksit yarı iletken) ve CCD (Charge Coupled Device-Yüklenme Eşleşmiş Cihaz) olmak üzere iki farklı görüntü sensörü bulunmaktadır. Genel olarak her iki sensör de

elektronik sinyalleri işler ve ışığı elektrik yüküne dönüştürür. CCD kameralarda çok sayıda ve çok küçük foto diyotlar vardır. Bir CCD sensörde her piksele ait akım gerilime dönüşür, depolanır ve analog sinyal olarak sensörden dışarı verilir. Diğer taraftan CMOS sensörlerde, transistörler her bir piksel bölgesinde sinyalin yükseltilmesi için kullanılır ve her piksel bölgesinden çıkan sinyal tek tek okunur. Bu yüzden kullanılan birkaç transistörle ışık duyarlılığı düşüktür (Acharya ve Ray, 2005). Buna rağmen hem CMOS sensörler hem de CCD sensörler uygun şekilde tasarlandıkları zaman iyi görüntü sağlayabilirler.

Nesnelerin görüntüleri kamera ve tarayıcı gibi cihazlar kullanılarak elde edilir. Nesnelerden yansıyan ışığın dalga boylarına göre, kullanılan algılayıcılar da yapısal olarak farklılıklar gösterir. Bu cihazlar ışığın farklı dalga boylarında görüntü elde edebilmek üzere üretilmişlerdir (Kızıl ötesi, X-ray v.b). Bununla birlikte bir sayısal kamera USB (Universal serial bus), FireWare (IEEE 1394), Kamera link veya Gigabit Ethernet (IEEE 802.3) aracılığıyla bilgisayara bağlanmakta ve bu şekilde sayısal görüntüler bilgisayara aktarılmaktadır.

Lensler kamerada oluşan görüntünün büyüklüğünü ve netliğini doğrudan etkiler. Lens seçimi yapılırken öncelikle kamera formatına uygun seçim yapılmalıdır. Lensin kameranın formatına eşit veya daha büyük olması gerekmektedir. Buna ek olarak odak uzaklığı, görüntülenecek nesne büyüklüğü, ışıklandırma ve lens montaj durumu göz önüne alınmalıdır. Kamera lensleri odak uzaklığı bakımından sabit odaklı ve ayarlanabilir odaklı olarak ikiye ayrılır. Odak uzunluğu mm cinsinden verilir ve direk olarak görüş açısı ile ilgilidir. Küçük odak uzunlukları geniş görüş açısı sağlarken, büyük odak uzunlukları ise dar görüş açısı sağlamaktadır. Ortamdaki ışığın durumuna göre lensin ayarlanabilir olması, görüntünün netliğini etkilemektedir. Bu da iris kontrolü ile gerçekleşir. İnsanın gözüne fazla ışık geldiğinde nasıl göz kısılır, az ışık olduğunda açılırsa, lenslerde de bu durumu sağlamak için ayarlanabilir bir iris kullanılabilir. Lenslerin yanında F (F/1.4 veya F/1.2) simgesi ile gösterilen ışığın girdiği açıklık değerini gösteren bir değer de bulunur. Bu değer ne kadar küçükse lensin ışık geçirme yeteneği o kadar büyüktür ve bununla bağlantılı olarak kameraya gönderilen görüntü o kadar hızlıdır. Lensler montaj tipine göre C ve CS olarak ikiye ayrılır. C montaj şekline sahip bir lensin CS montaj şekline sahip bir kameraya, araya bir yüzük aparatı takılarak, montajı yapılabilir.

4.2. Aydınlatma Sistemi

Makine görme sistemlerinin başarısı, görüntüleme yapılan ortamdaki aydınlatmanın kalitesi ve seviyesi tarafından etkilenir (Brosnan ve Sun, 2004). İyi tasarlanmış bir aydınlatma sistemi, görüntü karşıtlığını artırarak, görüntü analizi başarısını yükseltebilir (Gunasekaran, 1996; Brosnan ve Sun, 2004). Makine görme sistemlerinde kamera tarafından elde edilen görüntü, nesneden yansıyan ışık ile doğrudan ilişkilidir. Görüntü alınan ortamda, ışık seviyesinde oluşacak değişimler (doğal aydınlatmanın değişimi), yanlış lamba seçimi, bununla birlikte lambaların yanlış konumlandırılması, nesne renk bilgisinin doğru belirlenememesine ve sistemde kullanılan yazılımın olumsuz etkilenmesine neden olabilmektedir. Bu nedenle makine görme sistemlerinde yazılımın işlevsel kullanılabilmesi için aydınlatma önem teşkil etmektedir.

Kullanılan ışık kaynağının spektral güç dağılımı S(λ), renk bilgisinin elde edilmesinde oldukça etkilidir. Bu nedenle CIE tarafından renk sıcaklığı temel alınarak standart aydınlatma değerleri oluşturulmuştur. Bunlar; A (2856K), B (4874K), C (6774K), D50 (5000K), D55 (5500K), D65 (6500K), D75 (7500K), E, F2, F7, F11 şeklinde sıralanmaktadır (Pascale, 2003). Spektral güç dağılımı bilinen lambaların kullanımı, görüntülenen nesnenin renk değerlerinin hesaplanması imkânı sağlamıştır. Dikkat edilmesi gereken diğer bir nokta da, aydınlatma sisteminde kullanılacak lambanın aydınlatma karakteristiği (A, B, D55, D65 vb.), makine görme sisteminin yazılımında kullanılması muhtemel cihaz bağımsız renk uzaylarının değerlerini doğrudan etkilediğidir.

Sonuç olarak aydınlatma sisteminde kullanılacak ışık kaynağının seçilmesinde; kaynağının dalga boyu, renksel geri verimi, renk sıcaklığı ve bununla birlikte kullanılacak kameranın duyarlılığı göz önünde bulundurulmalıdır.

BÖLÜM 5

ÖRÜNTÜ TANIMA

Örüntü, üzerinde ölçüm ve gözlem yapılabilen bilgilerdir (Türkoğlu, 2003). Bunlara örnek olarak ses ve görüntü verilebilir. Görüntü bilgileri söz konusu olduğunda örüntü tanıma, elde edilen bir görüntünün içerisinde bulunan, benzer özeliklere sahip ve aralarında ilişki kurulabilen nesnelerin, sınıflandırma yöntemleri kullanılarak bir sınıfa koyma işlemi olarak tanımlanabilir. İnsanlar günlük hayatlarında örüntü tanıma olayını geçmiş yaşantı ve tecrübeleri ile sürekli gerçekleştirmektedirler. Örüntü tanıma, makine öğrenmesinin ve buna bağlı olarak makine görmesinin önemli bir basamağıdır. Örüntü tanıma görevini bilgisayar yazılımları yardımı ile makinelere yaptırmak, günümüz teknolojisi ile mümkün olmakla birlikte, son yıllarda yapılan uygulamalarda hızlı bir büyüme sergilemiştir. Örüntü tanıma, telekomünikasyon, medikal görüntüleme, biyoloji, malzeme bilimi, robotik, veri madenciliği, üretim sanayi gibi çok önemli alanlarda kullanılmaktadır. Bununla birlikte otomatik örüntü tanıma sistemleri endüstri alanlarında üretimin niteliğini ve niceliğini geliştirmek için de kullanılırlar.

Bir örüntü tanıma sistemi eğitim ve test olmak üzere iki evreden oluşur (Şekil 5.1). Sistemin en önemli elemanları; ön işleme, öznitelik çıkarma, öznitelik seçimi ve sınıflandırmadır (Jain v.d., 2000). Ön işleme, uygulamanın şekline göre farklılık gösterebilir. Bu tez çalışmasında ön işleme basamağında görüntü işleme tekniklerinden görüntü maskeleme ve bölütleme (segmentasyon) kullanılmaktadır.

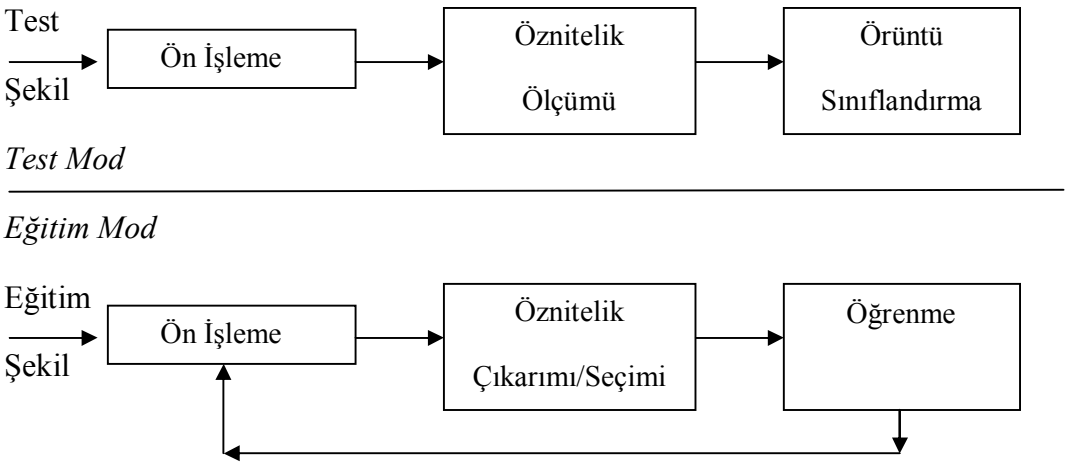

Şekil 5.1. Örüntü tanıma yapısı (Jain v.d., 2000)

5.1. Görüntü İşleme

Sayısal görüntü işleme, sayısal formatta bir görüntünün dönüşümleri ile ilgilenir. Sayısal görüntü işlemede giriş ve çıkış görüntülerinin her ikisi de sayısaldır (Pitas, 2000). Bu nedenle görüntü yakalama elemanları tarafından elde edilen görüntü, bilgisayarın işlem yapabileceği sayısal bir formata dönüştürülmelidir. Sayısal görüntü üzerinde görüntü işleme teknikleri kullanılarak, örüntü tanıma için gerekli veriler elde edilir.

Sayısal görüntü işlemede bilgisayar tarafından, iki boyutlu bir resmin işlem yapılmasına başvurulur ve görüntü iki boyutta, *f(x,y)* olarak ifade edilir. Sayısallaştırılmış bir resmin en küçük birimi pikseldir (Kavdır, 2000). İfadedeki *x* ve *y* değerleri uzaysal koordinatları ve *f* ifadesi de belirlenen koordinatlardaki parlaklığı göstermektedir. Sayısal bir resmin matematiksel ifadesi aşağıdaki gibidir.

$$f(x,y)=\begin{bmatrix} f(0,0) & f(0,1) & \dots & f(0,N\text{-}1) \\ f(1,0) & f(1,1) & \dots & f(1,N\text{-}1) \\ . & & & \\ . & & & \\ f(M-1,0) & f(M-1,1) & \dots & f(M-1,N\text{-}1) \end{bmatrix}$$

Bu tezde, görüntü işlemenin iki önemli basamağı üzerinde durulmaktadır. Bunlar, görüntünün maskelenmesi ve bölütlenmesi işlemleridir.

5.1.1. Görüntü maskeleme

Görüntü maskeleme en temel görüntü işleme operasyonlarından biridir. Resmin içerisinde bulunan bir alanın resmin diğer kısımlarından (arka fon) ayrılarak, elde edilmesi işlemidir. Elde edilen maskede bulunan her bir piksel bir (1) ya da sıfır (0) değerini alır. Sıfır siyah alanları, bir ise beyaz alanları oluşturur.

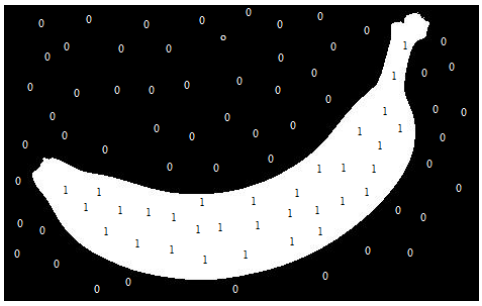

Şekil 5.2. Maskelenmiş görüntü

5.1.2. Bölütleme (Segmentasyon)

Bölütleme, görüntü işlemenin zor ve en önemli uygulamalarından biridir. Bölütleme farklı özelliklere sahip alanların bir birinden ayrılması, diğer bir ifadeyle benzer karakteristik alanların gruplandırılmasıdır. Due ve Sun'a göre, gıdaların kalitelerine göre değerlendirilmesi için geliştirilen görüntü bölütleme tekniği dörde ayrılır. Bunlar eşikleme-temelli, bölge-temelli, gradyan-temelli ve sınıflandırma temellidir. Literatürde en çok eşikleme-temelli ve bölge-temelli bölütleme kullanılmaktadır. Diğer iki bölütlemenin daha az kullanıldığı düşünülmektedir (Due ve Sun, 2004).

Eşikleme-temelli; Bu yöntemde en uygun ayırıcı bir eşik değeri hesaplanmalıdır. Elde edilen eşik değeri resmin piksellerinin ayrılmasında kullanılır. Eşikleme işleminde giriş görüntüsünde *f(x,y)* bulunan piksel değerlerinin belirlenen bir eşik değeri $T_{eşik}$ ile karşılaştırılması sonucunda, çıkış görüntüsü *f(x,y)* elde edilir. Çıkış görüntüsünü oluşturan piksellerin değeri, 1 veya 0 dır.

$$f(x,y) = \begin{cases} 1 & \text{Eğer } z(x,y) > T_{eşik} \\ 0 & \text{Diğer} \end{cases}$$

Eşikleme-temelli yöntem uygulaması farklılık gösterebilmektedir. Bu farklılık genel veya bölgesel, basit veya uyarlamalı eşikleme şeklinde olabilmektedir. Genel yöntemde bölütlenecek görüntü için tek bir eşik değeri belirlenirken, bölgesel yöntemde bir bölge içindeki her piksel için farklı eşik değeri hesaplanır. Basit eşiklemede önceki gözlemlerden elde edilen eşik değerine göre işlem yapılırken, uyarlamalı eşiklemede ise her yeni görüntü için eşik değeri hesaplanır (Unay, 2006).

Bölge-temelli: Bu metot iki temel sınıfa bölünür. Birinci sınıf bölgenin büyüyerek birleşmesi, diğeri bölgenin bölünerek birleşmesidir. İlki aşağıdan yukarıya yöntemidir. Bu yöntem homojenlik ölçütlerine göre daha büyük bölgeler içerisinde alt bölgeleri veya pikselleri gruplandırır. İkincisi yukarıdan aşağıya yöntemidir. Bu yöntemde, belirlenen ölçüt doyuma ulaşana kadar resmi küçük küçük gruplara böler (Due ve Sun, 2004).

Gradyan-temelli: Eşikleme yönteminin aksine gradyan yöntemi, yüksek gradyan büyüklükleri tarafından kenarları doğru bir şekilde bulmaya yarar. Resmin gradyanı üzerine kurulmuş, kenar belirlemeye benzer bir yöntemdir (Due ve Sun, 2004).

Sınıflandırma-temelli: Yapay sinir ağları, bulanık mantık, istatistik gibi sınıflandırma teknikleri üzerine kurulmuş, farklı nesnelerin her bir pikselini belirlemeye yarayan bir yöntemdir (Due ve Sun, 2004). Bu yöntemi Leemans ve arkadaşları, Bayes sınıflandırma olarak, elma kusurlarını ayırmak için başarılı bir şekilde kullanmışlardır (Leemans v.d., 1999).



(a) (b) (c)

Şekil 5.3. Bölütleme teknikleri. (a) Eşikleme (b) Kenar temelli bölütleme (c) Bölge-temelli bölütleme (Sun, 2000)

5.2. Öznitelik Çıkarımı

Bölütleme işlemi sonucunda elde edilen örüntülerin sınıflandırılabilmesi için bu örüntüler hakkında ölçülebilir veya gözlenebilir bilgiye ihtiyaç vardır. Bu da örüntülerin karakteristik yapılarının elde edilmesini sağlayan özniteliklerin çıkarılmasını gerektirir. Örüntü tanıma sistemlerinde sınıflandırma aşamasında doğru kararlar verilebilmesi, yeterli sayıda ve etkin özelliğin elde edilmesi ile gerçekleşebilir. Çıkarılan öznitelikler uygulama alanına göre farklılıklar gösterebilir. Elma sınıflandırmasında kullanılan bazı öznitelikler aşağıda sıralanmaktadır.

Biçimsel Öznitelikler: Örüntünün şeklini belirlemek için yapılan ölçümlerdir. Şekil öznitelikleri örüntünün fiziksel ölçümleridir. Bu ölçümlerle örüntünün karakteristiği ortaya çıkar. Biçimsel öznitelikler arasında sayabileceklerimizden bazıları aşağıda verilmiştir (Majumdar, 1997).

Çevre: Örüntüyü çevreleyen piksel mesafesidir ve örüntünün çevresi olarak tanımlanır. Örüntünün sınır mesafesinin ölçüsüdür.

Alan: Örüntünün içindeki piksellerin toplam alanıdır. Alan sonuçları örüntünün nesne boyunun ölçüsüdür.

Alan Çevre Oranı: 0 ve 1 arasında bir değer verilen örüntünün yuvarlaklığını ölçer. Oranın büyüklüğü örüntünün büyüklüğü ile doğru orantılıdır. Oran 1'e eşit ise, örüntü mükemmel yuvarlaklığa ulaşmıştır.

Uzamsal Moment: Uzamsal moment, nesneyi belirli bir şekilde tanımlamayan istatistiksel şekil ölçümleridir. Ayrıca, bir örüntünün özellikleri ile ilgili istatistiksel ölçümler verir (Majumdar, 1997).

Renk Öznitelikleri: Bir örüntünün renk öznitelikleri örüntünün sınırları içerisindeki her pikseli tanımlanması ile açıklanabilir. Bir örüntünün renk bileşenlerinin (R,G,B) istatistiksel değerlerinin kullanımı faydalı olabilmektedir. Bunlardan bir kaçı aşağıda verilmiştir (Majumdar, 1997).

Ortalama: Örüntünün renk bileşenlerinin ortalamasını verir.

Standart Sapma: Bir örüntünün renk bileşenlerinin standart sapması örüntünün renk bileşenlerinin ortalama değerden ne kadar farklı olduğunun ölçümünü verir.

Gradyan: Bir görüntüdeki piksel dağılımı değişiminin en çok olduğu yere doğru yönelmiş vektör alanını verir. Bununla birlikte vektör alanı büyüklüğü, piksel değeri değişimi hakkında bize bilgi verir.

Çarpıklık: Görüntü piksel değerlerinin dağılışında, simetriliğin bozulma derecesidir. Dağılış sağa doğru kuyruklu olarak uzuyorsa buna pozitif çarpıklık, sol tarafa kuyruklu olarak uzuyorsa buna da negatif çarpıklık denir.

Basıklık: Görüntü piksel değerlerinin dağılış eğrisinde meydana gelebilecek sivrilik veya yayvanlık, basıklık derecesi olarak tanımlanır.

Dokusal Öznitelikler: Görüntülerin birçok çeşidini analiz edebilmede önemli bir özniteliktir. Görsel doku tanımlanması zor bir kavram olmasına rağmen, tekrarlı örüntüleri içeren görüntülere dayandırılır. Görüntü dokusu hücresel ve soyut olarak tanımlanır. Görüntü dokusu niteliksel olarak incelik, kalınlık, düzgünlük, rasgelelik ya da düzensizlik özniteliklerinin birine veya bir kaçına sahip olup olmamasına göre değerlendirilebilir (Majumdar, 1997).

5.3. Öznitelik Seçimi

Sınıflandırıcının hata oranını düşürmek ve performansını artırmak için çıkartılan özniteliklerin tümü sınıflandırıcıda kullanılmaz. Bunun yerine en etkin ayırmayı gerçekleştiren öznitelikler belirlenir ve belirlenen öznitelikler temel alınarak sınıflandırma işlemi gerçekleştirilir. Öznitelik seçim işlemi, en uygun öznitelik alt kümesini belirlemek için bir kez yapılır. Ne zaman ki yeni öznitelikler eklenir veya eğitim verileri değiştirilirse işlem yeniden gerçekleştirilir.

Öznitelik seçiminin birçok yararı vardır. İlki, gereksiz öznitelikler süreçten çıkarılarak öğrenme sürecinin çalışma zamanında büyük ölçüde tasarruf edilir. İkincisi, önemsiz, gereksiz ve gürültülü öznitelikler olmaksızın öğrenme algoritmaları en önemli özniteliklere odaklanabilir ve daha basit ve daha doğru veri modeli inşa edebilirler. Böylelikle sınıflandırma performansı gelişir. Üçüncü olarak, öznitelik seçimi, daha basit ve daha genel bir model oluşturup, görevin altında yatan kavramı anlayıp daha iyi bir fikir vermede yardımcı olabilir (Tan, 2007).

Tüm öznitelikler kümesi N öznitelik içeriyorsa, aday alt kümelerinin toplam sayısı 2^N dir. En uygun öznitelikler alt kümesinin bulunması için çeşitli araştırma stratejileri vardır. Ardışık ileri yönde seçim (SFS), Ardışık Geri Yönde Seçim (SBS) ve Ardışık İleri Yönde Kayan Seçim (SFFS) bunlardan bir kaçıdır. Bu metotlarda değişim sadece alt kümeden özniteliklerin silinmesi veya eklenmesi yoluyla gerçekleşir. Adından da anlaşılacağı üzere SFS sırasıyla öznitelik uzayı araştırır. Boş bir kümeden başlar ve her yinelemede küme içerisine eklemek için en iyi tek bir özelliği seçer. Bunun tam tersi SBS, dolu bir öznitelikler kümesinden başlar ve her bir yinelemede kümeden en kötü bir özelliği siler. SFFS algoritması aşağıdan yukarı araştırma metodudur ve SFS algoritmasını genişletir. SFFS prosedürü alt küme sonuçları bir öncekinden daha iyi sonuçlandığı sürece her ileri adımdan sonra bir geri adım uygulamasını içerir. Sonuç olarak performans geliştirilemezse geri adım yoktur. Benzer uygulama Ardışık Geri Yönde Kayan Seçim (SBFS) prosedüründe de geçerlidir. Böylelikle geri yönde izleme dinamik olarak kontrol edilir ve sonuç olarak parametre ayarlarına ihtiyaç duyulmaz (Pudil v.d., 1994; Tan, 2007).

5.4. Sınıflandırma

Elde edilen bir örüntünün tanınması veya sınıflandırılması onu oluşturan piksellerin etiketlenmesi ile mümkündür. Bu nedenle örüntünün etiketlenme doğruluğu, uygulanan modelin başarısıyla ilişkilidir. Bu işlem denetimli ve denetimsiz sınıflandırma olarak adlandırılan iki yol ile gerçekleştirilebilir (Jain v.d., 2000). Örüntü tanıma işleminde hangi sınıflandırma yönteminin başarılı olacağı kesin olarak söylenemez. Örüntü tiplerine göre sınıflandırma yöntemlerinin başarısı değişebileceği gibi aynı örüntüden elde edilen farklı özniteliklere ve özniteliklerin sayısına göre de değişik sınıflandırma yöntemleri başarı sağlayabilir.

5.4.1. Denetimli sınıflandırma (Supervised Classification)

Denetimli sınıflandırmada, eğitim verilerinin sınıf etiketleri bilinmektedir. Eğitim örnekleri, bir girdi nesnesi ve onun arzu edilen çıktısı olarak sunulur. Denetimli sınıflandırma algoritması, eğitim verisi ve onun sınıfı arasında yaklaşık eşleşme fonksiyonunu bulmak içindir. Örüntü tanımada denetimli sınıflandırma, giriş şekli önceden belirlenen bir sınıfın üyesi olarak tanımlanır. Denetimli sınıflandırma için birçok algoritma ve yaklaşım önerilmektedir. Bunlar yapay sinir ağları, naive bayes sınıflandırma, Destek Vektör Makineleri, *k* En Yakın Komşuluk, diskriminant analiz vb. olarak sayılabilir (Tan, 2007).

5.4.1.1. Destek Vektör Makinesi (DVM)

Vapnik ve arkadaşları tarafından geliştirilmiş olan istatistiksel öğrenme teorisinden türetilmiş yeni bir sınıflandırma algoritmasıdır (Vapnik, 1999). DVM'nin

amacı iki sınıfı birbirinden ayıran hiper-düzlemin belirlenmesidir. Bu hiper-düzlem belirlenirken, iki farklı sınıfın en yakın noktaları arasındaki uzaklığı maksimum seviyeye çıkarması öngörülür.

1-) Doğrusal ayrılabilen durumlar için doğrusal DVM

Doğrusal olarak ayrılabilen DVM'nin eğitimi için, eğitim verisi d-boyutsal öznitelik uzayından N sayıda örnekten oluşur.

$$x_i \in R^d (i = 1, 2, ..., N); \qquad y_i \in \{-1, +1\}$$

Bu hiper-düzlemleri oluşturan noktalar destek vektörleri olarak adlandırılır ve bu düzlemler;

$$w.\, x_i + b = +1 \tag{5.1}$$

$w.\, x_i + b = -1;$ şeklinde ifade edilirler.

$y_i \in \{-1, +1\}$ ise sınıf etiketlerini, $\boldsymbol{w}$ ağırlık vektörünü (hiper-düzlemin normali) ve b eğilim değerini göstermektedir. Hiper-düzlemin sınırının maksimuma çıkarılması gerekmektedir. Bu işlem payın en büyük değeri alması, $\boldsymbol{w}$'nin düzgesini $\|\boldsymbol{w}\|$'i en küçük değere getirmekle gerçekleştirilir. Buna göre en uygun hiper-düzlemin bulunması aşağıdaki kuadratik programlama probleminin çözümü olarak tespit edilebilir.

$$\left\{ \begin{array}{l} \text{minimize: } \dfrac{1}{2}\|w\|^2 \\ \text{Koşulu ile: } y_i (w.x_i + b) \geq 1, \quad i = 1, 2, ..., N \end{array} \right\}$$

Doğrusal optimizasyon problemi aşağıda gösterildiği gibi lagrange formülasyonu kullanılarak ikili probleme dönüştürülebilir.

$$\left\{ \begin{array}{l} \text{maksimize: } \displaystyle\sum_{i=1}^{N} \alpha_i - \frac{1}{2} \sum_{i=1}^{N} \sum_{j=1}^{N} \alpha_i \alpha_j y_i y_j (x_i . x_j) \\ \text{Koşulu ile: } \displaystyle\sum_{i=1}^{N} \alpha_i y_i = 0 \quad ve \quad \alpha_i \geq 0, \quad i = 1, 2, ..., N \end{array} \right\}$$

Sonuç olarak, DVM için doğrusal ayrılan verilerin karar fonksiyonu aşağıdaki şekilde yazılabilir (Melgani ve Bruzzone, 2004).

$$y = \operatorname{sgn}\left(\sum_{i=1}^{N_s} \alpha_i y_i (x_i, x) + b \right) \tag{5.2}$$

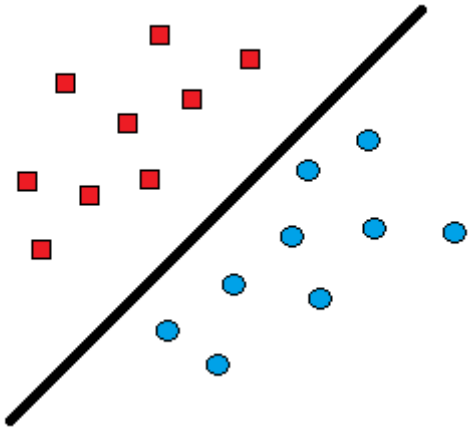

Şekil 5.4. Doğrusal ayrılabilen veriler için hiper-düzlem

2-) Doğrusal ayrılamayan veriler için Doğrusal DVM

Verilerin bazı durumlarda doğrusal olarak ayrılması mümkün olmamakla birlikte, hiper-düzlemin iki sınıfa ayırma işlemi doğru bir şekilde gerçekleşmeyebilir (Şekil 5.5). Gerçek veri sınıflandırma işlemlerinde genellikle karşılaşılan bir durumdur. Ayrılmayan verileri işlemek için en uygun ayrılabilen hiper-düzlem çözüm olarak genellenebilir. Bu hiper- düzlemin fonksiyonu için iki temel ölçüt gerekir. Bunlardan ilki sınırın maksimum hale getirilmesi ve diğeri sınıflandırma hatalarının minimum hale getirilmesidir. Buna göre fonksiyon;

$$\Psi(w, \xi) = \frac{1}{2}\|w\|^2 + C\sum_{i=1}^{N} \xi \tag{5.3}$$

ξ_i yanlış sınıflama hatalarının ölçüsüdür. C değeri kullanıcı tarafından girilecek düzenleyici parametresidir. Elde edilen bu fonksiyona ait kısıtlamalar;

$$y_i(w.x_i + b) \geq 1 - \xi_i, \qquad i = 1,2,...,N$$
$$\xi_i \geq 0, \qquad i = 1,2,...,N$$

şeklinde ifade edilir.

Şekil 5.5 doğrusal olarak ayrılmayan veriler için optimum hiper- düzlem gösterilmektedir (Melgani ve Bruzzone, 2004).

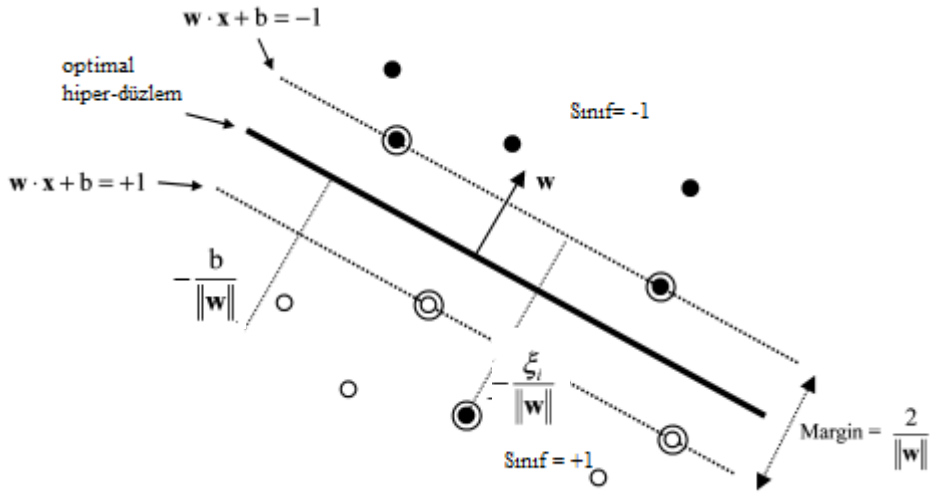

Şekil 5.5 Doğrusal ayrılamayan veriler için optimum hiper-düzlem (Melgani ve Bruzzone, 2004).

Hiper-düzleme en yakın pozitif ve negatif örnekler arasındaki mesafe, kenar boşluğu (margin) olarak adlandırılmaktadır.

3- Doğrusal olmayan DVM

Gerçekçi verilerle yapılan uygulamalarda genellikle doğrusal DVM'ler sınıfların ayrılmasında etkin sonuçlar vermezler. Bu tür problemlerin çözümünde doğrusal olmayan durumdan doğrusallığa bir köprü sağlayan çekirdek fonksiyonlar kullanılır. Doğrusal olmayan DVM tarafından kullanılan çekirdek fonksiyonları giriş uzayını

yüksek seviyeli uzaya dönüştürerek, normalde doğrusal olmayan eğrilerle çözülmesi gereken uzayı, hiper-düzlem kullanarak ikiye ayırabilir. Çekirdek fonksiyonları doğrusal öğrenme makinelerinin öğrenme gücünü yükselten daha yüksek boyutsal öznitelik uzayı içerisinde doğrusal olmayan öğrenme verilerini eşleştirmek için DVM'ler de kullanılır (Kong ve Zhang, 2007).

