

OLGUNLAŞMAMIŞ ŞEFTALİ MEYVESİNİ DOĞAL BAHÇE
KOŞULLARINDA ALINMIŞ GÖRÜNTÜLERDE GÖRÜNTÜ İŞLEME
TEKNİKLERİ VE YAPAY SINIFLANDIRICILARLA SAPTAYARAK
SAYAN ALGORİTMALARIN GELİŞTİRİLMESİ

Ferhat KURTULMUŞ



T.C.
ULUDAĞ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

OLGUNLAŞMAMIŞ ŞEFTALİ MEYVESİNİ DOĞAL BAHÇE KOŞULLARINDA
ALINMIŞ GÖRÜNTÜLERDE GÖRÜNTÜ İŞLEME TEKNİKLERİ VE YAPAY
SINIFLANDIRICILARLA SAPTAYARAK SAYAN ALGORİTMALARIN
GELİŞTİRİLMESİ

Ferhat KURTULMUŞ

Doç.Dr. Ali VARDAR
(Danışman)

DOKTORA TEZİ
TARIM MAKİNALARI ANABİLİM DALI

BURSA-2012

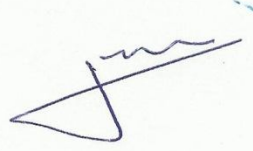
Her Hakkı Saklıdır

TEZ ONAYI

Ferhat KURTULMUŞ tarafından hazırlanan “Olgunlaşmamış Şeftali Meyvesini Doğal Bahçe Koşullarında Alınmış Görüntülerde Görüntü İşleme Teknikleri ve Yapay Sınıflandırıcılarla Saptayarak Sayan Algoritmaların Geliştirilmesi” adlı tez çalışması aşağıdaki jüri tarafından oy birliği/oy çokluğu ile Uludağ Üniversitesi Fen Bilimleri Enstitüsü Tarım Makinaları Anabilim Dalı’nda **DOKTORA TEZİ** olarak kabul edilmiştir.

Danışman : Doç. Dr. Ali VARDAR

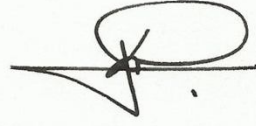
Başkan : Prof. Dr. Bülent EKER
Namık Kemal Üniversitesi
Ziraat Fakültesi
Tarım Makinaları Anabilim Dalı



Üye : Prof. Dr. Rasim OKURSOY
Uludağ Üniversitesi
Ziraat Fakültesi
Tarım Makinaları Anabilim Dalı



Üye : Prof. Dr. İsmail KAVDIR
Çanakkale Onsekiz Mart Üniversitesi
Ziraat Fakültesi
Tarım Makinaları Anabilim Dalı



Üye : Doç. Dr. Ali VARDAR
Uludağ Üniversitesi
Ziraat Fakültesi
Tarım Makinaları Anabilim Dalı



Üye : Doç. Dr. Eşref İŞİK
Uludağ Üniversitesi
Ziraat Fakültesi
Tarım Makinaları Anabilim Dalı



Yukarıdaki sonucu onaylarım
Prof. Dr. Kadri ARSLAN
Enstitü Müdürü
.././....(Tarih)

U.Ü. Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada;

- tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- ve bu tezin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı,

beyan ederim.

.././....

Ferhat KURTULMUŞ

ÖZET

Doktora Tezi

OLGUNLAŞMAMIŞ ŞEFTALİ MEYVESİNİ DOĞAL BAHÇE KOŞULLARINDA ALINMIŞ GÖRÜNTÜLERDE GÖRÜNTÜ İŞLEME TEKNİKLERİ VE YAPAY SINIFLANDIRICILARLA SAPTAYARAK SAYAN ALGORİTMALARIN GELİŞTİRİLMESİ

Ferhat KURTULMUŞ

Uludağ Üniversitesi
Fen Bilimleri Enstitüsü
Tarım Makinaları Anabilim Dalı

Danışman: Doç. Dr. Ali VARDAR

Bu çalışmanın amacı ülkemiz için ekonomik değeri yüksek olan şeftali meyvesinin verim haritalamasına yönelik olarak meyvenin erken gelişme döneminde ve doğal ortamından alınmış sıradan renkli görüntülerinden meyveleri tespit ederek sayabilecek algoritmaların geliştirilmesi ve en iyi algoritma performanslarının ortaya koyulmasıdır. Algoritmaların geliştirilmesi ve test edilmesi için görüntüler Bursa Barakfaki köyünde yerel bir çiftçiye ait Elegance Lady çeşidi şeftali bahçesinden alınmıştır. Çalışmada histogram eşitleme ve logaritma dönüşümü gibi görüntü işleme tekniklerinden yararlanılarak doğal koşullarda alınmış görüntülerin aydınlanma koşulları zenginleştirilmiştir. Görüntü işleme tekniklerinden yararlanarak geliştirilen algoritmalar renk, şekil ve doku bilgisini kullanılan öznitelik çıkarma yöntemleriyle görüntülerden çıkarmışlardır. Bu çalışmada kullanılan öznitelik çıkarma yöntemleri, olgunlaşmamış şeftali bitkisini renkli görüntülerde saptama anlamında yenidirler. Çıkarılan özniteliklerle farklı sınıflandırıcıların performanslarını ortaya koymak amacıyla 7 adet sınıflandırıcı eğitilerek denenmiştir. Diskriminant analizi, K-en-yakın komşu, naive Bayes, regresyon ağaçları, sınıflandırma ağaçları, yapay sinir ağları ve destek vektör makinası bu çalışmada kullanılan sınıflandırıcılardır. Görüntülerde arka plan elemesi yapmak ve potansiyel meyve bölgelerini saptamak amacıyla üç farklı görüntü tarama yöntemi geliştirilmiştir. Algoritmaların meyve olarak sınıflandırdığı alt-pencereler blob analiziyle tekilleştirilip meyve sayıları tespit edilmiştir. Farklı meyve tarama yöntemleri, istatistiksel ve deneysel yollarla belirlenen farklı öznitelik birleşimleri, farklı yapay sınıflandırıcılarının kullanımıyla değişik algoritmalar türetilmiş, eğitim ve test setleri üzerinde denemeler gerçekleştirilmiştir. Geliştirilen algoritmaların performansları farklı aydınlanma koşullarını içerecek şekilde karşılaştırılmıştır. Çalışma kapsamında geliştirilen algoritmaların bazılarında % 85'ler düzeyinde saptama başarısı elde edilmiştir. Geliştirilen algoritmalar doğal bahçe koşullarında alınmış görüntülerdeki aydınlanma değişimlerinden fazla etkilenmemişlerdir.

Anahtar Kelimeler: Bilgisayarlı görü, meyve saptama, olgunlaşmamış şeftali, verim haritalama, hassas tarım, yapay sınıflandırıcılar

2012, xvii + 198 sayfa.

ABSTRACT

PhD Thesis

DEVELOPPING ALGORITHMS TO DETECT AND COUNT IMMATURE PEACH IN COLOUR IMAGES ACQUIRED IN NATURAL ORCHARD CONDITIONS USING IMAGE PROCESSING AND ARTIFICIAL CLASSIFIERS

Ferhat KURTULMUŞ

Uludag University
Graduate School of Natural and Applied Sciences
Department of Agricultural Machinery

Supervisor: Assoc. Prof. Dr. Ali VARDAR

The objectives of this study were to develop algorithms for detecting and counting immature peach fruit, having economic importance for our country, in colored natural canopy images acquired in natural orchard conditions using image processing and artificial classifiers and to provide algorithms having the best performance. For developing and testing algorithms, images were obtained from a peach orchard located in Barakfaki, Bursa. By utilizing image processing techniques such as logarithm transform and histogram equalization, illumination conditions of the images taken under natural conditions were enhanced. Algorithms extracted features via feature extraction methods relied on color, shape and texture. Feature extraction methods used in this study were novel for detecting immature peach fruits in color images. To provide performances of different classifiers with extracted features, 7 classifiers were trained and performed. Discriminant analysis, K-nearest neighbors, naive Bayes, regression trees, classification trees, neural networks and support vector machines were the classifiers used in this study. To eliminate background and to locate potential fruit regions in the images, 3 different image scanning approaches were developed. To count fruits in the images, sub-windows classified as fruit by the classifiers were singularized by a blob analysis. Various algorithms were derived by usage of different image scanning approaches, different feature combinations determined by statistical and experiential methods, different classifiers. Using a training set and a test set, experiments were carried out. Performances of the algorithms were compared including different illumination conditions. Some of the algorithms developed in the present study provided about 85% of detection performance. Proposed algorithms were not affected intensively by illumination changes in the images taken under natural orchard conditions.

Keywords: Computer vision, fruit detection, immature peach, yield mapping, precision agriculture, statistical classifiers

2012, xvii + 198 pages.

TEŐEKKÜR

Bu tez alıŐması sırasında, bilgi ve tecrübesiyle bana her zaman destek olan danıŐman hocam Do. Dr. Ali VARDAR'a, tez izleme komitemde bulunup deėerli fikirleriyle katkıda bulunan Prof. Dr. İsmail KAVDIR ve Do Dr. EŐref IŐIK'a tez alıŐmalarımın bir kısmını yurt dıŐında tamamlamama olanak saėlayan Yksek ėretim Kurulu'na, YurtdıŐında alıŐmalarımda bana byk destek saėlayan Do. Dr. Won Suk LEE'ye, alıŐmalarımda bana yardımcı olan deėerli arkadaŐlarım Ce YANG, Rajneesh BANSAL ve Ezgi KABERLİ'ye, tez alıŐmamı hazırlarken oėu zaman ihmal ettiėim aileme en iten duygularımla teŐekkr ederim.

Ferhat KURTULMUŐ

.../.../....

İÇİNDEKİLER

	Sayfa
ÖZET	i
ABSTRACT	ii
TEŞEKKÜR	iii
SİMGE ve KISALTMALAR DİZİNİ	viii
ŞEKİLLER DİZİNİ	xi
ÇİZELGELER DİZİNİ	xv
1. GİRİŞ	1
2. KAYNAK ARAŞTIRMASI.....	7
2.1. Görüntü İşleme ve Bilgisayarlı Görü ile İlgili Kavramlar	7
2.1.1. Görüntü işleme ve bilgisayarlı görünün tanımı	8
2.1.2. Görüntü işleme teknikleri	9
2.1.3. Sayısal görüntü.....	10
2.1.4. Görüntü türleri	12
2.1.4.1. İkili görüntü (Binary image)	12
2.1.4.2. Gri seviyeli görüntü (Gray scale / Gray level image)	13
2.1.4.3. Renkli görüntü (Color image)	15
2.1.4.4. Renk modelleri	15
2.1.5. Görüntü karakteristikleri	20
2.1.5.1. Görüntü çözünürlüğü.....	20
2.1.5.2. Görüntü histogramı.....	20
2.1.5.3. Görüntü kontrastı	21
2.1.6. Temel gri seviye ve ikili görüntü işlemleri.....	22
2.1.6.1. Histogram eşitleme ile kontrast artırma.....	22
2.1.6.2. Eşikleme (thresholding).....	23
2.1.6.3. Görüntü negatifi	24
2.1.7. Blob analizi ve bölge etiketleme (Region labeling).....	25
2.1.7.1. Bölge etiketleme algoritması	27
2.1.7.2. Bölge sayma algoritması	27
2.1.7.3. Küçük bölgelerin kaldırılması.....	28
2.1.8. Kenar saptama.....	28
2.1.9. Görüntü öznitelik çıkarımı (image feature extraction).....	29
2.1.10. Sayısal görüntülerde frekans analizi ve bazı dönüşümler (transformations).....	29
2.1.10.1. Konvolüsyon (convolution) ve filtreleme.....	30
2.1.10.2. İki boyutlu ayrık Fourier dönüşümü.....	30
2.1.10.3. Ayrık dalgacık (wavelet) dönüşümü	31

2.2. Görüntü Tanıma Uygulamalarında İstatistiksel Sınıflandırıcılar ve Bilgisayarlı Öğrenme Teknikleri	32
2.3. Şeftali	33
2.4. Önceki Çalışmalar	35
3. MATERYAL ve YÖNTEM	49
3.1. Materyal	49
3.1.1. Şeftali bahçesi	49
3.1.2. Görüntü almada kullanılan kamera	49
3.1.3. Matlab yazılımı	50
3.1.4. GIMP görüntü işleme programı	51
3.1.5. SPSS istatistiksel analiz programı	51
3.1.6. SAS istatistiksel analiz programı	51
3.1.7. Meyve tanıma denemelerinin yapıldığı bilgisayar donanımı	51
3.2. Yöntem	51
3.2.1. Görüntü alma	51
3.2.2. Görüntünün yeniden boyutlandırılması	52
3.2.3. Eğitim ve test setlerinin oluşturulması	53
3.2.4. Aydınlanma zenginleştirilmesi için görüntü ön işlemleri	53
3.2.5. Çalışmada geliştirilen görüntü tarama yöntemleri ve potansiyel meyve bölgeleri	54
3.2.5.1. Renk histogramı esaslı eşikleme ve görüntü ikilileştirmesi	54
3.2.5.2. Görüntü tarama yöntemi 1	56
3.2.5.3. Görüntü tarama yöntemi 2	58
3.2.5.4. Görüntü tarama yöntemi 3	61
3.2.6. Çalışmada kullanılan öznelik çıkarma yöntemleri	64
3.2.6.1. Meyve ve arka plan örneklerinin hazırlanması	64
3.2.6.2. Özmeve (eigenfruit) öznelik çıkarma yöntemi	65
3.2.6.3. Dönüşten bağımsız dairesel Gabor doku analizi	69
3.2.6.4. GLCM (Haralick) doku öznelikleri	72
3.2.7. Çalışmada kullanılan yapay sınıflandırıcılar	77
3.2.7.1. Yapay sınıflandırıcılar için veri hazırlama	78
3.2.7.2. Diskriminant analizi	78
3.2.7.3. Naive Bayes	80
3.2.7.4. K-en-yakın komşular	81
3.2.7.5. Sınıflandırma ve regresyon ağaçları	82
3.2.7.6. Destek vektör makinası	83

3.2.7.7. Yapay sinir ağları	84
3.2.8. Çalışmada kullanılan öznitelik setlerinin oluşturulması	85
3.2.8.1. İkili lojistik regresyon kullanılarak GLCM özniteliklerinin olgunlaşmamış şeftaliyi ayırt etmede istatistiksel anlamlılık analizi.....	86
3.2.8.2. Özmeyve ve Gabor doku özniteliklerinin birlikte oluşturduğu set.....	86
3.2.8.3. Şeftali tanımada anlamlı özniteliklerin tespiti için SAS adimli diskriminant (STEPDISC) analizi.....	87
3.2.8.4. Deneme-yanılma yoluyla belirlenen öznitelik seti.....	87
3.2.9. Çoklu saptamaların tekilleştirilmesi ve meyve sayımı.....	87
3.2.10. Geliştirilen algoritmaların genel yapısı, eğitim ve test setleri üzerinde yapılan denemeler	88
3.2.10.1. Özmeyve ve GLCM özniteliklerinin kademeli değerlendirildiği algoritmalar	92
3.2.10.2. Özmeyve ve Gabor doku özniteliklerinin birlikte değerlendirildiği algoritmalar	96
3.2.10.3. STEPDISC analiziyle belirlenen özniteliklerin birlikte değerlendirildiği algoritmalar	100
3.2.10.4. Deneme-yanılma yoluyla belirlenen özniteliklerin birlikte değerlendirildiği algoritmalar	104
3.2.11. Algoritmaların performans değerlendirmeleri.....	104
4. BULGULAR ve TARTIŞMA	106
4.1. Aydınlanma Değişimleri ve Zenginleştirilmesi Sonuçları.....	106
4.2. Renk Histogramı Esaslı Görüntü İkileştirilmesi Sonuçları.....	107
4.3. Dairesel Gabor Doku Analizi Sonuçları.....	109
4.4. İkili Lojistik Regresyon Kullanılarak GLCM Özniteliklerinin Olgunlaşmamış Şeftaliyi Ayırt Etmede İstatistiksel Anlamlılık Analizi Bulguları.....	110
4.5. Şeftali Tanımada Anlamlı Özniteliklerin Tespiti İçin STEPDISC Analizi Bulguları	112
4.6. Çalışmada kullanılan YSA'ların eğitim sonuçları.....	112
4.6.1. GLCM özniteliklerinin YSA eğitimi.....	112
4.6.2. Gabor ve özmeyve özniteliklerinin birlikte YSA eğitimi.....	115
4.6.3. Stepdisc analiziyle elde edilen öznitelik setinin YSA eğitimi.....	117
4.6.4. Deneme-yanılma yoluyla elde edilen öznitelik setinin YSA eğitimi.....	119
4.7. Çoklu Saptamaların Tekilleştirilmesi Sonuçları.....	121
4.8. Özmeyve ve GLCM Özniteliklerinin Kademeli Değerlendirildiği Algoritma Denemelerinin Sonuçları.....	123
4.8.1. Görüntü tarama yöntemi 1 ile özmeyve ve GLCM özniteliklerinin kademeli değerlendirildiği algoritma denemelerinin sonuçları.....	123

4.8.2. Görüntü tarama yöntemi 2 ile özmeve ve GLCM özniteliklerinin kademeli değerlendirildiği algoritma denemelerinin sonuçları.....	128
4.8.3. Görüntü tarama yöntemi 3 ile özmeve ve GLCM özniteliklerinin kademeli değerlendirildiği algoritma denemelerinin sonuçları.....	133
4.8.4. Özmeve ve GLCM özniteliklerinin kademeli değerlendirildiği algoritma performanslarına genel bakış.....	138
4.9. Özmeve ve Gabor Doku Özniteliklerinin Birlikte Değerlendirildiği Algoritma Denemelerinin Sonuçları.....	139
4.9.1. Görüntü tarama yöntemi 1 ile özmeve ve Gabor doku özniteliklerinin algoritmada birlikte değerlendirildiği denemeler	139
4.9.2. Görüntü tarama yöntemi 2 ile özmeve ve Gabor doku özniteliklerinin algoritmada birlikte değerlendirildiği denemeler	145
4.9.3. Görüntü tarama yöntemi 3 ile özmeve ve Gabor doku özniteliklerinin algoritmada birlikte değerlendirildiği denemeler	150
4.9.4. Özmeve ve Gabor doku özniteliklerinin birlikte değerlendirildiği algoritma performanslarına genel bakış.....	155
4.10. STEPDISC Analiziyle Belirlenen Özniteliklerin Birlikte Değerlendirildiği Algoritma Denemelerinin Sonuçları.....	156
4.10.1. Görüntü tarama yöntemi 1 ile STEPDISC analiziyle belirlenen özniteliklerin algoritmada birlikte değerlendirildiği denemeler	156
4.10.2. Görüntü tarama yöntemi 2 ile STEPDISC analiziyle belirlenen özniteliklerin algoritmada birlikte değerlendirildiği denemeler	161
4.10.3. Görüntü tarama yöntemi 3 ile STEPDISC analiziyle belirlenen özniteliklerin algoritmada birlikte değerlendirildiği denemeler	165
4.10.4. STEPDISC analiziyle belirlenen özniteliklerin algoritmada birlikte değerlendirildiği algoritmaların performanslarına genel bakış	170
4.11. Deneme-Yanılma Yoluyla Belirlenen Özniteliklerin Birlikte Değerlendirildiği Algoritma Denemelerinin Sonuçları.....	171
4.11.1. Görüntü tarama yöntemi 1 ile ve deneme-yanılma yoluyla belirlenen özniteliklerin algoritmada birlikte değerlendirildiği denemeler.....	171
4.11.2. Görüntü tarama yöntemi 2 ile deneme-yanılma yoluyla belirlenen özniteliklerin algoritmada birlikte değerlendirildiği denemeler	176
4.11.3. Görüntü tarama yöntemi 3 ile deneme-yanılma yoluyla belirlenen özniteliklerin algoritmada birlikte değerlendirildiği denemeler	180
4.11.4. Deneme-yanılma yoluyla belirlenen özniteliklerin algoritmada birlikte değerlendirildiği algoritmaların performanslarına genel bakış	184
4.12. Başarılı ve Yanlış Saptamalar.....	185
5. SONUÇ	188
KAYNAKLAR.....	192
ÖZGEÇMİŞ.....	198

SİMGELER ve KISALTMALAR DİZİNİ

Simgeler	Açıklamalar
A_n	Gaussian filtresi
a^*	Rengin kırmızılığı (+) ya da yeşilliği (-)
B_{disk}	Yapısal disk elemanı
b^*	Rengin sarılığı (+) ya da maviliği (-)
c	Nesne sayısı
C	Kovaryans matrisi
$C(y k)$	Gözlemi sınıflandırmanın sayısal değeri
c_{jk}	Sınırları olmayan noktalar için enterpolasyon katsayıları
$d_M(p, r)$	Mahalonobis mesafesi
e^d	Öklit mesafesi
F	Fonksiyon frekansı
F_n	Düzgünleştirilmemiş simetri ölçüsü
$f(x, y)$	İki boyutlu sayısal görüntü fonksiyonu
$f(x, y)_{max}$	Görüntünün en yüksek piksel değeri
$f(x, y)_{min}$	Görüntünün en düşük piksel değeri
$f'(x, y)$	Kontrast iyileştirmesi yapılmış piksel değeri
$\mathcal{F}(\omega_x, \omega_y)$	Fourier katsayısı
$g_{norm}(p)$	Normalize edilmiş gradyan vektörü
$g(p)$	Piksel gradyanı
$g(x, y)$	Gaussian fonksiyonu
$G(x, y)$	Gabor fonksiyonu
G	Gri değer aralığı
G_b	Renk bileşeninin yoğunluk değeri
HX ve HY	p_x ve p_y 'nin entropi değerleri
$h(k)$	Renk değerinin görüntü içinde sayıca dağılımı
$h(x, y)$	Doğrusal ve konumdan bağımsız çekirdek matrisi
$il(\omega_x, \omega_y)$	Fourier katsayısının imajiner kısmı
I'	Logaritma görüntüsünü
I_{ikili}	İkili görüntü
k	Endeks değeri
K	Komşuların sayısı
K	Sınıf sayısı
LL, LH, HL ve HH	Sayısal görüntüyü farklı frekans bandları
M	Görüntü genişliği (piksel)
N	Görüntü yüksekliği (piksel)
n	Yarıçap endeksi
n_j	Düğümdeki sınıfın nesne sayısı
p	Olasılık
p	Piksel
$Pr(x)$	Olasılık ölçüsü
$P(a_i v_j)$	Öznitelik sınıf etiketiyle belirlenen olasılığı
$p(i, j)$	i ve j gri seviyeleri arasındaki eş-oluşum olasılığı
P_{ij}	Gri seviyelerin oluşum sayısı

Simgeler**Açıklamalar (Devam)**

$\hat{P}(k x)$	Sonsal olasılık
$\mathcal{R}(\omega_x, \omega_y)$	Fourier katsayısının reel kısmı
S	Radyal simetri katkılarının toplamı
S_n	Radyal simetri katkısı
St	SVM eğitim seti
T	Matris veya vektör transpoze gösterimi
$u(s)$	İki boyutlu enterpolasyon fonksiyonu
u_n	Veri dağılımını en iyi ifade eden ortonormal vektör
u_k	Kovaryans matrisinin özvektörü
ω_k	Görüntünün ağırlığı
w_n	Pozitif ağırlık
$\langle w, x \rangle + b$	Pozitif ne negatif sınıflar için ayırıcı hiperdüzlem
v_{MAP}, v_{NB}	En olası hedef değerleri
x	Dikey piksel enkeksi
X_N	Normalize edilmiş değer
X'	Normalize edilmemiş değer
X_{min}	En düşük değer
X_{max}	En yüksek değer
y	Yatay piksel endeksi
y_i	Cevap değişkeni
\bar{y}	Düğüm ortalaması
\vec{y}	Tahmin edilen sınıflandırma
\ominus	Aşınma operatörü
\oplus	Genleşme operatörü
\otimes	Konvolüsyon operatörü
\circ	Morfolojik açınım operatörü
α_i	Lagrange çarpanı
ϑ	Eş-oluşum matrisi yön açısı
Ψ	Eğitim setinin ortalaması
Γ	Kare görüntü
Φ_i	Görüntünün ortalamaadan farklılığı
Φ_f	Meyve uzayına projeksiyonu yapılan aday görüntü
λ_k	Kovaryans matrisinin özdeğeri
σ	Ölçek parametresi
σ_G	Gabor doku özneteliği sayısal değeri
ϕ	Gabor filtresi uygulanmış görüntü
μ	Ortalama piksel yoğunluğu
$\hat{\mu}_k$	Ağırlıklı olmayan veri için sınıf ortalamasının tahmini

Kısaltmalar	Açıklamalar
cROI	Dairesel ilgi bölgesi
CCD	Charge coupled device
CMYK	Siyan-magenta-sarı-siyah renk modeli
DWT	Ayrık dalgacık dönüşümü
FAO	Food and Agriculture Organization of the United Nations
GIS	Coğrafi bilgi sistemi
GIMP	Gnu Image Manipulation Program
GLCM	Gri seviye eş-oluşum matrisi
GPS	Küresel konumlama sistemi
HSI	Hue-doygunluk-yoğunluk
JPEG	Joint Photographic Experts Group
MSE	Hata karelerinin ortalaması
NDI	Normalize edilmiş fark endeksi
NIR	Yakın kızıl ötesi
PCA	İlkesel bileşenler analizi
RGB	Kırmızı-yeşil-mavi renk modeli
ROI	İlgi bölgesi
RST	Radyal simetri dönüşümü
SD	Serbestlik derecesi
SIFT	Ölçekten bağımsız öznitelik dönüşümü
STEPPDISC	Adımlı discriminant analizi
SURF	Hızlandırılmış öznitelik
SVM	Destek vector makinası
YSA	Yapay sinir ağı
YCbCr	Luminans-mavi krominans-kırmızı krominans