Çekirdek fonksiyonu kullanarak doğrusal olarak ayrılamayan iki sınıflı bir problemin çözümü ile ilgili karar kuralı aşağıdaki şekilde yazılmaktadır.

$$y = \operatorname{sgn}\left(\sum_{i=1}^{N_s} \alpha_i y_i k(x_i, x) + b \right) \tag{5.4}$$

$k(x_i,x)$ çekirdek fonksiyondur, N_s destek vektör sayısıdır (Kong ve Zhang, 2007). DVM'de kullanılan çekirdek fonksiyonlarının bazıları aşağıda verilmiştir.

a-) Doğrusal Fonksiyon

b-) Yarıçap Temelli Fonksiyon (YTF)

c-) Kuadratik Fonksiyon

d-) Polinomsal Fonksiyon

e-) Çoklu Katmanlı Ağı (ÇKA)

Çekirdek fonksiyonlarında bulunan bazı değerlerin (Polinomsal fonksiyonda "p", radyal tabanlı fonksiyonda "σ" gibi) değiştirilmesi ile sınıflandırma başarısı olumlu veya olumsuz olarak değişebilir.

5.4.1.2. *k* En Yakın Komşuluk (*k*-EYK)

k En Yakın Komşuluk (*k*-EYK) (Fix ve Hodges, 1951) yöntemi, örüntü tanıma ve sınıflandırma problemleri çözümünde kullanılan denetimli sınıflandırma yöntemleri

arasındadır. Bu metot öznitelik uzayında en yakın eğitim örneklerini temel alarak, nesnelerin sınıflandırılması için kullanılır. *k*-EYK tüm makine öğrenme algoritmaları arasında en basitlerinden biridir. Bu algoritmada, yeni bir örnek geldiğinde onun en yakın *k* komşusuna bakılarak, örneğin hangi sınıfa ait olduğuna karar verilir. *k*-EYK sınıflandırıcı algoritmasında, belirlenen eğitim örnekleri ve test örnekleri arasında benzerlik ölçütü olarak, en çok kullanılanlardan birisi olan öklid uzaklığı temel alınabilir.

Eğitim seti; D= $\{X_1, X_2, X_3....X_n\}$,

D deki örneklerin sınıfı; D=$\{C_1, C_2, C_3....C_c\}$

X_i , *P* özellikleri ile eğitim örneği $\{X_{i1}, X_{i2}, X_{i3}....X_{ip}\}$

i= 1,2,3.....n, eğitim örneklerinin sayısı

k değeri girildikten sonra etiketsiz bir vektör için, öklit mesafesi tarafından test örnekleri X_l ve eğitim örnekleri X_i mesafesi hesaplanır.

$$D(X_i, X_l) = \sqrt{\sum_{r=1}^{p} (x_{ir} - x_{lr})^2} \tag{5.5}$$

Bu *n* mesafeleri sıralanır ve en yakın *k* komşu seçilir. c' sınıfları vardır ve her sınıf $k_{j'}$'ye (X_l hücresindeki en yakın komşular) sahiptir. $1 \le c' \le c$

$$\sum_{j'=1}^{c'} k_{j'} = k \tag{5.6}$$

Sonuç olarak, etiketlenmemiş vektör en yakın *k* eğitim örnekleri arasında en sık olan sınıfa atanarak sınıflandırılır.

$X_1 \in C_j$ ise DN = $\{k_{j'}\}$,

DN, X_l ve C_j nin arasındaki en yakın mesafenin sayısını belirler (Chang v.d., 2011).

k-EYK algoritması şu adımlara göre gerçekleştirilir;

a) İlk olarak "*k*" değeri belirlenir,

b) Test örnekleri ve eğitim örnekleri öklit uzaklıkları hesaplanır,

c) Bulunan uzaklıklara göre küçükten büyüğe doğru sıralanır ve
d) Belirlenen komşulara göre baskın olan sınıf seçilir.

5.4.2. Denetimsiz sınıflandırma (Unsupervised Classification)

Denetimsiz sınıflandırmada eğitim verilerinin sınıf etiketleri mevcut değildir. Bu da denetimli sınıflandırmayla denetimsiz sınıflandırma arasındaki ayırıcı özelliktir. Bu yöntemin sınıflandırılacak görüntü hakkında yeterli bilgi olmadığı durumlarda kullanılması uygundur. K-ortalama kümelemesi, özörgütlemeli harita (SOM) algoritmaları denetimsiz sınıflandırmada sıklıkla kullanılan yöntemlerdendir (Tan, 2007).

BÖLÜM 6

MAKİNE GÖRME SİSTEMİ KULLANARAK GERÇEK ZAMANLI ELMA SINIFLANDIRMA OTOMASYONU

Önceleri mekanik tasarımlarla ve insan gücü ile gerçekleştirilen elma sınıflandırma işlemleri, teknolojinin gelişimi ile birlikte yerini makine görme sistemlerine bırakmıştır. Bu şekilde insan gücü gereksinimleri ve sınıflandırmadaki hata oranları azalmış, ayrıca birim zamandaki sınıflandırılan elma miktarı da artmıştır.

Bu çalışmada, elma sınıflandırma uygulaması için gerçek zamanlı çalışan makine görme sistemi tasarlanmıştır. Sistemin yazılımı Windows XP Profesyonel işletim sistemi altında MATLAB programlama dili kullanılarak elde edilmiştir. Gerçekleştirilen makine görme sisteminin bünyesinde birbirinden bağımsız iki yazılım bulunmaktadır. İlk yazılım, elmaları renk ve boylarına göre dört sınıfa ayırmaktadır. Diğer yazılım da ise elmaların yüzeyinde bulunan ve kusur olarak tanımlanan örüntülerin toplam alanına göre, elmaların Ekstra, Sınıf 1, Sınıf 2 ve Reddedilen şeklinde dört sınıfa ayrılması amaçlanmıştır.

6.1. Elma Sınıflandırma Makine Görme Sistemi

Bu tezde elmaları sınıflandırmak için geliştirilen makine görme sistemi şekil 6.1'de görülmektedir. İçeriğinde temel olarak, bilgisayar (yazılım), görüntüleme cihazı (renkli kamera), lens, aydınlatma sistemi, PLC (Programlanabilir Mantıksal Denetleyici), sensörler, giriş/çıkış kartı, döner rulolu konveyör sistemi, ayırıcı birim ve giriş birimi bulunmaktadır.

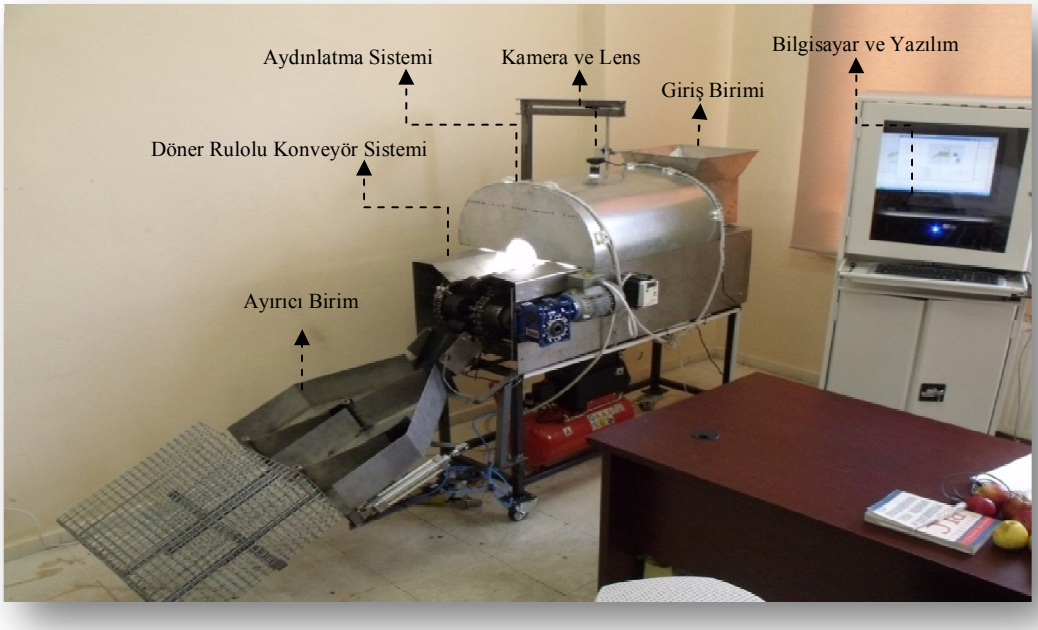

Şekil 6.1. Elma sınıflandırma makine görme sistemi

Giriş birimine dökülen elmaların tek sıraya geçerek, tasarlanan döner rulolu konveyör sistemi üzerinde dönerek ilerlemeleri sağlanmıştır. Elmaların aydınlatma sisteminin içine girip kameranın altından geçtikleri anda fotoğrafları çekilmektedir. Bu işlem sonucunda, elde edilen RGB sayısal görüntüler yazılım tarafından işlenir. Elde edilen algoritma sonuçlarına göre elmalara ait sayısal sınıflandırma bilgisi, giriş/çıkış kartı ve PLC tarafından ayırıcı birime ulaşır. Bu sonuçlara göre elmalar uygun olan bir sınıfa, ayırıcı birim tarafından ayrılır.

6.1.1. Kamera ve lens

Bölüm 4'te anlatılan kamera ve lens seçiminde dikkat edilmesi gereken hususlar göz önüne alınarak, kamara ve lens seçimi yapılmıştır. Bu çalışmada IDS firmasının uEye serisi UI-1240LE-C kamerası kullanılmıştır. Bu kamera endüstriyel uygulamalar için tasarlanmış, 1.3 mega piksel (çözünürlük=1280x1024 piksel) çözünürlükte 25 fps renkli bir kameradır. Bünyesinde CMOS sensör kullanılmıştır. Bununla birlikte

kamerada, algılanan resmi sayısal hale getiren sayısallaştırıcı birim bulunmaktadır. Bu nedenle görüntüler, görüntü sayısallaştırıcı kartına ihtiyaç olmadan USB 2.0 bağlantı ile bilgisayara, sayısal formatta gönderilebilmektedir. Kameranın bu özelliğinden dolayı, çok çeşitli sistemlerle sorunsuz olarak bütünleştirilebileceği düşünülmektedir.

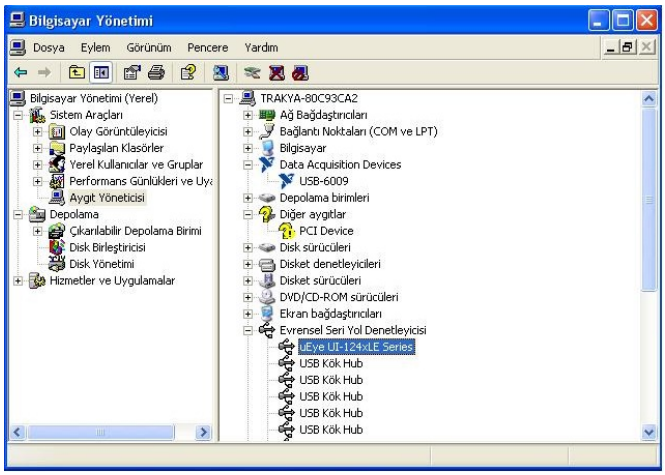

Şekil 6.2. Kameranın USB bağlantı durumu

Kameradan iyi bir performans sağlanması, sisteme uygun lensin seçilmesi ile mümkündür. Çalışma doğrultusunda hangi odak uzunluklu lensin seçileceği, görüntülenecek alan ve çalışma mesafesi ile ilgilidir. Bu çalışmada, 6mm odak uzunluklu Azure marka lens kullanılmıştır.

Bu tez çalışmasında, konveyör sistemi üzerinde dönerek ilerleyen elmaların tüm yüzeyine yakın bir alanının kamera tarafından görüntülenebilmesi amaçlanmıştır. Elmanın tüm yüzeyine yakın bir alanın görüntülenebilmesi için kamera altında en az yarım tur atabilmesi gereklidir. Görüntüleme alanı, elmanın ortalama çapı 75 mm olduğu göz önüne alınarak hesaplanırsa, en az 235,6 mm olması gerekir. Kameranın konumu ve elde edilen minimum görüntüleme alanına göre 6 mm odak uzunluklu lens kullanıldığında görüntülenebilecek alan hesaplanırsa;

Çalışma Uzaklığı =300 mm

Kullanılan Sensör format =1/2" (Genişliği 6,4 mm alınır)

Odak Uzaklığı = (Çalışma uzaklığı x sensör boyu)/ (Görüntülenecek alan + sönsör boyu)

Bu hesaba göre 6 mm lens seçildiğinde görüntüleme alanı 319 mm bulunur (Şekil 6.3). Kullanılan lens ile elde edilen görüntüleme alanı çalışmamız için uygundur.

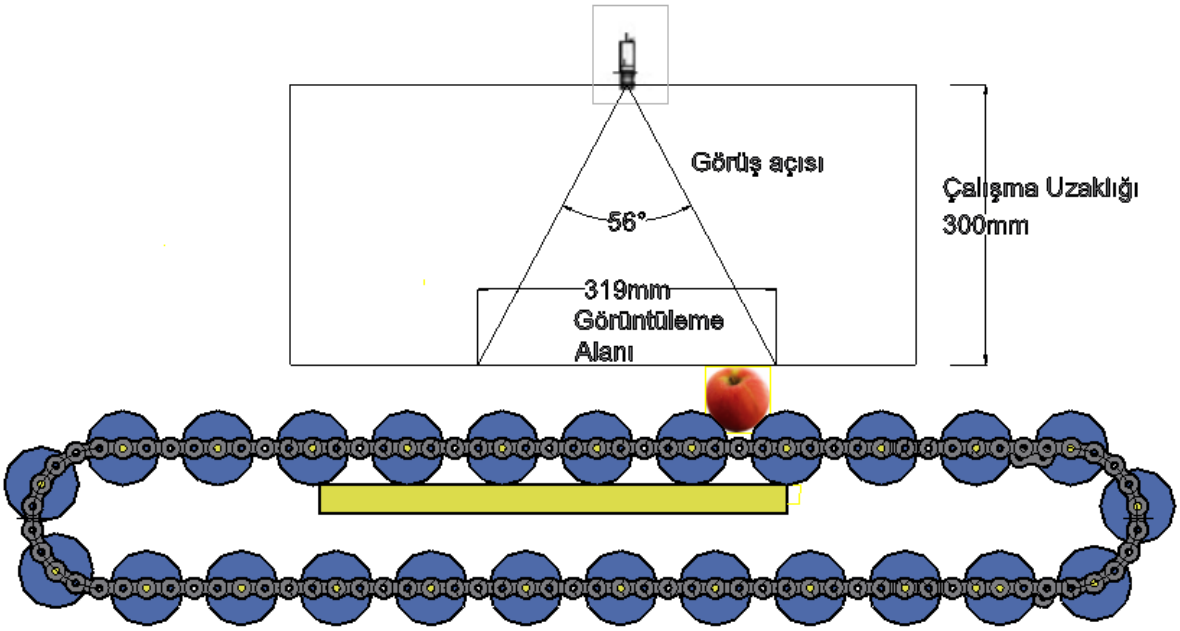

Şekil 6.3. Kamera konumu ve seçilen lense göre görüntüleme alanı

Kameranın konumlandırılması ve çözünürlüğü göz önüne alındığında, elde edilen görüntüdeki her bir pikselin boyu 319/1024 = 0,3115 mm olarak bulunmuştur. Elmanın kusur alanlarının ve boy bilgilerinin bulunmasında bir pikselin boyu temel alınmıştır.

Kameradan elde edilen görüntünün kalitesini artırmak, lens üzerinden ayarlanan odaklanma oranı ve iris ayarları ile mümkündür. Kullanılan yazılım üzerinden de görüntüyü iyileştirme ayarları yapılabilir fakat bunlar lens üzerinden yapılan ayarlama yanlışını tolere edemez. Lens ayarlarında dikkat edilmesi gereken diğer bir husus da lenste ışığın girdiği açıklık değerinin uygun olarak seçilmesidir. Çalışmada kullanılan kamera ve lensin özellikleri EK-E'de verilmişir.

6.1.2. Aydınlatma sistemi

Makine görme sisteminde en önemli etkenlerden biri de aydınlatmadır. Aydınlatma ışık seviyesinde oluşacak değişimler, lambanın yanlış konumlandırılması, bununla birlikte yanlış lamba seçimi sistemde kullanılan yazılımın yanlış hesaplar yapmasına neden olabilir.

Çalışmada ilk olarak, döner rulolu konveyör sistemi üzerinde dönerek ilerleyen elmaların görüntülerinin elde edildiği alanda doğal aydınlatma ortadan kaldırılmıştır. Bunun nedeni ideal ışık ortamının oluşturularak, aydınlatmada meydana gelebilecek değişimlerin algoritmayı olumsuz etkilemesini önlemektir.

Bu çalışmada, iki farklı aydınlatma sistemi denenmiştir. İlk olarak aydınlatma sistemi, 30 derecelik açı ile yerleştirilen sekiz adet 40W'lık halojen lambanın konumlandırıldığı dört köşe bir kabin tarafından oluşturulmuştur. Bu aydınlatma sistemi altında elde edilen elma görüntüsünde gerçekleştirilen maskeleme algoritması sonucu şekil 6.4.b'de görülmektedir. Işıktan kaynaklanan parlamaların olmasından dolayı sınıflandırma sistemi yanılgıya düşmekte ve elmanın yerini bazen bulamamaktadır. Bu nedenle elma dışında kalan parlak bir alanı maskelemektedir. Diğer aydınlatma sistemi tasarımında ise eşit aralıklarla konumlandırılmış ve elektronik balast ile desteklenmiş dört adet Philips marka floresan lamba (TLD-18W/950) kullanılmıştır. Floresan lamba kullanılarak oluşturulan aydınlatma sistemi altında elde edilen elma görüntüsünde gerçekleştirilen maskeleme algoritması sonucu, şekil 6.4.d'de görülmektedir. Sınıflandırma sistemi, elde edilen görüntü içerisinde elmanın yerini doğru olarak bulmakta ve elmanın bulunduğu alanda maskeleme işlemini gerçekleştirmektedir.

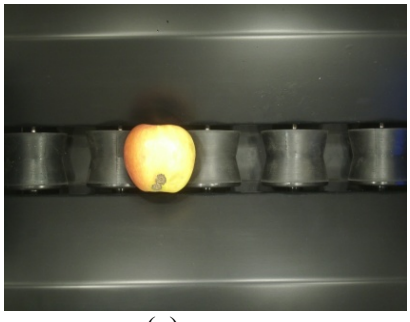

(a)

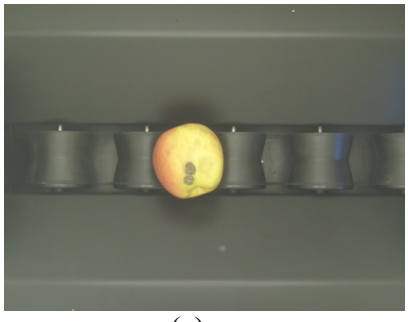

(c)



(b) (d)

Şekil 6.4. Farklı aydınlatmaların görüntü maskeleme sonuçları. a-) Halojen lamba ile aydınlatılmış görüntü b-) Halojen aydınlatma ile elde edilen maskeleme sonucu c-) Floresan lamba ile aydınlatılmış görüntü d-) Floresan aydınlatma ile elde edilen maskeleme sonucu

Aydınlatma sistemi tasarımında dikkat edilen hususlara bakıldığında; renk görüntüleme indeksi yüksek, gün ışığına yakın (renk sıcaklığı 5000K-6500 K), ışık şiddeti uygun lamba seçilmiştir. Bununla birlikte görüntülenen nesnenin tüm yüzeyine eşit ışık seviyesi gitmesi için lambalar uygun konumlandırılmıştır. Aydınlatma sisteminde, 4 adet Philips marka TL-D 90 Graphica 18W/950 floresan modeli kullanılmıştır. Bu lamba, renk sıcaklığı 5300 K (yaklaşık D_{55} standart ışık kaynağı) ve renk görüntüleme indeksi (R_a) 97% özelliklerine sahiptir. Bu lambaların 30 cm yarıçapında, 67 cm uzunluğunda içi beyaza boyanmış bir kabine uygun aralıklarla konumlandırılmasıyla aydınlatma sistemi oluşturulmuştur (Şekil 6.5).



Şekil 6.5. Aydınlatma sistemi

6.1.3. Programlanabilir Mantıksal Denetleyici (PLC)

PLC, içerisine yüklenen program sayesinde zaman, sayma, sıralı kontrol, aritmetik, veri yönlendirme, iletişim vb. kontrol fonksiyonları yapabilen ve farklı programlama dilleri yardımı ile yazılımı zenginleştirilebilen, endüstri için tasarlanmış bilgisayarlardır. PLC'lerle günümüzde karmaşık kontrol sistemlerini gerçekleştirmek mümkündür (Beyazıt, 2005).

PLC'ler genellikle endüstriyel süreç uygulamalarında ve üretimde kullanılır. PLC'nin temel avantajları kolay, esnek, güvenilir ve basit sistem yapılandırılmasının sağlanması ile birlikte bakım maliyetinin düşük olmasıdır. Bundan dolayı karmaşık sistemler PLC kontrol sistemlerine kaydırılmıştır (Aydoğmuş, 2009). Günümüzde, Allen Bradley, General Electric, GEC, Siemens, Westinghouse gibi firmalar orta maliyette, yüksek performanslı PLC'ler üretmektedirler.

Bu tezde kullanılan PLC Siemens'in üretmiş olduğu S7300 CPU 313C' modelidir. Bu modelde 24 adet sayısal giriş, 16 adet sayısal çıkış, 5 adet analog giriş ve 2 adet analog çıkış bulunmaktadır. Analog giriş 4-20mA veya 0-10V olarak kullanılabilir. Kullanılan PLC'nin çıkış ve giriş gerilimi 24V olup, transistör çıkışlıdır. PLC yazılımı için Siemens'in, Simatic Manager Step7 V5.3 programı kullanılmıştır. Program yazımına geçilmeden önce, yazılımda kullanılan PLC cihaz modeli ve haberleşmede kullanılan donanım tanıtılmıştır. Daha sonra giriş ve çıkış adreslerine dikkat edilerek programın fonksiyonları (FC) yazılmıştır.



Şekil 6.6. PLC görünüşü

Bu tez çalışmasında, PLC hem makine görme sisteminde hem de kütleye duyarlı elma sınıflandırma sisteminde kullanılmaktadır. Makine görme ile elma sınıflandırma işleminde, PLC'nin iki temel görevi vardır. İlki konveyör üzerinde sensörlerden aldığı bilgiyi yazılıma iletmek, ikincisi yazılımdan gelen elma sınıflandırma sonuçlarına göre ayırıcı birimde bulunan pnömatik pistonları, selenoid kontrollü valfler yardımı ile uygun konuma getirmektir. PLC'nin kütle duyarlı elma sınıflandırma sistemindeki görevleri Bölüm 7'de verilmiştir.

6.1.4. Sensör

Otomasyon sistemlerinin en önemli parçalarından biri algılama özellikleridir. Otomasyon sistemi, sistemde oluşacak değişimleri algılamalı ve bu değişimler sonucunda elde ettiği verilere göre karar verme işlemi gerçekleştirmelidir. Elma sınıflandırma sisteminde, iki adet cisimden yansımalı optik sensör kullanılmaktadır. Cisimden yansımalı optik sensörler, vericiden gönderilen ışının bir cisme çarpıp, geriye yansıtılması ve yansıtılan ışının alıcı tarafından alınması vasıtasıyla çalışır. Algılanan cismin rengi ve parlaklığı, algılama mesafesini etkilemektedir. Bu sensörlerden ilki konveyör sisteminde iki rulo arasında elma olup olmadığını algılar (Şekil 6.7.a). Diğeri konveyör sistemini oluşturan döner ruloların bağlı olduğu yirmi beş (25) adet milin algılanması işlemini gerçekleştirir (Şekil 6.7.b).



(a) (b)

Şekil 6.7. Optik sensör bağlantısı

6.1.5. Giriş/Çıkış kartı

Bu çalışmada veri toplama kartının temel görevi, yazılım ortamında geliştirilen algoritmalar ile PLC arasındaki gerçek zamanlı veri giriş/çıkışını sağlamaktır. Bu işlem, National Instruments firmasının ürettiği ve yazılım tarafından desteklenen NI USB-6009 veri toplama kartı ile yapılmıştır. Yazılımın donanımı tanıyabilmesi için ilk önce veri toplama kartının sürücüsü kurulur (NI-DAQmix) ve 'daqregister ('nidaq')' komutuyla yazılıma tanıtılır.

NI USB-6009 veri toplama kartının çalışma prensibi incelendiğinde, sayısal girişlerin ve çıkışların çalışma geriliminin 5V doğru akım olduğu görülmektedir. Veri toplama kartı sayısal giriş ve çıkış bağlantı örnekleri şekil 6.8'te verilmiştir.

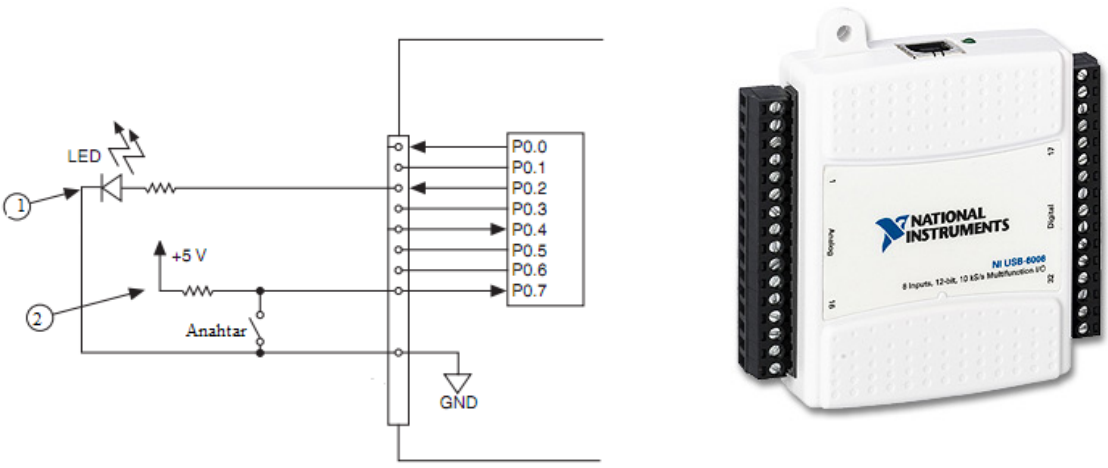

Şekil 6.8. Giriş/Çıkış kartı bağlantı şekli

Veri toplama kartında sayısal giriş olarak ayarlanan kanallar (P0.7) normalde bir (5V DA) çıkışı verir. Şekil 6.8'de örneği verilen P0.7 kanalı, anahtar kapatılarak toprak (GND) ile temas ettirilirse, giriş sıfıra düşer. Bu da dışarıdan veri toplama kartına giriş sinyali geldiğini gösterir. Veri toplama kartında sayısal çıkış kanalı olarak ayarlanan P0.2 kanalı normalde sıfır çıkışı verir. Algoritma çıkış sinyali ürettiğinde, P0.2 kanalı 5V'a yükselir.

Uygulamada kullanılan sensörlerin sinyal çıkışları ve PLC'nin sayısal giriş/çıkış sinyalleri 24V DA kullanmaktadır. Bundan dolayı 5V DA sinyal giriş/çıkışına sahip NI USB 6009 veri toplama kartı ile bu elemanların doğrudan kullanımı gerçekleştirilemez. Bu nedenle veri toplama kartının giriş kanalları için 24V DA ile 5V DA'ın tetiklenmesi gerekir. Bununla birlikte yine aynı şekilde veri toplama kartının çıkış kanalları için ise 5V DA ile 24V DA'ın tetiklenmesi gerekir. Bu işlemi gerçekleştirmek için tasarlanan gerilim dönüştürücü devre, şekil 6.9'da görülmektedir.

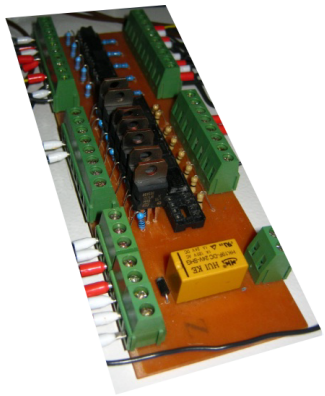

Şekil 6.9. Gerilim dönüştürücü devre

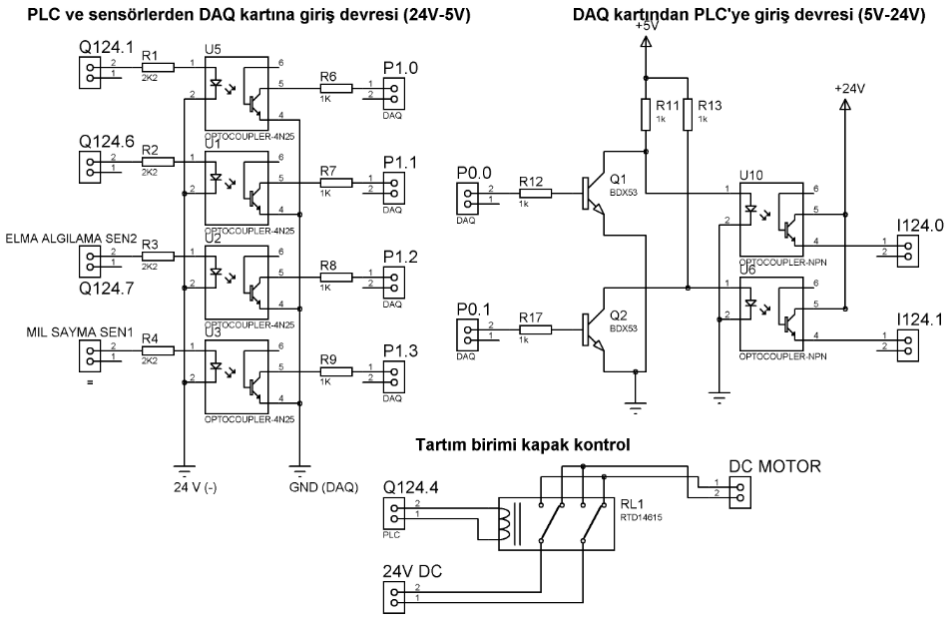

Şekil 6.10. Gerilim dönüştürücü devre tasarımı ve bağlantı adresleri

6.1.6. Mekanik sistem tasarımı

Sistem mekanik olarak üç kısımdan oluşmaktadır. Bunlar giriş birimi, döner rulolu konveyör sistemi ve ayırıcı birimdir. Aşağıda bu kısımlara yer verilmiştir.

6.1.6.1.Giriş birimi

Bu kısımda döner rulolu konveyörün hareketinden yararlanılmıştır. Giriş biriminin içerisine konulan elmalar, ruloların hareket etmesiyle sadece bir elmanın geçebileceği ağızdan, teker teker sıralanarak, konveyörde yol alırlar. Bu birim, 1 mm paslanmaz çelikten yapılmış birimin alt kısmı konveyör bandına oturacak şekilde tasarlanmıştır (Şekil 6.11).

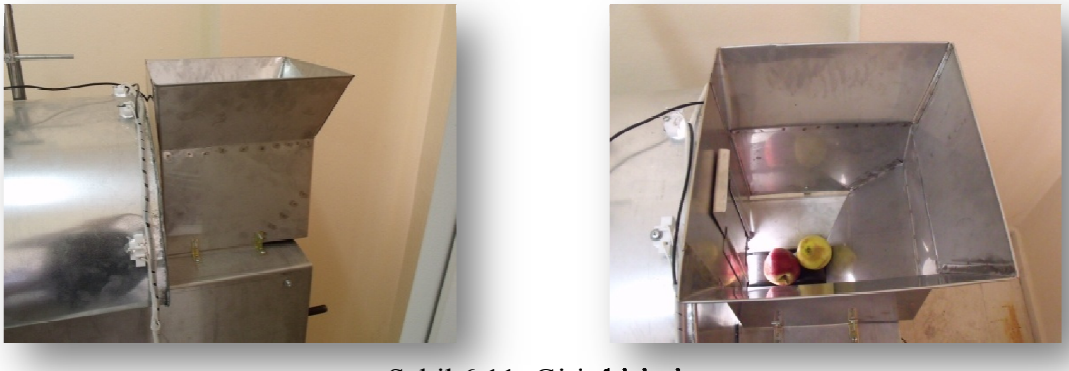

Şekil 6.11. Giriş birimi

6.1.6.2. Döner rulolu konveyör sistem

Kameranın elmanın tüm yüzeyine yakın bir alanını görebilmesi için elmaların kameranın görüş alanından dönerek geçmesini sağlayan, döner rulolu bir konveyör sistemi tasarlanmıştır. Bu işlem için yurtdışından ülkemize getirilen elma sınıflandırma

makineleri incelenmiş ve sonrasında onların yaptığı işi en uygun maliyetle gerçekleştirmenin yolları aranmıştır. İlk etapta konveyör sisteminde bulunan ruloların çelikten 90 mm çapında yapılması düşünülmüş, numune olarak yapılan ruloların çok ağır ve işçilikli olduğu görülmüştür. Bu rulolar aynı zamanda oval olmadıklarından üzerinde dönerek ilerleyecek elmanın ruloya temas eden yüzey alanın az olmasına neden olmuşlardır. Bu da hem elmanın kamera altında oynamasına neden olmuş, hem de elmanın dönerek ilerlemesinde sorun teşkil etmiştir. Bununla birlikte elmaların çabuk bozulabilir bir yapıda oldukları düşünüldüğünde, elma ile temas eden kısımlarının kauçuk veya benzeri yumuşak bir maddeyle kaplanmaları gereksinimleri ortaya çıkmıştır.

Bunun sonucunda rulolar kauçuktan yapılmıştır. Oval bir yapıda olan kauçuk rulolar 80 mm çapında 220 mm uzunluğunda paslanmaz çelik bir milin tam ortasında olacak şekilde, mile iki adet segman atılarak konumlandırılmışlardır. Miller zincire iki taraftan yerleştirilmiş, yerinden oynamasın diye de segman atılmıştır. Bu şekilde kauçuk rulolar, altında bulunan zemine temas ettiğinde, kendi ekseni etrafında dönme hareketini yapacak ve üzerlerinde taşıdıkları elma da dönme hareketini tekrarlayacaktır.



Şekil 6.12. Kauçuk oval rulo ve bağlantısı

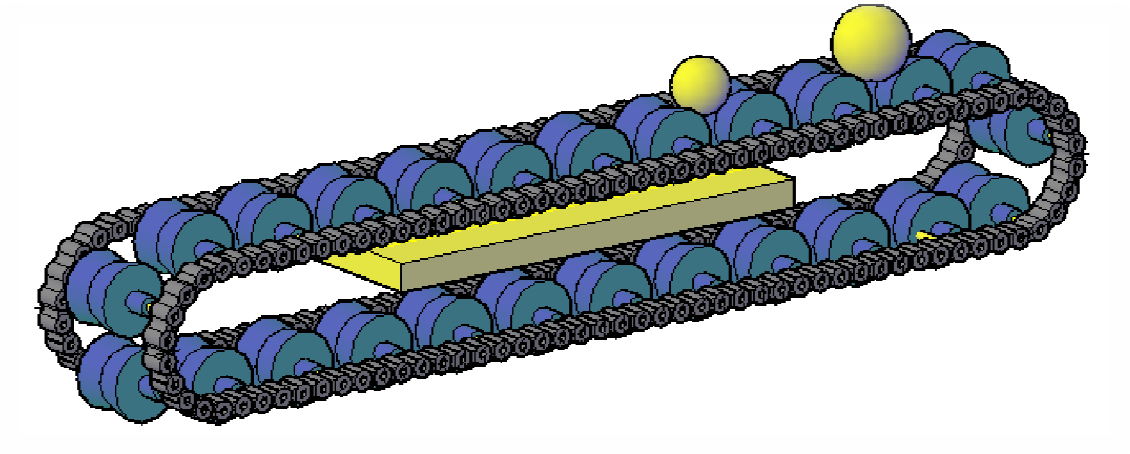

Şekil 6.13. Konveyör perspektif görünüş çizimi

Döner rulolu konveyör sisteminin yan kısımları 2 mm paslanmaz çelikten, CNC makinesinde kesim ve bükme işlemlerine maruz bırakılarak yapılmıştır (Şekil 6.14). Paslanmaz çelik malzemesinin seçilmesinin nedeni, elmanın teması sonucunda insan tüketimine zararlı oluşumu engelleme çabasıdır.

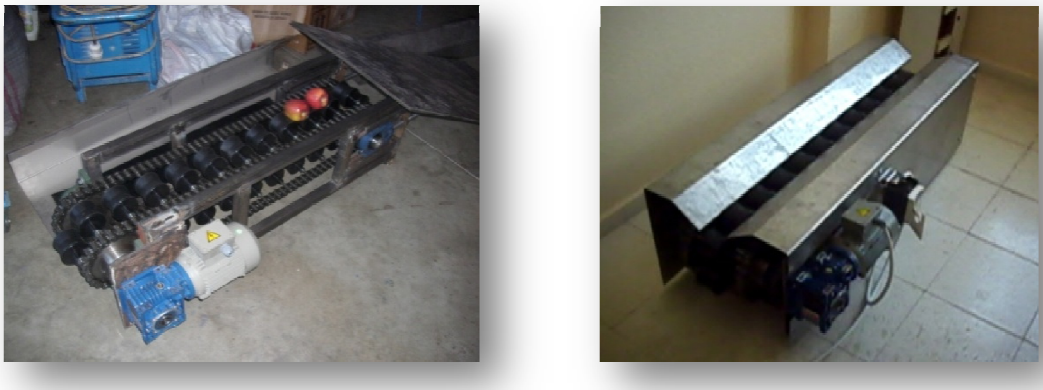

Şekil 6.14. Konveyör görünüş

Elde edilen döner rulolu konveyör sisteminde dönme hareketi, 3 fazlı asenkron motor ve motora monte edilen redüktör ile gerçekleştirilmiştir.

6.1.6.2.1. Konveyör hız kontrolü

Döner rulolu konveyör sisteminin dönüş hızı, seçilen motorun devir hızı ve redüktör ile doğrudan ilgilidir. Redüktör, motordan elde edilen yüksek dönüş hızını, konveyör sistemi için gerekli olan dönüş hızına ve torkuna dönüştürmek için kullanılan kapalı dişli sistemidir.

Döner rulolu konveyör sisteminin 0,5 m/sn dönüş hızı ile çevrilmesi için gerekli redüktör devir sayısı;

$$n_2 = \frac{V.6.10^4}{dt.\pi} = \frac{0,5.6.10^4}{200.3,14} = 47,7 d/dk \quad (6.1)$$

olarak bulunur. Buna göre seçilen redüktörün devir sayısı 48d/dk'dır.

V = Konveyör hızı (m/sn)

dt = Dişli çapı

n_2 = Redüktör devir sayısı (d/dk)

Motorun devir hızının ve ona bağlı konveyör hızının değişimi motor frekansının değiştirilmesiyle mümkündür. Bunun için motor, frekans invertörü yardımı ile sürülür. Bu durumda invertör ile motorun frekansı düşürüldüğünde, motorun hızı da doğru orantılı olarak düşecektir.

$$n_s = \frac{60.f}{p} \quad (6.2)$$

n_s = Motor devir sayısı (d/dk), f = Frekans (Hz), p = Motor kutup sayısı

İnvertörün frekans değişimi, üzerinden elle yapılabildiği gibi gerekli bağlantıların yapılması ile SCADA sisteminden de gerçekleştirilmektedir. Frekans invertörünün bir diğer faydası, 3 fazlı asenkron motoru 1 faz ile sürebilmeye imkân tanımasıdır. Bu da konveyör sistemin üç faz olmayan alanlarda da kullanılmasını sağlamıştır.

6.1.6.3. Ayırıcı birim

Elmaların yüzey kalitesi, renk/boy ve kütle sınıflarına ayrılması işleminin son basamağı ayırıcı kısımdır. Döner rulolu konveyör sisteminden gelen elmalar, doğrudan ya da tartım işleminden geçirilmesinden sonra ayırıcı birime ulaşır. Bu işlemle paralel olarak, yazılım ve PLC algoritmaları tarafından gönderilen sonuçlara göre elmanın hangi sınıfa mensup olduğu bilgisi ayırıcı birime ulaşır. Sonrasında PLC'den gelen sinyallerin valfleri tetiklemesiyle birlikte, pnömatik pistonlara bağlı paletler, elmaları yüzey kalitesi, renk-boy ve kütlelerine göre 4 farklı yöne yönlendirerek, sınıflandırır. Hızlı bir elma sınıflandırma işleminin doğruluğu, gerçekleştirilen bu paralel işlemin zamanlama uyumuna bağlıdır.

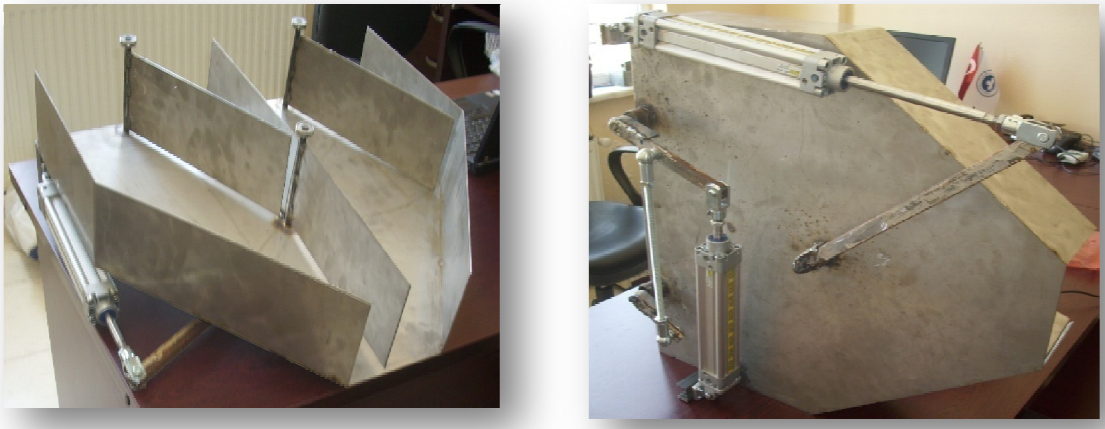

Şekil 6.15. Ayırıcı birim

6.1.7. Makine görmesi ile elma sınıflandırma ara yüz yazılımı

Ara yüz yazılımı, MATLAB GUI yardımı ile yapılmıştır. Yazılım içerisinde iki farklı pencere vardır. İlki, elmaların renk ve boyuna göre sınıflandırılma işleminin yapıldığı penceredir. Burada makine görme sisteminin bünyesinde gerçek zamanlı olarak elde edilen elma görüntüleri üzerinde, elmalara ait renk ve boy bilgisi izlenebilmektedir.

Sınıflandırılan elmaların hangi sınıfa atamalarının yapıldığı elma istatistikleri kısmından grafiksel olarak görüntülenebilir. Aynı zamanda, yazılım üzerinden elma boy eşik değerlerine buradan müdahale edilerek, sınıflandırma dereceleri değiştirilebilir. Elmaları renk ve boya göre sınıflandırma yazılımında, "durdur" butonuna basıldığı anda, kullanıcı tercihli olarak, sınıflandırılan son on (10) elmanın işlem görmemiş görüntüsü, elma yüzeyinin kırmızı ve sarı alan yoğunluğu ve elmanın maskelenmiş görüntüsü ekrana getirilmektedir (Şekil 6.16).

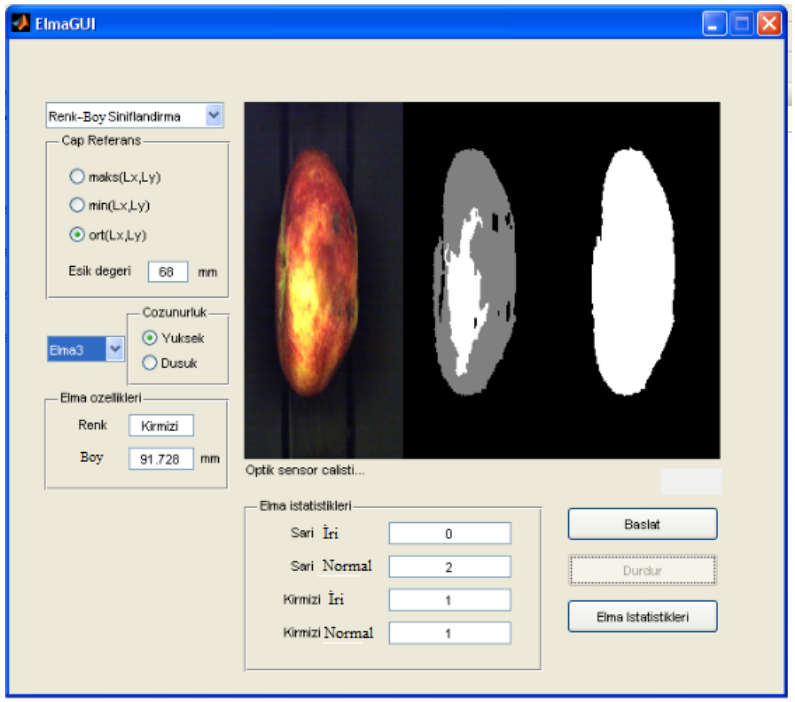

Şekil 6.16. Elma renk/boy'a göre sınıflandırma GUI

İkinci pencere, elmaların yüzey kalitesine göre sınıflandırılmasının yapıldığı kısımdır. Bu pencerede gerçek zamanlı olarak elde edilen elma görüntülerinde, elma yüzeyinde bulunan kusurlar, elmanın sap ve çiçek çukurundan ayrılarak görüntülenmekte ve toplam kusur alanı mm^2 cinsinden ekrana yazılmaktadır. Kullanıcı tarafından ara yüz üzerinden girilen kusur alanı eşik değerlerine göre elma uygun sınıfa aktarılır. Elma istatistikleri bu pencerede de olup, dört farklı sınıfa atanan elma sayıları görülmektedir. Görüntülenen elmanın yüzey kalitesine göre sınıflandırma işlemi bittiği anda ekrana, elmanın işlem görmemiş iki yüzeyinin görüntüsü ve örüntü tanıma

uygulaması sonucunda kusur olarak tanımlanan örüntüler, maskelenmiş elma görüntüsü içerisinde açık gri tonda görüntülenir (Şekil 6.17).

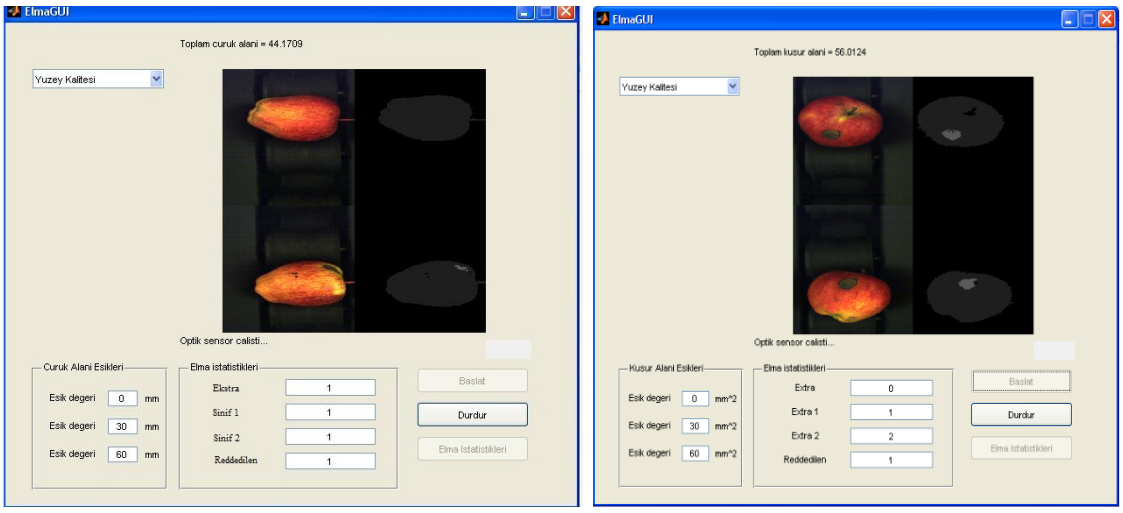

Şekil 6.17. Elma yüzey kalitesine göre sınıflandırma GUI

6.2. Elmaların Renk Ve Boyunun Gerçek Zamanlı Çoklu-Renk Uzayı Kullanılarak Belirlenmesi

6.2.1. Çoklu-renk uzayı yardımı ile arka plan ayırma

Görüntü yakalama aracı ile elde edilen RGB görüntü içerisinden elmanın bulunduğu alanı arka plandan ayırma işlemi, eşikleme yöntemi ile başarılır. RGB görüntü, renk uzayı dönüşüm yöntemleri ile HSV, CIE XYZ ve CIE L*a*b* renk uzaylarına dönüştürülür. Bunun sonucunda arka plan ayırma işlemi diğer bir ifade ile elmanın maskelenmesi HSV renk uzayının "*S*" bileşeni, CIE XYZ renk uzayının "*Y*" bileşeni ve CIE L*a*b* renk uzayının "*a*" bileşeninin eşikleme sonuçlarının bir maskede toplanması ile elde edilir.

$$f(x,y) = \begin{cases} 1 & Eğer \quad z(x,y) > T \\ 0 & Değilse \end{cases}$$

f(x, y) arka plandan ayırma işlemi sonucunda elde edilen resim, *z(x, y)* orijinal resim ve *T* eşik değeridir.

RGB görüntü MATLAB'ın görüntü işleme araç kutusunun 'rgb2hsv' komutu ile HSV renk uzayına dönüştürülür. RGB görüntünün cihaz bağımsız CIE XYZ ve CIE L*a*b* renk uzaylarına dönüştürülmesi yazılımın hazır fonksiyonları yardımı ile uygulanabilir.

```
rgb = imread('elma.png');    Görüntü Matlab çalıçma alanı içerisine
                             yüklenir.
C = makecform('srgb2xyz');   RGB'den XYZ' renk uzayına dönüştürme yapısı
xyz = applycform(rgb,C);     RGB renk uzayından XYZ renk uzayına dönüşüm
C2 = makecform('srgb2lab'); RGB'den L*a*b* renk uzayına dönüştürme yapısı
                             Oluşturulur.
lab = applycform(rgb,C2);    RGB renk uzayından L*a*b renk uzayına dönüşüm
```

Fakat yazılımın hazır fonksiyonlarının RGB görüntünün cihaz bağımsız renk uzaylarına dönüşümü gerçekleştirme zamanı, gerçek zamanlı bir sistem için fazla olduğu yapılan testlerde görülmüştür. Bu nedenle cihaz bağımsız renk uzaylarının dönüşümlerinde, yazılımın hazır fonksiyonları kullanılmamıştır. Renk uzayları arasındaki dönüşüm fonksiyonlarının algoritmaları sistemin aydınlatma koşulları göz önüne alınarak yazılmıştır.

6.2.1.1. RGB renk uzayından CIE XYZ renk uzayına dönüşüm

RGB renk uzayından CIE XYZ renk uzayına dönüşüm, sistemde kullanılan lambanın aydınlatıcı karakteristiği ile değişmektedir. Bu nedenden dolayı, sistemde kullanılan floresan lamba renk sıcaklığı 5300 K (yaklaşık D55) olduğu göz önüne alınarak, fonksiyon yazılmış ve dönüşümler buna göre yapılmıştır.

RGB renk uzayından CIE XYZ renk uzayına dönüşüm 3x3 matris yardımı ile gerçekleştirilir. İlk olarak doğrusal olmayan RGB değerleri doğrusal ve nominal

değerlere dönüştürülür. HP ve Microsoft şirketleri işbirliği yaparak monitörlerde, yazıcılarda ve internette kullanılmak üzere, RGB renk uzayı standardı geliştirmişlerdir. Bu standart renk uzayı, ITU-R BT.709 ana unsurlarını kullanır. ITU-R BT.709 standardı, video kamera kullanarak monitör içerisine gönderilen görüntünün tristimulus değerlerini dönüştürmek için matematiksel bir metot sağlar (Stokes v.d., 1996).

$$\begin{aligned} R' &= R/255 \\ G' &= G/255 \\ B' &= B/255 \end{aligned} \tag{6.3}$$

Eğer $R', G', B' \le 0,04045$ (IEC 61966-2-1 standardına göre yuvarlatılmış değer)

$$Rs = R'/12,92; \quad Gs = G'/12,92; \quad Bs = B'/12,92 \tag{6.4}$$

$$\begin{aligned} &Değilse \quad R', G', B' > 0,04045 \\ Rs &= \left[\frac{R'+0,055}{1,055}\right]^{2.4} \\ Gs &= \left[\frac{G'+0,055}{1,055}\right]^{2.4} \\ Bs &= \left[\frac{B'+0,055}{1,055}\right]^{2.4} \end{aligned} \tag{6.5}$$

CIE XYZ renk uzayının 3x3 matris yardımı ile standart RGB değerlerinden elde edilmesi;

$$\begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = [M] \begin{bmatrix} Rs \\ Gs \\ Bs \end{bmatrix} \tag{6.6}$$

3x3 boyutlarında M matrisinin hesaplanması;

$$[M] = \begin{bmatrix} SrXr & SgXg & SbXb \\ SrYr & SgYg & SbYb \\ SrZr & SgZg & SbZb \end{bmatrix} \tag{6.7}$$

$$X_r = \frac{x_r}{y_r}\,, \qquad Y_r = 1\,, \qquad Z_r = (1 - x_r - y_r)/y_r\,, \quad X_g = x_g/y_g \tag{6.8}$$

$$Y_g = 1,\ Z_g = (1 - x_g - y_g)/y_g, \quad X_b = x_b/y_b, \tag{6.9}$$
$$Y_b = 1\,,\ Z_b = (1 - x_b - y_b)/y_b$$

$$\begin{bmatrix} S_r \\ S_g \\ S_b \end{bmatrix} = \begin{bmatrix} Xr & Xg & Xb \\ Yr & Yg & Yb \\ Zr & Zg & Zb \end{bmatrix}^{-1} \begin{bmatrix} X_W \\ Y_W \\ Z_W \end{bmatrix} \tag{6.10}$$

RGB renk uzayının renksellik koordinatları (X_r, Y_r), (X_g, Y_g) and (X_b, Y_b), referans beyaz ağırlıkları X_W, Y_W, Z_W'dır.

Ortalama gün ışığı (D65) referans beyaz'a göre RGB renk uzayından CIE XYZ_{D65} renk uzayına dönüşüm matrisi "M" aşağıda verilmiştir (Stokes v.d., 1996);

$$\begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = \begin{bmatrix} 0{,}4124564 & 0{,}3575761 & 0{,}1804375 \\ 0{,}2126729 & 0{,}7151522 & 0{,}0721750 \\ 0{,}0193339 & 0{,}1191920 & 0{,}9503041 \end{bmatrix} \begin{bmatrix} R \\ G \\ B \end{bmatrix} \tag{6.11}$$

6.2.1.2. XYZ_{D65} (D65 kaynak aydınlatma)'den XYZ_{D55} (D55 hedef aydınlatma) dönüşüm

Makine görme sisteminde, görüntülerin alındığı ortam aydınlatmasında Philips marka TL-D 90 Graphica 18W/950 floresan modeli kullanılmıştır. Bu lamba, renk sıcaklığı 5300 K olup yaklaşık D55 standart ışık kaynağı olarak tanımlanabilir. Oysa hesaplama 6.11'de elde edilen dönüşüm matrisi D65 standart ışık kaynağına göredir. Orijinal resmin XYZ koordinatlarını belirlemek için kullanılan aydınlatma, hedef RGB uzayın aydınlatmasından farklı olduğu durumlarda, kromatik adaptasyon dönüşümleri kullanılır. Kromatik adaptasyon bir nesnenin görünüşünü korumak ve aydınlatmanın rengini azaltmak için insan görme sisteminin yeteneğidir. Kromatik adaptasyon farklı

tipli aydınlatmalar altında incelenen bir beyaz nesne tarafından gözlenebilir. Literatürde birkaç kromatik adaptasyon tekniği vardır. Bunlardan en temeli Von Kries modelidir (Süsstrunk, 2001). Von Kries dönüşümü kullanılarak, D65 referans beyaza göre elde edilen XYZ_{D65} renk uzayını, aydınlatma sistemimizde kullanılan D55 referans beyaza göre CIE XYZ_{D55} renk uzayına dönüştürülür.

$$\begin{bmatrix} X_D \\ Y_D \\ Z_D \end{bmatrix} = [M] \begin{bmatrix} X_S \\ Y_S \\ Z_S \end{bmatrix} \tag{6.12}$$

$$[M] = [M_A]^{-1} \begin{bmatrix} \rho_D/\rho_S & 0 & 0 \\ 0 & \gamma_D/\gamma_S & 0 \\ 0 & 0 & \beta_D/\beta_S \end{bmatrix} [M_A] \tag{6.13}$$

$$\begin{bmatrix} \rho_S \\ \gamma_S \\ \beta_S \end{bmatrix} = [M] \begin{bmatrix} X_{WS} \\ Y_{WS} \\ Z_{WS} \end{bmatrix}, \qquad \begin{bmatrix} \rho_D \\ \gamma_D \\ \beta_D \end{bmatrix} = [M] \begin{bmatrix} X_{WD} \\ Y_{WD} \\ Z_{WD} \end{bmatrix} \tag{6.14}$$

Kaynak referans (D65) aydınlatma tristimulus değerleri (X_{WS}, Y_{WS}, Z_{WS}), hedef referans (D55) aydınlatma tristimulus değerleri (X_{WD}, Y_{WD}, Z_{WD}) ve koni cevap alanı, (ρ, γ, β). D65 (X_{WS}, Y_{WS}, Z_{WS} = 0.9505, 1.0000, 1.0890) ve D55 (X_{WD}, Y_{WD}, Z_{WD} = 0.95682, 1.0000, 0.92149) 2° standart gözlemciye göre hesaplanmıştır. $[M_A]$ ve $[M_A]^{-1}$ matrisleri Von Kries modeli tarafından tanımlanmıştır (http://brucelindbloom.com, Erişim tarihi: 10.07.2011).

Çizelge 6.1. İnsan gözündeki koni hücreleri dalga boyları

Koni Tipi	İSİM	ORAN
S	β	400-500 nm
M	γ	450-630 nm
L	ρ	500-700 nm

Çizelge 6.2. Aydınlatmaya göre tristimulus değerleri (http://brucelindbloom.com, Erişim tarihi: 10.07.2011)

Aydınlatma	X	Y	Z
A	1.09850	1.00000	0.35585
B	0.99072	1.00000	0.85223
C	098074	1.00000	1.18232
D50	0.96422	1.00000	0.82521
D55	0.95682	1.00000	0.92149
D65	0.95047	1.00000	1.08883
D75	0.94972	1.00000	1.22638
E	1.00000	1.00000	1.00000
F2	0.99186	1.00000	0.67393
F7	0.95041	1.00000	1.08747
F11	1.00962	1.00000	0.64350

XYZ_{D65}'den XYZ_{D55} Von Kries modeli kullanılarak elde edilen dönüşüm matrisi;

$$[M] = \begin{bmatrix} 1{,}0096 & 0{,}0331 & -0{,}0330 \\ 0{,}0036 & 0{,}9973 & -0{,}0007 \\ 0 & 0 & 0{,}8463 \end{bmatrix} \tag{6.15}$$

Von Kries dönüşüm matrisi yerine konulduğunda, D55'e göre XYZ değerleri elde edilir. Bu değerlerden renk uzayı dönüşüm fonksiyonları yardımı ile diğer cihaz bağımsız renk uzaylarına geçiş sağlanır.

Şekil 6.18.a'da verilen RGB elma görüntüsünün CIE L*a*b* renk uzayına dönüştürülmesi ve bu renk uzayının "*a*" bileşeninin görüntülenmesi iki farklı yöntemle yapılmış ve sonuçları karşılaştırılmıştır. İlk olarak yazılımın hazır fonksiyonu yardımı ile gerçekleştirilmiş ve elde edilen görüntü şekil 6.18.c'de verilmiştir. Aynı işlem yazılımın hazır fonksiyonu kullanılmadan, RGB görüntü normalize edildikten sonra D55 aydınlatma koşulları göz önüne alınarak, yukarıda belirtilen dönüşüm matrisleri ile ilk önce XYZ renk uzayına dönüştürülmüş ve buradan da CIE L*a*b* renk uzayının "*a*" bileşeni elde edilmiştir. Bu yazılan algoritma sonucunda elde edilen görüntü şekil 6.18.b'de verilmiştir.

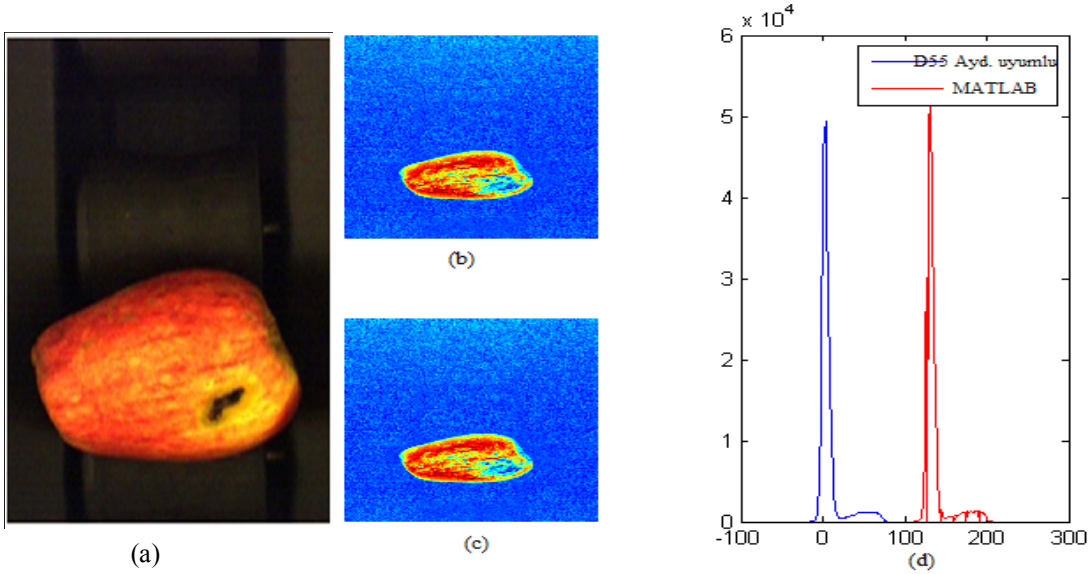

Şekil 6.18. D55 aydınlatma koşulları ve Matlab hazır fonksiyonunun, CIE L*a*b* renk uzayı "a" bileşeni sonuçlarının karşılaştırılması; a-) RGB görüntü b-)D55 uyumlu CIE L*a*b*/a bileşenin sonucu c-)Matlab CIE L*a*b*/a bileşeni sonucu d-)Histogram grafiği

İki farklı yöntemle elde edilen görüntülerin (Şekil 6.18.b ve Şekil 6.18.c) histogramları karşılaştırıldığında, histogramların band konumları (-10)-90 ve 110-210 arasında değişim göstersede yoğunluk seviyesi band aralıkları her ikisininde yaklaşık 100'dür. Bununla birlikte piksellerin yığılma eğrisi arasında benzerlik görülmektedir (Şekil 6.18.d). Bu nedenle iki yöntem de renk uzayı dönüşümünde benzer sonuçlar vermiştir. Fakat görüntünün çözünürlüğü düşürüldükten sonra, iki algoritmanın yüz (100) iterasyonda işlem zamanı karşılaştırıldığında, yazılımın hazır fonksiyonu kullanılarak, RGB renk uzayından CIE L*a*b* renk uzayına dönüşüm işlemi ortalama 34,45 ms zaman alırken, D55 aydınlatma koşulları göz önüne alınarak gerçekleştirilen algoritma ile bu dönüşüm ortalama 13,62 ms zaman almıştır (Şekil 6.19).