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 2.1.	Sayısal görüntü işlemenin temel adımları..... 10
Şekil 2.2.	Sayısal görüntünün temsil modeli..... 11
Şekil 2.3.	Örnek bir renkli görüntü (a) ve buna ait ikili görüntü (b)..... 12
Şekil 2.4.	Gri seviyeli örnek görüntü (a) ve gri seviyelerin sayısal temsili (b) 14
Şekil 2.5.	RGB renk modeli..... 16
Şekil 2.6.	HSI renk uzayının konik temsili..... 17
Şekil 2.7.	YCbCr renk modelinin görsel temsili..... 18
Şekil 2.8.	L*a*b renk uzayı..... 19
Şekil 2.9.	Gri seviyeli görüntü (a) ve histogram grafiği (b)..... 21
Şekil 2.10.	Düşük kontrastlı (a) ve yüksek kontrastlı görüntü (b)..... 21
Şekil 2.11.	Düşük kontrastlı (a) ve yüksek kontrastlı görüntü (b) histogramları... 23
Şekil 2.12.	Negatif görüntü dönüşüm tablosu..... 25
Şekil 2.13.	Örnek renkli görüntünün (a) ikili formu (b) ve etiketlenmiş formu (c) 26
Şekil 2.14.	Örnek görüntü (a) ve çıkartılmış kenar görüntüsü (b)..... 28
Şekil 2.15.	Örnek görüntü (a) ve iki boyutlu ayrık Fourier dönüşümü (b)..... 31
Şekil 2.16.	iki boyutlu görüntünün DWT ile dekompozisyonunun temsili 32
Şekil 3.1.	Elegance Lady çeşidi şeftali bahçesi..... 49
Şekil 3.2.	Görüntü alımında kullanılan standart CCD kamera..... 50
Şekil 3.3.	Şeftali bahçesinden alınan görüntülere ait örnekler..... 52
Şekil 3.4.	Histogram analizi amacıyla meyve (a) ve arka plan (b) piksellerinden oluşturulan mozaik görüntüler..... 55
Şekil 3.5.	Kayan alt-pencere yöntemiyle görüntü tarama yaklaşımı..... 57
Şekil 3.6.	Bir örnek görüntüye (a) ait ikili görüntü ve alt-pencerenin teğet çemberi (b)..... 58
Şekil 3.7.	Görüntü tarama yöntemi 2'ye ait aşamalar (Örnek görüntü (a), ikilileştirme sonrası (b) ve morfolojik açınım sonrası elde edilen bir aday merkez yeşil çerçeveye gösterilen bir ortogonal komşu ile birlikte)..... 60
Şekil 3.8.	RST dönüşümünde gradyan vektörü, negatif ve pozitif etkilenen pikseller..... 62
Şekil 3.9.	Örnek bir şeftali bitki örtüsü görüntüsü (a), RST dönüşümü sonrası elde edilen simetri haritası (b) ve eşikleme sonucu elde edilen potansiyel meyve konumları (c)..... 63
Şekil 3.10.	Kırpılarak hazırlanan meyve ve arka plan görüntülerine ait örnekler 65
Şekil 3.11.	Ortalama meyve görüntüsü ve özmevenin temsili: (a) ortalama meyve görüntüsü ve (b) birinci özvektörü temsil eden özmeve görüntüsü..... 66
Şekil 3.12.	Bir görüntünün meyve uzayına projeksiyonu ve meyve uzayından olan mesafe..... 69
Şekil 3.13.	Geleneksel (a) ve dairesel (b) Gabor fonksiyonlarının örnek gösterimleri..... 70
Şekil 3.14.	Örnek bir eş-oluşum (GLCM) matrisi..... 73
Şekil 3.15.	En uygun ayırıcı hiperdüzlem ve en yüksek marjin..... 84

Şekil 3.16.	Örnek bir yapay sinir ağı.....	85
Şekil 3.17.	Çalışmada geliştirilen algoritmaların genel işleyişleri.....	89
Şekil 3.18.	Görüntü tarama yöntemi 1 ile GLCM ve özmeve özniteliklerinin kademeli değerlendirildiği algoritmaların akış diyagramı.....	93
Şekil 3.19.	Görüntü tarama yöntemi 2 ile GLCM ve özmeve özniteliklerinin kademeli değerlendirildiği algoritmaların akış diyagramı.....	94
Şekil 3.20.	Görüntü tarama yöntemi 3 ile GLCM ve özmeve özniteliklerinin kademeli değerlendirildiği algoritmaların akış diyagramı.....	95
Şekil 3.21.	Görüntü tarama yöntemi 1 ile özmeve ve Gabor doku özniteliklerinin birlikte değerlendirildiği algoritmaların akış diyagramı.....	97
Şekil 3.22.	Görüntü tarama yöntemi 2 ile özmeve ve Gabor doku özniteliklerinin birlikte değerlendirildiği algoritmaların akış diyagramı.....	98
Şekil 3.23.	Görüntü tarama yöntemi 3 ile özmeve ve Gabor doku özniteliklerinin birlikte değerlendirildiği algoritmaların akış diyagramı.....	99
Şekil 3.24.	Görüntü tarama yöntemi 1 ile STEPDISC analiziyle belirlenen özniteliklerin birlikte değerlendirildiği algoritmaların akış diyagramı.....	101
Şekil 3.25.	Görüntü tarama yöntemi 2 ile STEPDISC analiziyle belirlenen özniteliklerin birlikte değerlendirildiği algoritmaların akış diyagramı.....	102
Şekil 3.26.	Görüntü tarama yöntemi 3 ile STEPDISC analiziyle belirlenen özniteliklerin birlikte değerlendirildiği algoritmaların akış diyagramı.....	103
Şekil 4.1.	Farklı aydınlanma koşullarındaki görüntüler.....	106
Şekil 4.2.	Bu çalışmada kullanılan görüntü zenginleştirmesinin etkisi: logaritma dönüşümü ve histogram eşitleme kullanımının öncesi (a) ve sonrası (b).....	107
Şekil 4.3.	Meyve ve arka plan mozaik görüntülerin histogram eğrileri.....	108
Şekil 4.4.	Eşikleme yoluyla elde edilen ikili görüntülere ait örnekler.....	109
Şekil 4.5.	Orijinal renkli görüntü ve farklı ölçeklerde Gabor filtresi uygulanmış versiyonları.....	110
Şekil 4.6.	GLCM özniteliklerinin eğitiminde kullanılan YSA'nın Matlab YSA eğitim penceresinde görünümü.....	113
Şekil 4.7.	GLCM özniteliklerinin eğitiminde kullanılan YSA'nın ağ eğitimine ait performans grafiği.....	114
Şekil 4.8.	GLCM özniteliklerinin eğitiminde kullanılan YSA'nın ağ eğitimine ait regresyon eğrileri.....	115
Şekil 4.9.	GLCM özniteliklerinin eğitiminde kullanılan ağın Matlab YSA eğitim penceresinde görünümü.....	116
Şekil 4.10.	Gabor ve özmeve özniteliklerinin birlikte eğitiminde kullanılan YSA'nın ağ eğitimine ait performans grafiği.....	116
Şekil 4.11.	Gabor ve özmeve özniteliklerinin birlikte eğitiminde kullanılan YSA'nın ağ eğitimine ait regresyon eğrileri.....	117
Şekil 4.12.	Stepdisc analiziyle elde edilen öznitelik setinin eğitiminde kullanılan ağın Matlab YSA eğitim penceresinde görünümü.....	118

Şekil 4.13.	Stepdisc analiziyle elde edilen öznelik setinin eğitiminde kullanılan YSA'nın ağ eğitimine ait performans grafiği.....	118
Şekil 4.14.	Stepdisc analiziyle elde edilen öznelik setinin eğitiminde kullanılan YSA'nın ağ eğitimine ait regresyon eğrileri.....	119
Şekil 4.15.	Deneme-yanılma yoluyla elde edilen öznelik setinin eğitiminde kullanılan ağın Matlab YSA eğitim penceresinde görünümü.....	120
Şekil 4.16.	Deneme-yanılma yoluyla elde edilen öznelik setinin eğitiminde kullanılan YSA'nın ağ eğitimine ait performans grafiği.....	120
Şekil 4.17.	Deneme-yanılma yoluyla elde edilen öznelik setinin eğitiminde kullanılan YSA'nın ağ eğitimine ait regresyon eğrileri.....	121
Şekil 4.18.	Çoklu saptamaların birleştirilmesi adımları: (a) çoklu saptamalar, (b) saptama merkezlerini temsil eden ikili görüntü ve (c) sonuç görüntüsü.....	122
Şekil 4.19.	Görüntü tarama yöntemi 1 ile GLCM ve özmeve özneliklerinin kademeli değerlendirildiği algoritmaların deneme sonuçlarına ilişkin bazı sonuç görüntüleri.....	124
Şekil 4.20.	Görüntü tarama yöntemi 2 kullanımıyla GLCM (YSA ile) ve özmeve özneliklerinin kademeli değerlendirildiği algoritmaya ait örnek meyve saptama adımları.....	128
Şekil 4.21.	Görüntü tarama yöntemi 2 ile GLCM ve özmeve özneliklerinin kademeli değerlendirildiği algoritmaların deneme sonuçlarına ilişkin bazı sonuç görüntüleri.....	129
Şekil 4.22.	Görüntü tarama yöntemi 3 ile GLCM ve özmeve özneliklerinin kademeli değerlendirildiği algoritmaların deneme sonuçlarına ilişkin bazı sonuç görüntüleri.....	133
Şekil 4.23.	Özmeve ve GLCM özneliklerinin kademeli değerlendirildiği algoritmaların meyve saptama yüzdeleri.....	138
Şekil 4.24.	Özmeve ve GLCM özneliklerinin kademeli değerlendirildiği algoritmaların yanlış pozitif yüzdeleri.....	139
Şekil 4.25.	Görüntü tarama yöntemi 1 ile Gabor ve özmeve özneliklerinin birlikte değerlendirildiği sınıflandırıcı olarak diskriminant analizinin kullanıldığı algoritmaya ait örnek meyve saptama adımları.....	140
Şekil 4.26.	Görüntü tarama yöntemi 1 ile Gabor ve özmeve özneliklerinin birlikte değerlendirildiği algoritmaların deneme sonuçlarına ilişkin bazı sonuç görüntüleri.....	141
Şekil 4.27.	Görüntü tarama yöntemi 2 ile Gabor ve özmeve özneliklerinin birlikte değerlendirildiği algoritmaların deneme sonuçlarına ilişkin bazı sonuç görüntüleri.....	145
Şekil 4.28.	Görüntü tarama yöntemi 3 ile Gabor ve özmeve özneliklerinin birlikte değerlendirildiği algoritmaların deneme sonuçlarına ilişkin bazı sonuç görüntüleri.....	150
Şekil 4.29.	Özmeve ve Gabor doku özneliklerinin birlikte değerlendirildiği algoritmaların meyve saptama yüzdeleri.....	155
Şekil 4.30.	Özmeve ve Gabor doku özneliklerinin birlikte değerlendirildiği algoritmaların yanlış pozitif oranları.....	156
Şekil 4.31.	Görüntü tarama yöntemi 1 kullanımıyla STEPDISC analiziyle belirlenen özneliklerin birlikte değerlendirildiği algoritmaların deneme sonuçlarına ilişkin bazı sonuç görüntüleri.....	157

Şekil 4.32.	Görüntü tarama yöntemi 2 ile STEPDISC analiziyle belirlenen özneliklerin birlikte değerlendirildiği algoritmaların deneme sonuçlarına ilişkin bazı sonuç görüntüleri.....	161
Şekil 4.33.	Görüntü tarama yöntemi 3 ile STEPDISC analiziyle belirlenen özneliklerin birlikte değerlendirildiği algoritmaların deneme sonuçlarına ilişkin bazı sonuç görüntüleri.....	165
Şekil 4.34.	STEPDISC analiziyle belirlenen özneliklerin birlikte değerlendirildiği algoritmaların meyve saptama yüzdeleri.....	170
Şekil 4.35.	STEPDISC analiziyle belirlenen özneliklerin birlikte değerlendirildiği algoritmaların yanlış pozitif oranları.....	171
Şekil 4.36.	Görüntü tarama yöntemi 1 ile deneme-yanılma yoluyla belirlenen özneliklerin birlikte değerlendirildiği algoritmaların deneme sonuçlarına ilişkin bazı sonuç görüntüleri.....	172
Şekil 4.37.	Görüntü tarama yöntemi 2 ile deneme-yanılma yoluyla belirlenen özneliklerin birlikte değerlendirildiği algoritmaların deneme sonuçlarına ilişkin bazı sonuç görüntüleri.....	176
Şekil 4.38.	Görüntü tarama yöntemi 3 ile deneme-yanılma yoluyla belirlenen özneliklerin birlikte değerlendirildiği algoritmaların deneme sonuçlarına ilişkin bazı sonuç görüntüleri.....	180
Şekil 4.39.	Deneme-yanılma yoluyla belirlenen özneliklerin birlikte değerlendirildiği algoritmaların meyve saptama yüzdeleri.....	184
Şekil 4.40.	Deneme-yanılma yoluyla belirlenen özneliklerin birlikte değerlendirildiği algoritmaların yanlış pozitif oranları.....	185

ÇİZELGELER DİZİNİ

	Sayfa
Çizelge 2.1. Yıllar bazında Türkiye ve Dünya şeftali ekim alanları, üretim ve verim değerleri.....	34
Çizelge 3.1. Kullanılan kameraya ait teknik özellikler.....	50
Çizelge 3.2. Eğitim ve test setlerinde denemeleri yapılan GLCM doku ve özmeyve özniteliklerinin karar verici olarak kademeli değerlendirildiği algoritmalar.....	89
Çizelge 3.3. Eğitim ve test setlerinde denemeleri yapılan doku ve özmeyve özniteliklerinin bir arada değerlendirildiği algoritmalar.....	90
Çizelge 4.1. İkili Lojistik Regresyon Model Tahmin Sonuçları.....	110
Çizelge 4.2. Tahmine edilen ikili lojistik regresyon modelinin R2 ve model uyum iyiliği.....	111
Çizelge 4.3. Stepdisc analizi ile belirlenen öznitelikler.....	112
Çizelge 4.4. Özmeyve ve GLCM doku özniteliklerinin kademeli değerlendirildiği görüntü tarama yöntemi 1'in kullanıldığı algoritmaların eğitim ve test setleri deneme sonuçları.....	125
Çizelge 4.5. Özmeyve ve GLCM doku özniteliklerinin kademeli değerlendirildiği görüntü tarama yöntemi 1'in kullanıldığı algoritmaların test setine ait güneşli ve gölgeli taraflardan alınan görüntülere göre deneme sonuçları.....	127
Çizelge 4.6. Özmeyve ve GLCM doku özniteliklerinin kademeli değerlendirildiği görüntü tarama yöntemi 2'in kullanıldığı algoritmaların eğitim ve test setleri deneme sonuçları.....	130
Çizelge 4.7. Özmeyve ve GLCM doku özniteliklerinin kademeli değerlendirildiği görüntü tarama yöntemi 2'in kullanıldığı algoritmaların test setine ait güneşli ve gölgeli taraflardan alınan görüntülere göre deneme sonuçları.....	132
Çizelge 4.8. Özmeyve ve GLCM doku özniteliklerinin kademeli değerlendirildiği görüntü tarama yöntemi 3'ün kullanıldığı algoritmaların eğitim ve test setleri deneme sonuçları.....	135
Çizelge 4.9. Özmeyve ve GLCM doku özniteliklerinin kademeli değerlendirildiği görüntü tarama yöntemi 3'ün kullanıldığı algoritmaların test setine ait güneşli ve gölgeli taraflardan alınan görüntülere göre deneme sonuçları.....	137
Çizelge 4.10. Özmeyve ve Gabor doku özniteliklerinin birlikte değerlendirildiği görüntü tarama yöntemi 1'in kullanıldığı algoritmaların eğitim ve test setleri deneme sonuçları.....	142
Çizelge 4.11. Özmeyve ve Gabor doku özniteliklerinin birlikte değerlendirildiği görüntü tarama yöntemi 1'in kullanıldığı algoritmaların test setine ait güneşli ve gölgeli taraflardan alınan görüntülere göre deneme sonuçları.....	144

Çizelge 4.12.	Özme yve ve Gabor doku özniteliklerinin birlikte değerlendirildiği görüntü tarama yöntemi 2'in kullanıldığı algoritmaların eğitim ve test setleri deneme sonuçları.....	147
Çizelge 4.13.	Özme yve ve Gabor doku özniteliklerinin birlikte değerlendirildiği görüntü tarama yöntemi 2'in kullanıldığı algoritmaların test setine ait güneşli ve gölgeli taraflardan alınan görüntülere göre deneme sonuçları.....	149
Çizelge 4.14.	Özme yve ve Gabor doku özniteliklerinin birlikte değerlendirildiği görüntü tarama yöntemi 3'ün kullanıldığı algoritmaların eğitim ve test setleri deneme sonuçları.....	152
Çizelge 4.15.	Özme yve ve Gabor doku özniteliklerinin birlikte değerlendirildiği görüntü tarama yöntemi 3'ün kullanıldığı algoritmaların test setine ait güneşli ve gölgeli taraflardan alınan görüntülere göre deneme sonuçları.....	154
Çizelge 4.16.	STEPDISC analiziyle belirlenen özniteliklerin birlikte değerlendirildiği görüntü tarama yöntemi 1'in kullanıldığı algoritmaların eğitim ve test setleri deneme sonuçları.....	158
Çizelge 4.17.	STEPDISC analiziyle belirlenen özniteliklerin birlikte değerlendirildiği görüntü tarama yöntemi 1'in kullanıldığı algoritmaların test setine ait güneşli ve gölgeli taraflardan alınan görüntülere göre deneme sonuçları.....	160
Çizelge 4.18.	STEPDISC analiziyle belirlenen özniteliklerin birlikte değerlendirildiği görüntü tarama yöntemi 2'nin kullanıldığı algoritmaların eğitim ve test setleri deneme sonuçları.....	162
Çizelge 4.19.	STEPDISC analiziyle belirlenen özniteliklerin birlikte değerlendirildiği görüntü tarama yöntemi 2'nin kullanıldığı algoritmaların test setine ait güneşli ve gölgeli taraflardan alınan görüntülere göre deneme sonuçları.....	164
Çizelge 4.20.	STEPDISC analiziyle belirlenen özniteliklerin birlikte değerlendirildiği görüntü tarama yöntemi 3'ün kullanıldığı algoritmaların eğitim ve test setleri deneme sonuçları.....	167
Çizelge 4.21.	STEPDISC analiziyle belirlenen özniteliklerin birlikte değerlendirildiği görüntü tarama yöntemi 3'ün kullanıldığı algoritmaların test setine ait güneşli ve gölgeli taraflardan alınan görüntülere göre deneme sonuçları.....	169
Çizelge 4.22.	Deneme-yanılma yoluyla belirlenen özniteliklerin birlikte değerlendirildiği görüntü tarama yöntemi 1'in kullanıldığı algoritmaların eğitim ve test setleri deneme sonuçları.....	173
Çizelge 4.23.	Deneme-yanılma yoluyla belirlenen özniteliklerin birlikte değerlendirildiği görüntü tarama yöntemi 1'in kullanıldığı algoritmaların test setine ait güneşli ve gölgeli taraflardan alınan görüntülere göre deneme sonuçları.....	175

Çizelge 4.24. Deneme-yanılma yoluyla belirlenen özneliklerin birlikte değerlendirildiği görüntü tarama yöntemi 2'in kullanıldığı algoritmaların eğitim ve test setleri deneme sonuçları.....	178
Çizelge 4.25. Deneme-yanılma yoluyla belirlenen özneliklerin birlikte değerlendirildiği görüntü tarama yöntemi 2'nin kullanıldığı algoritmaların test setine ait güneşli ve gölgeli taraflardan alınan görüntülere göre deneme sonuçları.....	179
Çizelge 4.26. Deneme-yanılma yoluyla belirlenen özneliklerin birlikte değerlendirildiği görüntü tarama yöntemi 3'ün kullanıldığı algoritmaların eğitim ve test setleri deneme sonuçları.....	182
Çizelge 4.27. Deneme-yanılma yoluyla belirlenen özneliklerin birlikte değerlendirildiği görüntü tarama yöntemi 3'ün kullanıldığı algoritmaların test setine ait güneşli ve gölgeli taraflardan alınan görüntülere göre deneme sonuçları.....	183

1. GİRİŞ

Son yıllarda özellikle gelişmiş ülkelerde bilgi teknolojilerinin gelişmesiyle insana, bitkiye, hayvana ve çevreye duyarlı, üretimde kalite ve verimlilik faktörlerini esas alan bir tarım anlayışı ortaya çıkmıştır. Her ne kadar uzun yıllar boyunca ülkemizde tarım, bilişim sektörünün dışında kalmış olsa da tarım biliminin doğal evrimi sürecinde ülkemiz çiftçilerinin de bu teknolojilerden yararlanması kaçınılmazdır. Hassas tarım İngilizce ifadesiyle “precision agriculture” genel olarak israfi önlemek, verimi artırmak ve çevreyi korumak ilkeleri doğrultusunda tarımsal üretim girdilerinin (gübre, kalker, yabancı ot ilacı, tohum, insektisit) alana özgü etkin kullanımı olarak tanımlanmaktadır. Bir başka ifadeyle de hassas tarım; toprak ve ürün yönetiminin, tarımsal üretimin yapıldığı araziye oluşturan ve kendine özgü farklı özellikleri bulunan her bir alt birimine uyarlanmasıdır (Ess ve Morgan 2003, Vatandaş ve ark. 2005). Bu tanımlamalar çerçevesinde özellikle geniş alanlarda yapılan tarımsal üretimde hassas tarımın önemi ortaya çıkmaktadır.

Gelişen teknolojiyle birlikte tarımsal üretim girdilerinin çevreye olan etkileri ve girdi maliyetlerinin azaltılması yönündeki baskılar günden güne artmaktadır. Tarım arazilerinin fiziksel ve coğrafi değişkenlikleri, tekdüze olmayan toprak, ürün ve çevre faktörleri, girdilerin çevreye etkisi ve maliyetlerinin yükselmesi karşısında da bu baskılar yoğunlaşmaktadır. Hassas tarım, girdilerin gerektiği miktarda kullanımıyla ekonomikliği sağlamayı ve bu yolla çevreye olan etkilerini azaltmayı ve ürün kalitesinde de tekdüzeliğin sağlanmasını amaçlamaktadır.

Hassas tarımın hedefleri olarak;

- 1) Gübre ve ilaç gibi kimyasal giderlerinin azaltılması,
- 2) Çevre kirliliğinin azaltılması,
- 3) Yüksek miktarda ve kaliteli ürün sağlanması,

- 4) İşletme ve yetiştiricilik kararları için daha etkin bir bilgi akışının sağlanması,
- 5) Tarımda kayıt düzeninin oluşturulması sayılabilmektedir (Vatandaş ve ark. 2005).

Hassas tarım yönteminin araçları veya bileşenleri yelpazesi, gelişen teknoloji ve artan yetiştirici ihtiyaçları doğrultusunda gün geçtikçe genişlemektedir. Bu araçlardan bazıları;

- 1) Küresel konumlama sistemleri (GPS),
- 2) Verim haritalama ve izleme,
- 3) Coğrafi bilgi sistemleri (GIS),
- 4) Toprak örnekleme,
- 5) Değişken oranlı girdi uygulama,
- 6) Ürün ve tarla koşullarını izleme,
- 7) Uzaktan algılama gibi teknolojilerdir (Kirişçi ve ark. 1999).

Ürün verimindeki alansal değişkenlik ve bunun getirdiği dezavantajlar hassas tarım teknolojilerini doğuran en büyük nedenlerden birisidir. Hassas tarım yöntemlerini ilke edinen her yetiştirici verim değişkenliğinin olup olmadığını, eğer varsa ne düzeyde olduğunu ve bunun bölgesel ve genel nedenlerini anlamalıdır. Bu bağlamda verim haritalama ve izleme veya verim haritası çıkarma, bu belirsizlikleri giderme yolunda hassas tarım teknolojisi araçları içerisinde uygulanacak ilk adımdır. Verim haritalama yetiştiriciler için birçok avantajlar sunmaktadır. Bu avantajlardan bazıları aşağıdaki şekilde sıralanabilir;

- 1) Verim haritaları hassas tarımın hedefleri doğrultusunda yetiştiricilere izleyecekleri yol konusunda bir ön bilgi sağlamaktadır.
- 2) Verim haritalama yoluyla hasat edilmiş ya da edilecek ürün miktarı bilgisine arazisinin bölgesel düzeyinde sahip olunabilmektedir. Verimin ya da ürün kalitesinin tarla ya da bahçenin nerelerinde düşük nerelerinde yüksek olduğu belirlenebilmektedir. Bir başka deyişle değişkenlik belirlenerek sayısallaştırılabilmektedir.
- 3) Bu teknoloji sayesinde değişken oranlı girdi uygulamada uygulanacak değişimin miktarı ve nerelere uygulanacağı saptanabilmektedir.
- 4) Kullandığı yüksek teknoloji sensörler ve ekipmanlar sayesinde kısa bir süre içerisinde verileri toplayarak insan gücü ve zamandan tasarruf sağlar.
- 5) Gelecek yetiştirme periyodu için gerekli önlemler bu bilgi sayesinde planlanabilmektedir.
- 6) Erken verim haritaları, bitkinin gelişme sürecinde verimi düşük arazi kısımlarının önceden saptanmasına ve erken müdahalelerle hasada kadar bu kısımlara iyileştirme uygulanmasına olanak tanır.
- 7) Erken verim haritaları hasat işlemleri için yatırım kararlarını almada yardımcı olarak hasat giderlerini azaltabilmektedir.
- 8) Erken verim haritalarıyla elde edilen bilgi sayesinde ürüne yönelik pazarlama stratejileri hasattan önce belirlenebilmektedir.