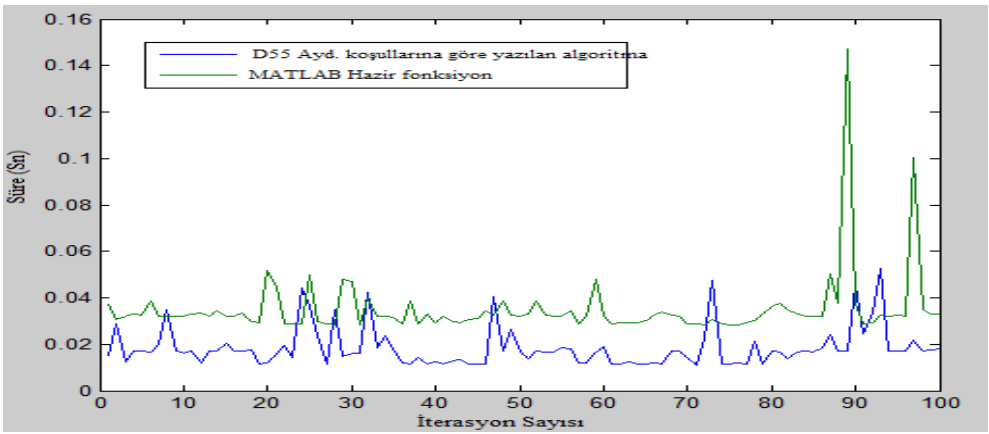

Şekil 6.19. D55 ayd. uyumlu yazılım ile Matlab hazır fonksiyon zaman karşılaştırması

6.2.2. Elmaların renk ve boyunun belirlenmesi

Kamera tarafından elde edilen görüntüde, elmanın bulunduğu alanının arka plandan ayrılması ile elde edilen maskenin renginin ve boyunun belirlenmesiyle, elmanın renk ve boy bilgisi elde edilmiştir. Elmanın boyu maskelenen alan içerisinde, *x* (Lx) ve *y* (Ly) eksenlerinde maskenin kapladığı piksel sayısına göre hesaplanmıştır.

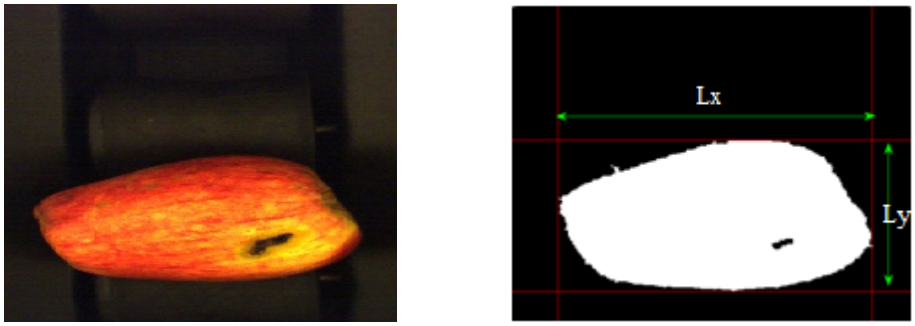

Şekil 6.20. Sol tarafta orijinal görüntü, sağ tarafta maskelenen elma görüntüsü

Elmanın rengi, elde edilen maske içerisinde sarı ve kırmızı renk piksellerinin yoğunluğuna ve dağılımına göre belirlenir. Görüntünün, üç farklı renk uzayında farklı bileşenlerinin histogramı incelendiğinde, görüntüde hangi piksellerin yoğun olduğu görülmektedir (Şekil 6.21.b,e,h). Histogram görüntüdeki piksellerin kordinatları hakkında bilgi vermez. Ancak histogramda, piksellerin yoğunluk eğrisi görüntülerdeki bölgelerin ayrılmasında kullanılan eşik değerlerinin seçilmesinde yardımcı olur.

Maske içersinde sarı ve kırmızı bölgelerin piksel miktarının belirlenmesi, iki farklı renk uzayının birer bileşeninin eşiklemesi ile gerçekleştirilir. CIE XYZ renk uzayının "*Y*" bileşeninin eşiklemesi (eşikleme değeri 0,5) elma görüntüsündeki sarı alanları belirginleştirerek göstermektedir. CIE L*a*b* renk uzayının "*a*" bileşeninin eşiklemesi (eşikleme değeri 15) ise elma görüntüsündeki kırmızı alanları belirginleştirmektedir. Eşikleme sonucunda elde edilen kırmızı ve sarı bölgelerin elma yüzeyinde kapladıkları alana göre, elmanın rengi ve buna bağlı olarak türü belirlenmiştir.

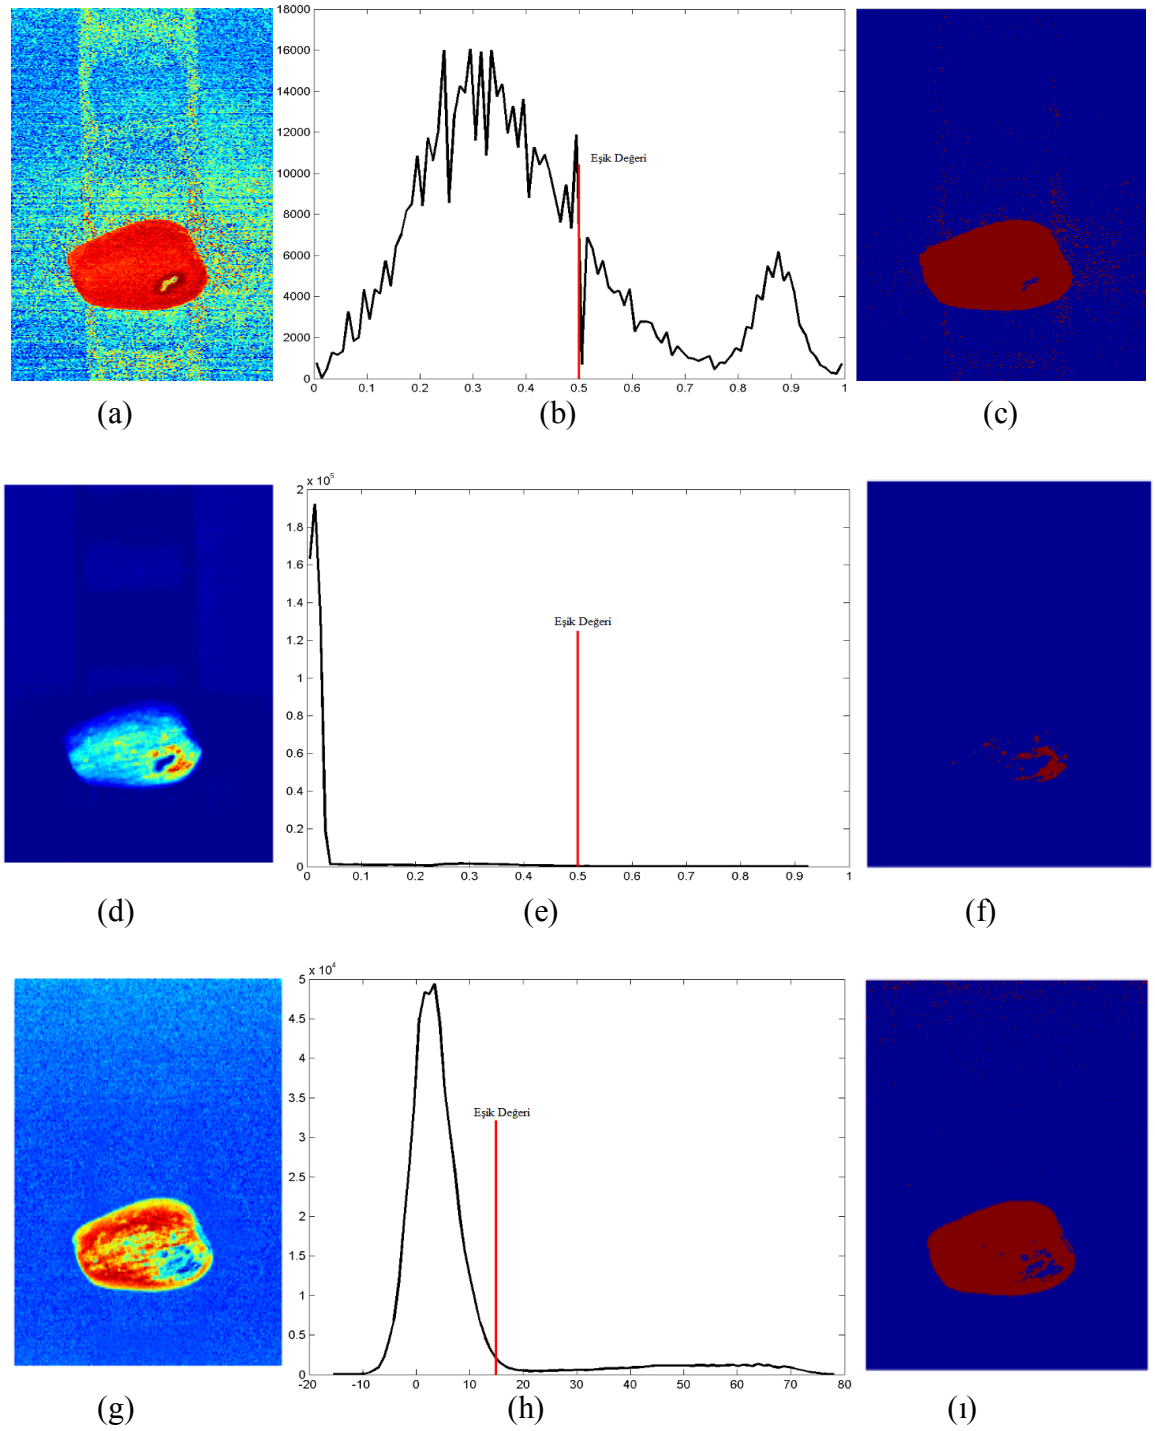

Şekil 6.21. Elma renk/boy bulmada kullanılan renk uzayları bileşenleri ve eşikleme sonuçları; a-) HSV renk uzayı "S" bileşeni b-) HSV 'nin "S" bileşeni histogramı c-) HSV 'nin "S" bileşeni eşikleme sonucu d-) CIE XYZ renk uzayı "Y" bileşeni e-) CIE XYZ renk uzayı "Y" bileşeni histogramı f-) CIE XYZ renk uzayı "Y" bileşeni eşikleme sonucu g-) CIE L*a*b* renk uzayı "a" bileşeni h-) CIE L*a*b* renk uzayı a bileşeni histogramı ı-) CIE L*a*b* renk uzayı "a" bileşeni eşikleme sonucu

Golden türü elmaların yüzeyinde kırmızı alan bulunmamaktadır. Bu bilgiden yararlanılarak, elde edilen elmanın maskelenmiş görüntüsünde, belirlenen sınır değerinden yüksek kırmızı piksellerin oluşturduğu alan bulunursa, elmanın rengine kırmızı denilmiştir. Diğer durumda ise elma sarı olarak etiketlenmiştir.

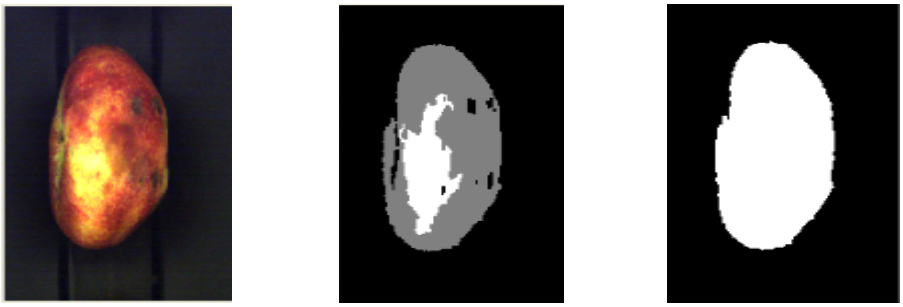

(a) (b) (c)

Şekil 6.22. Starking elma renk analizi sonuçları; a-) RGB görüntü b-) Elma yüzey renkleri c-)Maskelenmiş elma görüntüsü

6.3. Yüzey Kalitesine Göre Elmaların Sınıflandırılması

Elmaların kalite sınıflarına ayrılması Türk Standartlarına (TS 100) göre belirlenmiştir. Türk Standartları Enstitüsü'nün Ziraat İhtisas Grubu'nca TS 100 (1983)'ün revizyonu olarak hazırlanmış ve TSE Teknik Kurulu'nun 9 Ocak 2007 tarihli toplantısında kabul edilerek yayınlanmıştır. Buna göre elmalar kalitelerine göre Ekstra, Sınıf I, Sınıf II olmak üzere üç sınıfa ayrılır. Avrupa'da benzer bir sınıflandırma mevcuttur. Leemans ve arkadaşları da Avrupa Standartlarına göre elmaları ekstra, 1, 2 ve reddedilen olarak dört sınıfa ayırmışlardır (Leemans v.d., 2002).

Elmanın kalite sınıflandırılmasında yüzey kusurları öne çıkarılmıştır. Bu nedenle, bu çalışmada starking elmaların yüzeylerinde bulunan kusurların kapladıkları alana göre Ekstra, Sınıf I, Sınıf II ve Reddedilen olmak üzere elmaların dört gruba ayrılmasını öngören yüzey kalite sınıflandırılması yapılmıştır.

6.3.1. Görüntü yakalama

Elmaların kalitesine göre sınıflandırma işleminin başarısı elmanın yüzeyinin tamamına yakın bir alanının görüntülenebilmesine bağlıdır. Bu da döner rulolu konveyör üzerinde dönerek ilerleyen elmaların, kamera altından geçme anında birden fazla görüntüsünün elde edilmesi ile sağlanır. Bu çalışmada, elmaların yüzey kalitesine göre sınıflandırılması işleminde bir elmanın iki farklı görüntüsü üzerinde işlem yapılmaktadır. Bunun nedeni elmanın küresel bir cisme yakın olmasından dolayı tek bir görüntü yakalandığında, sadece elmanın bir yarısının görüntülenebilmesidir. Elmanın tüm yüzeyine yakın bir alanını görebilmek için en az iki fotoğraf karesi gerekmektedir. Yakalanacak ikinci görüntünün zamanının iyi ayarlanması gerekir. Yapılan çalışmalara bakıldığında, elde edilen görüntülerde elmanın ortalama çapı ve konveyör dönme hızı göz önüne alınmıştır (Leemans, 2004). Fakat çalışmamızda ortalama çap yerine, işlenecek her elma için dönme eksenine dik olan eksen boyu hesaplanmış ve buna göre ikinci fotoğraf belirlenmiştir. Elma kameranın görüş açısına girdiği anda, zaman aralıkları eşit yirmi beş fotoğraf karesi çekilmiştir. Elde edilen yirmi beş fotoğraf karesinin ilkinde elmanın dönme ekseni boyu elde edilip, ikinci fotoğraf karesi, elmanın dönme ekseni boyu ve konveyörün dönüş hızına göre geri kalan yirmidört fotoğraf karesinden seçilmiştir.

$$T_r = \frac{L_r}{\pi . D_r} \tag{6.16}$$

$$T_e = T_r . \frac{D_r}{D_e} \tag{6.17}$$

$$L_e = \frac{1}{2} . \frac{L_r}{T_e} \tag{6.18}$$

T_e = İki rulo arasındaki elma tur sayısı

T_r = İki rulo arasındaki rulo tur sayısı

D_e = Elma çap

D_r = Rulo çap

L_r = İki rulo arası uzunluğu (piksel)

L_e = Elmanın yarım tur atması için gereken mesafe

İkinci fotoğrafı bulmak için art arda çekilen yirmi beş (25) fotoğrafın düşeye izdüşümü alınarak, her bir karede elmanın görüş alanının üst sınırına göre ne kadar ilerlemiş olduğu bulunur. Yarım tur atmak için gereken mesafeden (L_e) büyük olan fakat en küçük uzaklığı veren fotoğraf, elmanın diğer yüzünü görüntülemekedir (Şekil 6.24).

.



(a) (b)

Şekil 6.23. Yarısı renkli kalem ile boyanmış elmanın görüntüsü; a-)Yan görünüş b-)Üst görünüş



(a) (b)

Şekil 6.24. Kamera altından dönerek ilerleyen elmanın farklı yüzeylerinin görüntüsü; a-)Birinci görüntü b-)İkinci görüntü

6.3.2. Elma yüzey kusurlarını örüntü tanıma kullanarak tanımlama

Çalışmanın bu bölümünde, elmaların yüzeyinde bulunan kusurlu bölgelerin örüntü tanıma kullanılarak, tanınması amaçlanmıştır. Örüntü tanıma algoritması sayesinde elma yüzeyinde bulunan kusurların tanınması ile diğer bölgelerden (elma sap, çiçek çukuru ve sağlıklı doku) ayrılarak, hatalı okuma yapılmanın önüne geçilmesi sağlanır. Böylece, elma yüzeyinde kusur olarak tanımlanan örüntülerin kapladıkları toplam alana göre elmalar Ekstra, Sınıf 1, Sınıf 2 ve Reddedilen olmak üzere dört kalite sınıfına ayrılmıştır. Görüntü yakalama cihazı tarafından elde edilen görüntüler eşikleme tekniği kullanılarak, arka fondan ayrılır ve bölütleme işlemine tabi tutulur. Bölütleme işlemi sonucunda elde edilen örüntülerin öznitelikleri çıkarılır ve öznitelik seçim yöntemi tarafından en etkili öznitelikler belirlenir. Örüntülere ait bu öznitelikler kullanılan iki adet denetimli sınıflandırıcıya girdi sağlar ve bu sınıflandırıcıların başarı performansları ölçülerek en uygun olanı seçilir. Sınıflandırma işlemi sonucunda örüntüler, kusurlar ve diğerleri (elma sap/çiçek çukuru ve sağlıklı bölgeler) olarak iki gruba sınıflandırılmıştır.

Elma yüzey kursularının örüntü tanıma kullanılarak tanımlanmasının temel öğeleri şekil 6.25'te verilmiştir (Unay ve Gosselin, 2007).

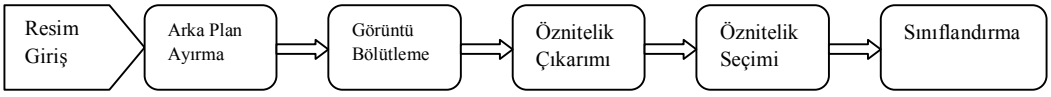

Şekil 6.25. Elma yüzey kusurlarının tanıma sisteminin mimarisi

6.3.2.1. Arka plan ayırma (Maskeleme)

Örüntü tanıma uygulamasında arka plan ayrıma işlemi, elma renk ve boyun belirlenmesi işleminde kullanıldığı gibi çoklu renk uzaylarının bileşenlerinin eşiklemesi

ile yapılır. Bölüm 6.2'de bu konu ayrıntılı olarak anlatılmıştır. Burada farklı olarak ele alınan, bir elmanın iki farklı görüntüsünde bu işlemin uygulanmasıdır.

6.3.2.2. Elma görüntülerini bölütleme (Segmentasyon)

Görüntü bölütleme işlemi benzer piksel özelliklerine sahip bölgelerin gruplandırılmasıdır. Bu bölgeler, elmanın sağlıklı dokuları, elmanın sapı ve çiçek çukuru olabileceği gibi yüzey kusuru da olabilir. Bu çalışmada, bölütleme işlemi kamera filtresine gerek duyulmadan, cihaz bağımsız bir renk uzayı olan CIE L^*C^*h yardımı ile eşikleme yöntemi kullanılarak gerçekleştirilmiştir.

$$f(x,y) = \begin{cases} 1 & Eğer \quad C > T \\ 0 & Değilse \end{cases}$$

Eşikleme işlemi farklı renk uzaylarının denenmesinden sonra CIE L^*C^*h renk uzayının "*C*" bileşeni üzerinde yapılmasına karar verilmiştir. Eşikleme sonucunda oluşan küçük adacıklar silinmiş ve elde edilen örüntüler numaralandırılmıştır (Şekil 6.26).

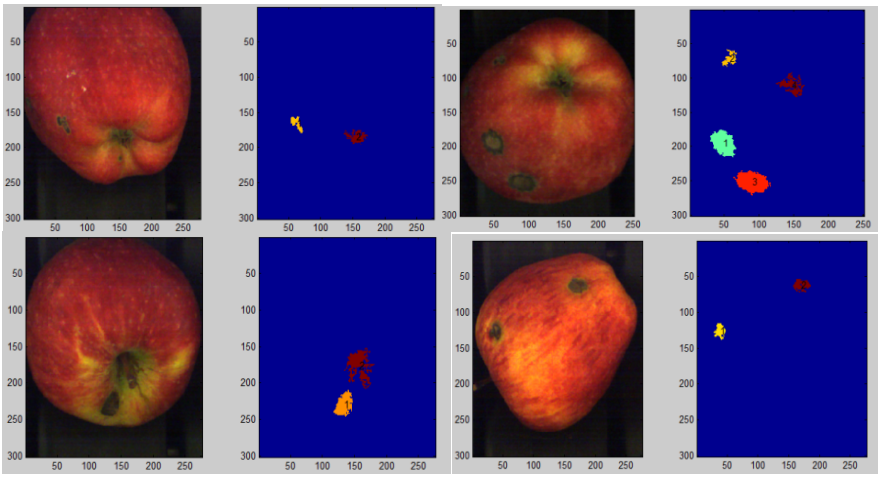

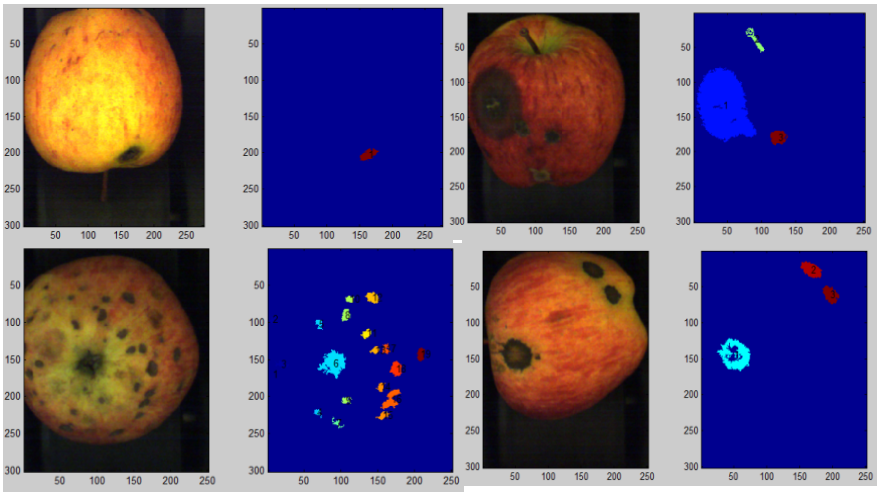

Şekil 6.26. Elma görüntüsü üzerinde bölütleme örnekleri

Bölütleme işlemi sonucunda elma görüntüsü üzerinde elde edilen bu örüntülerin etiketleri (sap, çiçek çukuru ve kusur) bu aşamada bilinmemektedir. Bu etiketler her örüntüye tek tek bizim tarafımızdan verilerek, bir veri tabanı oluşturulmuştur.

Çizelge 6.3. Bölütleme işlemi için gözlemlenen örnekler

Grup	**Örnek sayısı**
Sap	113
Çiçek çukuru	86
Kusur	387
Boş (Sağlıklı doku)	140
Toplam	726

Çizelge 6.3'te görüldüğü üzere, starking elma görüntüleri üzerinden yapılan bölütleme sonucu oluşturulan veri tabanında örüntüler sap, çiçek çukuru ve kusur olmak üzere üç gruba ayrılmıştır. Bir de bunların yanında "boş (sağlıklı doku)" diye adlandırılan görüntüdeki karanlık bölgelerden kaynaklanan örüntüler vardır. Bölütleme işleminde "boş" etiketlerinin oluşması istenmeyen bir durumdur.

6.3.2.3. Öznitelik çıkarımı

Bölütleme işlemi sonucunda elde edilen örüntülerin bir birinden ayrılabilmesi için temel karakteristik özelliklerinin çıkarılması gerekir. Bu çalışmada örüntülerin her biri için istatistiksel, dokusal ve şekilsel bilgilerini içeren yirmi beş (25) öznitelik çıkarılmıştır. Bu işlem sonucunda oluşan öznitelik vektörü, sınıflandırma aşamasında DVM ve *k*-EYK sınıflandırıcılarına girdi sağlayacaktır. Kullanılan yirmi beş (25) öznitelik aşağıda sıralanmıştır.

Ortalama;

Genel parlaklık değerini verir. RGB renk uzayının, kırmızı bileşeninin ortalaması (R_{ort}), yeşil bileşeninin ortalaması (G_{ort}) ve mavi bileşeninin ortalaması (B_{ort}) olmak üzere üç öznitelik aşağıdaki formüle göre elde edilmiştir.

$$Ortalama(\mu) = \frac{1}{N}\sum_{j=1}^{N} Pj \tag{6.19}$$

Pj= veri dizisi, N= veri dizisi adeti, μ= ortalama

Standart Sapma;

RGB renk uzayında, kırmızı bileşenin standart sapması (R_{std}), yeşil bileşenin standart sapması (G_{std}) ve mavi bileşenin standart sapması (B_{std}) olmak üzere üç öznitelik aşağıdaki formüle göre elde edilmiştir.

$$Standart\ Sapma(\sigma) = \sqrt{\frac{1}{N-1}\sum_{j=1}^{N}(Pj-\mu)^2} \tag{6.20}$$

Gradyan işlemi;

Maske erozyona uğratıldıktan sonra, RGB renk uzayında her bir bileşenine gradyan işlemi aşağıdaki formülle uygulanır.

$$\nabla F = \frac{\partial F}{\partial x} i + \frac{\partial F}{\partial y} j \tag{6.21}$$

Elde edilen sonuçlar üzerinden tekrar RGB bileşenleri için ortalama değer (RG_{ort} GG_{ort} BG_{ort}) ve standart sapma (RG_{std} GG_{std} BG_{std}) bulunarak altı adet öznitelik elde edilir.

Değişmez Moment(Hu);

Örüntü tanımada sıklıkla kullanılan özniteliklerden bir diğeri de, değişmez momentlerdir. İlk olarak Hu tarafından yedi adet değişmez moment geliştirilmiştir (Hu 1962). Bu çalışmada Hu tarafından geliştirilen momentlerden ilki kullanılmıştır. Bu momentler, örüntünün ölçeğinde oluşacak değişimlerde veya döndürme işlemi sonucunda sabit kalırlar. Buna göre *f(x,y)* örüntüsünün merkez momenti (Hu 1962);

$$\mu_{pq} = \int_{-\infty}^{\infty}\int_{-\infty}^{\infty} (x-\overline{x})^p (y-\overline{y})^q f(x,y)\partial(x-\overline{x})\partial(y-\overline{y}) \tag{6.22}$$

$$\overline{x} = m_{10}/m_{00}, \quad \overline{y} = m_{01}/m_{00} \tag{6.23}$$

$\overline{x}$, $\overline{y}$ örüntünün ağırlık merkezinin koordinatlarıdır. Merkezi moment ile normalize edilmiş Hu değişmez momenti (Hu 1962);

$\phi_1 = \mu_{20} + \mu_{02}$ şeklinde hesaplanır. (6.24)

Örüntünün tüm piksellerinin ortalama, standart sapma, minimum, maksimum ve maksimum ile minimum arasındaki farkı aşağıdaki gibidir:

$$ortalama(\mu) = \frac{1}{N}\sum_{j=1}^{N} Pj \tag{6.25}$$

$$Standart\ Sapma(\sigma) = \sqrt{\frac{1}{N-1}}\sum_{j=1}^{N}(Pj-\mu)^2 \tag{6.26}$$

$$minimum(min) = \min(1, \ldots..N) \tag{6.27}$$

$$maksimum(max) = \text{maks}(1, \ldots..N) \tag{6.28}$$

$$\text{maksmin}_gradient = \text{maks} - \min \tag{6.29}$$

Çarpıklık;

Örüntüyü oluşturan piksellerin dağılımındaki simetri bozukluğunu gösteren çarpıklık özniteliği formülü aşağıda verilmiştir;

$$Çarpıklık = \frac{\sum_{J=1}^{N}(Pj - \mu)^3}{N\sigma^3} \tag{6.30}$$

Basıklık ;

Örüntüyü oluşturan piksellerin dağılımındaki basıklık durumu aşağıdaki formülden elde edilmiştir.

$$Basıklık = \frac{\sum_{J=1}^{N}(Pj - \mu)^4}{N\sigma^4} \tag{6.31}$$

Alan;

Örüntünün kapladığı alan (piksel sayısına göre hesaplanır) ; S

Çevre;

Örüntünün Çevresi (Örüntünün çevresindeki piksellerin sayısıdır); $P = N_p$

Yuvarlaklık (Y);

$$Y = \frac{P^2}{4\pi S} \tag{6.32}$$

Maksimum Yarıçap (R); Örüntünün yarıçapı

Gerçek alan (N); Bir piksel alanı ile örüntünün kapladığı piksel sayısının çarpımı ile bulunur.

Çizelge 6.4. Sıralanmış öznitelikler

1	R_{ort}	**6**	B_{std}	**11**	GG_{std}	**16**	*Min*	**21**	*S*
2	G_{ort}	**7**	RG_{ort}	**12**	BG_{std}	**17**	*Maks*	**22**	*P*
3	B_{ort}	**8**	GG_{ort}	**13**	*Hu*	**18**	*Maks-Min*	**23**	*Y*
4	R_{std}	**9**	BG_{ort}	**14**	*Ortalama(μ)*	**19**	*Çarpıklık*	**24**	*R*
5	G_{std}	**10**	RG_{std}	**15**	*Std.Sapma (σ)*	**20**	*Basıklık*	**25**	*N*

Şekil 6.27'de, bölütleme işlemi sonucunda elde edilen 726 adet örüntüye ait yirmi beş öznitelik 0-1 arasında normalize edilerek, öznitelik haritası oluşturulmuştur. 726 örüntü satırı ve yirmi beş (25) öznitelik sitununun oluşturduğu öznitelikler matrisinin her bir elemanı haritada bir alan ile temsil edilmektedir. Burada belirtilen her örüntü, öznitelik uzayında bir noktaya karşılık gelir ve yirmi beş (25) elemanlı bir vektör ile temsil edilir. Normalize edilmiş öznitelikler vektörü, veri tabanına eklenir.