Tarımın en ilkel dönemlerinden beri insanlar ürün verimini ölçmenin farklı yöntemlerini geliştirmişler ve uygulamışlardır. En eski yöntem ürünün hasat edilip, ayrılıp ve temizlenmesinden sonra tartılmasıdır. Gelişen teknoloji ve hassas tarımın ihtiyaçları farklı verim ölçme ve neticesinde haritalama yöntemlerini doğurmuştur. Ürün verimini ölçme uygulamaları genel olarak üç başlık altında incelenir. Bunlar;

- 1) Hasat sonrası verim ölçüm yöntemi,
- 2) Yığın tipi verim ölçüm yöntemi,
- 3) Anlık (gerçek-zamanlı) verim ölçüm yöntemidir (Ess ve Morgan 2003, Kirişçi ve ark. 1999).

Bu yöntemler arasından ilki eski ve en basit olan yöntemdir. Hasat edilen ürünün ağırlığının depolama yerindeki tartım düzenleri veya tartım düzenlerine sahip taşıyıcılarla belirlenmesi prensibine dayanmaktadır. Tartım aşamasında ürünün nem değeri de belirlenmektedir. Bu yöntemle tartılıp kaydedilen verilerle verim ortaya konulabilmektedir. Ancak tek bir ortalama verim değeri bir tarlayı temsil edemeyeceğinden yerel esaslı tarımsal uygulamalar için uygun görülmektedir. Yığın tipi verim ölçüm yöntemi genellikle tahıllar için uygulanmaktadır. Ürünün hasat deposundan tarım arabasına nakledilmesi esnasında gerçekleştirilir. Belirli ve ölçülen alandan yapılan hasadın ağırlık ölçümleri biçerdöverin kabin içi görüntüleyicisinde izlenebilmektedir. Ürünün tartılması işleminin birinci yöntemde olduğu gibi ayrıca yapılması gerekmemeyle birlikte yöntemin hassasiyeti hassas tarım tekniği açısından yeterli olmamaktadır. Anlık verim ölçüm yönteminde ürünün verimi ürünün hasat edilmesi sırasında sürekli ölçülür ve kaydedilir. Bu yöntem konum belirleme sistemiyle entegre kullanılarak her bir veri noktası ayrı ayrı kaydedilmektedir. Hasat edilen alanın da belirlenmesi söz konusudur. Hassas tarım tekniği açısından en uygun olan bu yöntemle verim haritaları oluşturulabilmektedir (Kirişçi ve ark. 1999). Bu yöntemle özellikle tahılların hasadına yönelik birçok ticari sistem geliştirilerek biçerdöver donanımları arasında yer edinmiştir.

Açıklanan verim ölçme yöntemleri geleneksel yöntemler olmakla birlikte bu yöntemler ürünün hasadından sonra veya hasat esnasında uygulanmaktadır. Genellikle ürün ağırlığının çeşitli sensörlerle ölçülmesi ilkesine dayanan bu yöntemlerin kullanımıyla hasat öncesi verim haritalarının getirdiği avantajlardan yararlanılamamaktadır. Erken verim haritaları bitki gelişimi esnasında oluşturulduğundan tarım arazisinin herhangi bir alt kısmında saptanacak düşüklük erken müdahalelerle (ilaç, gübre, kültürel önlem vs.)

dengelenebilmektedir. Ayrıca hasat işlemlerinin planlanması (hasat yatırım kararları) için hasat edilecek ürünün miktarı bilgisini sunmaktadır. Ürünün pazarlama stratejilerini belirlemek üzere de üreticiyi henüz bitki gelişiminin erken safhasında bilgilendirmektedir. Herhangi bir zirai yöntem ile verim alınamayacak kadar olumsuz koşullara sahip arazi kısımlarının da belirlenerek buralara gereksiz yatırımlar yapılmasını engelleyebilmektedir. Ancak erken verim haritalarını elde etmek, geleneksel yöntemler kadar kolay olmamaktadır. Ürün veriminin bitkinin doğal ortamında, yani tarla-bahçede ölçülmesi gerekmektedir.

Son yıllarda özellikle meyve bahçelerinin verim haritalarının çıkarılması ya da robotla hasat yöntemlerinde kullanılmak amacıyla meyvelerin doğal ortamında tanımak ve/veya konumlamak için görüntü işleme ve bilgisayarlı görü yöntemleri araştırılmaktadır. Görüntülerden elde edilen meyve sayısı ile ortalama meyve büyüklüğü bilgisinden yararlanarak verim ölçülebilmektedir. Bu çalışmaların birçoğu “Önceki çalışmalar” bölümünde verilmiştir. Çalışmalar genellikle olgun meyvelerin görüntülerde saptanması üzerinde yoğunlaşmış olmakla birlikte olgunlaşmamış meyveleri saptamak üzerine de yeni teknikler araştırılmaktadır. Olgunlaşmamış meyveleri görüntü üzerinde saptamak oldukça zor bir işlemdir. Genç meyvelerin renkleri bir doğal bitki görüntüsünde en çok bulunan yaprak nesnelere çok yakındır. Bunun yanında bahçede doğal aydınlanma koşullarında elde edilen görüntülerde tekdüze olmayan aydınlanma, meyveleri tanımayı zorlaştırmaktadır. Meyvelerin yapraklar tarafından kısmen veya tamamen örtülmesi meyve saptamayı zorlaştıran diğer bir etmendir. Termal, multispektral ve hiperspektral gibi görüntüleme yöntemleri bazı araştırmacılar tarafından kullanılmış olsa da bu yöntemler uygulamada özellikle çiftçiler açısından oldukça büyük bir ekonomik yük getirmektedir. Sıradan renkli görüntülerle meyve saptama ve sayma görevini yerine getirebilecek bir sistem ekonomiklik ve kullanılabilirlik sağlayacaktır. Olgunlaşmamış meyveleri doğal ortamında sıradan renkli görüntülerden saptayan böyle bir sistem gelişmiş algoritmalara gereksinim duymakla birlikte getirdiği yoğun matematiksel altyapı ve programlama yükü başlı başına bir çalışma konusudur.

Bu çalışmada Bursa başta olmak üzere ülkemiz için ekonomik değeri yüksek olan şeftali meyvesinin verim haritalamasına yönelik olarak bitkinin erken gelişme

döneminde ve doğal ortamından alınmış sıradan renkli görüntülerinden meyveleri tespit ederek sayabilecek algoritmalar geliştirmek amaçlanmıştır. Yapılan ön çalışmalar ve kaynak araştırması sonucunda olgun ya da olgunlaşmamış şeftali meyvesinin bilgisayarlı görü ve görüntü işleme yöntemleriyle saptanması üzerine herhangi bir çalışmaya rastlanmamıştır. Bu çalışma ayrıca gelecekte olgunlaşmamış meyveleri renkli görüntülerden saptayarak verim haritalama sistemleri çıkarma üzerinde çalışan araştırmacılar için bir yapılabirlik çalışmasıdır. Genç meyveleri doğal ortamında tanımak ve algılamak üzere ayırt edici öznitelikleri saptamak, bu özniteliklerle farklı görüntü tarama, öğrenme-sınıflandırma algoritmalarının başarılarını ortaya koymak da bu çalışmanın amaçlarıdır.

2. KAYNAK ARAŐTIRMASI

2.1. Grnt İŐleme ve Bilgisayarlı Gr ile İlgili Kavramlar

Grnt iŐleme (image processing) ve bilgisayarlı gr (computer/machine vision) uygulamaları geliŐen teknoloji ile birlikte insan hayatında nemli bir yer edinmiŐtir. zellikle son kırk yılda bilgisayarların boyutlarının klmesi, kapasite ve veri iŐleme hızlarındaki artış grnt iŐleme teknolojilerindeki geliŐmeyi hızlandırmıŐtır (KarakuŐ 2006). Bu teknolojilerin kullanılma olanakları gnden gne artmakla beraber mevcut kullanım alanları aŐağıdaki gibi sıralanabilir;

- Tıp
- Astronomi
- Biyoloji
- OŐinografi
- Savunma sanayi
- Malzeme bilimi
- Endstriyel otomasyon
- Elektronik tketicilernleri
- Gvenlik
- Trafik denetimi

İnsan algılarının en geliŐmiŐi olan grme, insan algılamasında ok nemli bir rol oynar.

İnsan görme sistemi bilinen en gelişmiş mekanizmalara sahip olmakla birlikte; görüntüleri yakalama, gruplayarak analiz etme konusunda oldukça gelişmiştir (Jaehne 1997). Ancak elektromanyetik spektrumun görünebilir bandı (0.4µm ile 0.7µm dalga boyları arası) ile sınırlı olan insan görme sisteminin tersine görüntüleme makinaları, gama ile radyo dalgaları arasındaki neredeyse tüm elektromanyetik spektrumu kapsamaktadır (Gonzales ve Woods 2002). Birbirinden çok farklı ve birçok amaca yönelik olabilen görüntüleme makinaları; standart CCD kamera, tarayıcı, ultrason, manyetik rezonans, elektron mikroskobu, termal, multispektral ve hiperspektral gibi makinalar olabilmektedir.

2.1.1. Görüntü işleme ve bilgisayarlı görünün tanımlı

Literatürde terim olarak görüntü işlemenin nerede bitip görüntü analizi ve bilgisayarlı görü gibi diğer ilgili alanların nerede başladığı konusunda kesin bir ayrıma rastlanmamaktadır. En basit tanımlıyla görüntü işleme; ölçülmüş veya kaydedilmiş olan sayısal görüntü verilerini, elektronik ortamda (bilgisayar ve yazılımlar yardımı ile) amaca uygun şekilde değiştirilmesidir (Akar 2009). Görüntüleri birer sinyal olarak kabul eden sinyal işlemenin (signal processing) bir alt dalı olarak da incelenebilen alan, sayısal bir ortam üzerinde ve sayılarla ilgili olduğundan çoğu zaman sayısal görüntü işleme şeklinde anılmaktadır. Ayrıca görüntü işleme; hedef örüntüleri (pattern) sınıflandırmayı amaçlayan ve bilgisayarlı öğrenme (machine learning) bilimi altında incelenen örüntü algılama (pattern recognition) alanıyla da ilişkilidir. Görüntü işleme uygulamalarının yelpazesi var olan bir görüntünün istenen amaca göre zenginleştirilmesinden bir görüntüyü anlamlandırma ya da istenen hedef nesnelere tespitine kadar oldukça geniş bir kapsamdadır. Görüntü işleme; insan görme sisteminin gerçekleştirdiği işlemlerin bilgisayar ortamında otomatik olarak gerçekleştirilmeye çalışılması olarak tanımlanırsa, bunun; öğrenmeyi, ayrımlar yapmayı ve görsel girdiler üzerinde eylem gerçekleştirmeyi kapsadığı aşikârdır. Durum böyleyken amacı insan zekâsını taklit etmek olan yapay zekâ biliminin de işin içine girdiği görülmektedir. Bu bilinenlerin ışığında görüntü işleme ve bilgisayarlı görünün mantıksal kesişim alanı, bir görüntü üzerindeki nesnelere veya kendine özgü özellikleri bulunan bölgeleri tanıma şeklinde tanımlanmaktadır (Gonzales ve Woods 2002). Tanımlamadan anlaşılacağı

üzere bilgisayarlı görü ve görüntü işleme alanları kendi amaçlarına yönelik olarak birbirlerinin araçlarına ihtiyaç duydukça başvurmaktadırlar.

2.1.2. Görüntü işleme teknikleri

Sayısal görüntü işleme teknikleri amaca yönelik ve spesifik olarak çeşitlilikler göstermekle birlikte genel olarak dört madde halinde incelenmektedir.

- Görüntü zenginleştirme (image enhancement)
- Görüntü onarımı (image restoration)
- Görüntü sıkıştırma ve kodlaması (image coding)
- Görüntü bölütlemesi ve algılaması (image segmentation, representation and understanding) (Çulha 1996)

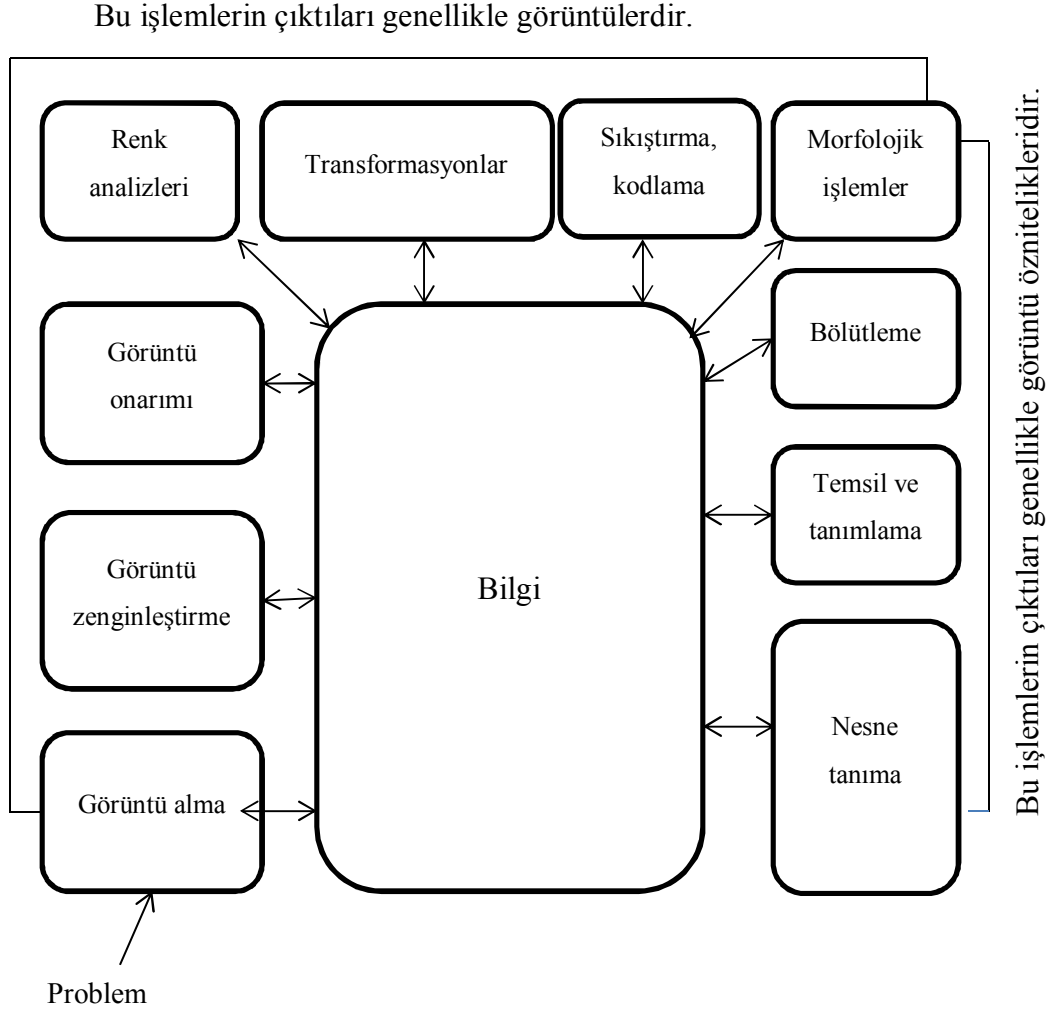
Görüntü zenginleştirmenin ana hedefi, spesifik bir uygulama için görüntü üzerindeki bir kısmın, görüntünün tamamının ya da belirli bir nesnenin görünebilirliğini artırmaktır (Russ 2011).

Görüntü onarımı herhangi bir nedenle bozulmaya uğramış görüntülerin orijinal görüntüye mümkün olduğunca yaklaştırılması çabalarıdır.

Görüntü sıkıştırması ve kodlaması sayısal bir görüntüyü yeterince temsil edebilecek en düşük veri miktarının bulunması çalışmalarıdır (Gonzales ve Woods 2002).

Görüntü bölütlemesi bir görüntünün benzer özniteliklere sahip alt kısımlarının bölünmesi veya ayrılması anlamına gelmektedir (Pratt 2007). Ayrılan ya da bölütlenen kısımların bireysel düzeyde sınıflandırılması ya da birbiriyle olan ilişkilerinin ortaya konulması da görüntü algılanması olarak ifade edilmektedir. Anlaşılacağı üzere bu tekniğin çıktısı diğerlerinden farklı olarak yeni bir görüntü değil, görüntü üzerindeki bölütlerin ya da alt kısımların niceliksel özellikleri hakkında bilgilerdir (Çulha 1996).

Bahsedilen tekniklerin hangilerinin ne şekilde kullanılacağı uygulamaya göre farklılıklar göstermektedir. Çoğu zaman karmaşık problemlerin çözümünde bu tekniklerin birlikte kullanımı söz konusu olmaktadır. Şekil 2.1’de sayısal görüntü işleminin temel adımları görülmektedir (Gonzales ve Woods 2002).




Şekil 2.1. Sayısal görüntü işleminin temel adımları

2.1.3. Sayısal görüntü

Doğal çevrede analog halde sinyaller ve görüntüler çok miktarda bulunmaktadır. Analog görüntü işleme insanlar ve hayvanlar tarafından gözleri yardımıyla sürekli yapılmaktadır. Buradaki analog kelimesinin ifade ettiği anlam, sinyallerin uzay-zamanda sürekli bir şekilde bulunmasıdır. Ancak görüntü işleme anlamında uzay-

zamanda bulunan bu analog sinyallerin bilgisayar ortamına uygun hale getirilmesi gerekmektedir. Bu işlem sayısallaştırma olarak ifade edilmektedir (digitizing). Görüntünün sayısallaştırılması işlemini kamera ve tarayıcılar gibi görüntü alma cihazları gerçekleştirmektedir (Bovik 2009, Karakuş 2006).

Görüntü işleme alanında sayısal görüntüler iki boyutlu sayısal bir fonksiyon $f(x, y)$ olarak ifade edilmektedir. İfadede x ve y uzaysal düzlem koordinatlarını temsil ederken, f 'nin herhangi bir (x, y) koordinatındaki şiddeti sayısal görüntünün o noktadaki yoğunluğu (intensity) ya da gri seviyesi (gray level) olarak adlandırılmaktadır. Bu şekildeki görüntü modeli birçok görüntü işleme yönteminde iki boyutlu bir vektör dizisi olan matris olarak ele alınmaktadır. Bu sonlu sayıda elementten oluşan sayısal görüntünün en küçük yapı taşı da piksel olarak adlandırılmaktadır. Şekil 2.2'de sayısal görüntünün gösterim modeli görülmektedir. Bu gösterimin matris olarak ifadesi de eşitlik 2.1' de verilmiştir (Gonzales ve Woods 2002, Karakuş 2006).



Şekil 2.2. Sayısal görüntünün temsil modeli

$$f(x,y) = \begin{bmatrix} f(0,0) & f(0,1) & \dots & f(0,N-1) \\ f(1,0) & f(1,1) & \dots & f(1,N-1) \\ \vdots & \vdots & \dots & \vdots \\ f(M-1,0) & f(M-1,1) & \dots & f(M-1,N-1) \end{bmatrix} \quad (2.1)$$

2.1.4. Görüntü türleri

2.1.4.1. İkili görüntü (Binary image)


İkili görüntü, her bir pikseli için sadece iki muhtemel değeri olan sayısal görüntüdür. Genellikle her piksel siyah veya beyazı temsilen sırasıyla 1 ve 0 değerleriyle kodlanmaktadır. İkili görüntüler aynı özelliklere sahip bölgeleri temsil eden piksel ve piksel gruplarını temsil etmek için kullanılmaktadır (Russ 2011). Bu tip görüntüler görüntü işleme uygulamalarında maskeleyme işlemleri için sıklıkla kullanılmaktadır. Hedef nesne veya bölgeler 1 yani beyaz olarak ifade edilirken, diğer pikseller için 0 değeri kullanılmaktadır. İkileştirme (binarization) yoluyla ikili görüntüler elde edilebilmektedir. Gri tonlamalı görüntülerin yoğunluk değerlerinde ya da renkli görüntülerin farklı renk kanallarının değerlerinde eşikleme (thresholding) yapılarak ikili görüntüler elde edilebilmektedir. Ayrıca doku (texture) analizi sonucu veya farklı bir yöntemle bölütlenmiş alanların temsili için ikili görüntüler oluşturulabilmektedir. Şekil 2.3' te örnek bir renkli görüntü ve ikili görüntü temsili verilmiştir.




Şekil 2.3. Örnek bir renkli görüntü (a) ve buna ait ikili görüntü (b)

2.1.4.2. Gri seviyeli görüntü (Gray scale / Gray level image)

Gri tonlamalı olarak da ifade edilebilen bu görüntü türünde görüntü farklı gri seviye değerlerinden oluşur. Gri değer aralıkları: $G = \{0,1,2,\dots,255\}$ şeklinde ifade edilir. Bilgisayarda en düşük veri depolaması byte olarak yapılır ve bir byte 8 bittir. Yani bir karakter 8 bit olarak temsil edilir (1 byte = 8 Bit ve $2^8 = 256$). Bir gri seviyeli görüntüde 256 tane farklı gri ton değeri, daha doğrusu gri değer bulunabilir. Bu gösterimde 0 gri değeri kural olarak siyah renge, 255 gri değeri ise beyaza karşılık gelir. Bu değerler arasında ise gri seviyeler oluşmaktadır (Karakuş 2006). Şekil 2.4'te gri seviyeli örnek bir görüntü görülmektedir. Şekilde (6, 8) pikseline karşılık gelen gri seviye değeri 70'dir.



a)



b)

Şekil 2.4. Gri seviyeli örnek görüntü (a) ve gri seviyelerin sayısal temsili (b)

2.1.4.3. Renkli görüntü (Color image)

Renkli görüntüler, piksel yoğunluklarını tayin etmede gri seviyeli görüntülerle benzer özellikler taşır. Ancak yalnızca tek bir görüntü düzlemi kullanmak yerine renkli görüntüler, üç adet yoğunluk elemanı ya da bileşeni (component) ile temsil edilirler. Farklı renk şemaları olmasına rağmen bu bileşenler genellikle kırmızı, yeşil ve mavidir (RGB). Örnek olarak CMYK renk modeli siyan, magenta, sarı ve siyah bileşenlerinden oluşmaktadır. Renkli görüntüler 24-bit gerçek renkli (true color) olarak bilinmekte ve $16\ 777\ 216$ kadar farklı renkleri eşzamanlı olarak bulundurabilmektedirler. Görüntüleme esnasında R(Kırmızı), G(Yeşil), B(Mavi) ile kodlanmış görüntüye ait üç adet gri seviyeli görüntü üst üste ekrana iletilir. Elektro-manyetik spektrumda $0.4-0.5\ \mu\text{m}$ dalga boyu mavi renge; $0.5-0.6\ \mu\text{m}$ dalga boyu yeşil renge; $0.6-0.7\ \mu\text{m}$ dalga boyu kırmızı renge karşılık gelmektedir. Bu dalga boylarında elde edilmiş üç gri seviyeli görüntü bilgisayar ekranında sırası ile kırmızı-yeşil-mavi 24 kombinasyonunda üst üste düşürülecek olursa renkli görüntü sağlanır. Eşitlik 2.2'de de görüldüğü gibi renkli görüntülerin $f(x,y)$ fonksiyonu gri seviyeli görüntüde olduğu gibi 0-255 arasında sayısal bir büyüklük değil, ancak yine elemanları bu değer aralığında olan 3 elemanlı bir vektördür (Karakuş 2006, Nixon ve Aguado 2002).


$$f(x,y) = \begin{bmatrix} f(0,0) = \begin{bmatrix} R \\ G \\ B \end{bmatrix} & f(0,1) = \begin{bmatrix} R \\ G \\ B \end{bmatrix} & \dots & f(0,N-1) = \begin{bmatrix} R \\ G \\ B \end{bmatrix} \\ f(1,0) = \begin{bmatrix} R \\ G \\ B \end{bmatrix} & f(1,1) = \begin{bmatrix} R \\ G \\ B \end{bmatrix} & \dots & f(1,N-1) = \begin{bmatrix} R \\ G \\ B \end{bmatrix} \\ \vdots & \vdots & \dots & \vdots \\ f(M-1,0) = \begin{bmatrix} R \\ G \\ B \end{bmatrix} & f(M-1,1) = \begin{bmatrix} R \\ G \\ B \end{bmatrix} & \dots & f(M-1,N-1) = \begin{bmatrix} R \\ G \\ B \end{bmatrix} \end{bmatrix} \quad (2.2)$$

2.1.4.4. Renk modelleri

Uygulamada farklı yazılım ve donanımların kullandığı çok çeşitli renk modelleri vardır. Bunlardan görüntü işleme alanında en çok kullanılan bazıları aşağıda açıklanmıştır.

RGB renk modeli: Bu renk modeli Kartezyen koordinat sistemini esas almaktadır. Şekil 2.5'teki kübik uzay RGB renk modelini temsil etmektedir. Şekildeki birim küp 0-255 arasındaki değerlerin 0-1 aralığına normalize edilmesiyle oluşturulmuştur. Bu renk

modelinde farklı renkler birim küpün orijininden uzanan vektörleri ile ifade edilmektedir (Gonzales ve Woods 2002). Işığın ana renkleri olan kırmızı, yeşil ve mavi birim küpün eksenleri üzerine çakışık köşelerinde yer alırken, ışığın ikincil renkleri magenta, sarı ve siyan küpün bu noktalara zıt köşeleri üzerinde bulunmaktadır. Gri seviye tonları ise Kartezyen koordinat sisteminin orijini (siyah) ile küpün bu orijine zıt köşegeni arasında (birim küpün ana köşegeni üzerinde) oluşmaktadır.




Şekil 2.5. RGB renk modeli

CMY ve CMYK renk modelleri: RGB renk modelinde açıklandığı üzere magenta, sarı ve siyan ışığın ikincil renkleridir. Bir başka açıdan bakıldığında bu renkler renk pigmentlerinin ana renkleri durumundadır. Örnek olarak siyan pigmentleriyle kaplanmış bir yüzey beyaz ışıkla aydınlatıldığında kırmızı ışık yüzeyden yansımamaktadır. Siyan, kırmızı ışığı yüzeyden yansıyan ve kırmızı-yeşil-mavinin eşit miktarlarından oluşan beyaz ışıktan çıkarmaktadır. Renkli fotokopi ve yazıcı gibi kağıt üzerine renk pigmentlerini bırakan birçok cihaz CMY veri girdisini kullanmakta ya da kendi içerisinde RGB-CMY dönüşümü yapmaktadır (Gonzales ve Woods 2002). Bu dönüşümün matematiksel ifadesi eşitlik 2.3'te verilmiştir.

$$\begin{bmatrix} C \\ M \\ Y \end{bmatrix} = \begin{bmatrix} 1 \\ 1 \\ 1 \end{bmatrix} - \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (2.3)$$

Bu eşitlikte birim küp esas alınarak 0-255 değer aralığı 0-1 arasında normalize edilmiştir. Eşitlikten anlaşılacağı üzere örnek olarak $C = 1 - R$ dir.

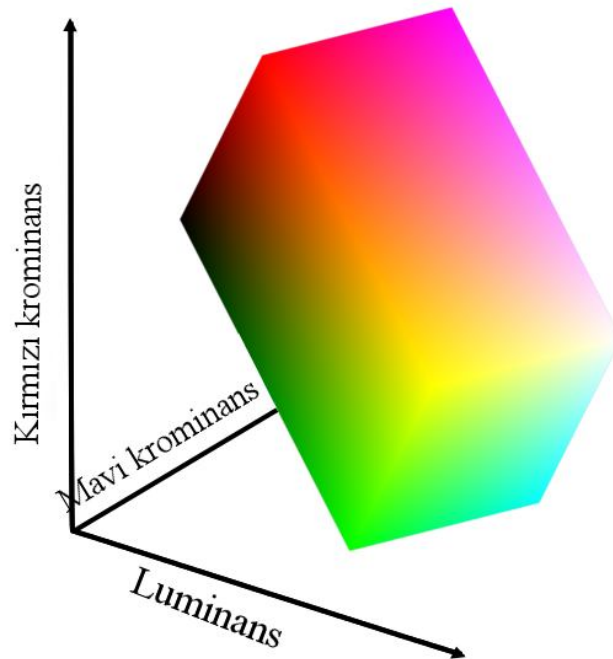
HSI (HSV) renk modeli: Silindirik ya da konik koordinat uzaylarında temsil edilebilen bu modelin HSV, HSL, HSB ve HLS gibi birçok gösterimi mevcuttur. Bu gösterimler arasında parlaklık değerinin hesaplanmasında matematiksel açıdan küçük farklılıklar olmasına rağmen, anlatımda kolaylık olması bakımından bu renk modelleri bu çalışmada aynı madde altında incelenmiştir. HSI açılımı hue-saturasyon-yoğunluk şeklindedir. Renk modelinin son terimi; aydınlanma, ışıklılık (lightness ya da luminance), yoğunluk (intensity), değer (value) ve parlaklık (brightness) gibi ifadeleri temsil etmektedir. Bu renk modeli 1970'lerde bilgisayarlı grafik uygulamaları için geliştirilmiştir. RGB ve CMY renk modellerinin insan renk algısını yeterince tatmin etmemesi bu renk modelinin geliştirilmesine katkıda bulunmuştur. Şekil 2.6'da bu renk modelinin konik uzayda temsili görülmektedir (Anonim 2012a).



Şekil 2.6. HSI renk uzayının konik temsili

Bu renk modelinde açısız boyutla temsil edilen hue bileşeni 0° ile 360° arasında renkleri ifade etmektedir. Hue açısının 0 değeri kırmızıyı, 120 değeri yeşili, 240 değeri maviyi temsil etmektedir. Diğer renkler de bu aralıklarda var olmaktadır. Bu modelde hue bileşeni tüm renk tonlarını tek başına yeterince ifade edemediğinden saturasyon ya da doymuluk elemanına ihtiyaç duyulur. Basit bir örnekle saturasyon bileşeni kırmızıdan pembeye geçişte değişen özelliği temsil eder. Konik renk uzayında düşey eksenle ifade edilen yoğunluk bileşeni ise aydınlanmayı göstermekte ve siyahtan beyaza geçerken değişen özelliği temsil etmektedir. (Forsyth ve Ponce 2003).

YCbCr renk modeli: Bu renk modeli sayısal video ve fotoğraf standardı geliştirme çabaları sonucunda ortaya çıkmıştır. JPEG görüntü sıkıştırma formatı bu modeli kullanmaktadır. Gri seviye bilgisi (Y) tek bir bileşen üzerinden taşınmaktadır. YCbCr modelinde Y luminansı ya da lumayı (gri seviye, yoğunluk), Cb ve Cr ise sırasıyla mavi-fark ve kırmızı-fark kroma bileşenlerini temsil etmektedir. Bu renk modeli tam bir renk uzayını ifade etmekten çok RGB modeli için bir kodlama sağlamaktadır. Buna rağmen bu renk modelinin mantıksal uzay modeli Şekil 2.7'deki gibi ifade edilmektedir.




Şekil 2.7. YCbCr renk modelinin görsel temsili

YCbCr renk modeli ve RGB renk modeli arasındaki dönüşüm ilişkisi aşağıdaki matris eşitliğiyle tanımlanmaktadır (Gonzales ve ark. 2004).

$$\begin{bmatrix} Y \\ Cb \\ Cr \end{bmatrix} = \begin{bmatrix} 16 \\ 128 \\ 128 \end{bmatrix} + \begin{bmatrix} 65,481 & 128,553 & 24,966 \\ -37,797 & -74,203 & 112,000 \\ 112,000 & -93,786 & -18,214 \end{bmatrix} \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (2.4)$$

L*a*b renk modeli: Geometrik olarak HSI yaklaşımına benzeyen L*a*b modeli, küresel bir yapıyla açıklanır. L, gri seviye eksenini yani luminansı temsil ederken, a ve b renk ve saturasyonu birlikte tanımlayan ortogonal eksenlerdir. Şekil 2.8'de L*a*b renk uzayı ve koordinat sistemi görülmektedir. Şekilde a ekseninin yeşil (+a) ile kırmızı (-a) arasındaki geçişi, b ekseninin ise sarı (+b) ile mavi (-b) arasındaki geçişi temsil ettiği görülmektedir.



Şekil 2.8. L*a*b renk uzayı

L*a*b ve RGB renk modelleri arasındaki ilişki eşitlik 2.5'de verilmiştir (Russ 2011).

$$\begin{bmatrix} L \\ a \\ b \end{bmatrix} = \begin{bmatrix} \frac{1}{3} & \frac{1}{3} & \frac{1}{3} \\ -\frac{\sqrt{2}}{6} & -\frac{\sqrt{2}}{6} & \frac{2\sqrt{2}}{6} \\ \frac{1}{\sqrt{2}} & -\frac{1}{\sqrt{2}} & 0 \end{bmatrix} \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (2.5)$$

2.1.5. Görüntü karakteristikleri

2.1.5.1. Görüntü çözünürlüğü

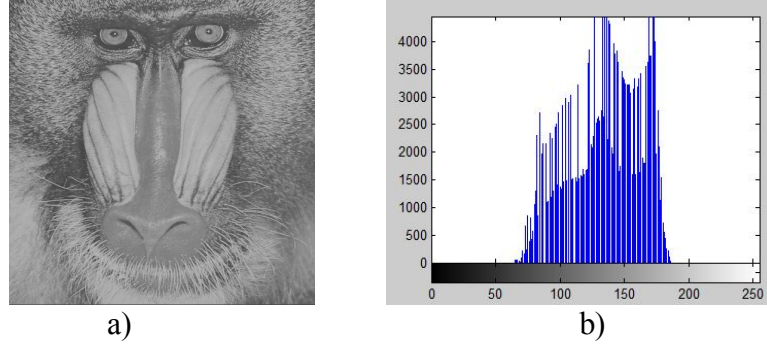
Görüntü çözünürlüğü, bir görüntünün saklayabildiği detayların bir ölçüsüdür. Sayısal görüntüdeki piksel sayısı çözünürlüğü ifade etmektedir. N piksel yüksekliğinde ve M piksel genişliğindeki bir görüntünün çözünürlüğü $M \times N$ şeklinde tanımlanır. Görüntü işleme açısından çözünürlüğün yüksek olması daha ayrıntılı görüntü anlamına gelirken, yüksek çözünürlüklü görüntüler üzerinde yapılan herhangi bir işleme veya hesaplamada bilgisayar donanım kaynaklarının daha fazla kullanılması ve hesaplama zamanlarının artması söz konusudur. Uygulamanın ve donanımın müsaade edebildiği optimum çözünürlüğün seçimi önem taşımaktadır.

2.1.5.2. Görüntü histogramı

Sayısal görüntüde histogram, görüntü içerisinde her gri seviye veya renk değerinden kaç adet olduğunu gösteren bir grafikdir. Bu grafik, değerlerin sayıca dağılımını gösteren bir fonksiyon olarak ifade edilmektedir. Bu grafiğe bakılarak görüntünün parlaklık durumu, kontrastı ya da tonları hakkında bilgi sahibi olunabilir (Akar 2009). Histogramlar, farklı renk bileşenleri ve gri seviye düzlemleri için elde edilebilirler. Bileşenin piksel değerleri dağılımları görüntüde yer alan farklı nesnelere için incelendiğinde eşikleme yöntemi için uygun eşik değerleri elde edilebilmektedir. Eşitlik 2.6'da histogram fonksiyonu görülmektedir.

$$h(k) = \sum_{k=0}^{255} p(k) \quad (2.6)$$

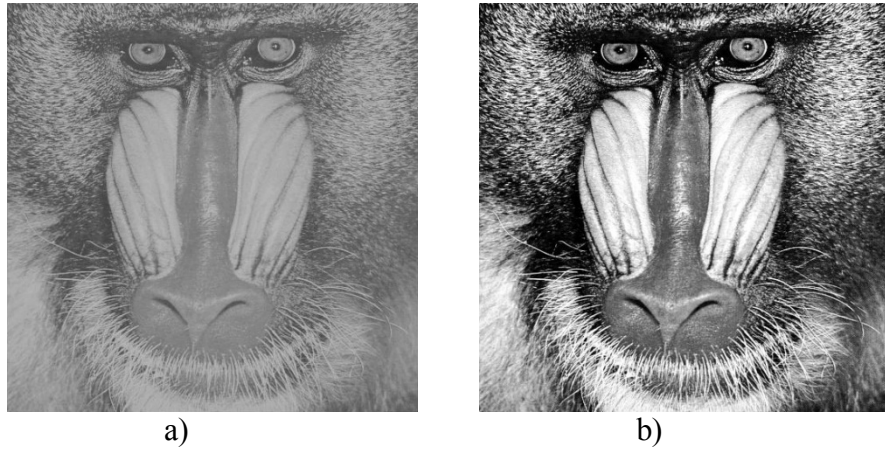
Burada verilen $h(k)$, k 'nci gri seviye veya renk değerinin görüntü içinde sayıca dağılımıdır (Karakuş 2006). Şekil 2.9, örnek bir gri seviyeli görüntü ve buna ait histogram grafiğini göstermektedir.



Şekil 2.9. Gri seviyeli görüntü (a) ve histogram grafiği (b)

2.1.5.3. Görüntü kontrastı

Zıtlık olarak da ifade edilebilen kontrast, bir sayısal görüntüde gri seviye ya da başka bir renk bileşeninin bir nesneyi ayırt etmedeki farklılık derecesidir. Kontrast bir görüntüdeki en parlak kısım ile en karanlık kısım arasındaki farkı ifade eder. Kontrastı artırılmış görüntülerde nesnelere ve renkleri birbirlerinden daha ayrı ve farklılığı daha belirgin biçimde olurken, düşük kontrastta renk tonları ya da gri seviyeler birbirine daha yakındır. Şekil 2.10'da Şekil 2.9'daki görüntünün yüksek ve düşük kontrastlı durumları verilmiştir.



Şekil 2.10. Düşük kontrastlı (a) ve yüksek kontrastlı görüntü (b)


2.1.6. Temel gri seviye ve ikili görüntü işlemleri

2.1.6.1. Histogram eşitleme ile kontrast artırma


Gri seviyeli bir görüntü düşünüldüğünde eğer görüntünün sahip olduğu en düşük ve en yüksek piksel değerleri birbirine çok yakınsa (110-150 gibi) veya görüntü piksellerinin büyük çoğunluğu böyle bir aralıktaysa görüntüde ayrıntıların seçimi güçleşmektedir. Şekil 2.11'de Şekil 2.10'daki görüntülere ait histogram dağılımları görülmektedir. Kontrastı az olan görüntülerin histogramları Şekil 2.11a'daki gibi dar bir aralıkta dağılım göstermektedir. En basit kontrast iyileştirmesi histogram eşitlik 2.7 ile yapılır (Karakuş 2006).

$$f'(x, y) = \left(\frac{f(x, y) - f(x, y)_{min}}{f(x, y)_{max} - f(x, y)_{min}} \right) \times 255 \quad (2.7)$$

Burada; $f(x, y)$ ham piksel değerini, $f(x, y)_{min}$ ve $f(x, y)_{max}$ ise görüntünün sahip olduğu en düşük ve en yüksek piksel değerlerini temsil etmektedir. Eşitlikte $f'(x, y)$, kontrast iyileştirmesi yapılmış piksel değerini göstermektedir.



a)



b)

Şekil 2.11. Düşük kontrastlı (a) ve yüksek kontrastlı görüntü (b) histogramları

2.1.6.2. Eşikleme (thresholding)

Eşikleme, bir görüntüdeki farklı yoğunluktaki veya renkteki ön ve arka plan bölgelerini bölütlemeye kullanılan en temel yöntemdir. Gri seviyeli ya da renkli görüntülere uygulanabilir. Belirlenen eşik seviyesinin altında kalan değerler 0, üstünde olan değerler 1 olarak kabul edilir ve görüntü ikili görüntüye dönüştürülür (Akar 2009). Eşik değeri belirlemek için farklı yöntemler vardır. Bunlardan bazıları;

- Histogram esaslı eşik belirleme,
- Kümeleşme esaslı eşik belirleme,


- Histogram entropisi esaslı eşik belirleme,
- Nesne özelliklerine dayanan eşik belirleme,
- Uzamsal esaslı eşik belirleme,
- Yerel uyarılama esaslı eşik belirleme yöntemleridir (Baykan 2007).

Histogram esaslı eşik bulma yönteminde görüntü histogramı incelenerek histogram eğrisinin oluşturduğu tepe ve çukurlar saptanır. Ayrımı yapılacak bölge veya nesnenin piksellerinin en çok dağılım gösterdiği piksel sınır değerleri eşik değeri olarak belirlenir.

2.1.6.3. Görüntü negatifi

Bir sayısal görüntünün yoğunluk değerlerinin tersi fotoğrafçılıkta kullanılan negatif görüntüyü ifade etmektedir. Negatif üretme işlemi genellikle bir görüntünün karanlık kısımlarında saklanmış beyaz ya da gri seviyeli ayrıntıları açığa çıkarmak için kullanılmaktadır. Değerleri $[0, L-1]$ arasında olan gri seviyeli bir görüntünün negatifi, Şekil 2.12'de görülen negatif dönüşüm tablosu ve eşitlik 2.8 ile tanımlanmaktadır (Gonzales ve Woods 2002).

$$s = L - 1 - r \quad (2.8)$$




Şekil 2.12. Negatif görüntü dönüşüm tablosu (Gonzales ve Woods 2002).

2.1.7. Blob analizi ve bölge etiketleme (Region labeling)


Bir ikili görüntüde bulunan çeşitli nesnelere tanımlamak ve etiketlemek için kullanılan yöntemler, bölge etiketleme, blob analizi, morfolojik analiz veya bağlantılı bileşenlerin tanımlanması gibi terimlerle anılmaktadır. Bireysel olarak etiketlenen nesnelere ayrı ayrı görüntülenip, işlenip ya da değiştirilebileceğinden bu yöntem çok kullanışlıdır. Bölge etiketleme, bir ikili görüntüde aynı ikili değere sahip bağlantılı piksel gruplarını tanımlayarak bulma işlemidir. Bu işlem yapılırken izlenen en basit yol, yatay ve dikey yönde aynı ikili değere sahip piksellerin olup olmadığının tüm görüntünün soldan sağa veya üstten alta tamamen taranması yoluyla aranmasıdır. Bu işlemin dikdörtgen görüntünün köşegeni doğrultusunda yapılması görevi karmaşıklaştırmakta ve genellikle gerekli olmamaktadır. Bağlantılı piksel gruplarının kaydı analizi yapılacak ikili görüntü ile aynı boyutlardaki ayrı bir etiket dizi değişkeni aracılığıyla yapılmaktadır (Bovik 2009). Şekil 2.13'te örnek bir görüntü üzerinde blob analizi ve bölge etiketleme süreci verilmiştir.



a)



b)



c)

Şekil 2.13. Örnek renkli görüntünün (a) ikili formu (b) ve etiketlenmiş formu (c)

2.1.7.1. Bölge etiketleme algoritması

Aşağıdaki algoritma bölge etiketlemenin mantıksal akış düzenini açıklamaktadır.

1. Verilen $N \times M$ boyutlarında bir ikili görüntü f karşısında $N \times M$ boyutlarındaki bölge etiket değişkenini tanımla:

Tüm n değerleri için $r(n) = 0$ ve bölge sayacının değeri $k = 1$.

Tüm n değerleri için Görüntüyü soldan sağa ve üstten alta tara.

2. Eğer $f(n) = 0$ ise bir şey yapma.

3. Eğer $f(n) = 1$ ve $f(n - (1,0)) = f(n - (0,1)) = 0$ ise $r(n) = 0$ ve $k = k + 1$ olarak tayin et. Bu durumda $f(n)$ 'nin sol ve üst komşuları nesnelere ait değildir.

4. Eğer $f(n) = 1$, $f(n - (1,0)) = 1$ ve $f(n - (0,1)) = 0$ ise $r(n) = r(n - (1,0))$ olarak tayin et. Bu durumda üst komşu $f(n - (1,0))$, $f(n)$ ile aynı nesneye aittir.

5. Eğer $f(n) = 1$, $f(n - (1,0)) = 0$ ve $f(n - (0,1)) = 1$ ise $r(n) = r(n - (0,1))$ olarak tayin et. Bu durumda sol komşu $f(n - (0,1))$, $f(n)$ ile aynı nesneye aittir (Bovik 2009).

2.1.7.2. Bölge sayma algoritması

Nesne sayısı değişken değerini ayarla: $c = 0$, Her bir n değeri için aşağıdaki süreci yap:

1. Eğer $f(n) = 0$ ise hiçbir şey yapma.

2. Eğer $f(n) = 1$ ise $c[r(n)] = c[r(n)] + 1$

Bu şekilde tüm ayırık bölgeler sayılmaktadır (Bovik 2009).

2.1.7.3. Küçük bölgelerin kaldırılması

Genellikle ikili görüntü üzerindeki ana (çoğunlukla en büyük) nesnelerin (blob) içerisinde sıfır değerli piksel gruplarının yani siyah lekelerin olması istenmez bu durumda bunların kaldırılması gereklidir. Bu amaçla aşağıdaki algoritma izlenir.

İzin verilen en düşük nesne boyutu S adet piksel olduğu varsayımıyla her n değeri için şunları yap:

1. Eğer $f(n) = 0$ ise hiçbir şey yapma.
2. Eğer $f(n) = 1$ ve $c[r(n)] < S$ ise $g(n) = 0$ olarak tayin et (Bovik 2009).

2.1.8. Kenar saptama

Görüntüde birbirlerinden oldukça farklı gri seviye ya da renk değerlerine sahip bölgeler arasındaki sınırlar kenar olarak tanımlanmaktadır (Çulha 1996). Kenar bilgisi görüntüdeki nesnelere konumlandırma açısından önem taşımaktadır. Kenar tanıma, gri seviyeli ya da renkli görüntüdeki anlamlı süreksizliklerin bulunması için en yaygın yaklaşımdır. Kenar saptama yöntemleri üzerinde sıklıkla çalışılan bir konudur. Genellikle bu yöntemler, kenar bulma operatörleri şeklinde adlandırılır. Canny, Sobel, Roberts, gradyan, Prewitt gibi operatörler görüntü işleme alanında kenar bulmada sıklıkla kullanılmaktadır. Şekil 2.14'te örnek görüntü ve kenar görüntüleri verilmiştir.



a)

b)

Şekil 2.14. Örnek görüntü (a) ve çıkartılmış kenar görüntüsü (b).

2.1.9. Görüntü öznitelik çıkarımı (image feature extraction)

Görüntü özniteliği, bir sayısal görüntüyü ya da görüntüde bulunan herhangi bir nesne-bölgeyi ayırt edici karakteristikler ve özelliklerdir. Öznitelikler bir görüntünün tamamını karakterize edebileceği gibi nesne, bölge gibi görüntüyü oluşturan alt kısımları da karakterize edebilir. Bazı öznitelikler görüntünün görsel tanımlamasından doğan doğal öznitelikler olmasına karşın, yapay öznitelikler görüntü üzerinde yapılan özel işlemlerin sonucudur. Doğal öznitelikler arasında piksel bölgelerinin yoğunluk değerleri ve gri seviye dokusal (textural) bölge özellikleri sayılabilir. Görüntü genlik histogramları ve uzamsal (spatial) tayfları yapay özniteliklere birer örnektir (Pratt 2007). Görüntü öznitelikleri, görüntü üzerindeki ortak özellikli bölgelerin bölütlenmesinde veya bu bölgelerin sınıflandırılarak etiketlenmesinde büyük önem taşımaktadır.

Özniteliklerin bir görüntü ya da görüntüde bulunan bir nesne-bölge için hesaplanması öznitelik çıkarımı (feature extraction) olarak tanımlanır. Uygulamanın tipine ve hedef fenomenin karakteristiğine göre görüntü öznitelikleri, şekil, doku ve renk bilgisi taşıyabilir. Sayısız öznitelik ve bunların çıkarma yöntemleri bulunmasına karşın, genel olarak öznitelikler şu şekilde sınıflandırılır:

- Genel öznitelikler; renk, doku, şekil gibi uygulama ve saha bağımsız özniteliklerdir. Bunları da alt fraksiyonlara ayırmak mümkündür.
 - Piksel düzeyindeki öznitelikler, her piksel için hesaplanırlar.
 - Yerel öznitelikler, görüntü bölütlemesi ya da kenar saptama sonrası görüntü alt kısımları üzerinde hesaplanırlar.
 - Global öznitelikler, görüntünün tamamı ya da görüntünün sürekli alt bölgeleri için hesaplanmaktadır.
- Sahaya özgü öznitelikler; insan yüzü, parmak izi, yazı karakteri tanıma gibi uygulamaya bağımlı özniteliklerdir (Lei ve ark. 1999).

2.1.10. Sayısal görüntülerde frekans analizi ve bazı dönüşümler (transformations)

Dönüşümler yardımıyla uzaysal tanım kümesindeki gri seviye ya da renk bilgileri, frekans uzayına dönüştürülerek görüntüye ait frekans bilgileri elde edilir. Dönüşümden

sonra görüntü üzerinde filtreleme işlemleri gerçekleştirilebilir. Yüksek frekanslı bilgiler alçak geçiren filtre yardımıyla elenebilir. Alçak frekanslı bilgiler ise yüksek geçiren filtre ile elimine edilerek görüntü keskinleştirilebilir. Bant geçiren filtre (band-pass filter) yardımıyla spektrumun istenilen bölgesine ait frekans bilgileri elde edilebilir (Baykan 2007).

2.1.10.1. Konvolüsyon (convolution) ve filtreleme

Konvolüsyon orjinal görüntü piksellerinin boyutu 2x2, 3x3 veya 5x5 gibi boyutlardaki çekirdek (kernel) maske matrisleriyle süzülmesi işlemidir. Birçok dönüşüm ve doğrusal filtreleme konvolüsyon esastır ve frekans sahası (frequency domain) yöntemlerinin temelinde konvolüsyon teoremi vardır. Konvolüsyon ile iki matris üst üste katlanarak birleştirir ve aralarındaki ilişki aranır (Çulha 1996, Baykan 2007, Karakuş 2006).

Bir görüntü fonksiyonuyla $f(x, y)$ doğrusal ve konumdan bağımsız çekirdek matrisi $h(x, y)$ 'nin konvolüsyonu sonucunda elde edilen $g(x, y)$ görüntüsü eşitlik 2.9 ile tanımlanır (Çulha 1996). Konvolüsyon işleminde çekirdek matrisinin değerleri ile her piksel ve komşuları küçük bir bölgede çarpılarak, bu çarpımların toplamları orijinal piksel konumuna yerleştirilir. Bu işlemler orijinal görüntünün tüm piksel değerleri için tekrarlanarak yeni görüntü elde edilir (Russ 2011).

$$g(x, y) = h(x, y) \otimes f(x, y) \quad (2.9)$$


2.1.10.2. İki boyutlu ayrık Fourier dönüşümü

Fourier dönüşümü, bir fonksiyonu frekans bileşenlerine ayırmada (dekompozisyon) kullanılır. İlk olarak Fransız matematikçi Joseph Fourier (1770-1830) tarafından her periyodik işaretin kompleks üstel fonksiyonların sonsuz toplamları ile edilebileceğini göstermesiyle ortaya çıkmıştır (Yakar 2006). Sayısal görüntü de $f(x, y)$ fonksiyonu şekline tanımlandığından Fourier dönüşümü sayısal görüntüyü de farklı frekans bileşenlerine ayırmaktadır. Bu yöntem görüntü işlemede oldukça fazla kullanım alanına sahiptir. Öznitelik çıkarımı, görüntü bölütlemesi ve zenginleştirilmesi gibi alanlarda Fourier dönüşümünden yararlanılmaktadır. Bu dönüşümün sinyal ve ses işleme gibi elektrik-elektronik mühendisliğine konu olan alana özgü birçok formu vardır. İki

boyutlu ayrık Fourier dönüşümü görüntü işleme tekniği açısından önem taşır. Bir sayısal görüntü fonksiyonuna $f(x, y)$ ait iki boyutlu ayrık Fourier dönüşümü eşitlik 2.10'da tanımlanmaktadır (Pratt 2007).

$$\mathcal{F}(\omega_x, \omega_y) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x, y) \exp\{-i(\omega_x x, \omega_y y)\} dx dy \quad (2.10)$$

Burada ω_x ve ω_y uzamsal (spatial) frekanslar, i ise $\sqrt{-1}$ dir. Bundan anlaşılacağı üzere Fourier katsayıları $\mathcal{F}(\omega_x, \omega_y)$ genellikle karmaşık yani imajiner sayılardır. Fourier katsayısının reel ve karmaşık kısımları hesaplama kolaylığı bakımından ayrı olarak $\mathcal{F}(\omega_x, \omega_y) = \mathcal{R}(\omega_x, \omega_y) + i\mathcal{I}(\omega_x, \omega_y)$ şeklinde ifade edilebilir. Şekil 2.15'te örnek görüntü ve iki boyutlu ayrık Fourier dönüşümü görülmektedir.