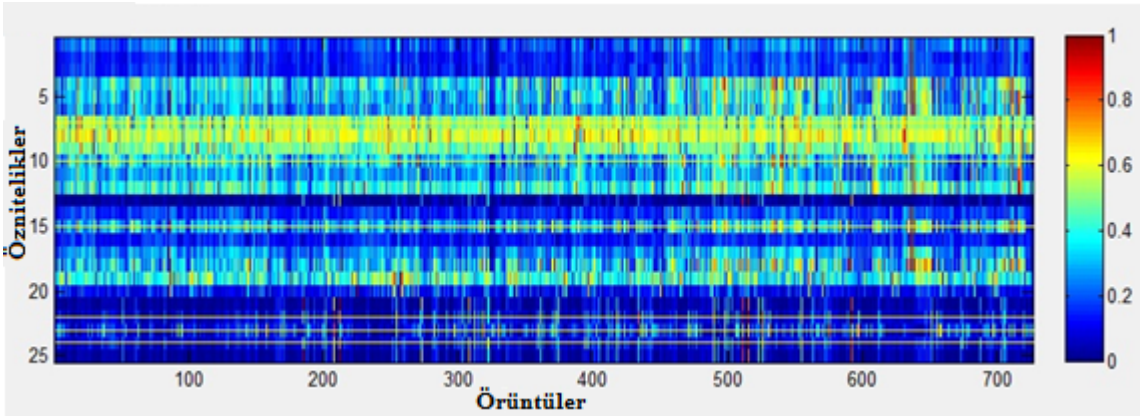

Şekil 6.27. Normalize edilmiş öznitelik haritası

6.3.2.4. Öznitelik seçimi

Örüntüleri bir birinden ayırmak için seçilen yirmi beş (25) özniteliğin hepsinin ayırıcılığı aynı başarıyı göstermemekle birlikte, bunların tümünün kullanılması hem

işlem süresini artırmakta hem de sınıflandırma performansını düşürmektedir. Bu nedenle elde edilen öznitelikler sınıflandırıcıya gönderilmeden önce bir eleme işleminden geçirilmesi gerekmektedir. Böylece örüntüler arasında en etkin ayırmayı gerçekleştiren öznitelikler belirlenmiş ve öznitelikler alt kümesi oluşturulmuş olacaktır. Öznitelikler alt kümesinin belirlenmesi için Ardışık İleri Yönde Seçim (SFS), Ardışık Geri Yönde Seçim (SBS) ile Ardışık İleri Yönde Kayan Seçim (SFFS), Ardışık Geri Yönde Kayan Seçim (SBFS) yöntemleri Ververidis ve Kotropoulos tarafından geliştirilen, öznitelik seçim programı ile karşılaştırılmıştır (Ververidis ve Kotropoulos 2010). Alt kümede belirlenen öznitelikler temel alınarak, örüntülerin sınıflandırma işlemi gerçekleştirilmiştir.

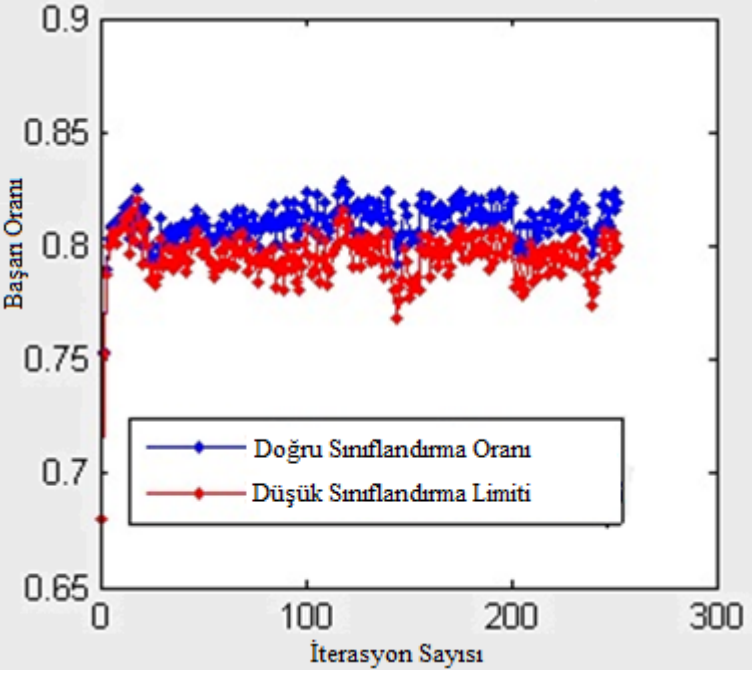

Şekil 6.28. SFFS öznitelik seçimi eğrisi

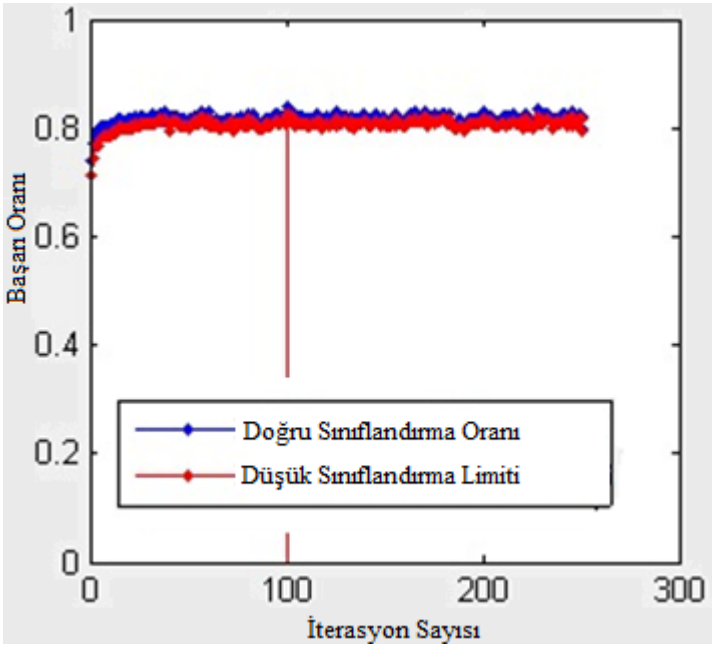

Şekil 6.29. SBFS öznitelik seçimi eğrisi

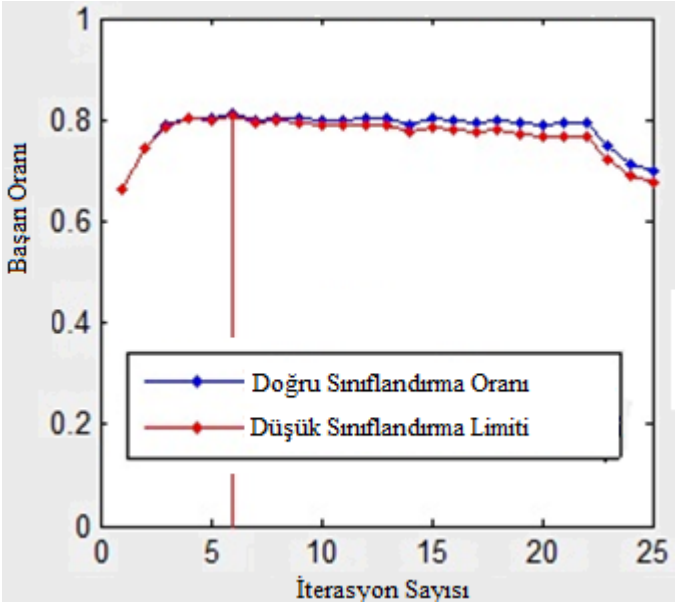

Şekil 6.30. SFS öznitelik seçimi eğrisi

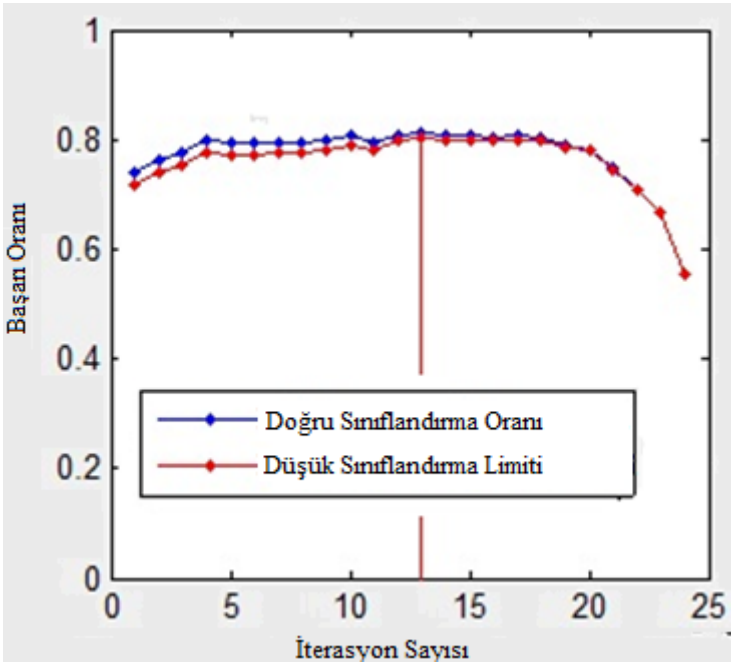

Şekil 6.31. SBS öznitelik seçimi eğrisi

Çizelge 6.5. Öznitelik seçim yöntemleri ile seçilen öznitelik alt kümeleri ve sınıflandırma başarıları

Öznitelik Seçim Yöntemi	Başarı Oranı(%)	Seçilen Öznitelikler
Ardışık ileri yönde seçim (SFS)	81,1	[8, 10, 15, 22, 23, 24]
Ardışık Geri Yönde Seçim (SBS)	81,3	[1, 2, 5, 6, 10, 11, 14, 16, 19, 22, 23, 24]
Ardışık İleri Yönde Kayan Seçim (SFFS)	82,9	[1, 3, 5, 6, 10, 11, 14, 15, 16, 18, 23, 24]
Ardışık Geri Yönde Kayan Seçim (SBFS)	83,1	[1, 2, 4, 5, 6, 10, 14, 16, 18, 23, 24]

Öznitelik seçim yöntemleri içerisinde %83,1 başarı oranıyla SBFS en başarılı öznitelik seçim yöntemi olarak bulunmuştur. Yöntem sonucunda elde edilen on bir elemanlı öznitelik alt kümesi [1, 2, 4, 5, 6, 10, 14, 16, 18, 23, 24] numaralı özniteliklerden oluşur. Bunların içerisinden rasgele seçilen üç özniteliğin oluşturduğu, öznitelik uzayı içerisinde, örüntülere ait öznitelik verilerinin dağılımı şekil 6.32 ve şekil 6.33'de verilmiştir. Bununla birlikte, elde edilen diğer özniteliklerin oluşturduğu iki boyutlu öznitelik uzayları da EK-A'da verilmiştir.

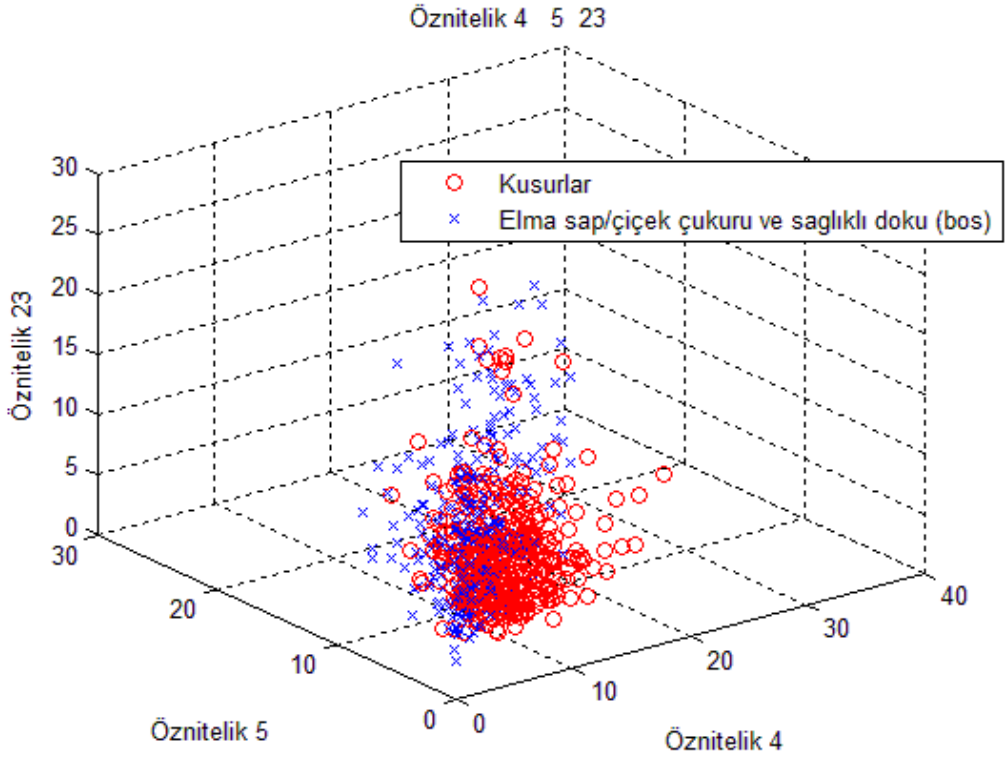

Şekil 6.32. İki sınıf için " 4-5-23" numaralı öznitelik uzayında verilerin dağılımı

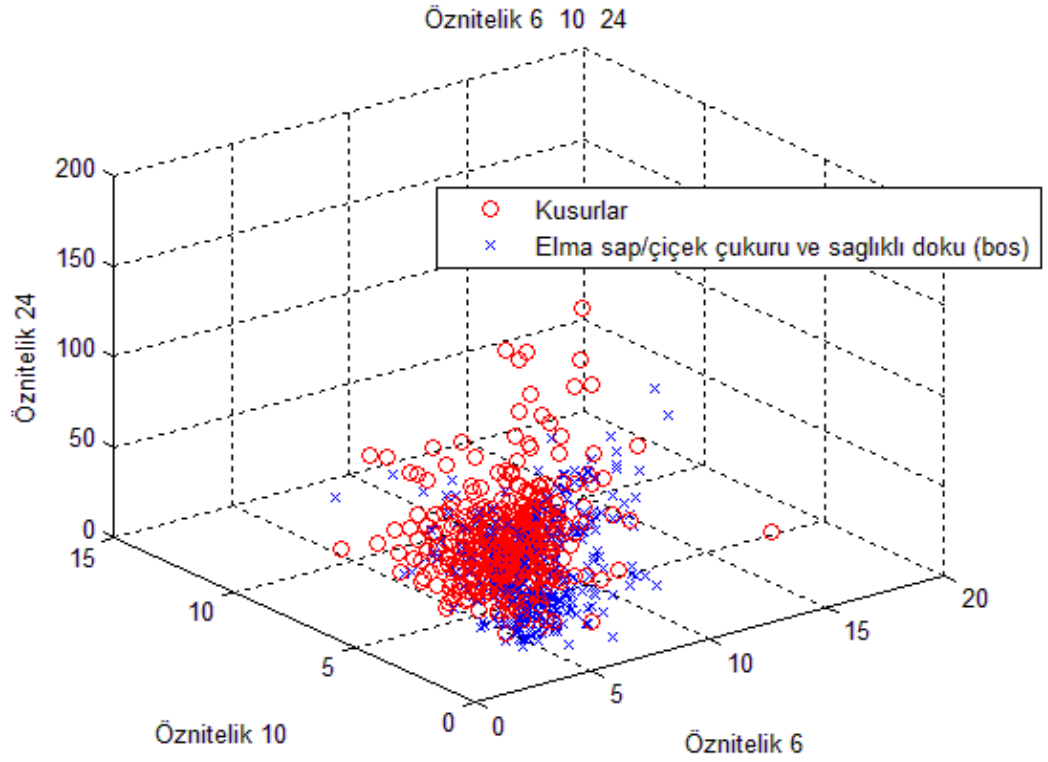

Şekil 6.33. İki sınıf için " 6-10-24" numaralı öznitelik uzayında verilerin dağılımı

6.3.2.5. Sınıflandırma

Bu aşamada amaç, elde edilen örüntüleri çıkarılan ve seçilen özniteliklerine göre en doğru sınıfa tayin etmektir. Sınıflandırmada, örüntülerin kusurlar ve diğerleri olmak üzere iki sınıfa ayrılması amaçlanmaktadır. "Diğerleri" olarak tanımladığımız grup; elma sap, elma çiçek çukuru ve sağlıklı bölgeler (boş) olarak belirlenmiştir. Bunu gerçekleştirebilmek için çok sayıda elmadan toplanan örüntüler ve bu örüntülere ait öznitelik vektörlerinin oluşturduğu veriler kullanılmıştır. Bu örüntü verileri, sınıflandırma işleminde kullanılmak üzere test ve eğitim kümelerine bölünür. Eğitim kümesinin küçük seçilmesi, yapılan çalışmanın istatistiksel olarak karar fonksiyonunun genelleme yeteneğini düşürmektedir. Bu ayrıntıya dikkat edilerek, belirlenen eğitim kümesi tarafından sınıflandırıcı eğitilir. Bir sonraki aşamada, sınıflandırıcı test kümesine uygulanır ve sınıflandırma sonuçlarının doğruluğu kontrol edilir. Sonuçta, hangi sınıfa ait olduğu bilinen örüntülerle eğitilen karar kuralı yardımı ile sınıfı bilinmeyen örüntülerin doğru sınıfa atanmasını sağlamaktır.

Çizelge 6.6. Sınıflandırma işlemi için toplam örüntü miktarı

Toplam Örüntü	
Grup	**Adet**
Elma sap	113
Elma Çiçek Çukuru	86
Kusur	387
Boş	140

Bu çalışmada, tüm veri kümesinden, 10 kez 100 adet kusur örüntüsü ve 100 adet diğerlerinden (Elma sap/çiçek çukuru ve boş) olmak üzere toplamda 200 örüntü örneği içerecek şekilde veri, rasgele örneklem kullanarak belirlenmiştir. Bu metot sonucunda, on (10) farklı 200 örnekli veri kümesi oluşturulmuştur. Her veri kümesinin %80'i eğitim kümesi %20'si test kümesi olarak bölünmüştür. Kullanılan sınıflandırıcı karar fonksiyonları her grubun eğitim kümesi ile eğitilmiş ve test kümesi ile sınıflandırma başarı oranı test edilmiştir.

$D_{eğitim}$=1,2,3,4…..10 ; D_{test}=1,2,3,4,….10

Seçilecek sınıflandırıcı amaca ve örüntü veri kümesinin yapısına göre değişiklik gösterebilir. Bu tezde, elma yüzey kusurlarının tanınmasında Destek Vektör Makineleri ile *k* En Yakın Komşuluk sınıflandırıcısı kullanılmış ve sınıflandırma sonuçları analiz edilmiştir. Bir sonraki bölümde bu iki sınıflandırıcıya değinilmiştir.

6.3.2.5.1. Destek Vektör Makineleri (DVM)

DVM, her örüntü bir, $x \in R^d$, öznitelik vektörü ile temsil edildiği *n* öznitelikli bir uzayda iki sınıfı ayırmak için bir hiper düzlem hesaplar ve bu hiper düzlemi iki sınıfı ayırt etmek için kullanır. Bu çalışmada, örüntüler ikili DVM sınıflandırması uygulanarak kusurlar ve diğerleri olmak üzere iki sınıfa ayrılmıştır. Algoritma sonucunda öznitelik vektörünün hangi sınıfa ait olduğunu gösteren bir sonuç etiketi $y \in \{1,-1\}$ bulunmaktadır.

$$y = \text{sgn}\left(\sum_{i=1}^{N_s} \alpha_i y_i k(x_i, x) + b \right)$$

$y = +1$, örüntü "kusur" olarak tanımlanırsa

$y = -1$, örüntü "kusur değil" olarak tanımlanırsa lacağı etikettir.

Örüntüler, kullanılan yazılımın DVM fonksiyonları ile eğitim ve test aşamalarından geçirilmiştir. DVM ile sınıflandırmada, ilk olarak eğitim kümesi belirlenir ve karar fonksiyonu eğitilir. DVM algoritmasının eğitim ve test kümesinde kullanılan örüntüler yirmi beş öznitelik arasından SBFS yöntemi ile belirlenen on bir (11) öznitelik ile temsil edilirler. DVM'ler denetimli bir sınıflandırma algoritması olduğundan eğitim aşamasında örüntülerin ait oldukları sınıfı belirten etiketleri de algoritmaya verilmiştir. DVM eğitiminden sonra eğitim kümesinden tamamen farklı örüntülerin bulunduğu test kümesi uygulanarak bu kümedeki örüntülerin sınıflandırılması yapılmıştır. Elde edilen sonuç kümesi ile referans küme karşılaştırılarak sınıflandırma başarı oranları hesaplanmıştır.

DVM'lerin sınıflandırma performansı, öznitelik vektörleri arasında benzerliği hesaplayan çekirdek fonksiyonu ile doğrudan ilişkilidir. DVM'lerde farklı çekirdek fonksiyonlar kullanılarak, doğrusal olarak ayrılmayan verileri en uygun şekilde doğrusal olarak ayırabilecek, yüksek boyutlu hiper-düzlemin elde edilmesi amaçlanmaktadır. Bu tezde, kullanılan örüntü verilerinin dağılımı bilinmediğinden DVM'lerin farklı çekirdek fonksiyonlarının sonuçları incelenmiştir. DVM algoritması kullanılarak yapılan sınıflandırmada, verilerin eğitiminde, Doğrusal, Gaussian Yarıçap Temelli Fonksiyon (YTF), Kuadratik, Polinomsal ve Çok Katmanlı Algılayıcı çekirdek fonksiyonları denenmiş ve sınıflandırma başarı performansları matematiksel ifadeleri ile birlikte Çizelge 6.7'de verilmiştir.

Çizelge 6.7. Destek Vektör Makineleri'nde kullanılan temel çekirdek fonksiyonlarının sınıflandırma başarı oranları

Çekirdek Fonksiyon	**En Yüksek Başarı Oranı(%)**	**Ortalama Başarı Oranı(%)**	**Fonksiyon**
Doğrusal	81,6667	73,16668	$K(x_i, x_j) = x_i^T * x_j$
Gaussian Yarıçap Temelli Fonksiyon (YTF)	90	75,83333	$K(x_i, x_j) = \exp\left(-\frac{\left\|x_i - x_j^T\right\|^2}{2\sigma^2}\right)$
Kuadratik	80	68,16666	$K(x_i, x_j) = (x_i^T * x_j).*(1+(x_i^T * x_j$
Polinomsal	71,6667	56,16667	$K(x_i, x_j) = (x_i^T * x_j + 1)^d$
Çok Katmanlı Algılayıcı (ÇKA)	60	54,5	$K(x_i, x_j) = \tanh(P1*(x_i^T * x_j) + P2$ P1= Ölçek değeri, P2 =Sapma değeri

Deneysel sonuçlara göre Gaussian Yarıçap Temelli Fonksiyon (YTF) performansı diğer çekirdek fonksiyonlara göre daha yüksek çıkmıştır. Bununla birlikte, eğitim ve test kümesinin değiştirilmesi ile başarı oranlarında da değişim görülmüştür (Çizelge 6.8).

Çizelge 6.8. Destek Vektör Makineleri'nde kullanılan temel çekirdek fonksiyonlarının kullanılan test kümelerine göre sınıflandırma başarı oranları

DVM Çekirdek Fonksiyon					
Test Kümesi	**Doğrusal Başarı Oranı(%)**	**YTF Başarı Oranı(%)**	**Kuadratik Başarı Oranı(%)**	**ÇKA Başarı Oranı(%)**	**Polinomsal Başarı Oranı(%)**
1	65	66,6667	60	58,3333	60
2	68,3333	63,3333	60	46,6667	53,3333
3	81,6667	80	55	46,6667	33,3333
4	81,6667	81,6667	80	56,6667	46,6667
5	71,6667	81,6667	73,3333	60	71,6667
6	61,6667	68,3333	68,3333	60	60
7	71,6667	70	70	55	66,6667
8	73,3333	68,3333	61,6667	53,3333	43,3333
9	75	90	73,3333	60	61,6667
10	81,6667	88,3333	80	48,3333	65

Sonuçta, Gaussian Yarıçap Temelli Fonksiyon (YTF) diğer çekirdek fonksiyonlar ile karşılaştırıldığında, farklı eğitim ve test kümelerinde elde ettiği başarı oranlarının ortalamasının daha yüksek olduğu gözlenmiştir.

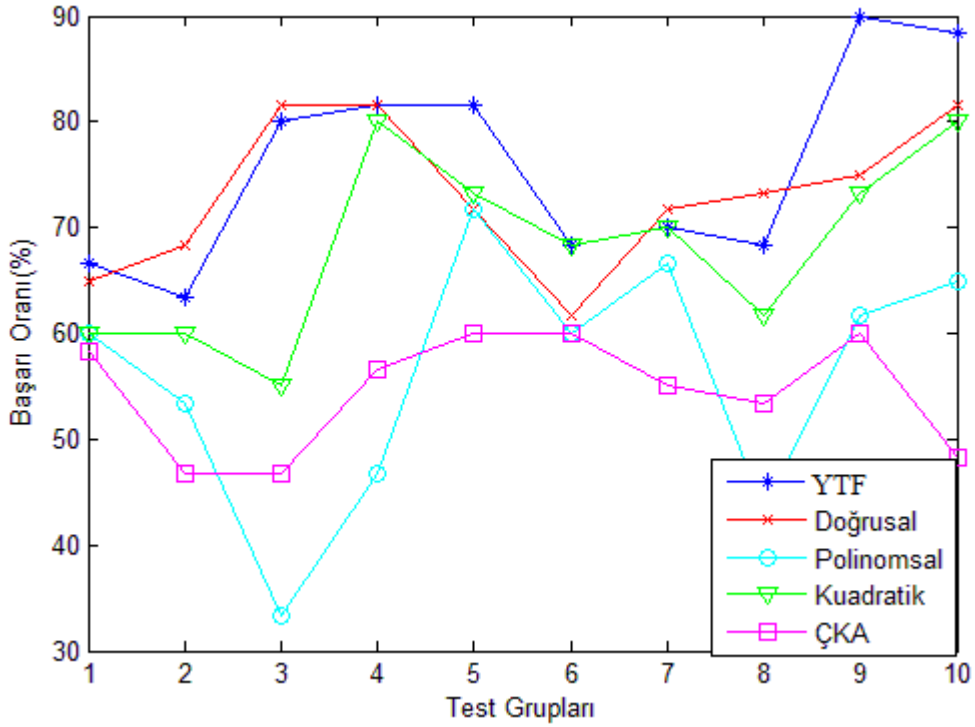

Şekil 6.34. On farklı test kümesine göre DVM çekirdek fonksiyonların sınıflandırma başarı grafiği

Çekirdek fonksiyonlarda kullanılan parametrelerin $\sigma = 5$, polinom derecesi (d) = 3, P1= 1, P2 = -1 seçilmiştir.

6.3.1.2. *k* En Yakın Komşuluk (*k*-EYK)

k En Yakın Komşuluk sınıflandırıcı hakkında detaylı bilgi Bölüm 5.4'te verilmiştir. *k*-EYK yönteminde sınıflandırılacak örüntülerin, eğitim kümesindeki en yakın olduğu belirlenen *k* adet veriye göre sınıflandırması yapılır. Buna göre sınıflandırıcının kullanım aşamasında ilk olarak *k* değeri girilmiştir. *k* değeri, öklid uzaklığı temel alınarak örüntü uzayında ona en yakın komşularının sayısıdır.

Bu çalışmada örüntülerin en yakın komşularının sayısı [1, 2, 3, 4, 5] olarak belirlenmiş ve bu değerler ile farklı test grubu üzerinde yapılan analiz sonuçları incelenmiştir (Çizelge 6.9).

Çizelge 6.9. *k* En Yakın Komşuluk yönteminde kullanılan farklı *k* değerlerinin kullanılan test kümelerine göre sınıflandırma başarı oranları

***k*-EYK**					
Test Kümesi	***k* =1 Başarı Oranı(%)**	***k* =2 Başarı Oranı(%)**	***k* =3 Başarı Oranı(%)**	***k* =4 Başarı Oranı(%)**	***k* =5 Başarı Oranı(%)**
1	66,6667	66,6667	70	70	71,6667
2	66,6667	66,6667	73,3333	70	68,3333
3	73,3333	73,3333	76,6667	76,6667	73,3333
4	63,3333	63,3333	58,3333	63,3333	56,6667
5	65	65	78,3333	76,6667	78,3333
6	65	65	70	68,3333	73,3333
7	71,6667	71,6667	68,3333	68,3333	75
8	58,3333	58,3333	53,3333	56,6667	55
9	78,3333	78,3333	85	81,6667	86,6667
10	73,3333	73,3333	70	70	71,6667
Ortalama	68,16666	68,16666	70,33332	70,16667	71

k-EYK uygulamasının, belirlenen *k* değerlerine göre [1, 2, 3, 4, 5] farklı test kümelerine göre performans grafiği şekil 6.35'te verilmiştir.

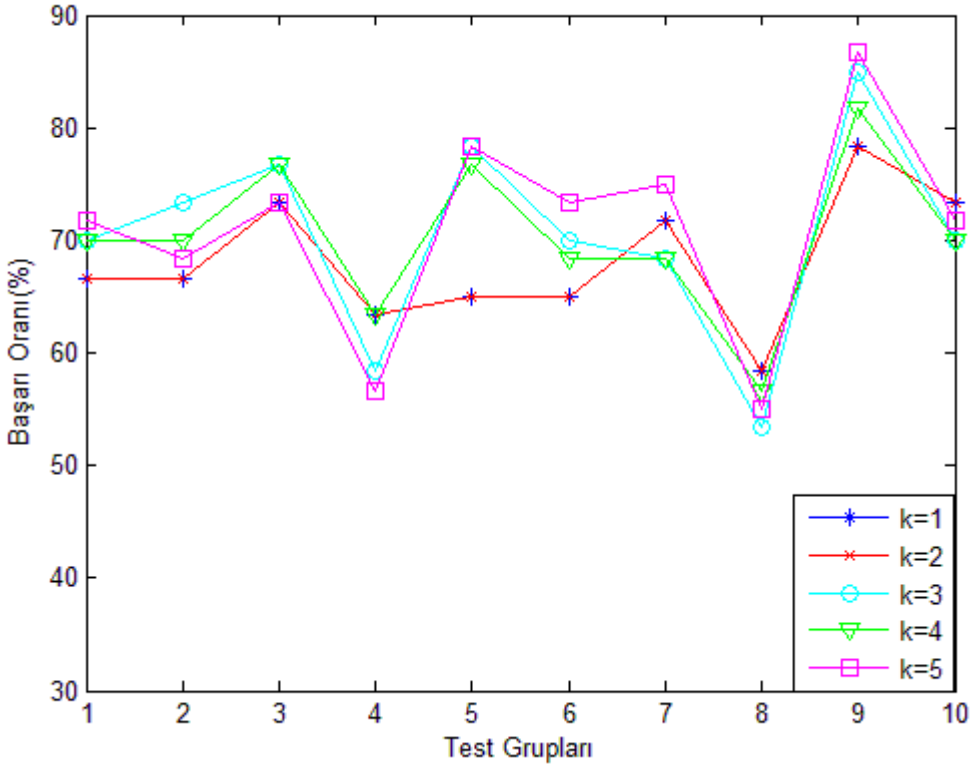

Şekil 6.35. *k* En Yakın Komşuluk algoritmasının belirlenen *k* değerlerine göre on farklı test kümesindeki sınıflandırma başarı grafiği

Deneysel sonuçlara göre en yakın komşuluk sayıları bir (1) ve iki (2) olarak alındığında tüm test kümelerinde sınıflandırma başarıları aynı çıkmıştır. Bu nedenle grafik üzerinde tek bir çizgi olarak görülmektedir. En yakın komşuluk sayıları üç (3), dört (4) olarak belirlenmiş *k*-EYK algoritması benzer sonuçlar verdiği görülmüştür. En yakın komşuluk sayısı beş (5) olarak belirlenmiş *k*-EYK algoritması, diğerlerine göre en yüksek %86,66 sınıflandırma başarı oranına çıkarak az da olsa öne çıkmayı başarmıştır. En iyi *k* değeri farklı eğitim ve test kümelerinde sınıflandırma başarı ortalamaları da göz önüne alındığında [5] olarak belirlenmiştir.