Şekil 2.15. Örnek görüntü (a) ve iki boyutlu ayrık Fourier dönüşümü (b)

2.1.10.3. Ayrık dalgacık (wavelet) dönüşümü

Sayısal görüntünün frekans analizinde kullanılan diğer bir dekompozisyon yöntemi ayrık dalgacık dönüşümüdür (DWT). Gürültü azaltma (denoising), görüntü sıkıştırma, öznelik çıkarma gibi uygulamalarda bu yöntemden faydalanılmaktadır. JPEG 2000 sıkıştırma standardı bu yöntemi kullanmaktadır. DWT uzamsal olarak konumlandırılmış bir dizi frekans kanalları içerisinde sinyal dekompozisyonu olarak tanımlanır. Sinyal iki adet tamamlayıcı filtreden geçirilmekte, bunun sonucunda da kestirim (approximation) ve detay olmak üzere iki adet sinyal bileşeni ortaya çıkmaktadır. Bu bileşenler veri

kayıbı olmaksızın tekrar birleştirilebilmektedir. Bu işlem rekonstrüksiyon olarak adlandırılmaktadır. Bu işlemlerin matematiksel tanımı ayrık dalgacık dönüşümü ve ters ayrık dalgacık dönüşümüdür. Bir sayısal görüntü DWT ile farklı uzamsal çözünürlüklü görüntülerin sekansına dekompoze edilebilmektedir. İki boyutlu görüntüde N seviyesindeki bir dekompozisyon, görüntüyü $3N+1$ sayıdaki farklı frekans bandlarına (LL, LH, HL ve HH) ayırmaktadır (Mohideen ve ark. 2008). Şekil 2.16'da iki boyutlu görüntünün DWT ile dekompozisyonunun temsili görülmektedir. Dekompozisyonlarda alçak frekanslı alt bandlar (LL) görüntüdeki aydınlanmayı temsil ederken, yüksek frekanslı olanlar görüntü ayrıntılarını yani görüntüde bulunan nesnelere ve diğer her şeyi temsil etmektedir.



Şekil 2.16. İki boyutlu görüntünün DWT ile dekompozisyonunun temsili

2.2. Görüntü Tanıma Uygulamalarında İstatistiksel Sınıflandırıcılar ve Bilgisayarlı Öğrenme Teknikleri

Görüntü işleme ve bilgisayarlı görü uygulamalarında karşılaşılan karmaşık problemlerin çoğunda yapay zeka ve bilgisayarlı öğrenme tekniklerinden yararlanılmaktadır. Bu tür problemler görüntüye ait bir nesnenin ya da görüntünün tamamının önceden bilinen bir sınıfa dahil edilmesini içerir. Bir sınıflandırıcı, önceden bilinen sınıfların belirli sayıda gözlem ya da örneklerinden oluşan bir eğitim setini esas alarak bilinmeyen bir nesnenin muhtemel sınıfını belirleyen bir yöntemdir. Eğitim setinden öznelik çıkarma yöntemleriyle hedef nesnelere öznelikleri bir vektör dizisi oluşturacak şekilde hazırlanır. Her bir gözlem veya örnek için bir kullanıcının bu örneklere karşılık gelen sınıfları temsilen bir kategori değişkeni veya numerik vektör hazırlaması etiketleme

işlemidir. Öznitelikler çıkarıldıktan sonra sınıflandırıcıların öğrenme ya da eğitimi için iki farklı durum söz konusudur (Anonim 2012b). İlk durumda eğitim setindeki her örneğin asıl sınıfı sınıflandırıcıya etiketleme yoluyla bildirilir. Sınıflandırıcının girdi ve çıktı arasında bir fonksiyon üretmesi beklenir. Bu danışmanlı (supervised) öğrenme dolayısıyla sınıflandırma olarak adlandırılır. İkinci durumda sınıflandırıcıya örneklerin dahil olduğu sınıflar hakkında bilgi verilmez. Girişte verilen bilgilere göre sınıflandırıcı her bir örneği kendi arasında sınıflandıracak şekilde kendi kurallarını oluşturur. Buna da danışmansız (unsupervised) sınıflandırma denmektedir.

Sınıflandırıcılar parametrik ve parametrik olmayanlar şeklinde de incelenmektedir. Öznitelik değerlerinin örneğin normal dağılım gibi bir kurala bağlı olarak dağılım gösterdiğini varsayan sınıflandırıcılar parametrik sınıflandırıcılar olarak adlandırılırlar. Parametrik olmayan sınıflandırıcılar istatistiksel kabullenme yapmazlar ve öznitelik değerleri arasındaki gizli interaksiyonları ortaya çıkarma konusunda daha iyidirler. Naive Bayes ve diskriminant sınıflandırıcıları parametrik sınıflandırıcılara birer örnektir. K-en-yakın komşu, yapay sinir ağları, destek vektör makinası gibi sınıflandırıcılar ise parametrik olmayanlardır.

2.3. Şeftali

Anavatanı Çin olan şeftalinin (*Prunus persica* L.) yetiştiriciliği M.Ö. 2000’li yıllardan beri yapılmaktadır. Halen üç adet vahşi şeftali çeşidi Çin’de bulunmaktadır. Dünyada şeftali üretimi Ekvatorun üst ve altından itibaren 24° ve 45° enlem değerleri arasında yapılabilmektedir (Childers ve ark. 1995). Şeftaliler sekiz metreye kadar yükselen ağaçlar teşkil eder. Ağaçları genellikle yayvan bir taç şeklindedir. Ağaç gövdeleri kırmızımtırak gri renktedir. Yaprakları söğüt yaprağı şeklinde uzunlukları genişliklerine göre fazladır. Yaprak ayasının üst yüzü parlak yeşil, alt yüzü grimsi yeşildir. Şeftali meyvesi sert çekirdeklidir. Meyve kabuğu meyve olgunlaşmasının erken döneminde yeşil iken olgunlukla birlikte sararır ve çeşidine göre açık veya koyu kırmızı yanaklıdır. Kabuk tüylü ya da tüysüz olabilmektedir (Özbek 1978).

Ülkemiz tarımı ve ekonomisinde dünyada üretimi en fazla yapılan meyveler içerisinde yer alan şeftali üretiminin önemli bir yeri vardır. Ülkemizde 2010 yılı verilerine göre

yaklaşık 14 milyon adet şeftali ağacından yılda ortalama yaklaşık 545 bin ton ürün elde edilmektedir. Çizelge 2.1’de FAO verilerine göre son 5 yıllık Türkiye ve Dünya şeftali ekim alanı, üretim ve verim değerleri verilmiştir. Yıllık şeftali ihracatımız ise yaklaşık 10 bin tondur. Ağaç sayısı ve üretim yönüyle Marmara Bölgesi (Bursa başta olmak üzere) lider konumunda yer almaktadır. Yurtiçi ihtiyacın karşılanması ve ihracatın geliştirilmesi büyük ölçüde şeftali üretiminde verimin artırılmasına bağlıdır. (FAO 2010, Vural ve Turhan 2011).

Vural ve Turhan (2011)’e göre şeftali üretimindeki başlıca masraflar; gübreleme, sulama, çapalama, budama, seyreltme, ot temizliği ve ot toplama gibi tarımsal uygulamalardan kaynaklanmaktadır. Ayrıca araştırmacılar çalışmalarında özellikle gübre girdisinin uygun miktarda ve tekniğine uygun şekilde kullanılması gerektiğini, diğer girdilere oranla aşırı kullanılmamasına dikkat edilmesine ihtiyaç bulunduğunu vurgulamışlardır. Bu açıdan bakıldığında da şeftali üretiminde hassas tarım uygulamalarının önemi açığa çıkmaktadır.

Çizelge 2.1. Yıllar bazında Türkiye ve Dünya şeftali ekim alanları, üretim ve verim değerleri (FAO 2010)

Yıllar	Ekim Alanı (ha)		Üretim (ton)		Verim (hg/ha)	
	Dünya	Türkiye	Dünya	Türkiye	Dünya	Türkiye
2006	1 465 860	27 700	18 110 911	552 775	123 551	199 558
2007	1 496 801	29 400	19 121 018	539 435	127 746	183 481
2008	1 503 675	28 200	19 882 212	551 906	132 224	195 711
2009	1 513 999	27 900	20 406 077	547 219	134 783	196 136
2010	1 538 682	28 773	20 528 283	534 903	133 415	185 904

2.4. Önceki Çalışmalar

Parrish ve Goksel (1977), henüz renkli görüntüleme yaygın değilken siyah-beyaz TV kamerası kullanarak örüntü tanıma tekniklerini temel alan otomatik robot elma hasat sistemi üzerine fizibilite çalışması yapmışlardır. TV kamera lensi önünde jelatin renk filtreleri yerleştirilerek kırmızı ve yeşil renk kanalları arasında kontrast elde etmişlerdir. Piksel yoğunluk değerleri kullanarak elde ettikleri bağlı pikseller üzerinde morfolojik işlemler yaparak meyveyi tanımaya çalışmışlardır.

Whittaker ve ark. (1987) doğal ortamda olgun domates meyvesini siyah-beyaz kamera kullanarak tanıma ve domatesleri konumlandırma üzerine bir araştırma yapmışlardır. Şekil bilgisini piksel gruplarını analiz ederek çıkarmışlardır. Görüntülere Sobel filtresi uygulayarak kenar çıkarma işlemi yapmışlardır. Daha sonra bu kenar bilgisi içeren görüntüye dairesel Hough transform uygulayarak domates kontörlerine karşılık gelen yay parçalarını elde etmişlerdir. Araştırmacılar yuvarlak kıvrımlı yaprak şekillerinin meyve tanımda büyük zorluklar çıkardığını bildirmişlerdir.

Levi ve ark. (1988) renkli kamera ve yapay aydınlatma kullanarak portakal meyvesini saptayan bir sistem geliştirmişlerdir. Renk bilgisini ve Sobel operatörü kullanarak gradyan görüntüler elde etmişler, önceden tanımlı meyve şablonu ile eşleştirme yaparak meyveleri saptamışlardır. Bu yöntemle görünür meyvelerin %70'ini saptayabilmişlerdir. Araştırmacıların bildirdiğine göre geliştirdikleri algoritma yeşil meyveler üzerinde düşük performanslar sergilemiştir.

Pla ve ark. (1993) yapay aydınlatma kullanarak, dairesel nesnelere saptamak üzere bir çalışma yapmışlar, geliştirdikleri yöntemi portakal meyvesi üzerinde test etmişlerdir. Meyvelerin bulunduğu ve konkav yüzeyler içeren görüntüleri almada siyah-beyaz kamera ve flaş lambaları kullanmışlardır. Araştırmacıların bildirdiğine göre geliştirdikleri sistem portakalın erken olgunluk döneminde meyveleri tanımayı başarmıştır. Yapay aydınlatma koşulları altında sistemleri sırasıyla %75 ve %80'lik başarılı saptama ve hatalı saptama oranları sağlamıştır.

Buemi ve ark. (1995) renkli kamera kullanan bilgisayarlı görü sistemine sahip bir robotla domates hasat sistemi geliştirmişlerdir. Görüntü bölütlemesi için hue-saturasyon-yoğunluk renk modelinde hue ve saturasyon bileşenlerini çıkararak eşikleme yöntemini kullanmışlardır. Aynı görüntüyü stereo kameralar kullanarak üç boyutlu olarak oluşturmuşlardır. Araştırmacıların bildirdiğine göre geliştirdikleri bilgisayarlı görü sistemi, görüntülerdeki domateslerin %90'ını tanıyabilmiştir.

Morimoto ve ark. (2000) meyveleri tanıma ya da sınıflandırma uygulamalarında kullanılmak üzere meyve şekillerini analiz eden bir algoritma geliştirmişlerdir. Çalışmalarında meyve şekillerini değerlendirmede fraktal boyutlar ve yapay sinir ağlarından yararlanmışlardır. Meyve şekillerini şeklin ağırlık merkezi çevresinde bulunan yarıçapların oluşturduğu tek boyutlu profil yapısına göre karakterize etmişlerdir. Meyvenin farklı yönlerdeki altı profil durumlarını çıkartarak tek boyutlu profil verisinin düzensizliklerini atraktör ve fraktal boyutlarda ölçmüşlerdir. Üç katmanlı bir yapay sinir ağını tek boyutlu profil verisini izlemek ve tanımlamak için eğitmişlerdir. Çeşitli meyveler için tanımlama hataları, atraktör ve fraktal boyutlardaki şekiller arasındaki ilişkileri araştırmışlardır. Araştırmacılar, atraktör ve fraktal boyutların yapay sinir ağlarıyla kullanımının meyve şekillerinin kantitatif olarak değerlendirilmesine olanak verdiğini bildirmişlerdir.

Hayashi ve ark. (2002) geliştirdikleri patlıcanın robotla hasadı sisteminin bir parçası olarak patlıcanı doğal ortamında algılayabilen bir bilgisayarlı görü algoritması geliştirmişlerdir. Bu amaçla renk karakteristikleri ve morfolojik öznitelikleri kullanmışlardır. Bitki görüntülerinden patlıcanı ayırmak amacıyla görüntülerdeki gri yoğunluklu pikselleri parlaklığa göre ayırarak arka planı elimine etmişlerdir. Bu yöntemle bazı yaprak ve gövde kısımları meyve olarak algılanabileceğinden patlıcanın morfolojik özniteliklerinden de yararlanmışlardır. Morfolojik değerlendirmeler sonucu dikey yönelimli cisimleri meyve olarak kabul etmişlerdir. Aday nesneyi mantıksal “VE” operasyonu ile 2 şablona ayırmışlar ve dikey olarak bölünmüş iki nesne elde etmişlerdir. Kısa nesnelere eleyerek en yüksek alana sahip nesneyi elde etmişlerdir. Algoritmalarında nesnelere içerisine dikey çizgiler atayarak en uzun çizgiyi barındırabilen cismi patlıcan olarak algılatmışlardır.

Annamalai ve Lee (2004) yeşil narenciye meyvelerini yeşil yapraklar arasından spektral farklılıklarına göre ayırt etmek üzere bir araştırma yapmışlardır. Laboratuvar tipi bir spektrofotometre kullanarak yeşil narenciye meyveleri ve yeşil yapraklar arasında ayırt edici olabilecek ve gerçek-zamanlı spektral esaslı bir verim haritalama sisteminde kullanılabilen kritik dalga boylarını araştırmışlardır.

Bulanon ve ark. (2004) elma hasat robotunun sensör sistemini oluşturmak üzere bir bilgisayarlı görü algoritması geliştirmişlerdir. Meyveleri tanımda krominans modeli kullanmışlardır. Bu modelden öznitelikler çıkartarak meyveleri bulmak amacıyla bir yapay sinir ağı ve bir karar teorik sınıflandırıcı kullanmışlardır. Araştırmacıların bildirdiğine göre her iki yöntemle de olgun meyveler için %80'den fazla başarı oranları elde etmişlerdir.

Stanjko ve ark. (2004) elma meyvesinin doğal yetiştirme periyodunda sayıları ve çaplarını tahmin etmek üzere bir yöntem ortaya koymuşlardır. Araştırmacıların algılama algoritmaları yaprak ve meyvelerin farklı ısı depolama kabiliyetleri prensibine göre çalışmıştır. Bu amaçla termal kamera kullanarak görüntüler toplamışlardır. Renkli kırmızı-yeşil-mavi renk modelindeki görüntüleri bileşenlerine ayırarak bitki ve toprak piksellerini ayırmak üzere NDI endeks hesaplaması yapmışlardır. NDI görüntü üzerinde genel eşikleme yaparak meyve ve yaprakları ayırabilmişlerdir. Algoritmalarının sonuçlarını elle sayılan ve algoritma tarafından sayılan meyveler arasında regresyon analizi yaparak değerlendirmişlerdir. Denemelerinde korelasyon katsayılarını 0,83 ve 0,88 arasında elde etmişlerdir.

Regunathan ve Lee (2005) olgun portakalları saptamak üzere bir bilgisayarlı görü sistemi geliştirmişlerdir. Hue ve saturasyon renk kanallarını kullanarak meyve piksellerini bulmak için Fisher'in diskriminant analizi, yapay sinir ağları ve Bayesian sınıflandırması kullanmışlardır. Watershed dönüşümü ve blob analizi yaparak meyve sayısı ve boyutlarını saptamışlardır.

Kitamura ve Oka (2005) geliştirdikleri yeşil sera içi yeşilbiber robotla hasat sisteminin bir garçası olarak yeşilbiberi yeşil yapraklar arasından saptayabilen bir algoritma ortaya

koymuşlardır. Çalışmalarında yapay aydınlatma kullanımının başarıyı artırdığını saptayarak görüntü almada bir aydınlatma kaynağı kullanmışlardır. Görüntüleri alırken stereo vizyon teknolojisinden faydalanmışlar, yeşilbiber ve sensör arasındaki mesafeyi de böylelikle hesaplamışlardır. Renk modeli olarak hue-doygunluk-yoğunluk modelini kullanmışlardır. Bu renk bilgisi üzerinden piksel sınıflandırması sonucu ikili görüntü elde etmişlerdir. İkili görüntü üzerinde piksel gruplarının meydana getirdiği blob özelliklerini değerlendirerek yeşilbiberleri konumlamışlardır.

Zhao ve ark. (2005) bir çift stereo kamera, renk ve doku özniteliklerinden faydalanarak yeşil ve kırmızı elmaları saptamak üzere bir bilgisayarlı görü sistemi geliştirmişlerdir. Kırmızılık (redness) renk verisi kullanarak buldukları bloblar üzerine daire saptama yöntemlerini uygulayarak meyve saptamada başarı oranını artırmaya çalışmışlardır. Doku esaslı kenar saptama yöntemini kırmızılık ölçüsü ve alan eşiklemeyle kombine ederek meyvelerin konumunu saptamak üzere daire bulma yöntemlerinden yararlanmışlardır. Laplacian filtreleri kullanarak meyve ve yeşil bitki örtüsü arasındaki doku farklılıklarını artırmışlardır.

Chamelat ve ark. (2006) doğal bitki örtüsünde üzüm meyvesini tanımak için bir bilgisayarlı görü algoritması geliştirmişlerdir. Bu amaçla renkli görüntülerden yararlanarak kırmızı-yeşil-mavi ve hue-saturasyon-yoğunluk renk modellerinde öznitelik çıkartımı yapmışlardır. Morfolojik öznitelik olarak Zernike momentlerini kullanmışlardır. Bir destek vektör makinesini özniteliklerle eğitmişler ve geliştirdikleri algoritmayı farklı koşullarda alınmış görüntüler üzerinde test etmişlerdir. Araştırmacılar çalışmalarının eğitim seti için performans sonucunu %99 olarak rapor etmişlerdir.

Chinchuluun ve Lee (2006) olgun narenciye meyveleri için bir verim haritalama sisteminin parçası olarak olgun meyveleri saptayan bir bilgisayarlı görü sistemi geliştirmişlerdir. Kırmızı-yeşil-mavi ve hue-saturasyon-yoğunluk renk modellerinden yararlanarak K-means kümeleme yöntemi ile meyve piksellerini sınıflandırmışlardır. Ayrıca düzensiz aydınlanma koşullarının olumsuz etkilerini azaltmak için gamma doğrulaması uygulamışlardır. Ortaya koydukları algoritmanın performansını el ile sayılmış ve algoritma tarafından bulunmuş meyve sayıları arasında regresyon analizi

yaparak deęerlendirmişlerdir. İnsan gözlemi ve el ile sayılmış meyve sayıları arasındaki korelasyon katsayısını 0,83 olarak bildirmişlerdir.

Tabb ve ark. (2006) olgun elmaları otomatik bir hasat sisteminde kullanılmak üzere konumlamak için bir gerçek zamanlı algoritma geliştirmişlerdir. Kırmızı-yeşil-mavi renk modelinde arkaplan modelleme konseptini kullanarak elma bölütlemesi probleminde yenilikçi bir çözüm getirmişlerdir. Arkaplan modellemede arkaplan renk dağılımlarını gerçek veri ile tahmin etmişlerdir. Bu amaçla Gaussian'ların küresel karışımı adında ve hareket algılama uygulamalarında yaygınca kullanılan Gaussian'ların karışımı prensibini temel alan bir algoritma geliştirmişlerdir. Geliştirdikleri algoritma saniyede ~14-16 kare hızında kırmızı ve sarı elmaların yaklaşık %85-96'sını başarıyla tanımlayabilmiştir.

Kane ve Lee (2007) multispektral görüntüleme yönteminden yararlanarak yeşil narenciye meyvelerini saptamak üzere piksel sınıflandırma esaslı bir görüntü işleme sistemi geliştirmişlerdir. Bir NIR kameradan yararlanarak görüntüleri farklı dalga boylarında toplamışlardır. Farklı dalga boylarında toplanan görüntüleri birleştirmek için bir endeks hesaplama yöntemi kullanmışlardır. Multispektral görüntülemeye yararlanarak geliştirdikleri sistemle meyve piksellerinin %84,5'ini saptayabilmişlerdir.

Safren ve ark. (2007) elma verimini bahçe koşullarında tahmin etmek üzere hiperspektral görüntüleme kullanarak bir bilgisayarlı görü algoritması geliştirmişlerdir. Bu amaçla doğal bahçe koşullarında elde ettikleri hiperspektral görüntülerden bir veritabanı oluşturmuşlardır. Pikselleri elma, yaprak, dal, ve gökyüzü olarak sınıflara ayırmışlar, her sınıfın spektral imzasını kayıt etmişlerdir. Görüntülere ön işlem olarak normalizasyon uygulamışlar ve çok boyutlu hiperspektral veri üzerinde boyut azaltma yöntemi olarak *ilkesel bileşenler analizini* uygulamışlardır. Geliştirdikleri özel bölütleme yöntemi neticesinde elma piksellerini sınıflandırmışlardır. Daha sonra piksel gruplarının oluşturduğu bloklar üzerine sırasıyla morfolojik kapanım, dinamik eşikleme ve boşlukları kapama gibi morfolojik işlemler uygulamışlardır. Bir gürültü azaltma yöntemi kullandıktan sonra temas eden meyve gruplarını ayırmak için ise watershed dönüşümü yöntemini kullanmışlardır. Son olarak meyve sayısını elde etmek üzere blob

analizi yapmışlardır. Araştırmacıların bildirdiğine göre hiperspektral görüntüleme kullanarak geliştirdikleri sistem %14,1'lik hata oranıyla görüntülerdeki elmaların %88,1'ini başarıyla saptayabilmiştir.

Yang ve ark. (2007) kompleks yapıdaki olgun domates öbeklerini sera koşullarında otomatik hasat sistemi için saptamak ve tanımak amacıyla bir bilgisayarlı görü algoritması geliştirmişlerdir. Deneme verisini bir domates serasından toplamışlar ve algoritmalarını denemelerle test etmişlerdir. Renkli bir stereo görüntüleme kamerasını görüntüleme sensörü olarak kullanmışlardır. Ortaya koydukları yöntem ile stereo kameranın sağladığı görüntünün üç boyutlu rekonstrüksiyonunu sağlamışlardır. Olgun meyveleri yaprak, sap, arka plan ve gürültülerden ayırmak için bir görüntü katmanı geliştirme yöntemi ortaya koymuşlardır. Üç boyutlu görüntünün sağladığı derinlik bölütlemesi ile hedef meyve kümelerini konumlandırmışlardır.

Zhang ve ark. (2007) sera ortamında salatalıkları saptamak üzere bir bilgisayarlı görü sistemi geliştirmişlerdir. Standart CCD renkli kamera kullanarak görüntüleri toplamışlardır. Bir şablonlama yöntemi ve geri yayımlı yapay sinir ağı kullanarak meyve ayırımı yapmışlardır. Renkli görüntüleri kırmızı-yeşil-mavi renk modelinde bileşenlerine ayırarak piksel sınıflandırması için en uygun renk elemanını mavi olarak tespit etmişlerdir. Homojen olmayan aydınlanma koşullarını elimine etmek için HSI renk modeline geçiş yaparak ikinci öznelik olarak saturasyon renk elemanını kullanmışlardır. Çıkardıkları iki özneliği kullanarak bir yapay sinir ağı eğitmişler ve test seti üzerinde de denemişlerdir. Yapay sinir ağının oluşturduğu ikili görüntüdeki bloklar üzerinde alan, şekil ve doku analizleri yaparak salatalık meyvelerini saptamışlardır. Geliştirdikleri algoritma ile görüntülerdeki meyvelerin %76'nı bulabilmişlerdir.

Hannan ve ark. (2009) olgun portakalları tanımak üzere renk bölütlemesi ve daire saptama yöntemlerini kullanmışlardır. Meyveleri saptamak için renk eşikleme ve daire çevre uzunluğu esaslı daire saptaması kullanmışlardır. Olgun meyvelerin nispeten ayırt edici renk özneliklerinden yararlanarak görüntülerdeki meyvelerin %90'ını %4'lük hatalı saptama oranıyla bulabilmişlerdir.