BÖLÜM 7

KÜTLE DUYARLI ELMA SINIFLANDIRMA OTOMASYONU

Bu çalışmada elmaların, kütlelerine göre hassas tartım işlemine tabi tutularak sınıflandırılması yapılmıştır. Bunu gerçekleştirebilmek için, makine görme sisteminden bağımsız endüstriyel bir otomasyon sistemi oluşturulmuştur.

Teknolojinin gelişmesi ile birlikte insanlar tarafından yapılan üretim, yerini makineler tarafından yapılan ve denetlenen otomatik üretim sistemlerine bırakmıştır. Bu işlerin planlanan sıra ile doğru olarak yapılmasını ve denetlenmesini sağlayan sürece, endüstriyel otomasyon denilmektedir. Kurtulan, endüstriyel otomasyon sistemlerini üç bölüm altında incelemiştir. Bunlar, endüstriyel kumanda sistemleri, geri beslemeli kontrol sistemleri ve veri iletişim sistemleridir. Endüstriyel kumanda sistemleri, en küçük üretim birimlerinin çalışma koşullarını düzenleyen, lojik temelli sistemlerdir. Geri beslemeli kontrol sistemleri, çeşitli üretim sistemlerinin her türlü bozucu etkiye karşı, sürecin istenen değerlerde çalışmasını sağlayan sistemlerdir. Veri iletişim sistemleri bilginin güvenilir ve hızlı dolaşımını sağlayan, donanım ve yazılım sistemleridir ki bu işlemi gerçekleştiren SCADA (Supervisory Control and Data Acquisition) yazılımları kullanılır. PLC (Programlanabilir Lojik Kontrolör) ise endüstriyel otomasyon sisteminin üç bölümünde de etkin olarak kullanılmaktadır (Kurtulan, 2003). Geçmişte kullanılan kontrol sistemlerinin uzun vadede çok maliyetli olması, karmaşık bir yapıya sahip olması, kontrol zorluğu, bakım masrafı ve programlanabilir olmaması gibi nedenlerle, söz konusu sistemler teknolojik gelişmelere de açık değillerdir. Bu olumsuzluklar göz önüne alındığında, PLC ve SCADA sistemlerinin avantajları öne çıkmakta ve böylelikle sektörde kullanımları yaygınlaşmaktadır.

Endüstriyel otomasyon mekanik, pnömatik ve elektronik sistemlerin birlikte kullanılmasından oluşmaktadır. Bu çalışmada kullanılan kütle duyarlı elma sınıflandırma endüstriyel otomasyon sistemi üç bileşende incelenmektedir.

- Denetleyiciler (Kontrol Sistemi Elemanları); PLC ve SCADA
- Giriş Birimleri; Yük hücresi ve sınır anahtarı
- Çıkış Birimleri; DC motor ve valfler

7.1. Kütle Duyarlı Elma Sınıflandırma PLC Programı

Bu çalışmada kullanılan PLC hakkındaki bilgi, Bölüm 6.1.3'te ayrıntılı olarak verilmiştir. PLC, kütle duyarlı elma sınıflandırma sisteminde daha işlevsel olarak kullanılmaktadır.

Bu çalışmada, tartım sisteminde "el" olarak adlandırılan plastik kısma düşen elma, yük hücresi tarafından algılanır ve kütleye bağlı olarak transmiter yardımı ile 0-10V aralığında gerilime dönüştürülür. Kütleye bağlı olarak oluşturulan gerilim PLC'nin analog modülüne aktarılır. Tartım biriminde meydana gelen titreşimleri göz ardı etmek amacıyla düşme anından 1,5 sn sonra analog modülüne gelen gerilim değeri kalibrasyon fonksiyonuna gönderilerek yapılan hesaplamalar sonucu elmanın gerçek kütlesi bulunur. Bulunan kütle değerinin karşılaştırma komutları kullanılarak, elmanın hangi kütle sınıfına ait olduğu belirlenir. Yazılan PLC programının akış diyagramı aşağıda verilmiştir (Şekil 7.1).

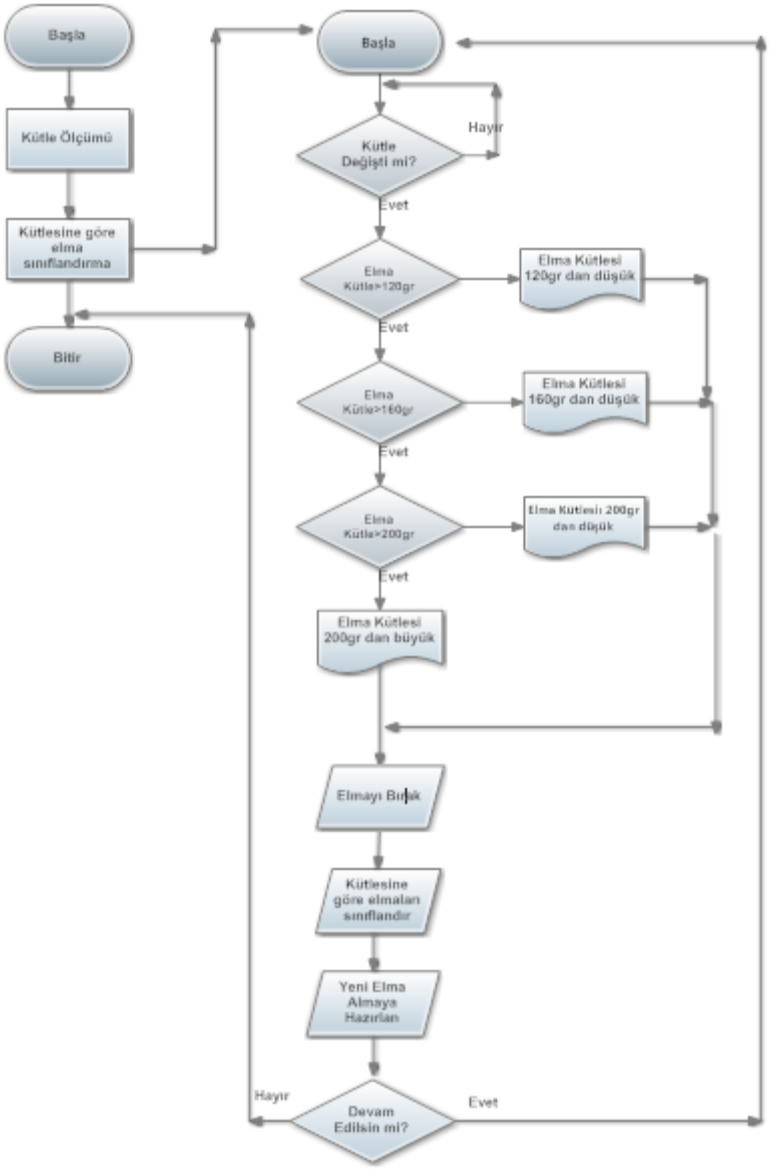

Şekil 7.1. PLC akış diyagramı

PLC'lerin haberleşmeye imkân vermesi, SCADA sistemleri sayesinde sürecin bir merkezden kontrol edilmesini ve gözlenmesini sağlar.

7.2. SCADA (Supervisory Control and Data Acquisition)

SCADA kelimesi, Supervisory Control and Data Acquisition'nın kısaltılmasından oluşur. İşletme operatörleri, SCADA'yı kullanarak bir sistemin işleyişini görüntüler, kontrol ve kumanda ederler. SCADA sistemleri, endüstriyel süreçlerde (çimento üretimi, demir-çelik sanayi, kimya sanayi vb.) telekomünikasyonda, taşımacılıkta, enerji santrallerinde ve füzyon gibi bilimsel deneylerin kontrolünde kullanılmaktadırlar. SCADA sistemleri yüz binleri bulan giriş/çıkış sayılı süreçleri kontrol edebilmektedirler (Daneels ve Salter, 1999).

SCADA yazılımı sayesinde, kütlesine göre elma sınıflandırma endüstriyel otomasyon sisteminin işleyişi görüntülenerek, kontrol ve kumanda edilebilmektedir. SCADA programı olarak, endüstriyel otomasyon sisteminde PLC'ler ve RTU (Uzak terminal birim)'larla sorunsuz şekilde çalışabilen WINCC 7.0 (Demo sürüm) kullanılmıştır. SCADA ile PLC arasındaki bağlantı MPI (Multi-Point Interface) haberleşme protokolü ile sağlanmıştır.

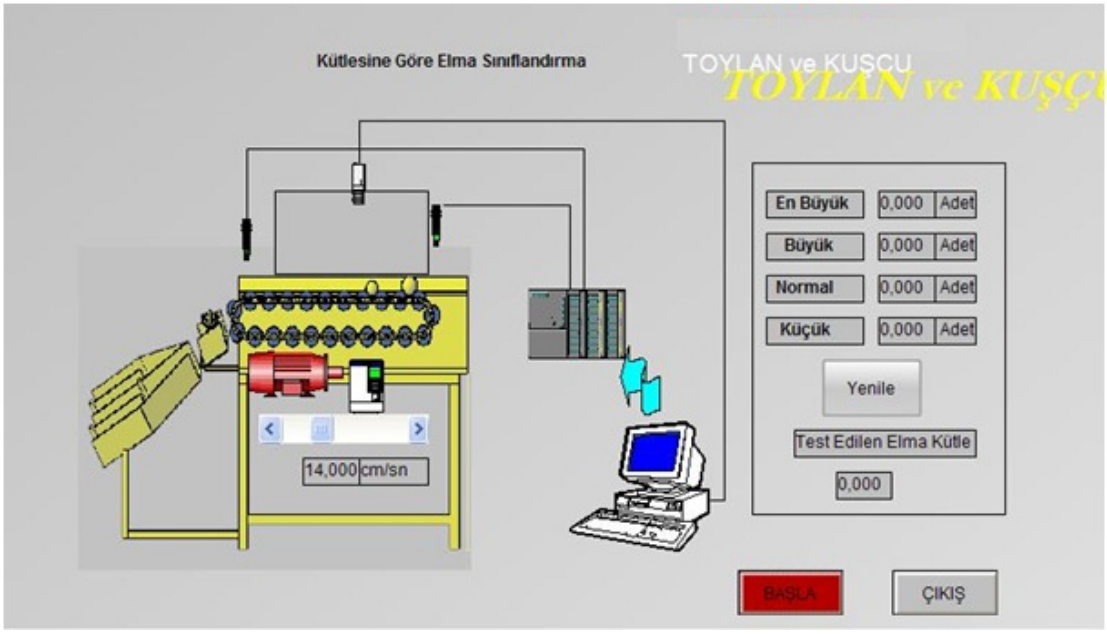

Şekil 7.2. Kütlesine göre elma sınıflandırma SCADA ekranı

Elma sınıflandırma sisteminin açılması ve kapanması, konveyör bant hızı kontrolü, sensörlerin durumları, kütlesine göre sınıflandırılan elma miktarları görüntülenmesi işlemleri SCADA ekranı üzerinden yapılmaktadır (Şekil 7.2).

7.3. Kütle Duyarlı Elma Sınıflandırma Sistemi Giriş /Çıkış Elamanları

Elmaların kütle sınıflandırılmasının yapılabilmesi hassas bir tartım işlemini gerektirmektedir. Bu işlem, strain gage (gerinim ölçer) tabanlı bir platform tipi yük hücresi (load cell) ile gerçekleştirilebilir. Bu çalışmada Esit marka 6kg kapasiteli tek noktadan belli bir alanda tartım yapabilen yük hücresi kullanılmıştır.



Şekil 7.3.Yük hücresi ve transmiter

Sınıflandırma işleminin doğru yapılabilmesi, yük hücresinden gelen sinyallerin doğru okunabilmesi ile mümkündür. Yük hücresinden gelen sinyalleri PLC'de işlemeye uygun duruma getirmek için sayısal mikroişlemcili bir transmiter kullanılmıştır.

Yük hücresinin montajı, döner rulolu konveyör çıkışına saplamalar ile yapılmıştır. Konveyörden çıkan elmaların yük hücresinde tartılabilmesi için elmanın sabit duracağı ve kütlenin oluşturduğu ağırlık kuvveti bilgisinin alınmasından sonra ayırıcı kısma gönderileceği uygun maliyet, optimum fayda gözetilerek bir tartım sistemi geliştirilmiştir (Şekil 7.4).



Şekil 7.4. Tartım sistemi

Yük hücresine ek olarak tartım sistemi içerisinde iki adet sınır anahtarı, bir adet 24V rediktörlü doğru akım motoru bulunmaktadır. Bu elemanlar kütle bilgisi ölçülme işleminden sonra elmayı ayırıcı birime göndermek için kullanılır. Ayırıcı birime ulaşan elmalar PLC'nin gönderdiği sınıf bilgisini içeren komutlara göre pnömatik pistonlar yardımı ile uygun sınıfa ayrılırlar.

BÖLÜM 8

SONUÇ VE TARTIŞMA

Üretilen sebze ve meyveler tüketiciler tarafından rengi, boyu, kütlesi ve kusurlu olma durumlarına göre talep edilmektedir. Bu ürünlerin pazarlanmasında en önemli etkenlerden biri de standardizasyondur. Eğer sınıflandırma insanlar tarafından yapılıyorsa işçilerin ürünleri sınıflandırırken kişisel kararları öne çıkabilmekte ve bu da sınıflandırmada standardın kaybolmasına sebep olabilmektedir. Bu nedenle sınıflandırma işlemininin makineler tarafından otomatikleştirilmesi zorunluluk haline gelmektedir. Bu çalışmada elma üreticilerinin bir elma sınıflandırma makinesinden beklentileri doğrultusunda fonksiyonel bir elma sınıflandırma sistemi geliştirilmiştir.

Geliştirilen elma sınıflandırma sisteminde kullanıcının tercihine göre, birbirinden bağımsız olarak çalışan üç farklı sınıflandırma seçeneği vardır. Bunlar; elmaların renk ve boyuna göre sınıflandırılması, elmaların yüzey kalitesine göre sınıflandırılması ve elmanın kütlesine göre sınıflandırılmasıdır. Bu tez çalışmasında öncelik elmaların yüzey kalitesine ve renk/boyuna göre sınıflandırılması işlemine verilmiş ve bunu sağlamak için gerçek zamanlı çalışan makine görme sistemi tasarlanmıştır.

İlk olarak, her bir elmanın farklı açılardan görüntüsünü elde edebilmek için bir döner rulolu konveyör sistemi tasarlanmıştır. Bu şekilde elmanın tüm yüzeyine yakın bir alanı kamera yardımı ile görüntülenmiştir. Bununla birlikte elmanın toplu olarak konulduğu giriş birimi ve elmaların uygun sınıfa ayrıldığı ayırıcı birim tasarlanmıştır.

Konveyör sisteminde dönerek ilerleyen elmaların, görüntü yakalama cihazı tarafından (kamera) elde edilen sayısal görüntüsünden arka planı ve elma görüntüsünü açık bir şekilde ayırmak (maskeleme), renk/boyunu belirlemek ve elmanın yüzey kusurlarının belirlenebilirliğini artırmak için çoklu-renk uzayı kullanılmıştır. Elde edilen görüntüde elmanın bulunduğu alanın maskelenmesi, HSV renk uzayının "S" bileşeni, CIE L*a*b renk uzayının "a" bileşeni ve CIE XYZ renk uzayının "Y" bileşenin eşikleme sonuçlarının bir maskede toplanması ile elde edilmiştir. Elmanın maskelenmiş

görüntüsünde, CIE XYZ renk uzayının "Y" bileşeninin, elma yüzeyindeki sarı alanları, CIE L*a*b* renk uzayının "a" bileşeninin ise elma yüzeyindeki kırmızı alanları daha belirgin olarak gösterdiği görülmüştür. Bu iki renk uzayı sayesinde elma yüzeyindeki sarı ve kırmızı renk yoğunluğu belirlenerek, elmanın rengi ve türü hakkında bilgi sahibi olunmuştur. Elma görüntüsünün bölütlenmesinde CIE L^*C^*h renk uzayının "C" bileşeninin eşiklemesi kullanılmaktadır. Bu işlemlerde kullanılan cihaz bağımsız renk uzaylarının RGB renk uzayından dönüşümleri MATLAB'ın sağladığı hazır fonksiyonlar ile yapılmamış, kullanılan aydınlatma elemanına göre algoritmalar tekrar yazılmıştır. Bu şekilde gereksiz kodların silinmesi ve düzenlenmesi ile görüntü işlemede kullanılan renk uzayı dönüşümlerinde harcanan sürenin yaklaşık üç kat kısaltılması mümkün olmuştur.

Geliştirilen makine görme sistemi, gerçek zamanlı olarak bir dakikadan daha az bir sürede 96 elmayı rengine göre iki (Kırmızı, Sarı); boyuna göre de iki (İri boy, Normal boy) olmak üzere toplamda dört farklı sınıfa ayırma başarısı göstermiştir. Geliştirilen yazılımda, bir elmanın renk ve boyuna göre ortalama sınıflandırılma süresi 260 ms'dir. Fakat ayırıcı birim, mekanik parçaların ataleti nedeniyle bu hızı desteklememektedir. Bu çalışmada ayırıcı birimin geliştirilmesi ile hem sınıf sayısı hem de sınıflandırılan elma sayısı rahatlıkla artırılabilir.

Çalışmanın diğer bölümü olan starking türü elmaların yüzey kalitesine göre sınıflandırılmasında makine görmesi kullanılarak, görüntü işleme temelli akıllı bir örüntü tanıma algoritması geliştirilmiştir. Örüntü tanıma algoritması maskelenen elma görüntüsünün bölütlenmesi, bölütleme sonucunda elde edilen örüntülerin özniteliklerinin çıkarılması, öznitelik seçimi ve örüntünün sınıflandırılması basamaklarından oluşur.

Bölütleme işlemi sonucu elde edilen örüntülere ait istatistiksel, dokusal ve şekilsel özelliklerini içeren yirmi beş öznitelik çıkarılmıştır. Özniteliklerin çeşitli yöntemler yardımıyla ayırt edicilik güçlerinin belirlenmesinin ve daha etkili olanlarının oluşturduğu bir öznitelik alt kümesi elde edilmesinin, sınıflandırmanın doğruluğu ve performansı açısından gerekli olduğu görülmüştür. Bu nedenle en yüksek ayırt edicilik özelliklerine sahip öznitelikleri belirlemek için, SFS, SBS, SFFS, SBFS öznitelik seçim yöntemleri karşılaştırılmış ve sonuçta, SBFS yöntemi ile oluşturulmuş on bir elamanlı öznitelik alt kümesi %83,1 sınıflandırma doğruluk oranı ile örüntüleri, kusur, elma sapı,

elma çiçek çukuru ve sağlıklı doku olarak, diğer yöntemlere göre daha başarılı etiketlenmesini sağlamıştır. Bunun sonucunda örüntüler, öznitelik çıkarım yöntemleri tarafından elde edilen yirmi beş öznitelik arasından SBFS yöntemi ile belirlenen on bir (11) elemanlı öznitelik vektörü ile temsil edilmiştir.

Örüntü tanımanın en son basamağı, her bir örüntünün belirlenen sınıflandırma algoritmaları ile tanınmasıdır. Örüntülerin kusurlar ve diğerleri olarak iki sınıfa ayrılması, iki farklı denetimli sınıflandırma yönteminin karşılaştırılması sonucunda belirlenmiştir. Bunlardan ilki Destek Vektör Makineleri'dir (DVM). DVM algoritması kullanılarak yapılan sınıflandırmada verilerin eğitiminde kullanılan çekirdek fonksiyon seçeneklerinden Doğrusal, Gaussian Yarıçap Temelli Fonksiyon (YTF), polinomsal, Çoklu Katman Algılayıcı (ÇKA) ve kuadratik çekirdek denenmiş ve sınıflandırma doğruluğu performansları karşılaştırıldığında, Gaussian YTF çekirdek fonksiyonlu DVM'nin en yüksek %90 sınıflandırma başarısıyla diğerlerine göre öne çıktığı görülmüştür. Diğer sınıflandırma yöntemi öklid uzaklığına bağlı *k* En Yakın Komşuluk yöntemidir. En yakın komşularının sayısı bir, iki, üç, dört, beş olarak belirlenmiş ve sonuçlar incelendiğinde beş (5) olarak belirlenen en yakın komşuluk sayısında sınıflandırma başarısı en yüksek %86,6 oranına çıkmıştır. Veritabanı üzerinde yapılan deneysel çalışmalarda DVM yöntemi, *k*-EYK yöntemine göre farklı test kümelerinde değişim gösterse de, genelde öne çıkarak daha yüksek bir başarım sağlamıştır. Bu da bizim verilerimize göre karşılaştırılan iki yöntem arasından, Gaussian YTF çekirdek fonksiyonlu DVM karar kuralının daha uygun olduğunu göstermiştir.

Örüntü tanıma algoritması sayesinde elma yüzeyinde bulunan kusurlu bölgelerin tanınarak, diğer bölgelerden (elma sap, çiçek çukuru ve sağlıklı doku) ayrılması sağlanmıştır. Elmalar yüzeyinde bulunan kusur alanına göre Ekstra, Sınıf 1, Sınıf 2 ve Reddedilen olmak üzere dört kalite sınıfına ayrılmışlardır. Fakat elma yüzey kusuruna göre sınıflandırma çalışması teori bakımından uygun olup, gerçek zamanlı çalışan bir sistem için sınıflandırma hızının artırılması gerekir.

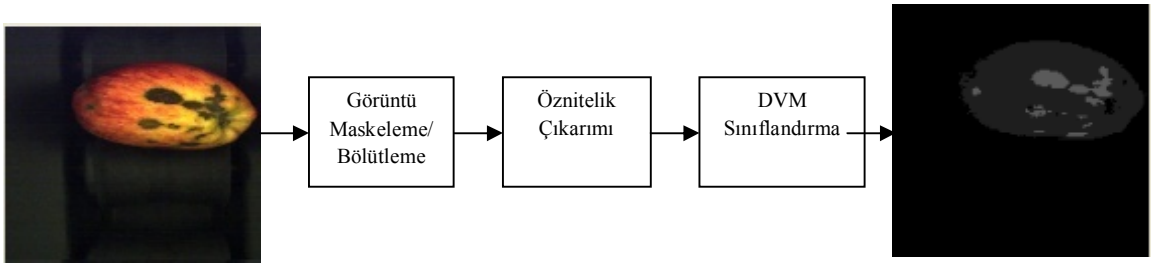

Şekil 8.1. Elma yüzey kusurlarının örüntü tanıma ile belirlenmesi (Açık gri alanlar kusur olarak tanımlanmıştır)

Bu tez çalışmasında, elmaların renk/boyuna ve yüzey kusur miktarına göre yapılan çalışmaya ek olarak çift renkli (kırmızı-sarı) elma türlerinde, kendi içerisinde renk yoğunluğuna göre ayrıştırılması da yapılmış fakat ek bir fonksiyon olarak eklenmemiştir.

Elde edilen bütün sonuçlar ve yapılan analizler, geliştirilen makine görme sistemi algoritmalarının gerçek zamanlı olarak gerçekleştirilebilirliğini göstermektedir. Geliştirilen makine görmesi kullanılarak elma sınıflandırma sisteminin en önemli özelliklerinden biri de endüstriyel sistem üzerinde uygulanmasıdır. Yapılan çalışmalar teoride kalmayıp uygulama aşamasına geçirilmiştir. Bu şekilde, hasat sonrasında toplanan elmaların sınıflandırılmasında kullanılması amaçlanmıştır.

Kullanıcının üçüncü tercihi olarak, elmalar hassas tartı aleti ile tartılıp çeşitli oranlarda eşik değerleri temel alınarak kütlesine göre dört faklı sınıfa ayrılmışlardır. Bu seçenekte program akışı tamamen PLC içerisine yazılan algoritma sayesinde gerçekleştirilmiştir. Bu işleme SCADA yazılımı eklenerek veri toplama ve gözlemleme özelliği kazandırılmıştır.

BÖLÜM 9

ÖNERİLER

Gerçek zamanlı bir makine görme sisteminde, fotoğraf çekme süresi bununla birlikte görüntü işleme ve örüntü tanıma algoritmalarının işlem süreleri mümkün olduğunca kısaltılmalıdır. Bu nedenle öncelikle kullanılan kamera fps değeri yüksek seçilmelidir. Bunun yanında, yazılan algoritmaların işlem süreleri kontrol edilmeli ve bu işlem süreleri uzun sürüyorsa kodlar tekrar gözden geçirilmelidir. Aksi takdirde gerçekleştirilen sistemden yüksek performans alınması zorlaşacaktır.

Makine görme sistemlerinde görüntü alınan ortam doğal aydınlatmadan yalıtılmalıdır. Çünkü aydınlatmada oluşacak değişimler yazılımı olumsuz etkilemektedir. Işık, görüntü alınan hat boyunca eşit dağılmalı ve görüntülenecek nesnenin üzerinde mümkün olduğunca eşit yayılmalıdır. Kullanılan aydınlatma özenle seçilmelidir. Makine görme sistemleri için tasarlanmış LED teknolojisi kullanılabilir. Daha düşük maliyetli çözüm isteniyorsa bu çalışmadaki D55 floresan veya D65 floresanları önerilebilir.

Örüntü tanıma uygulamasında elma kusurlarının tanınması yerine, elmanın sap ve çiçek çukurunun algoritmalar yardımı ile tanınması elmanın çapının bulunmasında yardımcı olabilir. İki bölgenin tanınma işleminden sonra bu bölgeleri birleştiren eksene dikey en geniş ekvatoral çap, elmanın çapı olarak tanımlanabilir (TS 100).

Elma küreye yakın bir ürün olduğundan yüzey kalitesine göre sınıflandırılması işleminde elma yüzeyindeki kusurların, kameranın dik görüş açısına girmediği durumlarda geometrik bozulma söz konusu olabilir. Bu sorunu ortadan kaldırmanın bir yöntemi kamera kalibrasyonunun yapılmasıdır. Diğer bir yöntem ise işlenecek her elmaya ait belirli aralıklarla çekilecek fotoğraf sayısının artırılmasıyla, her fotoğrafta sadece kameraya dik olan belirli bir bölgenın alınmasıdır. Böylelikle hem istenmeyen gölgeli alanların önüne geçilecek, hem de kusurların geometrik bozulması önlenebilecektir.

KAYNAKLAR

Acharya T., Ray A. K., 2005, "Image Processing: Principles and Applications",John Willy & Sons, Inc., Publication, sf:37-40

Aleixos N., Blasco J., Navarro´n F., Molto´ E., 2002, "Multispectral inspection of citrus in real-time using machine vision and digital signal processors", Computers and Electronics in Agriculture, 33,121–137

Aydogmus Z., 2009, "Implementation of a Fuzzy-based level control using SCADA", Expert Systems with Applications, 36, 6593-6597

Bennedsen B., Peterson D., 2004, "Identification of apple stem and calyx using rotating apples" Comput. Electron. Agr., 48(2), 92-102 unsupervised feature extraction", Transactions of ASAE, 47(3), 889–894

Bennedsen B.S., Peterson D.L., Tabb A., 2005, "Identifying defects in images of Beyazit H (2005). Applied PLC Programming and Operator Panel Nobel press.

Blasco J., Aleixos N., Go´mez J. , Molto´ E., 2007, "Citrus sorting by identification of the most common defectsusing multispectral computer vision", Journal of Food Engineering, 83,384–393

Brosnan T., Sun D.W., 2004, "Improving quality inspection of food products by computer vision—a review", Journal of Food Engineering 61, 3–16

Bruce J., Balch T., Veloso M., 2000, "Fast and Inexpensive Color Image Segmentation for Interactive Robots", Proceedings of the 2000, International Conference on intelligent Robots and Systems, 2061-2066

Chang R., Zheng Pei Z., Zhang C., 2011, "A Modified Editing k-nearest Neighbor Rule", Journal of Computers, vol. 6, no: 7,1493-1500

Daneels A., Salter W., 1999, "What is Scada?", Proceeding of the 7th international conference on Accelerator and large Experimental Physics Control Systems Trieste italy, 1-2

Pascale D., 2003, "A Review of RGB Color Spaces", Babel Color, 15

Diaz, R., Gil, L., Serrano, C., Blasco, M., Molto´ , E., Blasco, J., 2004, "Comparison of three algorithms in the classification of table olives by means of computer vision", Journal of Food Engineering, 61(1), 101–107

Du C-J., Sun D-W., 2004, "Recent developments in the applications of image processing techniques for food quality evaluation", Trends in Food Science & Technology, 15, 230–249

Du C-J., Sun D-W., 2005, "Comparison of three methods for classification of pizza topping using different colour space transformations", Journal of Food Engineering, 68, 277–287

Fix E., Hodges J. L., 1951, "Discriminatory analysis, nonparametric discrimination, consistency properties," U.S. Air Force Sch. Aviation Medicine, Randolf Field, Texas, Project 21-49-004, Contract AF 41(128)-31, Rep. 4

González J. M. C., Rodríguez M.A.V., Pulido J.A.G., Pérez J.M.S., 2010, "Detecting skin in face recognition systems", A colour spaces study, Digital Signal Processing 20 806–823

Gonzalez R., Woods R.E., 2002, "Digital Image Processing", 2 ed, Prentice Hall Press. p. 295, ISBN 0-201-18075-8

Graves M., Batchelor B, 2004, "Machine Vision for the inspection of natural products", springer-Verlag London Limited, ikinci baskı, sf:5

Guedalia I. D., 1997, "Visual based quality sorting of fruit. Sensors for non-destructive testing—measuring the quality of fresh fruits and vegetables" In Proceedings from the Sensors for Non-destructive Testing International Conference and Tour, 232–238; Orlando FL., USA, 1997, North Regional Agricultural Engineering Service.

Gunasekaran S., 1996, "Computer vision technology for food quality assurance", Trends in Food Science and Technology, 7(8), 245–256.

Heinemann P. H., Hughes R., Morrow C. T., Sommer H. J., Beelman H. J., West P. J., 1994, "Grading of mushrooms using a machine vision system", Transactions of the ASAE, 37(5), 1671–1677.

Hu M-K.,1962, "Visual pattern recognition by moment invariants", IRE Transactions on Information Theory, IT-8 February, 179–187

Jack K., 1995, "Video Demystified", LLH Technology Publishing,sf:15

Jain A., Duin R. P. W., Mao J., 2000, "Statistical pattern recognition: a review", IEEE Trans. on Pattern Analysis and Machine Intelligence, 22(1), 4-37

Kavdır İ., Guyer D.E., 2008, "Evaluation of different pattern recognition techniques for apple sorting", Biosystems Engineering, 99, 211 – 219

Kavdır İ., 2000, "Apple sorting using neural networks, statistical classifiers and spectral reflectance imaging",doktora tezi

Kleynen O., Leemans V., Destain M.-F., 2005, "Development of a multi-spectral vision system for the detection of defects on apples", Journal of Food Engineering, 69, 41–49

Kondo N. , Ahmad U., Monta M., Murase H., 2000, "Machine vision based quality evaluation of Iyokan orange fruit using neural networks", Computers and Electronics in Agriculture, 29, 135–147

Kong R., Zhang B., 2007, "Autocorrelation Kernel Functions for Support Vector Machines Natural Computation", ICNC 2007. Third International Conference on, 512 – 516

Kurtulan S., 2003,PLC ile Endüstriyel Otomasyon,Birsen yayın evi, 3.Baskı, sf:1

Leemans V., Magein H., Destain M.-F., 1998, "Defects segmentation on Golden Delicious apples by using colour machine vision", Computers and Electronics in Agriculture, 20, 117–130

Leemans V., Destain M. F., 2004, "A real-time grading method of apples based on features extracted from defects", Journal of Food Engineering, 61(1), 83–89

Leemans V., Magein H., Destain M.-F., 2002, "On-line Fruit Grading according to their External Quality using Machine Vision", Biosystems Engineering,83 (4), 397–404

Li Q., Wang M., Gu W., 2002, "Computer vision based system for apple surface defect detection", Computers and Electronics in Agriculture, 36(2), 215–223

Majumdar S., 1997, "Classification of cereal grains using machine vision",Biyosistem bölümü Manitoba Winnipeg Universitesi, Kanada,doktora tezi

MathWorks Inc, 2002. MATLAB Image Processing Toolbox User's Guide.