Okamoto ve Lee (2009) yeşil narenciye meyvelerini ağaç üzerinde saptayabilmek için hiperspektral görüntüleme yönteminden yararlanarak bir araştırma yapmışlardır. Bir hiperspektral kamera ile 369–1042 nm arasında görüntüler toplamışlardır. Meyve ve yaprak arasında ayırt edici özneliklere ulaşmak için farklı dalga boylarının sunduğu bilgileri birleştirmek üzere bir endeks hesaplama yönteminden yararlanmışlardır. Piksel sınıflandırmada doğrusal diskriminant analizini uygulamışlar ve daha sonra gürültü azaltma, etiketleme ve alan eşikleme gibi görüntü işleme yöntemlerinden faydalanmışlardır. Araştırmacıların bildirdiğine göre hiperspektral görüntüleme yöntemi kullanarak geliştirdikleri sistem, görüntülerdeki meyvelerin %80–89’unu saptayabilmiştir.

Bulanon ve ark. (2009) olgun narenciye meyvelerini robotla hasat yöntemleri için saptamak ve konumlamak üzere renkli ve termal görüntülerin birleşimi esaslı bir algoritma geliştirmişlerdir. Termal ve renkli kameraları üst üste konumlamışlar, aynı görüntü karesini aynı anda her iki kamera ile çekmişlerdir. Görüntülerde referans olarak bir PVC çerçeve kullanmışlar ve bu referans ile iki görüntüyü bilgisayar ortamında birleştirmişlerdir. Termal görüntü verisini yoğunluk görüntüsüne normalizasyon yaparak dönüştürmüşlerdir. Görüntü birleşimi için Laplacian piramidi ve bulanık mantık yöntemlerini ayrı ayrı denemişlerdir. Kaynak görüntüleri ve birleştirilmiş görüntüler arasındaki benzerlikleri çapraz entropi hesaplaması yaparak değerlendirmişlerdir. Araştırmacıların bildirdiğine göre bulanık mantık Laplacian piramidine göre daha iyi performans göstermiştir.

Mao ve ark. (2009) temel renk özneliğini kullanarak olgun Fuji elmasını ağaç üstünde tespit eden bir algoritma geliştirmişlerdir. Meyveler için ayırt edici renk özneliklerini istatistiksel analiz yöntemi ile saptamışlardır. Geliştirdikleri yeni yöntem elma merkezlerini konumlandırabilmiştir. Renk farklılıklarını kullanarak elmaları doğal çevrelerinden ayırabilmişlerdir. Alan parametresini kullanarak arka plan nesnelere elemişlerdir. İki yönlü çizgisel tarama algoritması kullanarak temas eden meyveleri ayırmışlardır. Son olarak çevre ve çap parametreleri yardımıyla elmaları

konumlandırmışlardır. Araştırmacılar olgun meyveler için geliştirdikleri algoritma ile elmaların %90'ını saptayabildiklerini bildirmişlerdir.

Yongsheng ve ark. (2009) Elma meyvesini kırmızı-yeşil ve yeşil-mavi renk endekslerinin oranlarına göre algılayan bir algoritma geliştirmişlerdir. Elma görüntülerini ön-aydınlanma ve arka-aydınlanma koşullarında elde etmişlerdir. Araştırmacılar gürültü yok etme, alan doldurma gibi ön işlemler yaparak kontör görüntüleri oluşturmuşlardır. Kontör görüntülerinden genetik algoritmalar kullanarak şekil özniteliklerini çıkarmışlardır. Öbekleşmiş ve örtüşen elmalar için çoklu genetik algoritmalar çalıştırarak ve her elmanın arka plandan ayrıldığı kontör noktalarını dönüştürerek farklı görüntü işleme tekniklerinden yararlanmışlardır. Araştırmacıların bildirdiğine göre geliştirdikleri elma algılama algoritması gölgeler, arka aydınlanma ve toprak tarafından meydana gelen olumsuz etkileri eleyebilmiştir. Olgun meyveler için ortaya koydukları algoritma %97 doğruluk sağlamıştır.

Wachs ve ark. (2009) yeşil ve kırmızı elmaları saptayabilmek için renkli ve termal görüntüleme yöntemlerinden birlikte yararlanarak bir çalışma yapmışlardır. Çalışmalarında öznitelikleri eş zamanlı olarak renkli görüntü ve kızılötesi görüntülerden ayrı ayrı çıkarmışlardır. Ortak öznitelikleri çıkarmak için renkli ve termal görüntüleri bir kayıt ve birleştirme yöntemi kullanarak özdeşleştirmişlerdir. Haar benzeri öznitelikler ve Viola-Jones sınıflandırıcıdan (Viola ve Jones, 2004) yararlanmışlardır. Alt-pencere esaslı görüntü taraması uygulamışlar ve alt-pencereleri sınıflandırarak meyveleri saptamışlardır.

Qingbing ve ark. (2009) üst üste örtüşen meyveleri saptayabilmek için bir markör kontrollü watershed dönüşümü esaslı algoritma geliştirmişlerdir. Greylfurt meyvesi görüntülerinden L^*a^*b renk modelinde kontör çıkarma çalışması yapmışlardır. Araştırmacılar gürültü azaltmak için karşılıklı filtreler kullanmışlar ve nesne kenarlarını görüntüde zarar vermeden korumuşlardır. Kenar çıkarma işlemi için gradyan şiddeti yöntemine başvurmuşlardır. K-means kümeleme yöntemiyle meyveleri ayırmışlardır. Daha sonra bazı morfolojik açma ve kapama operasyonları kullanarak daha düzgün

kenarlar elde etmişlerdir. Morfolojik genişletme-daraltma, watershed dönüşümü gibi görüntü işleme yöntemleri kullanarak hedef meyveleri saptayabilmişlerdir.

Al-Mallahi ve ark. (2010) konveyör kayışı üzerinden geçen patates yumrularının oluşturduğu öbekler içinden görüntü işleme yöntemleriyle patates yumrularını saymak üzere bir çalışma gerçekleştirmişlerdir. Bu amaçla TV kamerası kullanarak görüntüleri toplamıdır.öbek içinden patates yumrularını tekleştirme için bir tekleştirme algoritması kullanmışlardır. Algoritmaları komşu yumrular arasındaki temas noktalarını saptamış ve sürekli kontörleri analiz etmiştir.

Bulanon ve Kataoka (2010) olgun ve kırmızı elmanın robotla hasadına yönelik meyve tanımlama ve konumlandırması için lazer sensör destekli bir bilgisayarlı görü algoritması geliştirmişlerdir. Olgun meyvelerin arka plandan ayırımı için renk esaslı bir yöntem kullanmışlardır. Bu amaçla krominans katsayıları olan r ve g değerlerini öznitelik uzayı olarak kullanmışlardır. Teorik karar yaklaşımı kullanarak öznitelik uzayında meyve sınıfını ayıracak iki adet karar fonksiyonu geliştirmişlerdir. Bölütledikleri görüntülere bir alçak geçirgen filtre uygulayarak gürültü azalımı sağlamışlardır. Elde ettikleri bağlı piksellerden oluşan bloblar üzerinde Laplacian kenar detektörü uygulayarak bölüt kenarlarını elde etmişlerdir. Bu aşamadan sonra blobların alan, ana eksen, uzunluk, genişlik, en-boy oranı ve bölüt merkezi gibi morfolojik parametreleri örtüşen meyveleri ya da tekil meyveyi ayırmada öznitelik olarak kullanmışlardır. Lazer sensörünü ise meyve ile algılayıcı sistem arasındaki mesafeyi ölçmek amacıyla kullanmışlardır. Araştırmacılar çalışmalarında geliştirdikleri robotla hasat sisteminin toplam başarısını %89 olarak bildirmişlerdir.

Moonranta ve ark. (2010) ananas meyvesinin doğal ortamında algılanması için bir bilgisayarlı görü algoritması geliştirmişlerdir. Bu amaçla en ucuz yöntemlerden biri olan standart bir video kamera kullanmışlardır. Geliştirdikleri algoritmayla olgun ananas meyvesini tanımayı, izlemeyi ve üç boyutlu rekonstrüksiyonunu amaçlamışlardır. Bir mobil platform üzerine kamera monte ederek ananas bitkisinin görüntülerini doğal bahçe koşullarında kaydetmişlerdir. Harris, SIFT ve SURF gibi farklı öznitelikleri destek makine sınıflandırıcısıyla deneyerek en uygun öznitelik setini belirlemeye

çalışmışlardır. Sonuç olarak SURF öznelik setinin işlem süresi ve sınıflandırma doğruluğu olarak en uygun olduğunu bildirmişlerdir.

Qiang ve ark. (2010) çalışmalarında bilgisayarlı görü algoritmalarını kullanan robotla meyve hasadı uygulamalarında meyvelerin bitki örtüsü nesnelere tarafından örtülmesi probleminde dikkat çekerek soruna çözümler getirmeye çalışmışlardır. Çalışmalarında narenciye meyvesini materyal olarak kullanarak farklı öznelik çıkarma yöntemleri geliştirmişlerdir. Çalışmalarında meyvelerden öznelik çıkarmak amacıyla yığın merkezi, kenar merkezi, dairesel Hough dönüşümü, en düşük daire karesi yöntemlerini kullanmışlardır. Araştırmacıların bildirdiğine göre ilk iki yöntem kısmen örtülmüş meyvelerde meyve dairesini doğrulukla saptayamamıştır. Dairesel Hough dönüşümünün ise yüksek hesaplama zamanı, yüksek hafıza kullanımı ve çok sayıda yanlış saptamalar gibi dezavantajlarını tespit etmişlerdir. En düşük daire karesi yöntemiyle gerçek zamanlı uygulamada başarı sağlamışlardır. Örtünme bölgesi alanı %52'den az ve örtünme açısı 216°'den daha az olduğunda en düşük daire karesi yönteminin öznelik çıkarma doğruluğunun bir robotla hasat sistemi için yeterli düzeyde olduğunu bildirmişlerdir.

Swanson ve ark. (2010) geliştirdikleri verim haritalama sisteminin bir parçası olarak yeşil portakalları algılayabilen bir bilgisayarlı görü algoritması geliştirmişlerdir. Araştırmalarında yapay aydınlatma kullanarak görüntüleri toplamışlardır. Meyvelerin küresel şekliyle ilham alarak yüzeylerinden yansıyan ışığı Lambertian yüzey modeli kullanarak modellemişlerdir. Bu model ışığında potansiyel nesnelere çap ve yoğunlukları üzerinden meyve tanıma işlemini gerçekleştirmişlerdir.

Yuan ve ark. (2010) sera ortamında yetiştirilen salatalığın robotla hasadına yönelik salatalığın algılanması ve konumlandırılması için bir görüntü işleme yöntemi geliştirmişlerdir. Bu amaçla farklı dalga boylarında spektral görüntüler elde etmişlerdir. Eşikleme yöntemiyle görüntüleri ikili resme dönüştürmüşler ve görüntüye gürültü filtreleri ve morfolojik operasyonlar uygulamışlardır. Geliştirdikleri algoritma ile salatalıkların %86'sını %12'lik hatalı saptama oranı ile saptayabilmişlerdir.

Aggelopoulou ve ark. (2011) görüntü işleme yöntemiyle elma bahçelerinde çiçek yoğunluğunu tespit ederek hasat verimini tahmin etmek üzerine bir araştırma yapmışlardır. Çalışmalarında belirledikleri ağaçlardan çiçeklenme döneminde renkli görüntüler almışlar ve gerçek ağaç verimlerini hasat sonunda ölçmüşlerdir. Görüntü alma işlemini ağaç arkasına güneş ve gökyüzü görüntüsünü engelleyen bir örtü malzemesi kullanarak gerçekleştirmişlerdir. Ağaç görüntüsünde beyaz çiçek bölütlemesini gri seviyeli görüntü üzerinde eşikleme yaparak yerine getirmişlerdir. İkili görüntü resmi üzerindeki piksel yoğunluğu ile hasat verimi arasındaki ilişkiyi veren bir fonksiyon üretmişlerdir. Ortaya koydukları yöntemle 53 ağacın hasat verimini %18'lik bir hatayla tahmin edebilmişlerdir.

Kurtulmuş ve ark. (2011) olgunlaşmamış yeşil narenciye meyvelerini doğal bitki örtüsü içerisinde tanımak ve görüntüdeki meyveleri saymak üzere renkli görüntüler kullanarak bir araştırma yapmışlardır. Doğal aydınlanma koşullarının dezavantajlarını azaltmak için logaritma dönüşümü ve histogram eşitleme yöntemlerini kullanmışlardır. *İlkesel bileşenler analizi* esaslı insan yüzü tanıma yöntemi olan *özyüz* (eigenface) yönteminden ilham alarak 'özmeyve' öznelik çıkarma yöntemini geliştirmişlerdir. Bu yöntemi kullanarak renkli görüntünün yoğunluk ve saturasyon elemanlarından öznelikler çıkarmışlardır. Ayrıca rotasyon bağımsız dairesel Gabor doku analizi yaparak doku özneliğini çıkarmışlardır. Alt-pencere esaslı görüntü tarama yöntemi kullanmışlar ve alt-pencereleri öznelikler üzerinde eşikleme yaparak sınıflandırmışlardır. Geliştirdikleri algoritma blob analizi sayesinde aynı meyveye ait duplikasyon saptamaları birleştirmiş ve görüntüdeki meyve sayılarını vermiştir. Geliştirdikleri algoritma test seti için %75,3 saptama doğruluğu sağlamıştır.

Linker ve Kelman (2011) elma meyvelerini doğal bitki örtüsünde tanımak ve konumlamak üzere bir algoritma geliştirmişlerdir. Algoritmalarında ilk olarak doğal ortamında siyah-beyaz olarak çekilmiş elma bitkisi görüntüsüne Canny kenar bulma detektörünü uygulamışlardır. Daha sonra detektörün herhangi bir elma nesnesine ait olması muhtemel olmayan küçük kenar çizgilerini elemişlerdir. Kenar görüntüsünü basitleştirmek amacıyla ikiden fazla komşusu olan dallanan çizgileri ve ayrıca dar açılı köşelere sahip kenar çizgilerini silmişlerdir. Elde ettikleri kenar görüntü resmi üzerinde

belirli yarıçaplarda daire taraması yaparak beklenen yarıçap aralığına girmeyen çizgileri silmişlerdir. Geliştirdikleri konvekslik kontrolünü geriye kalan kenarlara uygulamışlar ve aynı nesneye ait olan kenar çizgilerini birleştirerek elmaları tanıyarak konumlandırmışlardır.

Nuske ve ark. (2011) bağ verimini tahmin etmede kullanmak üzere üzümüleri doğal bitki örtüsünde tanıyarak saymak için bir bilgisayarlı görme sistemi gerçekleştirmişlerdir. Üzümleri tanımak için şekil ve doku özniteliklerinden yararlanmışlardır. Potansiyel meyve konumlarını belirlemek ve meyve tarama alanını daraltmak için radyal simetri transformundan yararlanmışlardır. Çıkardıkları öznitelik vektörlerini K-en-yakın komşular sınıflandırıcısı kullanarak sınıflandırmışlar ve üzüm meyvelerini saptamışlardır.

Patel ve ark. (2011) çeşitli meyvelerin robotla hasadında kullanımına yönelik genel bir meyve-arkaplan ayırma algoritması üzerinde çalışmışlardır. Ortaya koydukları algoritmayı geliştirmek ve test etmek amacıyla arama motorlarından doğal ortamlarında çekilmiş çeşitli meyve görüntüleri elde etmişlerdir. Çalışmalarında hue, saturasyon gibi renk bileşenlerini öznitelik olarak kullanmışlar ayrıca kenar çıkartarak ve Gabor filtreleri kullanarak farklı öznitelikleri bir araya getirmişler, öznitelik haritası oluşturmuşlardır. Bu öznitelik haritası üzerinde eşikleme yöntemiyle meyve arkaplan bölütlemesini yapmışlardır. Araştırmacıların bildirdiğine göre algoritmaları olgun meyve ve arkaplan ayırımını %95 doğrulukla yapabilmıştır.

Rakun ve ark. (2011) renkli görüntülerde renk, doku ve üç boyutlu şekil özniteliklerinin kombinasyonundan yararlanarak elma meyvesinin saptanması üzerine bir çalışma yapmışlardır. Potansiyel meyve bölgelerini belirlemek amacıyla standart kırmızı-yeşil-mavi renkli görüntüyü hue-doygunluk-yoğunluk renk modeline dönüştürüp hue katmanında eşikleme yöntemiyle renk ayırımını uygulamışlardır. Doku analizini işlenen görüntünün uzamsal-sıklık temsili ve destek vektör makinesi ile benzer örüntülerin sınıflandırılması ilkesine dayanarak gerçekleştirmişlerdir. Araştırmacılar çalışmalarında aynı kareyi farklı görüş açılarından 2 kez yakalayarak görüntünün üç boyutlu rekonstrüksiyonunu sağlamışlar ve bunun üzerinde küresel şekil analizi yapmışlardır.

Geliştirdikleri algoritma elde ettikleri farklı özniteliklerin sağladığı bilgilerden yola çıkarak görüntüde taranan nesnenin meyve olup olmadığına karar verebilmiştir.

Linker ve ark. (2012) elmaları doğal bahçe koşullarında alınan görüntülerde saptamak meyve sayılarını bulmak üzere bir çalışma yapmışlardır. Geliştirdikleri algoritma renk esaslı potansiyel meyve bölgelerinin bulunması, kontör çıkarımı, kontörlerden yay parçaları çıkarımı ve bunlara karşılık gelen dairelerin tespiti esasına göre çalışmıştır. Araştırmacılar görüntü yakalama işlemini önceden ayarlanmış gün içerisi saatlerde ayarlama yaparak gerçekleştirmişlerdir. Böylelikle doğal aydınlanmanın dezavantajlarını elimine etmeye çalışmışlardır.

Reis ve ark. (2012) beyaz ve kırmızı olgun üzümü algılamak üzere bağ koşullarında robotla hasat amaçlı gece ve gündüz koşullarında çalışabilecek bir algoritma geliştirmişlerdir. Renkli görüntülerde kırmızı-yeşil-mavi renk modelinde bileşenlerin meyveyi ayırt etmede etkili aralıklarını deneme yanılma yolu ile tespit etmişlerdir. Bu şekilde kırmızı ve beyaz üzüm arasındaki ayırt edici piksel sayısı oranlarını ortaya koymuşlardır. Beyaz veya kırmızı meyveyi ayırt ettikten sonra renk haritalama, morfolojik genişletme, siyah bölgeler ve sap tespiti işlemlerini uygulamışlardır. Blob analizi yöntemleriyle aday meyve bölgelerinin genişlik, yükseklik, çevre, merkez ve alan gibi parametrelerini belirlemişler, aday bölgenin dikey ve yatay eksenlerine göre salkım sapını konumlamışlardır. Araştırmacıların bildirdiğine göre hazırladıkları bilgisayarlı görü algoritması kırmızı ve beyaz meyveleri sırasıyla %97 ve %91 doğrulukla sınıflandırabilmiştir.

Sengupta ve Lee (2012) şekil ve doku bilgisini kullanarak yeşil narenciyeyi renkli görüntülerde algılamak üzere bir algoritma geliştirmişlerdir. Bu amaçla meyve ve arkaplan örneklerini manüel yöntem ile kırparak bir eğitim seti oluşturmuşlardır. Hazırladıkları örnekler üzerinde yerel doku öznitelikleri ve Tamura doku özniteliğini hesaplamışlardır. Bu özniteliklerle bir destek vektör makinesi eğitmişlerdir. Şekil bilgisini ise skaladan bağımsız SIFT özniteliğini çıkartarak kullanmışlardır. Yanlış saptamaları azaltmak amacıyla çok aydınlanmış ve az aydınlanmış görüntüler için farklı yaklaşımlar kullanmışlardır. Bu amaçla dairesel Hough dönüşümünden

yararlanmışlardır. Araştırmacılar geliştirdikleri sistemin %81,7'lik doğrulukla meyveleri saptayabildiğini bildirmişlerdir.

Wang ve ark. (2012a) olgun ve kırmızı elmaları saptamak üzere geliştirdikleri verim haritalama sisteminin bir parçası olarak elmaları doğal bahçe koşullarında saptayarak sayabilen bir algoritma geliştirmişlerdir. Çalışmalarında yapay aydınlatma kullanmışlardır. Hazırladıkları meyve bulma algoritmasında renkli görüntüleri hue-saturasyon-yoğunluk renk modelinde bileşenlerine ayırarak bu renk kanalları için uygun eşik değerlerini tespit etmişlerdir. Bu eşik değerlerini kullanarak elmaları arka plandan ayırmışlardır. Beklenen boyutlardan küçük piksel bölgelerini eşikleme yaparak elemişlerdir. Çalışmalarında ortalama meyve boyutlarından yola çıkarak görüntü üzerine morfolojik işlemler uygulamışlar ve temas eden meyveleri ayırmışlardır. Bir dizi morfolojik işlemler daha uygulayarak görüntülerdeki meyve sayılarını tespit etmişlerdir.

Yang ve Lee (2012) multispektral görüntüleme yöntemini kullanarak yabanmersini meyvesini bitkinin doğal koşullarında tanınması üzerine bir araştırma yapmışlardır. Yakın kızılötesi, kırmızı ve yeşil bantlarda görüntüler olarak MHSI, MYIQ ve MYCbCr renk modellerinde dekompozisyon yaparak meyve üzerinde ayırıcı olan öznelikleri çıkarmışlardır. Çıkardıkları öznelikler ile Bayesian ve destek vektör makinesi sınıflandırıcılarını eğitmişler ve meyveleri ayırt etmede kullanmışlardır. Geliştirdikleri yöntemle olgun meyvelerin %84'ünü saptayabilmişlerdir.

Zhou ve ark. (2012) meyve olgunlaşmasının erken safhasında verim haritası oluşturmada kullanılmak üzere Gala elmalarını renkli görüntülerde algılayan bir bilgisayarlı görü algoritması geliştirmişlerdir. Renkli görüntüleri standart bir kamera ile bitkinin doğal ortamında doğal aydınlanma koşullarında elde etmişlerdir. Çalışmalarında kırmızı-yeşil-mavi ve hue-doygunluk-yoğunluk renk modellerini dekompoze ederek renk bileşenlerinin kombinasyonları üzerinde eşikleme yöntemini kullanmışlardır. Renk analizleriyle elde ettikleri ikili görüntü üzerinde blob analizi yoluyla meyve sayılarını tespit etmişlerdir. El ile sayılmış meyve sayıları ve algoritmalarının bulduğu meyve sayıları arasında regresyon analizi yapmışlardır.

3. MATERYAL ve YÖNTEM

3.1. Materyal

3.1.1. Şeftali bahçesi

Şeftali meyvelerini renkli görüntüler üzerinde saptama amaçlı algoritmaların geliştirilmesi ve test edilmesi için görüntüler alınmak üzere Bursa Barakfaki köyünde yerel bir çiftçiye ait Elegance Lady çeşidi şeftali bahçesi seçilmiştir. Şeftali bahçesi yaklaşık olarak $40^{\circ}13'54.96''$ lik Kuzey enlemi ve $29^{\circ}17'6.17''$ lik Doğu boylamındadır. Görüntüler alındığı anda bahçede 4 yaşında 150 adet şeftali ağacı bulunmaktaydı. Şekil 3.1' de şeftali görüntülerinin alındığı bahçeye ait bir görünüş verilmiştir.



Şekil 3.1. Elegance Lady çeşidi şeftali bahçesi

3.1.2. Görüntü almada kullanılan kamera

Bu çalışmada, daha önce açıklanan çalışmanın amaçlarına uygun şekilde renkli görüntüleri şeftali bahçesinden almak üzere standart bir CCD (charge-coupled device) renkli kamera kullanılmıştır. Kullanılan kameranın markası Nikon modeli Coolpix L22'dir. Şekil 3.2'de kullanılan kamera görülmektedir. Çizelge 3.1'de kameraya ait teknik özellikler verilmiştir.



Şekil 3.2. Görüntü alımında kullanılan standart CCD kamera

Çizelge 3.1. Kullanılan kameraya ait teknik özellikler

Özellik adı	Özellik
Etkili pikseller	12 milyon
Görüntü sensörü	1/2.3-inç CCD; toplam piksel: ~12.39 milyon
Lens	3.6x zum NIKKOR; 6.7-24.0mm (35mm [135] görüntüleme açısı: 37-134mm); f/3.1-6.7; Dijital zum: 4x' kadar (35mm [135] görüntüleme açısı: Yaklaşık 536mm)
Odak menzili	Normal mod:30cm; Makro: 5cm

3.1.3. Matlab yazılımı

Bu çalışmada algoritma geliştirme aşamaları ve denemelerin kurulumu ve icrasında büyük ölçüde MATLAB R2012a (Matrix Laboratory, MathWorks Inc., Natick, MA) programlama dili ve 64 bit'lik yazılımı kullanılmıştır. Görüntü tarama, öznitelik çıkarımı, sınıflandırıcıların eğitimi ve denemeler kodlanarak MATLAB ortamında gerçekleştirilmiştir.

3.1.4. GIMP görüntü işleme programı

Çalışmada kırpma, merkezleme, mozaik görüntü oluşturma gibi algoritma eğitimi ile ilgili görüntülerin manuel olarak işlenmesinin gerektirdiği durumlarda GIMP (Gnu Image Manipulation Program) görüntü işleme yazılımından yararlanılmıştır.

3.1.5. SPSS istatistiksel analiz programı

Meyvelerin görüntülerde ayırt edici özniteliklerini belirlemek amacıyla kullanılan istatistiksel yöntemlerden biri olarak SPSS 20 istatistiksel analiz yazılımından yararlanılmıştır.

3.1.6. SAS istatistiksel analiz programı

Ayırt edici öznitelikleri istatistiksel olarak ortaya koymak amacıyla SAS istatistiksel analiz yazılımını bir diğer yöntem olarak kullanılmıştır.