Melgani F., Bruzzone L., 2004, "Classification of Hyperspectral Remote Sensing Images With Support Vector Machines", IEEE transactions on geoscience and remote sensing, vol. 42, 8, 1778 – 1790

Mendoza F., Dejmek P., Aguilera J. M., 2006, "Calibrated color measurements of agricultural foods using image analysis", Postharvest Biology and Technology, 41, 285–295

Miller, B. K., Delwiche, M. J., 1991, "Peach defect detection with machine vision. Transactions of the ASAE", 34(6), 2588–2597

Molto E., Blasco J., Aleixos N., 2000, "Multispectral, real-time inspection of citrus using a parallel architecture", In AgEng 2000 Agricultural Engineering into the Third Millennium, Warwick, UK, 2–7July, Paper 00-AE-001

Molto E., Blasco J., Benlloch J. V, 1998, "Computer vision for automatic inspection of agricultural produces", In SPIE Symposium on Precision Agriculture and Biological Quality, Boston, MA, USA.

Muir A. Y., Porteus R. L., Wastie R. L., 1982, "Experiments in the detection of incipient diseases in potato tubers by optical methods", Journal of Agricultural Engineering Research, 27, 131–138

Panigrahia S., Misrab M. K., Willsonc S., 1998, "Evaluations of fractal geometry and invariant moments for shape classification of corn germplasm", Computers and Electronics in Agriculture, 20(1), 1–20

Pearson T., 1995, "Machine vision system for automated detection of stained pistachio nuts", In: Proceedings of the SPIE. Vol. 2345,95–103

Pitas I., 2000, "Sayısal image processing algorithms and applications", John Wiley&Sons Inc., sf:1

Pudil P., Novovicova J., Kittler J., 1994, "Floating Search Methods in Feature selection", Pattern Recognition Letters, Volume 15, Issue 1, 1119-1125

Ruiz, L. A., Molto, E., Juste, F., Pla, F., Valiente, R., 1996, "Location and characterization of the stem-calyx area on oranges by computer vision", Journal of Agricultural Engineering Research, 64, 165–172

Shearer S. A., Payne F. A., 1990, "Color and defect sorting of bell peppers using machine vision", Transactions of the ASAE, 33(6), 2045–2050.

Shin M.C., Chang K.I., Tsap L.V., 2002, "does colorspace transformation make any difference on skin detection ?" ,Application of computer vision, 275-279

Stokes M., Anderson M., Chandrasekar S., Motta R., 1996, "A Standard default color space for the internet—sRGB", Version 1.10. International Color Consortium (ICC), 1899 Preston White Drive, Reston, VA,

Sun, D.-W., 2000, " Inspecting pizza topping percentage and distribution by a computer vision method", Journal of Food Engineering, 44, 245–249

Süsstrunk S., Holm J., Finlaysonc G.D., 2001, "Chromatic Adaptation Performance of Different RGB Sensors", IS&T/SPIE Electronic Imaging, SPIE Vol. 4300

Tan F., 2007, "Improvıng Feature Selectıon Technıques For Machıne Learnıng", Georgia State University, doktora tezi

Tekin Y., Editör: Öztaş K., 1995, "Tarım Alet ve Makinaları", Anadolu Üniversitesi Yayın no:861 4.Baskı, sf:314-315

Tkalcic M., Tasic J.F., 2003, "Colour spaces: percuptual, historical and application backround",Eurocon 2003, computer as a Tool.the IEEE Region vol.1 8, 304-308

Türkoğlu İ., 2003, "Örüntü Tanıma Sistemleri ders notları",Elazığ

Unay D., 2006, "Multispectral image processing and pattern recognition techniques for quality inspection of apple fruits", Press Universitaires de Lonvain, sf:25

Unay D., Gosselin B., 2007, "Stem and calyx recognition on 'Jonagold' apples by pattern recognition", Journal of Food Engineering, 78, 597–605

Vapnik V., 1999, "T h e Nature of Statistical Learning Theory", Springer, New York, 2.baskı

Wan Y. N., Lin C. M., Chiou J. F., 2002., "Rice quality classification using an automatic grain quality inspection system", Transactions of the ASAE, 45, 379–387

Wen Z., Tao Y., 1999, "Building rule-based machine vision system for defect inspection on apple sorting and packing lines", Expert Systems with Applications, 16, 307–313

Wen Z., Tao Y., 2000, "Dual-camera NIR/MIR imaging for stemend/ calyx identification in apple defect sorting", Transactions of the ASAE, 43(2), 449–452

Wen Z., Tao Y., 1998, "Brightness-invariant image segmentation for on-line fruit defect detection", Optical Engineering, 37(11), 2948– 2952

Westland S., Ripamonti C., 2004, "Computational Colour Science using Matlab", John Willy ltd, 27-28

Xiaobo Z., Jiewen Z., Yanxiao L., 2007, "Apple color grading based on organization feature parameters", Pattern Recognition Letters, 28, 2046–2053

Ververidis D., Kotropoulos C., 2010, http://www.mathworks.com/matlabcentral/ fileexchange/22970-feature-selection-using-matlab

Yang Q., 1993, "Finding stalk and calyx of apples using structured lighting" Computers and Electronics in Agriculture, 8, 31–42

Yılmaz İ., 2002, "Renk Sistemleri, renk uzayları ve dönüşümler", Selçuk Üniversitesi Jeodezi ve Fotogrametri Mühendisliği Öğretiminde 30. Yıl Sempozyumu, Konya

Yong X., Yaonan W., Tao P., 2009, "Influences of Color Spaces on Printing Defect Classification", Control and Decision Conference, 3354 - 3357

Türk Standardı, TS 100, Ocak 2007, elma, ICS 67.080.10

http://faostat.fao.org erişim tarihi:31.10.2011

http://www.efg2.com/Lab/Graphics/Colors/Chromaticity.htm\

http://www.hunterlab.com/appnotes/an09_96a.pdf

http://brucelindbloom.com/index.html?Eqn_RGB_XYZ_Matrix.html

EK-A

SEÇiLEN 11 ÖZNİTELİĞİN İKİ BOYUTLU ÖZNİTELİK UZAYI

(x = Kusurlar, x = Elma sap/çiçek çukuru ve sağlıklı doku (boş))

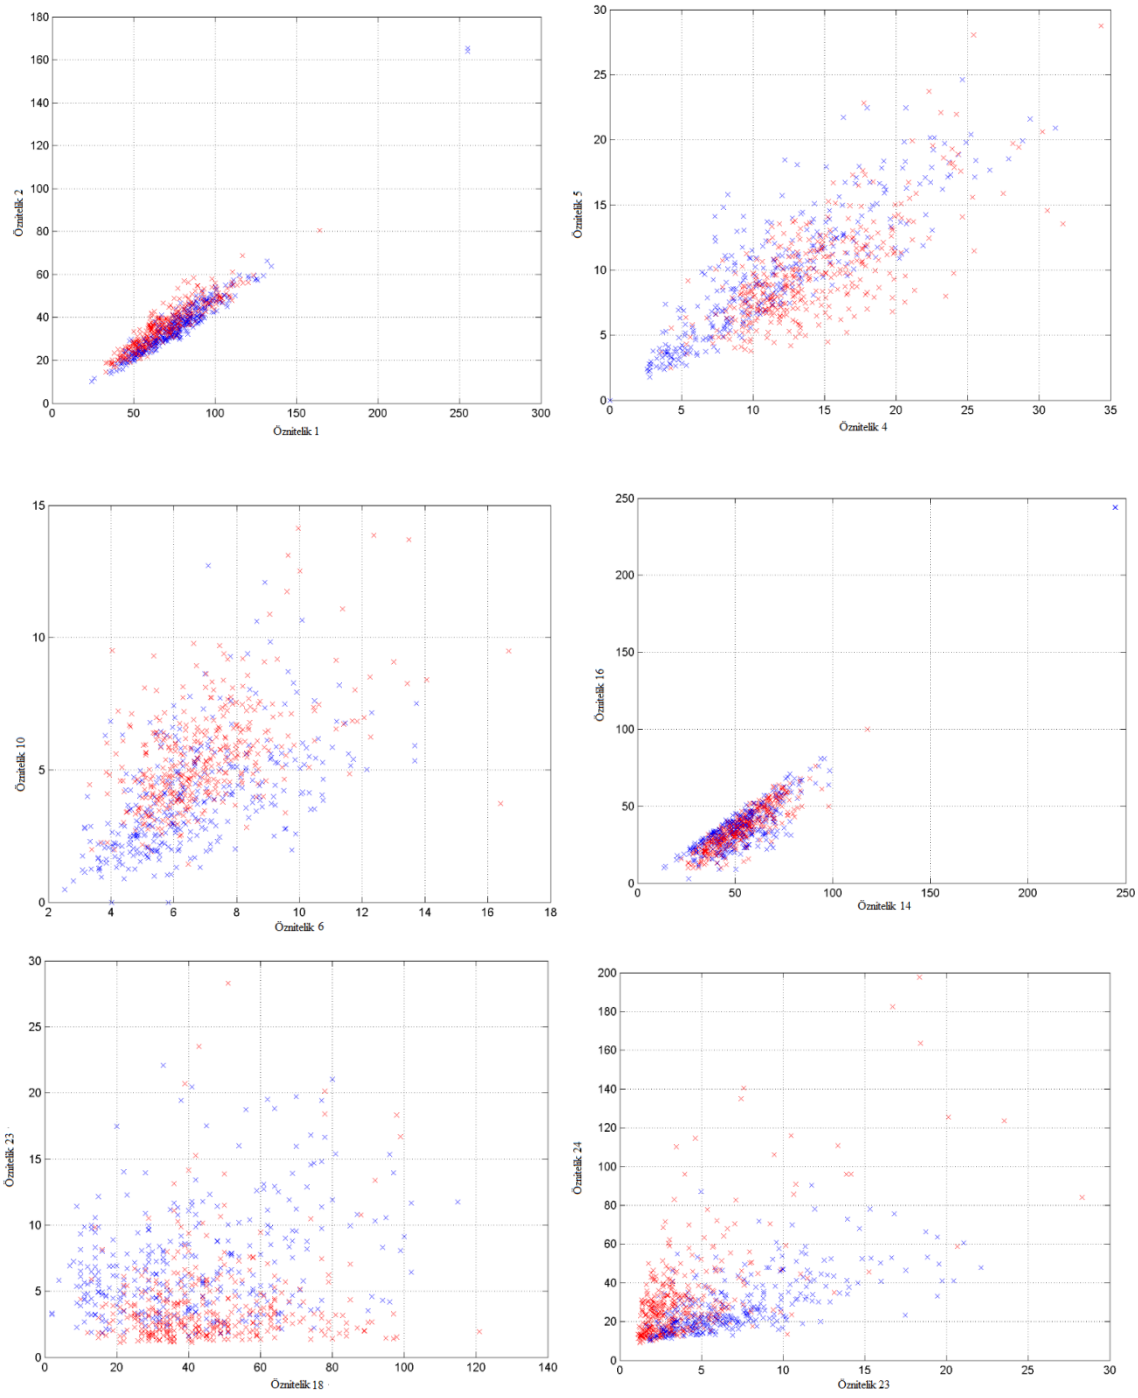

EK-B

ELMA GÖRÜNTÜSÜNÜN RENK UZAYLARI BİLEŞENLERİ VE PİKSEL DAĞILIMLARI

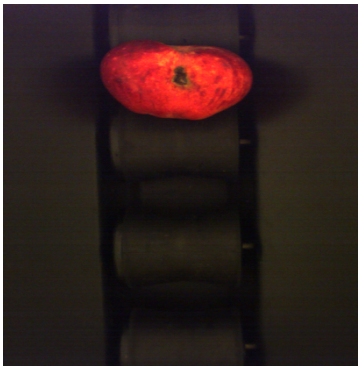

RGB Görüntü

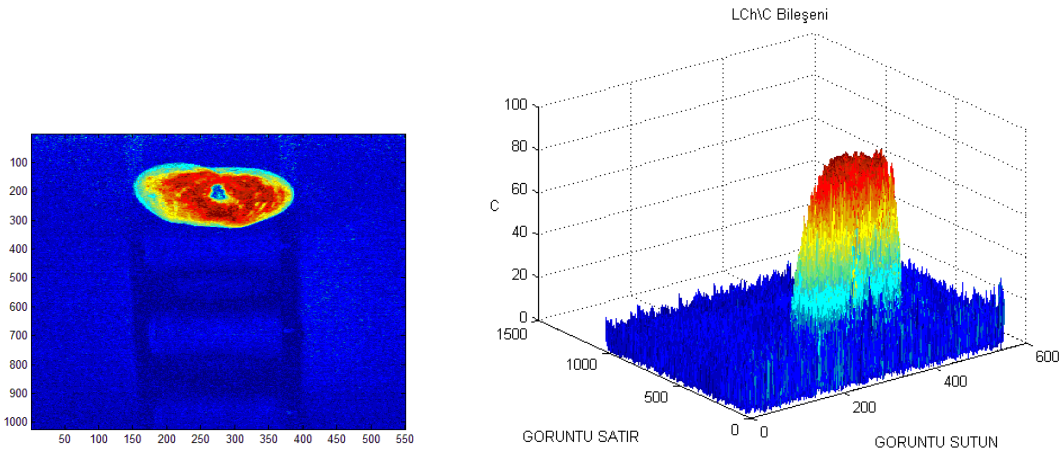

CIEL*C*h Renk Uzayı "C" Bileşeni

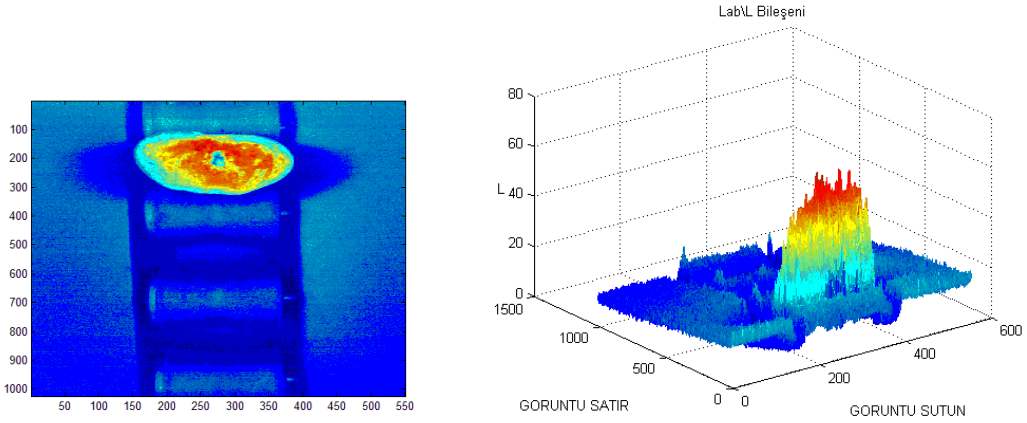

CIE L*a*b* Renk Uzayı "L" Bileşeni

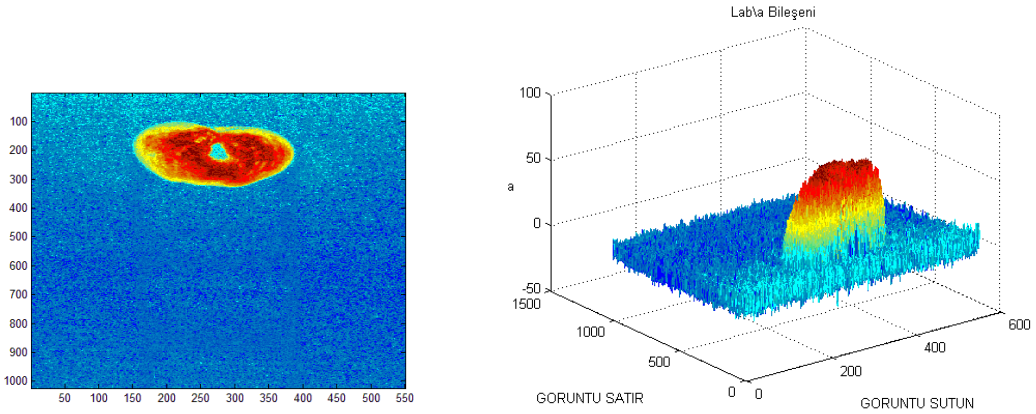

CIE L*a*b* Renk Uzayı "a" Bileşeni

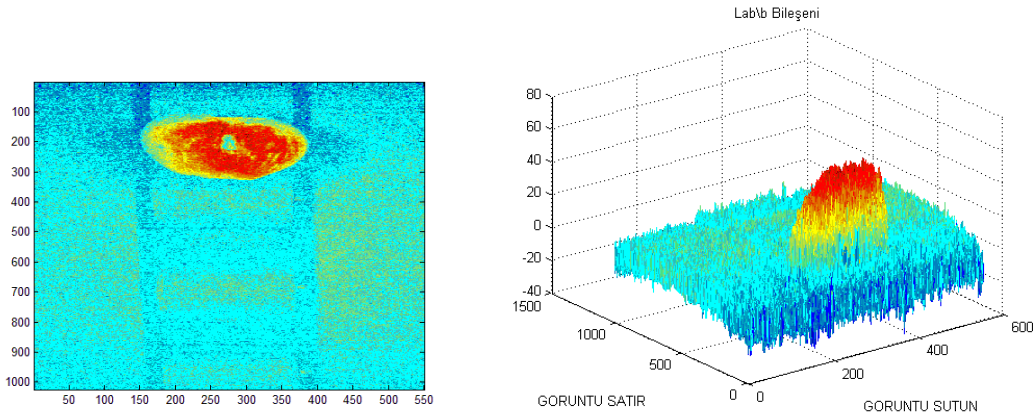

CIE L*a*b* Renk Uzayı "b" Bileşeni

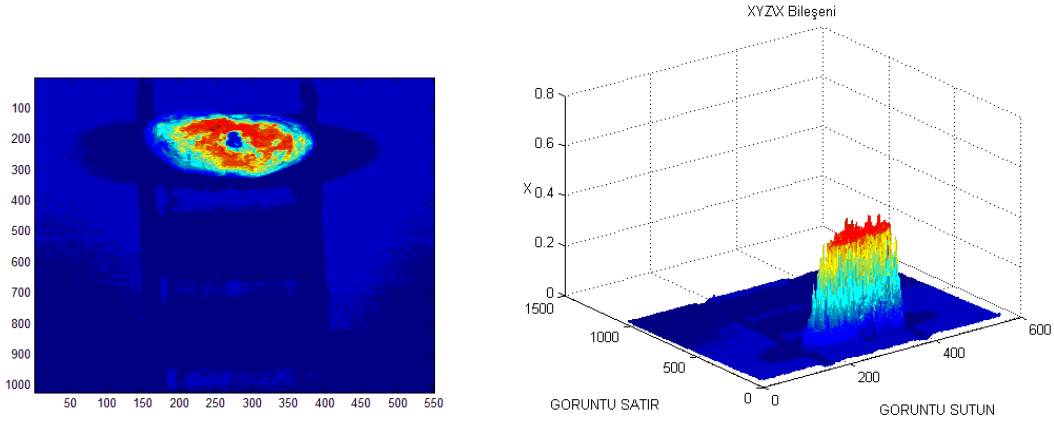

CIE XYZ Renk Uzayı “X” Bileşeni

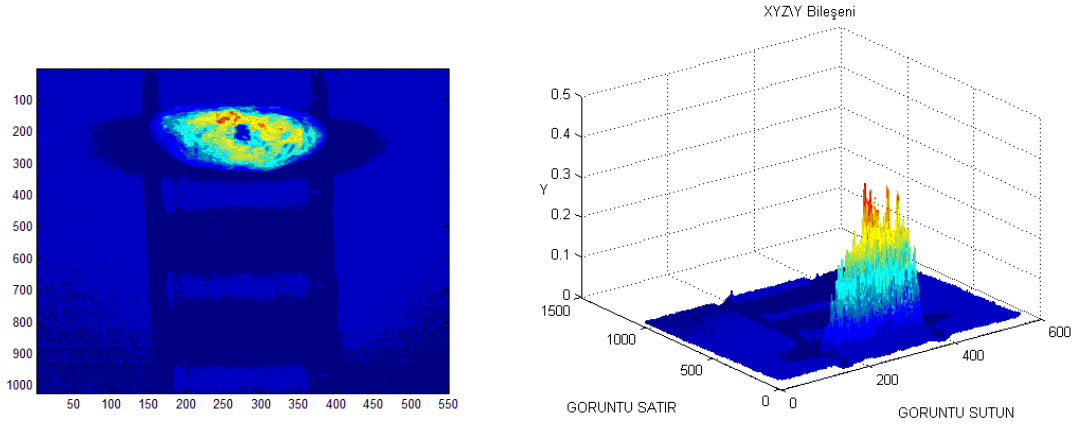

CIE XYZ Renk Uzayı “Y” Bileşeni

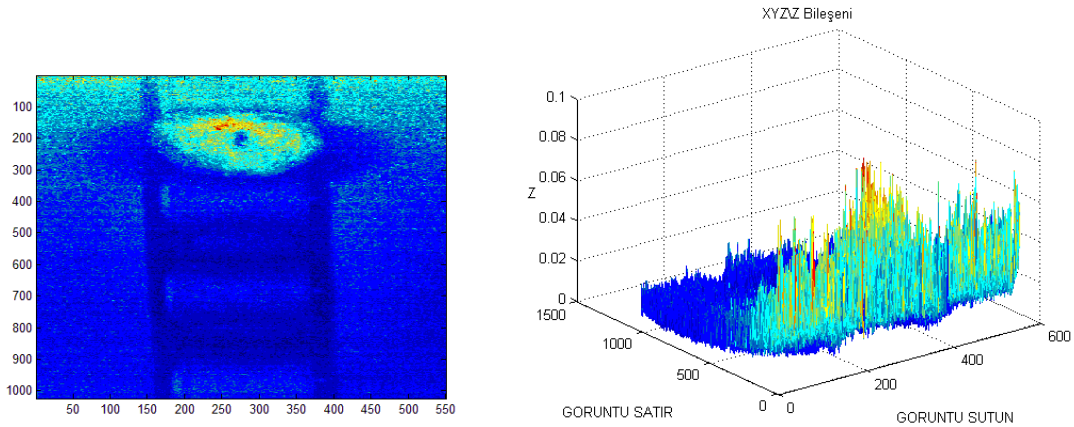

CIE XYZ Renk Uzayı “Z” Bileşeni

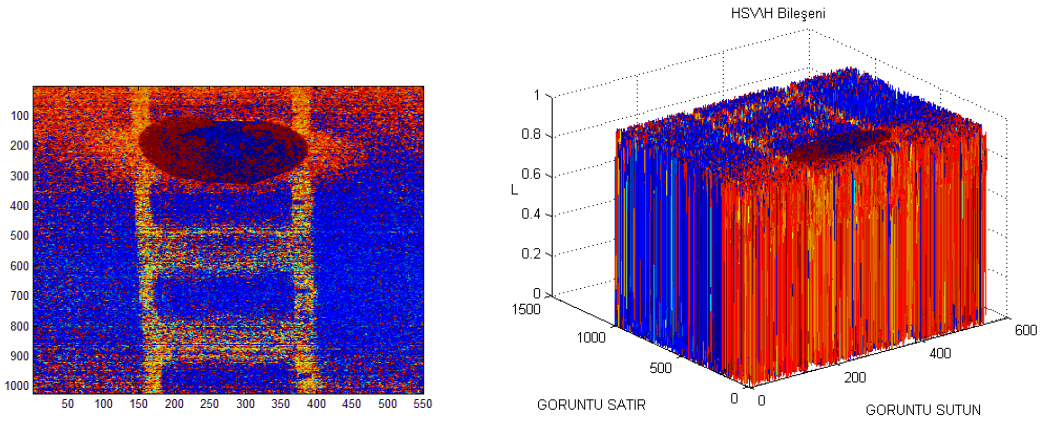

HSV Renk Uzayı “H” Bileşeni

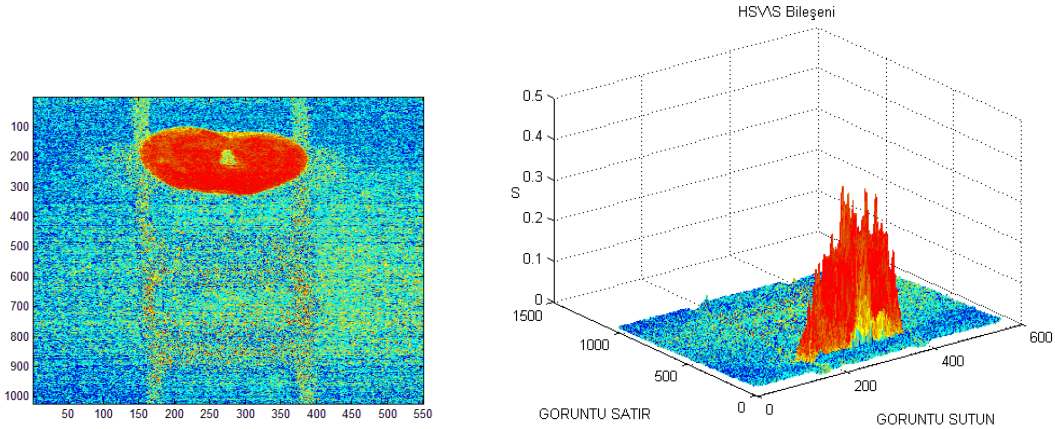

HSV Renk Uzayı “S” Bileşeni

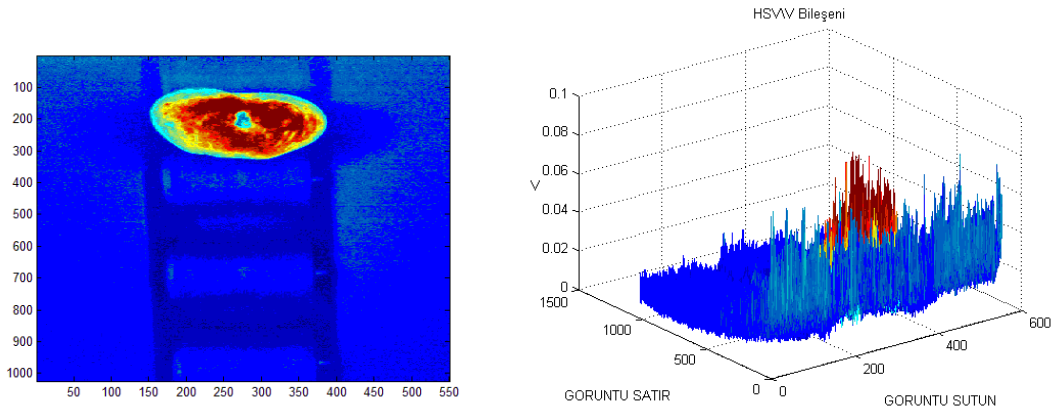

HSV Renk Uzayı “V” Bileşeni

EK-C

PROGRAMLANABİLİR MANTIKSAL DENETLEYİCİ MERDİVEN PROGRAMI

Network 1 : Title:

"M101.3" SCADA tarafından kontrol edilmektedir. Ağırlık duyarlımı yoksa Makine görme yazılımının mı çalışacağını belirler. Normalde kapalı olduğundan başlangıç makine görme sistemidir.

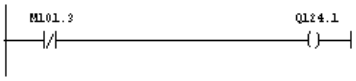

Network 2 : Title:

"M99.4" florosan lamba durumu belirlenir.

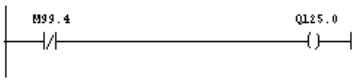

Network 3 : Title:

Comment:

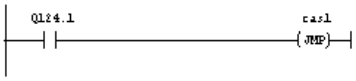

Network 4 : Title:

Comment:

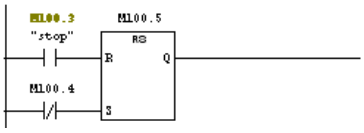

Network 5 : Title:

M100.6 SCADA "Başlat" butonuna etiketlidir. Bu nedenle kütle sınıflandırmasının içine girince lamba kapanır...



Network 6 : Title:

"FC1" Elma kütleye göre sınıflandırma



Network 7 : Title:

"FC2" yük hücresinde gelen değerin gerçek elma ağırlık değerine dönüştürülmesi

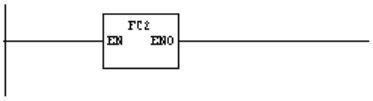

Network 8 : Title:

Bu kısım elma verilerinin toplandığı ve matlab veritoplama programı ile uyumlu çalışan kısımdır. 2 adet fotoğraf çekme sinyali matlaba gönderilir.



Network 9 : Title:

"I125.0=elma sayma" ve "I124.7=mil sayma" girişleri



Network 10 : Title:

İki sensörün aynı anda "1" olduğu durumda elma geldi ve elma göründükten sonraki 3. mil ve 5. mil de fotoğraf çek komutu shift register ile verilir

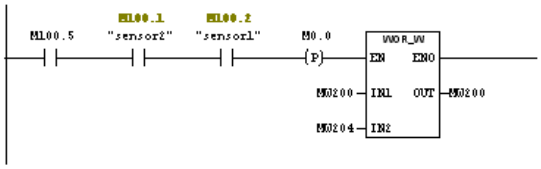

Network 11 : Title:

Comment:

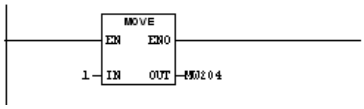

Network 12 : Title:

Comment:

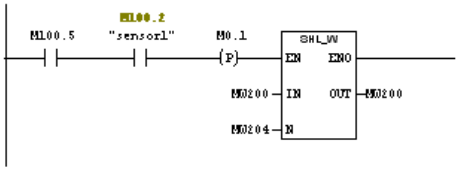

Network 13 : Title:

Comment:

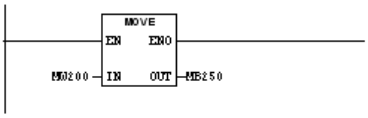

Network 14 : Title:

Comment:



Network 15 : Title:

Comment:

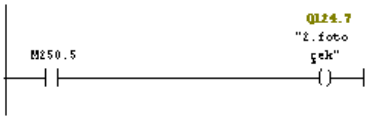

Network 16 : Title:

SCADA'dan verilen inverter hız bilgisi PLC'nin Analog çıkışına iletilir

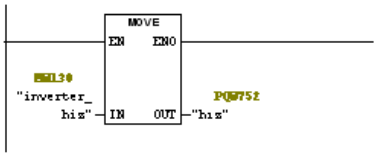

Network 17 : Title:

Yük hücresi bağlı olan Analog giriş "MW120" word'üne aktarılır.



Network 18 : Title:

"FC3" Elma renk/boy veya kusura göre sınıflandırma yapılacak ise FC3 çalıştırılır...