3.1.7. Meyve tanıma denemelerinin yapıldığı bilgisayar donanımı

Meyve tanıma algoritmalarına ait denemeler; Intel® Core™ i7-2600 CPU @3.40 GHz işlemcili, 8 GB RAM'li ve 64 bit işletim sistemi kurulu bir kişisel bilgisayarda gerçekleştirilmiştir

3.2. Yöntem

3.2.1. Görüntü alma

Meyve gelişim evresinin ilk safhalarında meyveler 4-5 cm iken Haziran ayı başlarında 4 yaşında 150 adet şeftali ağacından görüntüler alınmaya başlanmış, Eylül ayı ortaları bahçenin hasadına kadar görüntü almaya devam edilmiştir. Bu çalışmada kullanılan görüntüler 2-9 Haziran 2012 tarihleri arasında alınan görüntülerdir. Görüntüler çalışmanın amacına uygun olarak doğal aydınlanma koşullarında şeftalinin doğal bahçe koşullarında alınmıştır. Aydınlanma koşullarının çeşitlendirilmesi için görüntü alımı gün içerisinde farklı zamanlarda yapılmıştır. Doğal şeftali bitki örtüsü görüntüleri, algılama algoritmasını zorlayacak birçok görsel olasılığı direkt ve difüz aydınlanma koşulları dahil olmak üzere içermektedir. Çalışmada direkt ve difüz aydınlanma

koşullarının algoritma performansları üzerindeki etkilerini analiz etmek amacıyla şeftali ağaçlarının güneşli ve gölge taraflarından alınan görüntüler alındıkları tarafa göre kaydedilmiştir. Görüntüler 2048x1536 piksel çözünürlükte toplanmıştır. Görüntü toplamada kamera ve bitki örtüsü arası mesafe yaklaşık 50 cm olarak korunmuştur. Şekil 3.3’de alınan görüntülere ait örnekler görülmektedir.



Şekil 3.3. Şeftali bahçesinden alınan görüntülere ait örnekler

3.2.2. Görüntünün yeniden boyutlandırılması

Çalışmada algoritma geliştirme aşamalarında ve hesaplamalarda kolaylık olması açısından alınan görüntüler 800x600 çözünürlüğe yeniden boyutlandırılmıştır. Bu değer görüntüde şeftali meyvelerini ayırt etmek için gerekli detayların korunması açısından yeterli seviyededir. Görüntülerin yeniden boyutlandırmasında bikübik enterpolasyon (iki boyutlu kübik konvolüsyon enterpolasyonu) yöntemi kullanılmıştır. Bu yöntemde piksel çıktı değerleri 4x4 en yakın komşuluktaki piksellerin ağırlıklı ortalamasıdır. Eşitlik 3.1’de tek boyutlu enterpolasyon fonksiyonu ve eşitlik 3.2’de bunun iki yöne uygulanmasıyla oluşan iki boyutlu enterpolasyon fonksiyonu $u(s)$ verilmiştir.

$$u(s) = \begin{cases} \frac{3}{2|s|^3} - \frac{5}{2|s|^2} + 1 & 0 \leq |s| < 1 \\ -\frac{1}{2|s|^3} + \frac{5}{2|s|^2} - 4|s| + 2 & 1 \leq |s| < 2 \\ 0 & 2 < |s| \end{cases} \quad (3.2)$$

Burada s , enterpolasyonu hesaplanan nokta ile komşu piksel arasındaki mesafedir. Bu yöntem iki boyutlu görüntüde yatay ve düşey yönlere uygulanarak kullanılmıştır. Bir (x, y) noktasının enterpolasyonu için $x_k < x < x_{k+1}$ ve $y_k < y < y_{k+1}$ koşullarında iki boyutlu kübik konvolüsyon enterpolasyon fonksiyonu eşitlik 3.3'te verilmiştir.

$$g(x, y) = \sum_{l=-1}^2 \sum_{m=-1}^2 c_{j+l, k+m} u(\text{mesafe}_x) u(\text{mesafe}_y) \quad (3.3)$$

Burada $u()$ eşitlik 4.2'deki enterpolasyon fonksiyonu, mesafe_x ve mesafe_y her yöndeki 4 piksel komşu noktalarının uzaklıklarıdır. Sınırları olmayan noktalar için enterpolasyon katsayıları c_{jk} 'lar $c_{jk} = f(x_j, y_k)$ olarak ifade edilmektedir (Smith 2012).

3.2.3. Eğitim ve test setlerinin oluşturulması

Meyve tanıma algoritmalarının geliştirilmesi ve sınanması amacıyla alınan şeftali bitki örtüsü görüntülerinden rastgele olacak şekilde 32 görüntüden oluşan bir eğitim seti 64 görüntüden oluşan bir de test (doğrulama) seti oluşturulmuştur. Öznitelik çıkarma, görüntü tarama ve yapay sınıflandırıcılara ait katsayı ve diğer parametre değerleri eğitim seti kullanılarak belirlenmiştir. Test seti algoritma performanslarının ölçülmesi ve değerlendirilmesi amacıyla kullanılmıştır.

3.2.4. Aydınlanma zenginleştirilmesi için görüntü ön işlemleri

Doğal bahçe koşullarındaki alınan görüntülerin olumsuz değişken aydınlanma özelliklerini azaltmak ve görüntü aydınlanmasını zenginleştirmek amacıyla HSI renk modelindeki renkli görüntünün aydınlanmasını temsil eden yoğunluk (I) bileşenine histogram eşitleme ve logaritma dönüşümü işlemleri uygulanmıştır. Histogram eşitleme işlemi bundan önceki bölümde verilen eşitlik 2.7'ye göre yapılmıştır. Logaritma dönüşümü görüntü işlemede iyi bilinen ve bir çok araştırmacı tarafından kullanılan bir yöntemdir (Savvides ve Kumar 2003, Vishwakarma ve ark. 2009, Cheng ve ark. 2010).

Logaritma dönüşümü görüntülerdeki karanlık piksel bölgelerini açmaktadır (Chen ve ark. 2006). Bu dönüşümün matematiksel tanımı eşitlik 3.4'te verilmiştir.


$$I' = \log(f) \quad (3.4)$$

Burada f ve I' sırasıyla giriş görüntüsü ve logaritma görüntüsünü temsil etmektedir.


3.2.5. Çalışmada geliştirilen görüntü tarama yöntemleri ve potansiyel meyve bölgeleri

3.2.5.1. Renk histogramı esaslı eşikleme ve görüntü ikilileştirme

Renkli görüntüler üzerinde bir nesneyi arka plandan ayırmak için ilk akla gelen yöntem renge göre ayırım yapmaktır. Doğal bitki örtüsü içerisindeki genç şeftali meyveleri görsel olarak arka plan nesneleriyle oldukça yakın renklere sahiptir. Buna rağmen bu çalışmada alınan görüntüler üzerinde HSI, YCbCr, RGB gibi renk modellerinde renk bileşenlerinin histogram analizi yapılmıştır. Bu amaçla eğitim setinden genç şeftali meyveleri GIMP programı yardımıyla yalnızca meyve piksellerini içerecek şekilde kırılmıştır. Bu şekilde kırılan meyveler siyah arka planlı bir mozaik örnek görüntü üzerine sıralanmışlardır. Negatif örnek oluşturmak amacıyla da eğitim setinde bulunan görüntülerden arka plan piksel bölgeleri (meyve pikselleri içermeyen) yine GIMP programı yardımıyla rastgele bölgelerden kırılarak benzer şekilde bir başka mozaik görüntü oluşturulmuştur. Oluşturulan mozaik görüntülerin histogram eğrileri karşılıklı olarak incelenen renk bileşenleri için karşılaştırılmıştır. Şekil 3.4'te meyve ve arka plan örneklerine ait mozaik görüntüler görülmektedir. Farklı renk bileşenlerinin histogram eğrileri bulgular ve tartışma kısmında verilmiştir.



a)



b)

Şekil 3.4. Histogram analizi amacıyla meyve (a) ve arka plan (b) piksellerinden oluşturulan mozaik görüntüler

Meyve ve arka plan örneklerinin histogram eğrileri renk benzerliğini doğrular şekilde iç içe geçiktir. Ancak histogram eğrileri gözlenerek meyve ve arka plan renk bileşenleri arasında küçük farklılıklar bulunmuştur. Bu farklılıklar genç şeftali meyvelerini arka plandan ayırmada tek başına yeterli olmamasına rağmen meyve tarama bölgesini daraltabileceği düşünülmüştür. Renk histogramı eğrilerinin gözlemlenmesiyle meyve ve arka plan pikselleri arasında ayırt edici eşik değerleri belirlenmiştir. Histogram eğrilerinin gözlenmesiyle elde edilen farklı renk bileşenlerine ait eşik değerleriyle eşikleme yapılarak ikili görüntüler elde edilmiştir. Tek bir renk bileşenine ait eşikleme işleminin matematiksel ifadesi eşitlik 3.5’te verilmiştir.

$$I_{ikili} = \begin{cases} 1, & \text{Eğer } G_b \geq Eşik \\ 0 & \text{Eğer } G_b < Eşik \end{cases} \quad (3.5)$$

Burada I_{ikili} eşikleme sonucu elde edilen ikili görüntü değeri, G_b ise renk bileşeninin yoğunluk değeridir. Kullanılan farklı renk bileşenlerinin cevapları “VEYA” mantıksal karşılaştırma operatörü ile birleştirilmiştir. Yani bir piksel noktasına ait renk bileşeni değerlerinden en az biri eşik değerini geçtiyse buna karşılık gelen ikili görüntü değeri 1 olarak belirlenmiştir. Eşikleme işlemi sonucu elde edilen ikili görüntüler bir sonraki kısımlarda açıklanan görüntü tarama yöntemlerinin bazılarında kullanılmıştır. Bu çalışmanın bulgular ve tartışma kısmında eşikleme sonucu ortaya çıkan ikili görüntülere ait örnekler sunulmuştur.

3.2.5.2. Görüntü tarama yöntemi 1

Bu araştırmada kullanılan ilk görüntü tarama yaklaşımı görüntünün tamamının görüntü üzerinde kayan bir alt-pencere kullanılarak taranmasıdır. Bir alt-pencere görüntünün tamamı içerisindeki bir yerel bölgeyi sınırlayan kare çerçeve olarak düşünülebilir. Geliştirilen bu yöntemde alt-pencerenin verilen bir adım mesafesinde yatay ve düşey yönlerde görüntüyü taraması sağlanmıştır. Bu adım mesafesi, eğitim setindeki görüntülerde herhangi bir ayırt edici meyve kısmını es geçemeyecek şekilde 20 piksel olarak belirlenmiştir. Ayrıca bu yöntem birbirlerine çok yakın farklı meyvelerin tek bir meyve olarak algılanmasını önlenmesine yardımcı olmuştur. Tarama sürecinde her bir alt-pencere birbirinin içerisine geçmiş 3 farklı ölçekte kare çerçeveyi ifade etmektedir.

Bunun anlamı görüntüler 3 farklı ölçekte taranmıştır. Bu işlem görüntülerde bulunan farklı boyutlardaki meyvelerin taranmasına yardımcı olmuştur. Kullanılan eğitim seti görüntülerindeki meyve boyutları 80-130 piksel (gerçek boyut olarak 4-5 cm) arasındadır. Bu yüzden iç içe geçmiş kare alt-pencere boyutları da 80 x 80, 100 x 100 ve 130 x 130 piksel olarak belirlenmiştir. Kayan alt-pencere yöntemiyle görüntü tarama yaklaşımı Şekil 3.5'te görülmektedir. Şekilde kırmızı çerçeveler 3 farklı ölçekteki alt-pencereleri, sarı ve mavi çerçeveler ise düşey ve yatay yönlerdeki 20 piksellik adımları temsil etmektedir.



Şekil 3.5. Kayan alt-pencere yöntemiyle görüntü tarama yaklaşımı

Bu görüntü tarama yöntemiyle görüntüyü oluşturan bütün alt-pencereler taranmamıştır. Detayları sonraki bölümlerde açıklanan sınıflandırıcıların yanlış saptamalarını azaltmak amacıyla bir arka plan eleme yöntemi geliştirilerek izlenmiştir. Bu amaçla renk esaslı bir yöntem uygulanmıştır. Bir önceki kısımda tanımlanan renk histogramı esaslı görüntü ikilileştirmesi sonucu elde edilen ikili görüntü, görüntü tarama denemelerinde bir eleme şablonu olarak kullanılmıştır. Görüntü tarama esnasında renkli görüntüye karşılık gelen

ikili görüntü üzerindeki alt-pencerenin içerdiği ve arka plan piksellerini temsil eden beyaz piksel oranı alt pencerenin elenmesini sağlamıştır. Meyvelerin yuvarlak şekillerinden ilham alınarak bu oranın belirlenmesinde kare alt-pencerenin köşe pikselleri hariç tutulmuştur. Bunun için alt-pencere içerisinde bir dairesel ilgi bölgesi (circular region of interest) olarak tanımlanan teğet çemberden yararlanılmıştır. Teğet çember içerisinde bulunan beyaz piksellerin toplamının alt-pencereyi oluşturan toplam piksel sayısına oranı o alt-pencerenin elenip elenmemesi üzerine etkili olmuştur. Eşitlik 3.6'da bu oran matematiksel olarak tanımlanmıştır. Elenme kararı eşikleme yoluyla sağlanmıştır. Eğitim seti görüntüleri kullanılarak birçok olasılık denenmiş ve denemelerde eşik değeri 0,4 olarak kullanılmıştır. Şekil 3.6'da bir alt-pencere ve buna ait teğet çember görülmektedir. Bu yöntemde bir alt-pencere elendiğinde algoritmanın bundan sonraki aşamalarına devam edilmemekte ve bir sonraki alt-pencereye geçilmektedir.



a)

b)

Şekil 3.6. Bir örnek görüntüye (a) ait ikili görüntü ve alt-pencerenin teğet çemberi (b)

$$piksel\ oranı = \frac{cROI\ piksel\ sayısı}{Toplam\ piksel\ sayısı} \quad (3.6)$$

3.2.5.3. Görüntü tarama yöntemi 2

Çalışmada taranan görüntülerde görüntünün tamamının alt-pencerelerle taranması yerine arka plan bölgelerinin elenerek yalnızca potansiyel meyve alt-pencerelerin sınıflandırıcılar tarafından değerlendirilmesi amacıyla farklı görüntü tarama yöntemleri

de araştırılmıştır. Böyle bir yöntemin yanlış saptamaları azaltacağı ve hesaplama sürelerinin iyileştirilmesine katkıda bulunacağı düşünülmüştür. Görüntü tarama yöntemi 2, bir dizi görüntü işleme operasyonlarından oluşturulmuştur. İlk olarak daha önceki kısımlarda açıklanan renk histogramı esaslı eşikleme ve görüntü ikilileştirmesi yöntemi uygulanarak renkli görüntüye karşılık gelen ikili görüntü elde edilmiştir. Burada yöntem 1'den farklı olarak meyve pikselleri "1" ile arka plan pikselleri "0" ile temsil edilmiştir. Şekil 3.7'de görülen oluşturulan ikili görüntü çıktısı arka plan ve meyve piksellerinden oluşan geniş bağlantılı ve bağlantısız beyaz piksel bölgelerini içermektedir. Meyveleri arama alanını daraltmak ve dolayısıyla potansiyel meyve bölgelerini çıkarmak amacıyla bu ikili görüntüye yapısal disk elemanı (structuring disk element) kullanılarak morfolojik açınım (morphological opening) uygulanmıştır. Bir ikili görüntü I_{ikili} 'nin yapısal eleman B_{disk} ile morfolojik açınımı $I_{ikili} \circ B_{disk}$ ile gösterilmekte ve I_{ikili} 'nin B_{disk} ile aşınmasının (erosion) sonucunun B_{disk} ile genişmesi (dilation) olarak tanımlanmaktadır. Eşitlik 3.7'de morfolojik açınımın matematiksel olarak ifadesi görülmektedir (Gonzales ve Woods 2002).

$$I_{ikili} \circ B_{disk} = (I_{ikili} \ominus B_{disk}) \oplus B_{disk} \quad (3.7)$$


Burada \ominus ve \oplus sırasıyla aşınma ve genişleme operatörleridir. Eğitimi seti kullanılarak disk elemanı için en uygun disk yarıçapı belirlenmiştir. Çalışmada kullanılan düzgün disk şeklindeki yapısal elemanın yarıçapı 20 piksel olarak kullanılmıştır. Morfolojik açınımın sonuç çıktısı dairesel bloblar içeren diğer bir ikili görüntüdür. Bu yöntemin aşamaları Şekil 3.7'de görülmektedir. Blob analizi yöntemi kullanılarak blobların ağırlık merkezleri konumlandırılmıştır. Görüntü tarama işleminde kare alt-pencereler konumlanan bloblar üzerine çakıştırılarak elde edilmiştir. Meyve saptama olasılığını artırmak amacıyla bulunan merkezlerin 4 adet 20 piksel mesafesindeki dikey ve yatay ortogonal komşuları da tarama sürecine dahil edilmiştir. İlk bulunan merkez ve bunun komşularıyla birlikte 5 merkez de açıklanan ilk görüntü tarama yöntemine benzer şekilde 3 farklı ölçekte ele alınmıştır. Bu ölçekler ilk açıklanan meyve tanıma yöntemiyle aynı piksel ölçü değerlerine sahiptir. Bunun anlamı her bir potansiyel merkez 5×3 kadar alt-pencereye ayrılarak taranmıştır.



a)



b)



c)

Şekil 3.7. Görüntü tarama yöntemi 2'ye ait aşamalar (Örnek görüntü (a), ikilileştirme sonrası (b) ve morfolojik açınım sonrası elde edilen bir aday merkez yeşil çerçeveye gösterilen bir ortogonal komşu ile birlikte).


3.2.5.4. Görüntü tarama yöntemi 3

Bu çalışmada potansiyel meyve merkezlerini bulmada kullanılan diğer bir yöntem Loy ve Zelinsky (2003) tarafından ortaya konulan Radyal Simetri Dönüşümünü (RST) esas almaktadır. Bu yöntem bir görüntüde yüksek derecede radyal olarak simetrik noktaları konumlandırmak için bir görüntünün gradyanını kullanmaktadır. RST yöntemi her pikselin gradyan doğrultuları boyunca simetriye katkılarını hesaplamaktadır (Xiang ve ark. 2011). Genç şeftali meyvelerinin radyal şekilleri nedeniyle bu yöntemin meyve saptamada olası meyve bölgelerinin çıkarılmasında yardımcı olacağı düşünülmüştür. RST'yi herhangi bir görüntüye uygulamak için olası radyal nesne çaplarının önceden bilinmesi gerekmektedir. Bu yüzden 80, 100 ve 130 piksel çap değerleri eğitim setindeki meyve çaplarına uygun olarak seçilmiş ve RST işleminde kullanılmıştır. Her piksel p için gradyanı $g(p)$ elde etmek üzere bir Sobel maske konvolüsyonu önceden gri seviyeli görüntüye dönüştürülen şeftali bitki görüntüsüne uygulanmıştır. Daha sonra gradyan vektörleri eşitlik 3.8'e göre normalize edilmiştir.

$$g_{norm}(p) = g(p) / \|g(p)\| \quad (3.8)$$

Burada $g(p)$ normalizasyonu yapılacak vektörü, $\|g(p)\|$ Öklit kavramına göre vektör uzunluğunu, $g_{norm}(p)$ ise normalize edilmiş vektörü temsil etmektedir. Daha sonra önceden belirlenen her yarıçap n için pozitif ve negatif olarak etkilenen piksel değerleri eşitlik 3.9 ile hesaplanmıştır. Şekil 3.8'de RST dönüşümü hesaplamalarında kullanılan değişkenlerin görsel temsilleri verilmiştir (Loy ve Zelinsky 2003).

$$p_{ve}(p) = p \pm round(n \times g_{norm}(p)) \quad (3.9)$$



Şekil 3.8. RST dönüşümünde gradyan vektörü, negatif ve pozitif etkilenen pikseller

Herhangi bir yarıçap n 'deki radyal simetri katkısı S_n , düzgünleştirilmemiş simetri ölçüsü F_n ile iki boyutlu bir Gaussian filtresi A_n 'nin konvolüsyonu olarak tanımlanmaktadır. Eşitlik 3.10'da bu tanımın matematiksel ifadesi görülmektedir.

$$S_n = F_n \otimes A_n \quad (3.10)$$

Eşitlik 3.11'de verilen tam bir RST dönüşümü, tüm yarıçaplar (N) için radyal simetri katkılarının toplamı şeklinde tanımlanmaktadır.

$$S = \sum_{n \in N} S_n \quad (3.11)$$

Bu hesaplamalar sonucu elde edilen simetri haritası Şekil 3.9b'de görülen gri seviyeli bir görüntüdür. Bu görüntüde parlak bölgeler radyal açıdan daha simetrik bölgeleri temsil etmektedir. Hesaplamalarla elde edilen simetri haritası değerleri yaklaşık -140 ile +28 arasında değişen değerler olarak elde edilmiştir. Şekil 3.9b'de görülen gri seviyeli görüntü, görselleştirme açısından normalizasyon yoluyla oluşturulmuş sıradan 0-255 değer aralığındaki gri seviyeli görüntüdür. Potansiyel şeftali bölgelerini açığa çıkarmak için deneme seti üzerinde simetri değerleri için deneme-yanılma yoluyla bir eşik değeri araştırılmış ve bu değer eğitim setinde bulunan tüm görüntüler göz önüne alınarak en uygun 5 olarak belirlenmiştir. Bulunan eşik değeri ile simetri haritası üzerinde eşikleme yapılarak potansiyel meyve bölgelerini temsil eden blokları içeren ikili görüntü elde edilmiştir. Görüntü tarama yöntemi 3'ün; blob analizi, 3 farklı ölçekteki 4 ortogonal


komşuları gibi bu aşamadan sonraki adımları bir önce açıklanan yöntemle aynıdır. RST yöntemiyle potansiyel meyve bölgelerinin saptanmasının görüntü işleme adımları Şekil 3.9'da verilmiştir.



a)



b)



c)

Şekil 3.9. Örnek bir şeftali bitki örtüsü görüntüsü (a), RST dönüşümü sonrası elde edilen simetri haritası (b) ve eşikleme sonucu elde edilen potansiyel meyve konumları (c)

3.2.6. Çalışmada kullanılan öznitelik çıkarma yöntemleri

Bu çalışmada doğal bahçe koşullarında alınan görüntülerde meyve ve arka plan arasında ayırt edici olabilecek pek çok öznitelik çıkarma yöntemi araştırılmıştır. İnsan yüzü tanıma, plaka tanıma, parmak izi tanıma gibi diğer mühendislik alanlarında araştırılan görüntü işleme ve bilgisayarlı görü uygulamalarında denenmiş öznitelik çıkarma yöntemleri ön çalışmalarla denenerek meyve tanımada potansiyeli olabilecekler üzerinde yoğunlaşmıştır.

3.2.6.1. Meyve ve arka plan örneklerinin hazırlanması

Doğal bitki örtüsü görüntüsündeki şeftali ve arka plan arasında ayırt edici özniteliklerin analizi için özniteliklerin meyve ve arka plan nesnelerinin ayrı ayrı hesaplanabilmesine imkan veren bir yaklaşıma ihtiyaç duyulmuştur. Bu amaçla eğitim seti görüntülerinde GIMP programı yardımıyla manuel olarak bütün meyveler alt-pencere yaklaşımına uygun olarak tek tek kare çerçeveler içerisine merkezlenerek kırılmıştır. Öznitelik hesaplamalarında negatif örnekleri oluşturmak üzere arka plandan da rastgele bölgelerden yaprak, dal, gövde, toprak ve gökyüzü piksellerini içeren kare çerçeveler meyveler gibi kırılmıştır. Bu şekilde 58 meyve ve 153 arka plan çerçevelerinden oluşan bir örnek havuzu oluşturulmuştur. Şekil 3.10'da kırılarak hazırlanan meyve ve arka plan görüntülerinden oluşan örnekler görülmektedir.



Şekil 3.10. Kırılarak hazırlanan meyve ve arka plan görüntülerine ait örnekler

3.2.6.2. Özmeyve (eigenfruit) öznelik çıkarma yöntemi

Bilgisayarlı görü ve görüntü işleme araştırmaları ve uygulamaları içerisinde birçok çalışma; insan yüzü, yayalar, el işaretleri ve araç plakalarını saptama ve algılama üzerinde odaklanmıştır. *Özyüz* (eigenface) yöntemi ilk olarak Sirovich ve Kirby (1987) tarafından ortaya atılmış, Turk ve Pentland (1991) tarafından ilk olarak insan yüzlerini sınıflandırmak amacıyla kullanılmıştır. *İlkesel bileşenler analizi* (principle component analysis, PCA) esaslı bu yöntem insan algılamasına benzerliği nedeniyle yüz tanıma ve algılama uygulamalarında oldukça yaygın bir yöntemdir. Turk ve Pentland (1991) tarafından geliştirilen bu yöntem, insan yüzü tanıma ve algılama araştırmalarında birçok araştırmacı tarafından kullanılmıştır (Wong ve ark. 2001, Bae ve Kim 2005, Sharma ve ark. 2010). Genellikle insan algılaması, önceden bilinen bir yüzü farklı bakış koşulları, yaş, gözlük, sakal ve farklı saç stili gibi yüzün kısmen örtülerek kaplandığı durumlarda bile kolaylıkla ayırt edebilir. Meyve tanıma görevi de nesnelere üst üste örtülmesi açısından benzer zorlukları taşımaktadır. Bahçe koşullarındaki doğal bitki örtüsü görüntülerinde birçok meyvenin yapraklar, dallar ve diğer meyveler tarafından örtüldüğü görülmektedir. Bu bağlamda bu yaklaşımın meyve tanıma görevinde avantajlar sağlayacağı düşünülmüştür. Bu çalışmada bu yaklaşım “*özyüz* (eigenface)”


yerine “*özmeyve* (eigenfruit)” olarak adlandırılmıştır. *Özyüz* yüz tanıma yaklaşımının doğal bitki örtüsü koşullarında meyveleri tanımak için öznelik olarak ilk defa bu çalışmanın kapsamında kullanılması çalışmanın katma değerleri arasındadır.