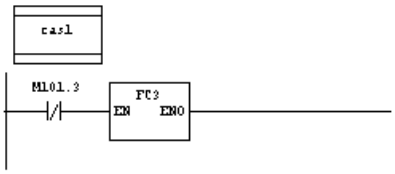

FONKSİYON 1 (Kütlesine göre elma sınıflandırma)

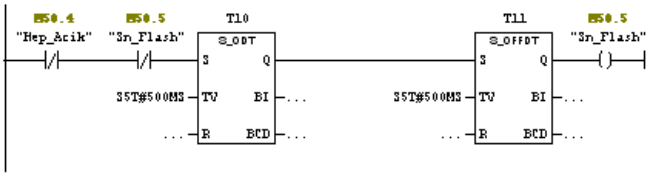

Network 2 : Title:

Kütle(MD60) 30gr'dan büyük veya küçük ise elma geldi.
Elma geldi bilgisinden 1.8 sn sonra kütle bilgisini oku..

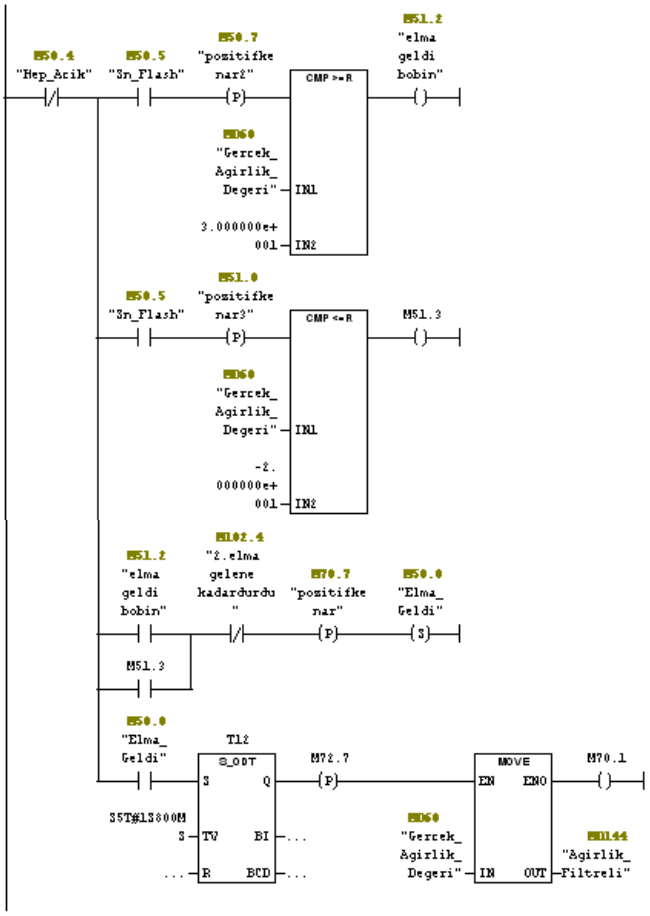

Network 3 : Title:

SCADA ekranındaki elma kütle değerini 7sn sonra sıfırla..

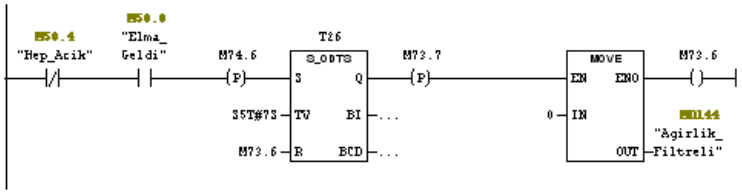

Network 4 : Title:

ikki elma arasındaki sınıflandırma süresi 10sn olarak belirlermiştir.



Network 5 : Title:

Comment:

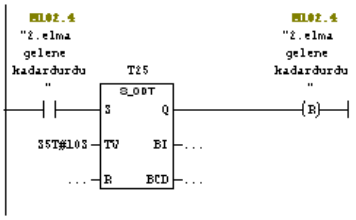

Network 6 : Title:

Ağırlık değerinin virgülden sonraki basamakları atılarak SCADA'ya gönderiliyor

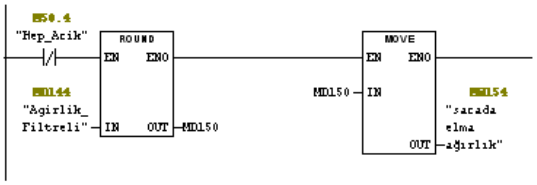

Network 7 : Title:

3s sonra elma geldi resetleniyor..

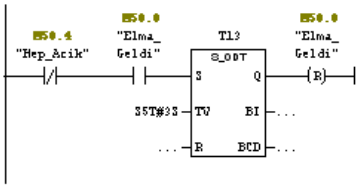

Network 8 : Title:

Elma geldikten 2s sonra elmanın bulunduğu kap açılıyor, elma ayırıcı birime düştükten sonra kapatılıyor

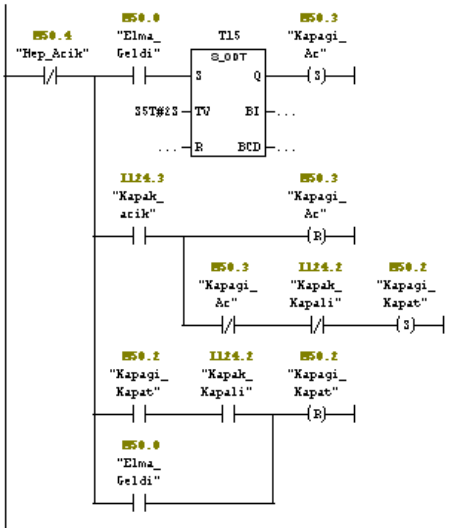

Network 9 : Title:

Kapağı çalıştıran DC motorun ileri ve geri dönmesi sağlanıyor.

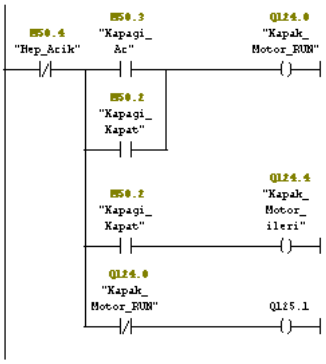

Network 10 : Title:

Elma geldikten 1.8sn sonraki yük hücresinden elde edilen kütle değerine göre elmalar 200gr dan yukarı olanlar 1. sınıfa, 160-200gr arası olanlar 2. sınıfa, 120.160 gr olanlar 3. sınıfa ve 120gr dan düşüklerde 4. sınıfa ayrılıyor.

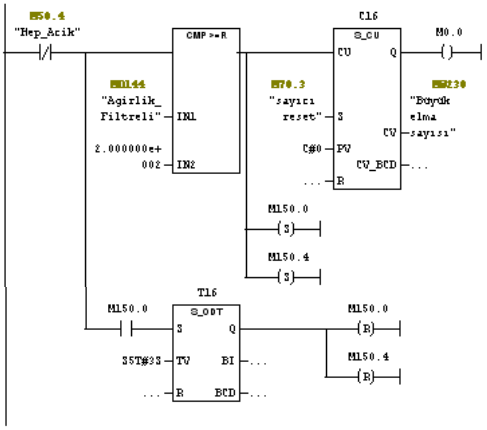

Network 11 : Title:

Comment:

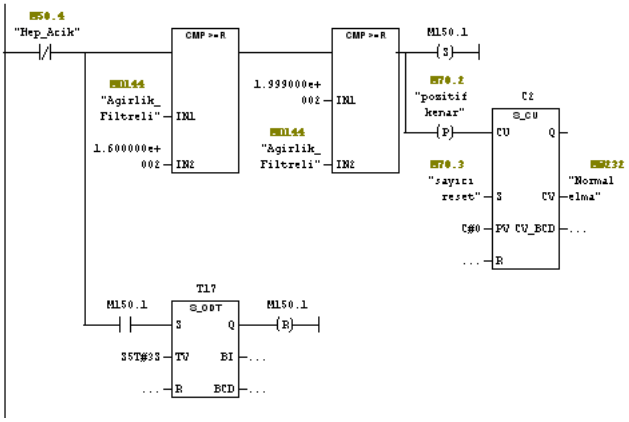

Network 12 : Title:

Comment:

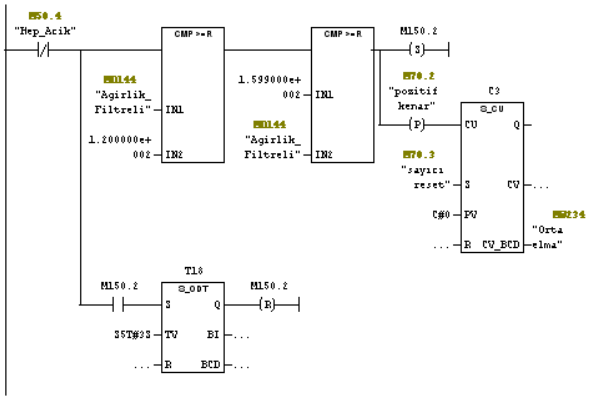

Network 13 : Title:

Comment:

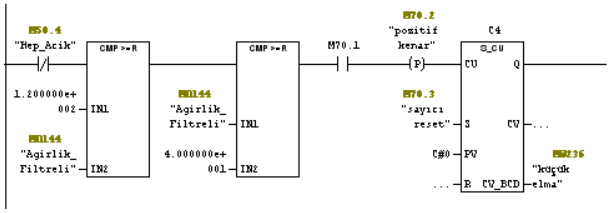

Network 14 : Title:

Pistonlar sınıfa göre hareket ettiriliyor....

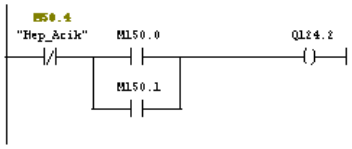

Network 15 : Title:

Comment:

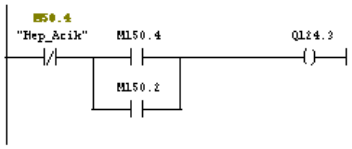

FONKSİYON 2(Kütle ölçümü)

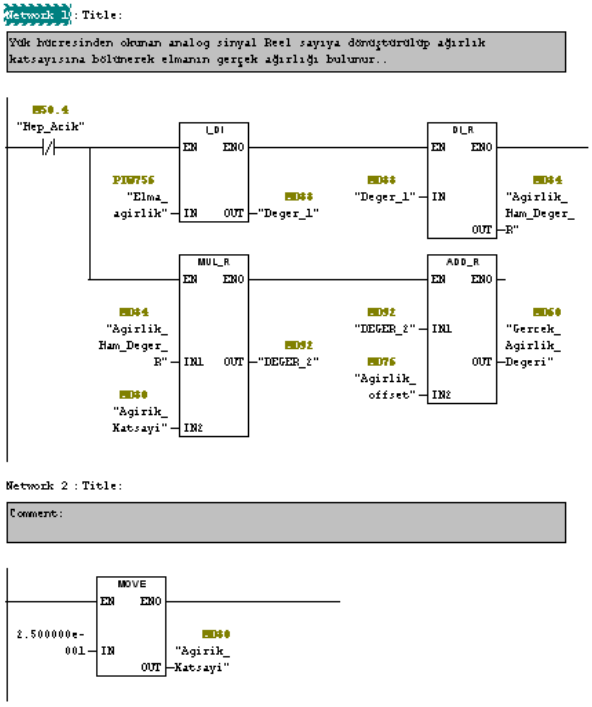

Fonksiyon3(Makine görmesi Piston hareketi)

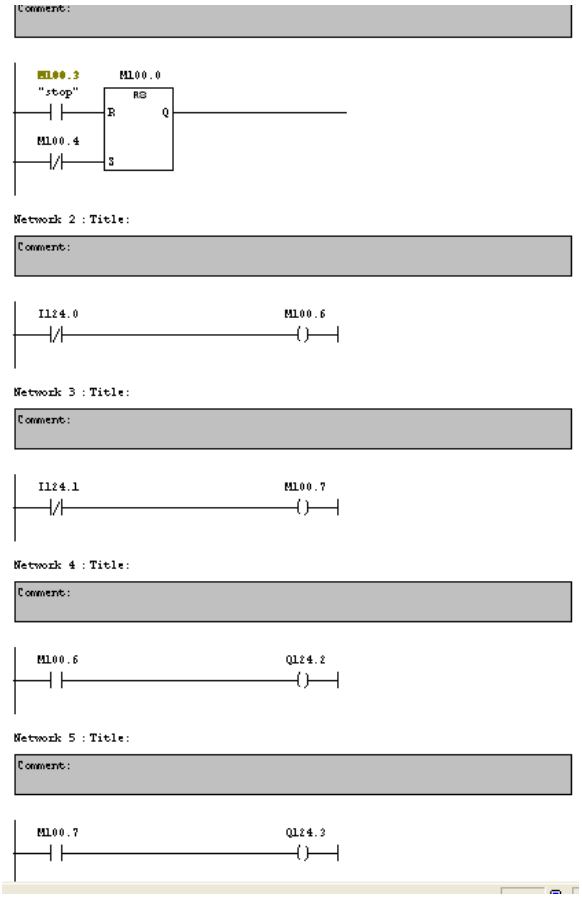

EK-D

MAKİNE GÖRMESİ ELMA SINIFLANDIRMA SİSTEMİNİN MATLAB ORTAMINDA YAZILAN KODLARDAN BAZILARI

*Rgb Renk Uzayından CIE XYZ ve CIE L*a*b* Renk uzayı Bileşenlerin D55 Aydınlatma Koşullarına Göre Elde Edilmesi*

```
function [a,Y,C] = rgb2lab_HT_D55_norm(appleImage)
Rprime = double(appleImage(:,:,1))/255;
Gprime = double(appleImage(:,:,2))/255;
Bprime = double(appleImage(:,:,3))/255;
R = 1/12.92*Rprime.*(Rprime<=0.04045)+
    (((Rprime+0.055)/1.055).^2.4).*(Rprime>0.04045);
G = 1/12.92*Gprime.*(Gprime<=0.04045)+
    (((Gprime+0.055)/1.055).^2.4).*(Gprime>0.04045);
B = 1/12.92*Bprime.*(Bprime<=0.04045)+
    (((Bprime+0.055)/1.055).^2.4).*(Bprime>0.04045);


T = 0.008856;


% sRGB D65
M = [0.412453  0.357580  0.180423
     0.212671  0.715160  0.072169
     0.019334  0.119193  0.950227];


XYZ = M*[R(:)';G(:)';B(:)'];

X = reshape(XYZ(1,:),size(R));
Y = reshape(XYZ(2,:),size(R));
Z = reshape(XYZ(3,:),size(R));


% http://brucelindbloom.com/index.html?Eqn_RGB_XYZ_Matrix.html
XYZ_WS = [0.95047   1.00000 1.08883]; % D65
XYZ_WD = [0.95682   1.00000 0.92149]; % D55


% Bradford
% MA = [0.8951000  0.2664000 -0.1614000
%      -0.7502000  1.7135000  0.0367000
%       0.0389000 -0.0685000  1.0296000];
% MAinv = [0.9869929 -0.1470543  0.1599627
```

```
%        0.4323053  0.5183603  0.0492912
%       -0.0085287  0.0400428  0.9684867];
% Von Kries
 MA = [0.4002400  0.7076000 -0.0808100
      -0.2263000  1.1653200  0.0457000
       0.0000000  0.0000000  0.9182200];
 MAinv = [1.8599364 -1.1293816  0.2198974
          0.3611914  0.6388125 -0.0000064
          0.0000000  0.0000000  1.0890636];

MM = MAinv*diag((MA*XYZ_WD')./(MA*XYZ_WS'))*MA;

XYZ_F2 = MM*XYZ;

X_F2 = reshape(XYZ_F2(1,:),size(R));
Y_F2 = reshape(XYZ_F2(2,:),size(R));
Z_F2 = reshape(XYZ_F2(3,:),size(R));

X_F2 = X_F2 / XYZ_WD(1);
Y_F2 = Y_F2 / XYZ_WD(2);
Z_F2 = Z_F2 / XYZ_WD(3);

XT = X_F2>T;
YT = Y_F2>T;
ZT = Z_F2>T;

fX = (7.787 * X_F2 + 16/116).*(~XT)+(X_F2.*XT).^(1/3);
fY = (7.787 * Y_F2 + 16/116).*(~YT)+(Y_F2.*YT).^(1/3);
fZ = (7.787 * Z_F2 + 16/116).*(~ZT)+(Z_F2.*ZT).^(1/3);

a = 500*(fX-fY);
b = 200*(fY-fZ);

C = sqrt(a.^2+b.^2);
```

Kamera tanıtılması ve yazılımsal ayarlarının yapılması

```
vid = videoinput('winvideo', 1,'RGB32_1280x1024','ROIPosition',[350 0
550 1024]);
src = getselectedsource(vid); % görüntüyü netleştirme ayarları
src.Exposure = -11;
src.Sharpness = 1;
triggerconfig(vid,'manual' triggering(immediate type)
set(vid,'FramesPerTrigger',1,'ReturnedColorSpace','rgb'set(vid,'Trigge
rRepeat',Inf);
```

GİRİŞ/ÇIKIŞ kartının tanıtılması ve giriş/çıkış ayarlarının yapılması

```
result = daqregister('nidaq');
dio = digitalio('nidaq','Dev1'); % 0-7 --> p0, 8-11 --> p1 [4 tane]
addline(dio,8:11,'in'); % P1.0, P1.1, P1.2,P1.3 giriş olarak ayarlandı
addline(dio,0:5,'out'); % P0.0 dan P0.4  çıkış olarak ayarlandı
putvalue(dio.Line(5:6),[0 0]); % başlangıçta bağlı olan iki çıkış
sıfırlandı..
```

Elma Renk/boy

```
image1 = getsnapshot(vid);
while sum(image1(:))==0
disp('Siyahti...')
image1 = getsnapshot(vid);
end
image1 = getsnapshot(vid);
yeni2 = image1(200:650,80:450,:);
if ~exist('son10Elma','var')
    try
     son10Elma = evalin('base','son10Elma');
     son10Elma_CapRenk = evalin('base','son10Elma_CapRenk');
     son10Sayaci = evalin('base','son10Sayaci');
     catch MException
    end
 end

   if ~exist('son10Elma','var')
     son10Sayaci = 1;
     son10Elma = zeros([size(yeni2) 10]);
     son10Elma_CapRenk = zeros(10,2);
     son10Elma(:,:,:,1) = yeni2;
   else
     son10Sayaci = son10Sayaci + 1;
     son1000Sayaci = son1000Sayaci+1;
        if son10Sayaci <= 10
          son10Elma(:,:,:,son10Sayaci) = yeni2;
        else
         son10Elma(:,:,:,1:end-1) = son10Elma(:,:,:,2:end);
         son10Elma(:,:,:,end) = yeni2;
         end
    end

% Yuksek cozunurluklu maskeleme yavas oldugu icin,
      dusuk cozunurluklu deniyoruz.
 [Nr,Nc,Nch] = size(yeni2);
% Ornekleme hizini dusurme orani
ddd = 8;
lowRes = yeni2(1:ddd:end,1:ddd:end,:);
 % Maskede 1'ler kirmizi, 2'ler sari oluyor.
mask = detectMiddleApple2_normEski(lowRes,se,ddd^2);
% Tekrar cozunurluk arttiriliyor.
mask = imresize(mask,[Nr Nc],'nearest');
```

```
% Maskenin renkten bagimsiz oluşu

M = mask > 0;
horizontalProjection = sum(M,1)>0;%yatayda topluyoruz
verticalProjection = sum(M,2)>0;%dikeyde topluyoruz
startX = find(horizontalProjection,1);%baştan taramaya başlıyor 1 olan
yerde duruyor
startY = find(verticalProjection,1);
endX = find(horizontalProjection,1,'last');%last-sondan başlıyor
taramaya
endY = find(verticalProjection,1,'last');

% Cevreleyen kutunun boyutlari
Lx = endX-startX;
Ly = endY-startY;

      try
            renk = renkler(median(mask(mask>0)));
      catch MException
 disp('Mil bir kaydiriliyor...')
 milCounter = milCounter + 1;
           continue;
      end

      try
         index = milCounter - fotodanOncekiMilSayisi;
         index = index + 25*(index<=0);

             if get(handles.radiobutton1,'Value')
                boy = max(Lx,Ly);
             elseif get(handles.radiobutton2,'Value')
                boy = min(Lx,Ly);
             else % if get(handles.radiobutton3,'Value')
                boy = mean(Lx,Ly);
             end
          miller(index,:) = [1 renk boy>boyEsik];
          disp(['Islem zamani: ' num2str(toc(elmaIslemeBaslangic))])
                    % 5 renk, 6 cap,
                    % renk 1 kirmizi, 0 sari
          set(handles.edit6,'String',num2str(boy*0.312));

                if renk
                   set(handles.edit5,'String','Kirmizi');
                else
                        set(handles.edit5,'String','Sari');
                end

          son10Elma_CapRenk(son10Sayaci,:) = [boy renk];
          tarih = datevec(datenum(date));
          tarih = tarih(1:3); % yil, ay, gun
          tarih = tarih(1)*10000+tarih(2)*100+tarih(3);
          son1000Elma_CapRenk(son1000Sayaci,:) = [tarih boy*0.312 renk
                  Lx*0.312 Ly*0.312 boyEsik*0.312];

    catch MException
      disp('Elma yokmus...');
    end
```

Elma Yüzey kalitesine göre sınıflandırma

```
ayarMiliSayisi = 11; % Toplam mil sayisi
milAraliklari = zeros(ayarMiliSayisi-1,1);
fotoCekmeSuresi = 2*median(milAraliklari)/10;
beklemeSuresi = 0;
beklemeZamanSayaci = uint64(0);
beklemeZamanSayaciRenk = uint64(0);

% Arka arkaya 25 tane fotograf cekiliyor.

      for k = 1:fotoSayisi
          image2(:,:,:,k) = getsnapshot(vid);
      end
yeni2 = image2(50:450,:,:,1);
% Yuksek cozunurluklu maskeleme yavas oldugu icin, dusuk
[Nr,Nc,Nch] = size(yeni2);
ddd = 8;
lowRes = yeni2(1:ddd:end,1:ddd:end,:);
mask = detectMiddleApple2_normEski(lowRes,se,ddd*ddd);
mask = imresize(mask,[Nr Nc],'nearest');
M = mask > 0;
horizontalProjection = sum(M,1)>0;%yatayda topluyoruz
verticalProjection = sum(M,2)>0;%dikeyde topluyoruz
startX = find(horizontalProjection,1);%baştan taramaya başlıyor 1 olan
yerde duruyor
startY = find(verticalProjection,1);
endX = find(horizontalProjection,1,'last');%last-sondan başlıyor
taramaya
endY = find(verticalProjection,1,'last');
cap = max(sum(M));
cap2 = endY-startY+1;
disp(['Cap1: ' num2str(cap) ', Cap2: ' num2str(cap2)])
% /////2. Fotoğrafı çekilen 25 fotoğraf arasından seçmek üzere yapılan
hesaplar//////////
cevre = pi*cap; % piksel
T = beklemeSuresi;
f = 1/T;

% Kameranin gorus alaninin uzunlugu [3.5 tane rulo arasi mesafe oldugu
icin:]
L = size(squeeze(image2(:,:,:,1)),1)/3.5; % birimi piksel
buyukRuloCapi = 78/0.3; % mm*mm/piksel = birimi piksel
kucukRuloCapi = 68/0.3; % mm*mm/piksel = birimi piksel
ortalamaRuloCapi = 73/0.3; % piksel
rulonunLdekiTurSayisi = L/(pi*buyukRuloCapi);
elmaninLdekiTurSayisi = rulonunLdekiTurSayisi*ortalamaRuloCapi/cap;
ikiElmaArasiBekleme =  1/2*L/elmaninLdekiTurSayisi;
disp('foto secimi')
maskeler = squeeze(image2(:,:,1,:))>100;
verticalSum = squeeze(sum(maskeler,2));
ustKenar = zeros(fotoSayisi,1);
      for k = 1:fotoSayisi
          ustKenar(k) = find(verticalSum(:,k),1);
       end
ikinciFotoIndeksi = find(ustKenar-ustKenar(1)>ikiElmaArasiBekleme,1);
```

```
 elma1 = image2(50:end-300,50:400,:,1);
 elma2 = image2(300:end-100,50:400,:,ikinciFotoIndeksi);
 disp('son 10 elma olaylari')
       if ~exist('son10Elma_Curuk1','var')
          try
          son10Elma_Curuk1 = evalin('base','son10Elma_Curuk1');
          son10Elma_Curuk2 = evalin('base','son10Elma_Curuk2');
          son10Sayaci_Curuk = evalin('base','son10Sayaci_Curuk');
          catch MException
          end
       end

       if ~exist('son10Elma_Curuk1','var')
           son10Sayaci_Curuk = 1;
           son10Elma_Curuk1 = zeros([size(elma1) 10]);
           son10Elma_Curuk2 = zeros([size(elma2) 10]);
           son10Elma_Curuk1(:,:,:,1) = elma1;
           son10Elma_Curuk2(:,:,:,1) = elma2;
       else
           son10Sayaci_Curuk = son10Sayaci_Curuk + 1;
              if son10Sayaci_Curuk <= 10
                 son10Elma_Curuk1(:,:,:,son10Sayaci_Curuk) = elma1;
                 son10Elma_Curuk2(:,:,:,son10Sayaci_Curuk) = elma2;
              else
       son10Elma_Curuk1(:,:,:,1:end-1) =son10Elma_Curuk1(:,:,:,2:end);
       son10Elma_Curuk2(:,:,:,1:end-1) =son10Elma_Curuk2(:,:,:,2:end);
       son10Elma_Curuk1(:,:,:,end) = elma1;
       son10Elma_Curuk2(:,:,:,end) = elma2;
              end
       end
mask1 = detectMiddleApple_SapKok(elma1);toc;
mask1 = imclose(mask1,strel('disk',1));toc;
dolu1 = imfill(mask1,'holes');
kahveM1 = dolu1-mask1;
% Adaciklar olusmustur diye, her birini etiketliyoruz.
L1 = bwlabel(kahveM1);toc;
etiketler1 = unique(L1);
etiketler1(1) = []; % 0'i atiyoruz.
% Her bir etiket icun, 100'den kucuk olanlari atiyoruz.
       for k = 1:length(etiketler1)
           if sum(L1(:)==etiketler1(k)) < 50
               L1(L1==etiketler1(k)) = 0;
            end
       end;
mask2 = detectMiddleApple_SapKok(elma2);
mask2 = imclose(mask2,strel('disk',1));
dolu2 = imfill(mask2,'holes');
kahveM2 = dolu2-mask2;
% Adaciklar olusmustur diye, her birini etiketliyoruz.
L2 = bwlabel(kahveM2);
etiketler2 = unique(L2);
etiketler2(1) = [];
        for k = 1:length(etiketler2)
           if sum(L2(:)==etiketler2(k)) < 50
              L2(L2==etiketler2(k)) = 0;
           end
        end;
```

```
grayElma1 = rgb2gray(elma1);toc;
features1 = extractFeatures_test(elma1,grayElma1,L1);
grayElma2 = rgb2gray(elma2);
features2 = extractFeatures_test(elma2,grayElma2,L2);toc;
    if isempty([features1;features2]) %kusur bulunamazsa elma "Ekstra"
diye ayrılır
         classes = 1;
    else
      featureMatrix = [features1;features2];
      A = featureMatrix;
      Ntest = size(featureMatrix,1);
      testingNorm = (A-repmat(min(A),[Ntest...
            1]))./(repmat(max(A),[Ntest 1])-repmat(min(A),[Ntest 1]));
       classes = svmclassify(svmStruct,testingNorm);
       curukInd = find(classes==2);
       curukMask1 = L1*0;
       curukMask2 = L2*0;
       etiketler1 = unique(L1);
       etiketler1(1)= [] ; % etiket = 0i atiyoruz.
       etiketler2 = unique(L2);
       etiketler2(1)= [] ; % etiket = 0i atiyoruz.

            for k = 1:length(curukInd)
                if curukInd(k)<=size(features1,1)
                   curukMask1(L1==etiketler1(curukInd(k)))=3;
                else
              curukMask2(L2==etiketler2(curukInd(k)-size(features1,1)))=3;
                end
             end
       axis(handles.axes1);
       imagesc(uint8(cat(1,cat(2,elma1,repmat((curukMask1+mask1)*30,[1
        1 3])),cat(2,elma2,repmat((curukMask2+mask2)*30,[1 1 3])))))
       axis square
       axis off
       drawnow;
       curukAlanlari = featureMatrix(curukInd,end);
       toplamCurukAlani = sum(curukAlanlari);
       set(handles.text25,'String',['Toplam kusur alani = '
            num2str(toplamCurukAlani)]);

                    % Ekstra
                    % Sınıf 1 <30
                    % sınıf 2 <60
                    % Reddedilen <90
        if toplamCurukAlani <=str2double(get(handles.edit10,'String'))
           putvalue(dio.Line(5:6),[0 0]);
           sayi = str2double(get(handles.edit1,'String'));
           sayi = sayi+1;
           set(handles.edit1,'String',num2str(sayi));
     elseif toplamCurukAlani<=str2double(get(handles.edit11,'String'))
           putvalue(dio.Line(5:6),[0 1]);
           sayi = str2double(get(handles.edit2,'String'));
           sayi = sayi+1;
           set(handles.edit2,'String',num2str(sayi));
     elseif toplamCurukAlani<=str2double(get(handles.edit12,'String'))
           putvalue(dio.Line(5:6),[1 0]);
           sayi = str2double(get(handles.edit3,'String'));
           sayi = sayi+1;
           set(handles.edit3,'String',num2str(sayi));
```

```
    else
          putvalue(dio.Line(5:6),[1 1]);
          sayi = str2double(get(handles.edit4,'String'));
          sayi = sayi+1;
          set(handles.edit4,'String',num2str(sayi));
    end

end
```

EK-E

KAMERA ve LENS ÖZELLİKLERİ



ÖZELLİKLER		
Odak uzaklığı :	6mm	
Çözünürlük :	1.3 mega-pixel	
Arka odak :	8.55mm	
Montaj	C	
F/No :	1.4	
Format :	1/2"	
Iris tipi :	Manual Iris	
Görüş Açısı :	**1/2"**	56°
	1/3"	43.6°
	1/4"	33.4°
Odaklanma Oranı :	∞ ~ 0.2m	
Elemanlar :	9 cam	
Ölçüler :	¢ 32 x32.514mm	
Ağırlık :	100g	



KAMERA ÖZELLİKLER	
Bağlantı	USB 2
Çözünürlük :	1280x1024
Sensör :	CMOS
Çözünürlük Derinliği	8 bit
Maks. Fps	25
Sensör Boyu	1/1.8"
Ölçüler :	44x44x25,4 mm
Ağırlık :	32 gr

ÖZGEÇMİŞ

03.06.1982'de Kırklareli'nde doğdu. İlk ve orta eğitimimi Kırklareli'nde tamamladıktan sonra Lise eğitimine Kırklareli Teknik ve Endüstri Meslek Lisesi Elektrik Bölümünde devam etti. 2000 yılında Marmara Üniversitesi Teknik Eğitim Fakültesi Elektrik bölümünü kazandı. 2004 yılında buradan mezun oldu. 2005 yılında Marmara Üniversitesi Fen Bilimleri Enstitüsü Elektrik Eğitimi Ana Bilim Dalı'nda Yüksek Lisansını eğitimine başladı. 2007 yılında Trakya Üniversitesi Teknik Eğitim Fakültesi Elektrik Eğitimi Bölümüne Araştırma görevlisi olarak atandı. Mart 2008'de Yüksek Lisansını bitirerek 2008 yılı başında Trakya Üniversitesi Mühendislik Mimarlık Fakültesi Makine Mühendisliği Bölümünde Doktora eğitimine başladı. Aynı yıl Kırklareli Üniversitesi Pınarhisar Meslek Yüksek Okuluna öğretim görevlisi olarak geçiş yaptı ve halen aynı görevi sürdürmektedir.

.