Özmeyve öznelik çıkarma yönteminin uygulanmasında Turk ve Pentland (1991)’ın orijinal çalışmalarında kullandıkları yöntem izlenmiştir. *Özmeyve* yöntemi bir meyve görüntüsünü *özmeyve* olarak adlandırılan ortonormal vektörlerin lineer kombinasyonu olarak temsil etmektedir. *Özmeyveler* meyve görüntülerinden oluşan eğitim setindeki kovaryans matrisinin özvektörleridir (bir matrisle çarpıldıklarında doğrultusunu değiştirmeyen vektörler). Bir kare meyve görüntüsü $N \times N$ ’lik bir matris olarak ele alınabilir. Bu matris de $N^2 \times 1$ vektör şeklinde yazılabilir. Görüntü Γ ile ifade edilirse eğitim setindeki görüntüler $\Gamma_1, \Gamma_2, \dots, \Gamma_M$ şeklinde yazılabilir. Eğitim setinin ortalaması eşitlik 3.12 ile bulunur.

$$\Psi = \frac{1}{M} \sum_{n=1}^M \Gamma_n \quad (3.12)$$

Eğitim setinde bulunan herhangi bir görüntü için ortalamadan farklılık eşitlik 3.13 ile hesaplanmaktadır. Ortalama şeftali meyvesi görüntüsü ve birinci *özmeyve* vektörünü temsil eden görüntü Şekil 3.11’de görülmektedir.

$$\Phi_i = \Gamma_i - \Psi \quad (3.13)$$



Şekil 3.11. Ortalama meyve görüntüsü ve *özmeyvenin* temsili: (a) ortalama meyve görüntüsü ve (b) birinci özvektörü temsil eden *özmeyve* görüntüsü

Burada Φ_i , eğitim setindeki herhangi bir görüntünün ortalamadan farklılığını temsil eden bir vektördür. Bu vektörlerin sayısı M 'dir. Eğer bu vektörler yatay olarak dizilirse $A = [\Phi_1 \Phi_2 \dots \Phi_M]$ şeklinde bir matris elde edilir. Elde edilen bu vektörler üzerinden, verinin dağılımını en iyi ifade eden M adet ortonormal u_n vektörü bulunmak istenmektedir. *İlkesel bileşenler analizi* (PCA) bu vektörlerin bulunmasında kullanılmaktadır. Bu u_n vektörlerinin her biri λ_k katsayılarını maksimum yapacak şekilde seçilir. Eşitlik 3.14 ve eşitlik 3.15'te k ncı vektör u_k 'nın bulunması açıklanmıştır.

$$\lambda_k = \frac{1}{M} \sum_{n=1}^M (u_k^T \Phi_n)^2 \quad (3.15)$$

u_n vektörleri eşitlik 3.16'daki ortonormallik koşulunu sağlamalıdır.

$$u_l^T u_k = \begin{cases} 1, & \text{Eğer } l = k \\ 0, & \text{Aksi halde} \end{cases} \quad (3.16)$$

Burada u_k ve λ_k sırasıyla eşitlik 3.17'de tanımlanan kovaryans matrisi C 'nin özvektörleri ve özdeğerleridir.

$$C = \frac{1}{M} \sum_{n=1}^M \Phi_n \Phi_n^T = AA^T \quad (3.17)$$

Elde edilen C matrisinin boyutu eğitim setindeki $N \times N$ 'lik görüntülerin tamamı için $N^2 \times N^2$ 'dir. Gerçekte eğitim setinde yer alan görüntülerin sayısı görüntülerin boyutundan çok daha küçüktür ($M < N^2$). Özvektörleri hesaplamayı kolaylaştırmak amacıyla N^2 'yi ele almak yerine $M-1$ adet anlamlı özvektör dikkate alınır. Bu varsayımla $M \times M$ 'lik ve elemanları $L_{mn} = \Phi_m^T \Phi_n$ olan bir diagonal $L = AA^T$ matrisi oluşturulmaktadır. Bu matrisin v_i ile gösterilen M adet özvektörü elde edilir. L 'nin özvektörlerinin hesaplanmasından sonra *özmevveler* (C 'nin özvektörleri), eşitlik 3.18 ile hesaplanmaktadır.

$$u_i = \sum_1^M v_{ik} \Phi_k \quad (3.18)$$


$$i = 1 \dots M \quad (3.19)$$

Elde edilen özvektörler bir meyve uzayı oluştururlar. Bir meyve görüntüsünün Γ bu uzaya projeksiyonu eşitlik 3.20 ve eşitlik 3.21'de verilmiştir. Projeksiyon işlemi ortalamanın çıkartıldığı her meyve görüntüsünün *özmeyveler*den biriyle çarpımıdır.

$$\omega_k = u_k^T (\Gamma - \Psi), k = 1 \dots M \quad (3.20)$$

$$\Phi_f = \sum_{i=1}^K \omega_i u_i \quad (3.21)$$

Burada ω_k görüntünün ağırlığıdır ve eğitim setinde bulunan her meyve Φ_i , K adet özvektörün doğrusal bir kombinasyonu şeklinde temsil edilebilmektedir. Eşitlik 3.21'de yer alan Φ_f , meyve uzayına projeksiyonu yapılan bir aday (meyve veya arkaplan) görüntüyü temsil etmektedir. Şekil 3.12'de meyve uzayının ve projeksiyon kavramının temsili görülmektedir. Bu temsilde algılama kolaylığı açısından birçok özvektörün oluşturduğu çok boyutlu uzay, sanki iki boyutlu düzlemmiş gibi ifade edilmiştir.



Şekil 3.12. Bir görüntünün meyve uzayına projeksiyonu ve meyve uzayından olan mesafe

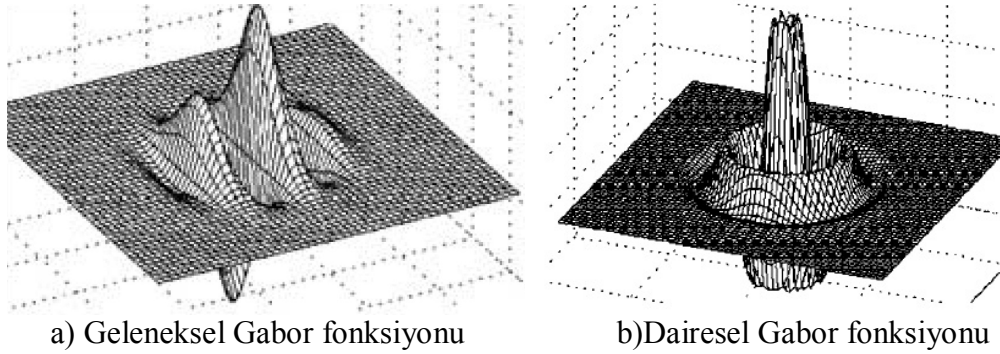
Şekil 3.12’de görülen bir görüntünün meyve uzayından olan mesafesi (muom) bu çalışmada bir öznitelik olarak kullanılmıştır. Muom, bir aday görüntünün meyve görüntülerinden oluşan eğitim setinde bulunan görüntülerle olan benzerliğinin bir ölçüsüdür. Bu benzerliği ölçmek amacıyla bu çalışmada eşitlik 3.22’de tanımlanan Öklit mesafesi (Euclidean distance) kullanılmıştır. Çalışmada geliştirilen ve denenilen algoritmalarda *özmeyve* özniteliği, algoritmanın türüne göre renkli görüntünün HSI renk modelinin gri seviyeli görüntüsünü temsil eden I ve diğer bir bileşen olan S bileşeni için ayrı ayrı hesaplanmıştır. *Özmeyve* öznitelik çıkarma yöntemi için hazırlanan örneklerin boyutları 36×36 piksel’dir. Bu değer; insan yüzünde bulunan göz, burun, kulak, ağız gibi ayrıntılar içermeyen genç şeftali nesnelerinin şekilsel bilgisini ifade etmek için yeterli bir büyüklük olarak seçilmiştir.

$$e^d = \|\Phi - \Phi_f\| \quad (3.22)$$

3.2.6.3. Dönüşten bağımsız dairesel Gabor doku analizi

Doku (texture) insanın görsel algısında önemli bir rol oynamaktadır. Bir sayısal görüntüde ise görüntüdeki bir alt bölge ya da nesnenin yüzey özelliklerini

sayısallaştırarak ifade etmek doku özneliği çıkarma kapsamındadır. Doku parametreleri bir banttaki tonal değişimin mekansal dağılımı hakkında bilgi vermektedir. Doku, renk düzeyleri arasındaki ilişkiyi ve komşu piksellerdeki değerler arasındaki ilişkiyi dikkate almaktadır. Bu çalışmada kullanılan doku özneliği çıkarma yöntemlerinden birisi, dönüşten bağımsız dairesel Gabor doku analizidir (rotation invariant circular Gabor texture analysis). Gabor doku analizi, Gabor (1946) tarafından tek boyutlu Gabor fonksiyonunun ortaya atılmasından beri birçok araştırmacı tarafından kullanılmıştır (Weldon ve ark. 1996, Li ve Staunton 2008, Xiaohua ve ark. 2009). Zhang ve ark. (2002), geleneksel iki boyutlu Gabor filtrelerini genişleterek dönüşten bağımsız dairesel Gabor doku segmentasyonunu ortaya koymuşlardır. Araştırmacılar geleneksel Gabor filtresini yeniden düzenleyerek filtrenin bir dairesel simetri versiyonunu ortaya çıkarmışlardır. Şekil 3.13'te geleneksel ve dairesel Gabor fonksiyonlarının örnek temsilleri görülmektedir.



Şekil 3.13. Geleneksel (a) ve dairesel (b) Gabor fonksiyonlarının örnek gösterimleri

Bu çalışmada meyvelerin dairesel şekillerine uygun olduğu için dönüşten bağımsız dairesel Gabor doku analizi, doku özneliği çıkarma yöntemlerinden biri olarak kullanılmıştır. Bu yöntemle öznelik çıkarma işleminde hesaplamalar, dairesel Gabor filtresini ilk olarak ortaya atan Zhang ve ark. (2002)'ye benzer şekilde yapılmıştır. Gabor fonksiyonunun en başından oluşturulması ve bu fonksiyonun geleneksel Gabor fonksiyonundan farklılıkları bu çalışmanın odak noktası olmamakla birlikte bu konularla ilgili daha fazla bilgi Zhang ve Lu (2000), Arivazhagan ve ark. (2006) ve Han ve Ma (2007)'nin çalışmalarında bulunabilir. Eşitlik 3.23 ve 3.24'te dairesel Gabor fonksiyonunun matematiksel tanımlaması verilmiştir.

$$g(x, y) = \frac{1}{2\pi\sigma^2} \exp(-(x^2 + y^2)/2\sigma^2) \quad (3.23)$$

$$G(x, y) = g(x, y) \exp(2\pi i F(\sqrt{x^2 + y^2})) \quad (3.24)$$

Burada $g(x,y)$ bir Gaussian fonksiyonunu, x ve y matris indislerini, σ ölçek parametresini, F fonksiyonun frekansını ve i ise karmaşık sayı birimi $\sqrt{-1}$ 'i temsil etmektedir. Bu çalışmada dairesel Gabor fonksiyonunun ölçek ve frekans parametreleri, eğitim setindeki görüntülere farklı değerlerde filtreler uygulayarak görsel açıdan en ayırt edici sonucu veren değer ikilisi olarak belirlenmiştir. Çalışmada kullanılan ölçek değeri σ 0,65, frekans değeri F ise 2'dir. Bulgular ve tartışma kısmında Gabor filtresi sonucu ortaya çıkan filtreli görüntüler verilmiştir. Bir görüntünün dairesel Gabor fonksiyonuyla konvolüsyonu sonucu eşitlik 3.25'te tanımlanan filtrelenmiş görüntü ortaya çıkmaktadır.

$$\phi = G(x, y) \otimes f \quad (3.25)$$

Burada ϕ , filtrelenmiş görüntü $G(x,y)$ dairesel Gabor fonksiyonu, \otimes konvolüsyon operatörü, f ise filtrelenmemiş gri seviyeli görüntüdür. Çalışmada konvolüsyon sonucu elde edilen filtrelenmiş görüntü, Gabor fonksiyonunda çarpım durumunda bulunan karmaşık sayı birimi i 'den dolayı karmaşık sayılar içermektedir. Bu karmaşık sayılardan kurtulmak ve sonuç görüntünün doku özneliğini temsil eden sayısal değeri σ_G 'yi elde etmek amacıyla sonuç görüntünün mutlak değerinin standart sapması eşitlik 3.26'ya göre hesaplanmıştır.


$$\sigma_G = \sqrt{\frac{1}{M \times N - 1} \sum_x \sum_y (|\phi(x, y)| - \bar{\phi})^2} \quad (3.26)$$

Burada M ve N matris (filtrelenmiş görüntü) boyutlarını temsil etmektedir. Çalışmada eğitim setindeki kırpılmış görüntülerin öznitelikleri 130×130 piksel ölçeğinde hesaplanmıştır.

3.2.6.4. GLCM (Haralick) doku öznitelikleri

Bu çalışmada genç şeftali meyvelerini görüntülerde ayırt etmek için kullanılan diğer bir öznitelik çıkarma yöntemi istatistiksel bir yaklaşım olan GLCM (gray level co-occurrence matrix) doku öznitelikleridir. Bu yöntem ilk defa Haralick ve ark. (1973) tarafından ortaya konulduğundan Haralick öznitelikleri olarak da adlandırılmaktadır. Gri seviye eş-oluşum matrisi olarak tanımlanan GLCM, bir görüntüde art arda gelen iki piksel arasındaki frekans matrisini ifade etmektedir. Bu piksellerden birisi referans pikseli, diğeri ise komşu piksel olarak adlandırılır. N^2 boyutlu bir kare matris olan GLCM'de matrisin her bir elemanı d mesafesindeki i ve j piksel değer çiftinin oluşum sayısını belirtir (Acar, 2012).

GLCM matrisinin oluşturulmasında pikseller arası uzaklığın yanı sıra, piksel çiftlerinin yönleri de önem taşımaktadır. Uygulamada en çok kullanılan yönler $\vartheta = 0, 45, 90, 135^\circ$ ve bunların simetrik benzerleridir. Bu çalışmada GLCM özniteliklerinin hesaplanmasında $0, 45, 90, 135^\circ$ lik yönlerde oluşturulan GLCM özniteliklerinin bir öznitelik için ortalaması o özniteliği temsil eden değer olarak kullanılmıştır. Şekil 3.14'te gri seviye sayısı 8, pikseller arası uzaklık $d=1$ ve yön açısı $\vartheta = 0$ olarak hesaplanmış bir eş-oluşum matrisinin örneği görülmektedir (Acar ve Özerdem 2012).



Şekil 3.14. Örnek bir eş-oluşum (GLCM) matrisi

Şekilde, görüntü matrisi içindeki (1,1) ve (1,2) piksel konumlarındaki (1,1)'lik piksel çifti bir kez tekrarlanmıştır. Dolayısıyla bu piksel çiftinin eş-oluşum matrisindeki (1,1) piksel konumundaki değeri, 1 olur. Benzer şekilde (6,2) piksel çifti, görüntü matrisi içinde 3 defa tekrarlandığından dolayı eş-oluşum matrisindeki değeri 3 olur. Bu adımlar görüntü matrisi içindeki diğer piksel çiftleri için de tekrarlanıp görüntüye ait eş-oluşum matrisi hesaplanır (Acar 2012).

GLCM doku özniteliklerini hesaplamak için gri seviyeler arasındaki eş-oluşum olasılığı kullanılmaktadır (Clausi 2002). Bu olasılığın hesaplanması eşitlik 3.27 ve 3.28'de verilmiştir.

$$\Pr(x) = \{p(i, j) | (d, \theta)\} \quad (3.27)$$

$$p(i, j) = \frac{P_{ij}}{\sum_{i,j=1}^G P_{ij}} \quad (3.28)$$

Burada $\Pr(x)$ olasılık ölçüsü, $p(i, j)$ i ve j gri seviyeleri arasındaki eş-oluşum olasılığı, P_{ij} gri seviyelerin oluşum sayısıdır.

Haralick ve ark. (1973), 14 adet GLCM özneliği ortaya koymuşlardır. Farklı araştırmacıların katkılarıyla günümüzde bu sayı artmıştır. Bu çalışma kapsamında Haralick ve ark. (1973), Soh ve Tsatsoulis (1999), Clausi (2002) tarafından ortaya konulan ve kullanılan toplamda 22 adet GLCM özneliği birlikte derlenmiştir. Bu öznelikler aşağıdaki eşitlikler kullanılarak hesaplanmıştır.

Enerji (uniformity / energy / angular second moment):

$$\sum_i \sum_j p(i, j)^2 \quad (3.29)$$

Entropi (entropy):

$$- \sum_i \sum_j p(i, j) \log(p(i, j)) \quad (3.30)$$

Benzeşmezlik (Dissimilarity):

$$\sum_i \sum_j |i - j| p(i, j) \quad (3.31)$$

Kontrast (contrast / inertia)

$$\sum_{n=0}^{N-1} n^2 \left\{ \sum_{i=1}^N \sum_{j=1}^N p(i, j) |i - j| = n \right\} \quad (3.32)$$

Ters fark (inverse difference):

$$\sum_i \sum_j \frac{1}{1+(i-j)^2} p(i, j) \quad (3.33)$$

Korelasyon (correlation):

$$\sum_{i,j=0}^{N-1} p_{i,j} \left[\frac{(i-\mu_i)(i-\mu_j)}{\sqrt{(\sigma_i^2)(\sigma_j^2)}} \right] \quad (3.34)$$

Homojenlik (homogeneity / inverse difference moment):

$$\sum_{i,j=0}^{N-1} i \frac{p_{i,j}}{1+(i-j)^2} \quad (3.35)$$

Oto-korelasyon (autocorrelation):

$$\sum_i \sum_j (ij) p(i,j) \quad (3.36)$$

Yığılım gölgesi (cluster shade):

$$\sum_i \sum_j (i + j - \mu_x - \mu_y)^3 p(i,j) \quad (3.37)$$

Yığılım belirginliği (cluster prominence):

$$\sum_i \sum_j (i + j - \mu_x - \mu_y)^4 p(i,j) \quad (3.38)$$

Maksimum olasılık (maximum probability):

$$MAX_{i,j} p(i,j) \quad (3.39)$$

Kareler toplamı (sum of squares):

$$\sum_{i=1}^N \sum_{j=1}^N (i - \mu)^2 p(i,j) \quad (3.40)$$

Toplam ortalama (sum average):

$$\sum_{i=2}^{2N} i p_{x+y}(i) \quad (3.41)$$

Toplam varyans (sum variance):

$$\sum_{i=2}^{2N} (i - \sum_{k=2}^{2N} k p_{x+y}(k))^2 p_{x+y}(i), p_{x+y}(k) = [\sum_{i=1}^N \sum_{j=1}^N p(i,j)]_{i+j=k} \quad (3.42)$$

Toplam entropi (sum entropy):

$$- \sum_{i=0}^{2G-2} p_{x+y}(i) \log(p_{x+y}(i)) \quad (3.43)$$

Varyans farkı (difference variance):

$$- \sum_{i=0}^{N-1} (i - \mu_{x-y})^2 p_{x-y}(i) \quad (3.44)$$

Entropi farkı (difference entropy):

$$- \sum_{i=0}^{N-1} p_{x-y}(i) \log(p_{x-y}(i)) \quad (3.45)$$

Korelasyon bilgi ölçüsü 1 (Information measures of correlation 1):

$$\frac{\text{entropi} - HXY1}{\text{MAX}\{HX, HY\}} \quad (3.46)$$

Korelasyon bilgi ölçüsü 2 (Information measures of correlation 2):

$$(1 - \exp[-2.0(HXY2 - \text{entropy})])^{1/2} \quad (3.47)$$

Eşitlik 3.46 ve 3.47'da kullanılan parametreler eşitlik 3.48 ve 3.49'a göre hesaplanmıştır. HX ve HY , p_x ve p_y 'nin entropi değerleridir.

$$HXY1 = - \sum_{i=1}^N \sum_{j=1}^N p(i,j) \log(p_x(i)p_y(j)) \quad (3.48)$$

$$HXY2 = - \sum_{i=1}^N \sum_{j=1}^N p_x(i)p_y(j) \log(p_x(i)p_y(j)) \quad (3.49)$$

En büyük korelasyon katsayısı (maximal correlation coefficient):

$$\sum_k \frac{p(i,k)p(j,k)}{p_x(i)p_y(k)} \quad (3.50)$$

Normalize edilmiş ters fark (inverse difference normalized (INN)):

$$\sum_{i,j} \frac{p(i,j)}{1+(|i-j|/\sigma)} \quad (3.51)$$

Normalize edilmiş ters moment farkı (Inverse difference moment normalized (IDN)):

$$\sum_{i,j} \frac{p(i,j)}{1+((i-j)^2/\sigma)} \quad (3.52)$$

Eşitliklerde kullanılan μ_x , μ_y , σ_x , σ_y sırasıyla p_x ve p_y fonksiyonlarına ait ortalama ve standart sapma değerlerini ifade etmektedir.

3.2.7. Çalışmada kullanılan yapay sınıflandırıcılar

Bu çalışmada olgunlaşmamış şeftaliyi renkli görüntülerde saptamada çıkarılan özneliklerle farklı sınıflandırıcıların performanslarını ortaya koymak amacıyla 7 adet sınıflandırıcı eğitilerek denenmiştir. Bu sınıflandırıcıların bazıları parametrik bazıları ise parametrik olmayanlardır. Geliştirilen görüntü tarama yöntemleriyle elde edilen alt-pencereler çıkarılan öznelikler kullanılarak bu sınıflandırıcılar tarafından sınıflandırılmışlardır. Diskriminant analizi, K-en-yakın komşu, naive Bayes, regresyon ağaçları, sınıflandırma ağaçları, yapay sinir ağları ve destek vektör makinası bu çalışmada kullanılan sınıflandırıcılardır. Bu sınıflandırıcılar arasından diskriminant analizi ve naive Bayes parametrik, diğerleri ise parametrik olmayan sınıflandırıcılardır.

3.2.7.1. Yapay sınıflandırıcılar için veri hazırlama

Herhangi bir sınıflandırıcıyı eğitmek için öznitelik vektörleri ve sınıfları temsil eden sınıf etiketlerinden meydana gelen bir eğitim setine ihtiyaç duyulur. Bu eğitim setindeki öznitelik vektörleri farklı öznitelik değerlerinin bir araya getirildiği değişken dizileridir. Sınıf etiketleri bir sayısal çıktı ya da bir kategoriye temsil eden a, b, c, 0, 1, 2, 3 gibi ifadelerdir. Bu çalışmada bir sonraki kısımda ayrıntıları verilen sınıflandırıcıların eğitiminde sınıf etiketleri olarak arka plan ve meyve sınıflarını temsil eden sırasıyla 0 ve 1 değerleri sınıf etiketi olarak kullanılmışlardır. Yapay sinir ağı (YSA) eğitiminde ise bu etiketlemede YSA'nın kendine özgü yapısından dolayı farklılıklar vardır ve YSA bölümünde detaylarıyla açıklanmıştır. Çalışmada hesaplanan öznitelik değerlerinin her biri kendine özgü bir değer aralığında dağılım göstermişlerdir. Bu durumun veri dağılımında düzensizliklerine ve sınıflandırıcıların eğitiminde performans düşüklüğüne neden olması bilinen bir gerçektir. Kavdır ve Guyer (2004), normalizasyonun giriş verisini normalize ederek farklı aralıklardaki öznitelik değerlerinin getirdiği dezavantajları elimine ettiğini bildirmişlerdir. Bu çalışmada hesaplanan özniteliklerin sayısal şiddetleri (magnitude) -1 ve 1 değer aralığına eşitlik 3.53 kullanılarak normalize edilmiştir.

$$X_N = \frac{2(X' - X_{min})}{X_{max} - X_{min}} \quad (3.53)$$

Burada X' normalize edilecek öznitelik değeri, X_N normalize edilmiş değer, X_{min} ve X_{max} ise sırasıyla öznitelik değerinin minimum ve maksimum değerleridir.

3.2.7.2. Diskriminant analizi

Diskriminant analizi Gaussian dağılımını kullanan parametrik bir danışmanlı öğrenme yöntemidir. Bu yöntem istatistik, örüntü tanıma ve bilgisayarlı öğrenme alanlarında iki veya daha fazla nesne sınıfını ya da olayı karakterize ederek ayıracak özniteliklerin lineer kombinasyonlarını bulmak amacıyla kullanılmaktadır (Gupta ve ark. 2010). Diskriminant analizini uygulamak için geleneksel yöntem, R. Fisher tarafından ortaya konulan lineer diskriminant analizidir (Guo ve ark. 2005). Bir sınıflandırıcı olarak ise bu yöntem sınıflandırma problemleri için yaygın olarak kullanılmaktadır. Değişken \vec{x} 'in

Gaussian dağılımı gösteren bir öznitelik olduğu varsayımıyla (parametrik yaklaşım) model, her sınıf y için çok değişkenli bir normal dağılım kullanarak tahminleyiciyi bulmaktadır. Bu model her sınıf için aynı kovaryans matrisine sahiptir ancak ortalamalar değişmektedir. Diskriminant analizi sınıflandırıcısını (LDA) eğitmek, her sınıf için bir Gaussian dağılımının parametrelerini tahmin etmektir. Aşağıdaki eşitlikler LDA sınıflandırıcısının bu çalışmada oluşturulmasını göstermektedir (Mathworks 2012).

$$M_{nk} = \begin{cases} 1, & k \text{ sınıfının gözlemi } n \\ 0, & \text{aksi halde} \end{cases} \quad (3.54)$$

Ağırlıklı olmayan veri için sınıf ortalamasının tahmini eşitlik 3.55'te verilmiştir.

$$\hat{\mu}_k = \frac{\sum_{n=1}^N M_{nk} x_n}{\sum_{n=1}^N M_{nk}} \quad (3.55)$$

Pozitif ağırlık w_n ile ağırlıklı veri için doğal genelleştirme eşitlik 3.56 ile ifade edilir.

$$\hat{\mu}_k = \frac{\sum_{n=1}^N M_{nk} w_n x_n}{\sum_{n=1}^N M_{nk} w_n} \quad (3.56)$$

Ağırlıksız veri için toplam kovaryans matrisinin tarafsız tahmini eşitlik 3.57 ile ifade edilmektedir.

$$\hat{\Sigma} = \frac{\sum_{n=1}^N \sum_{k=1}^K M_{nk} (x_n - \hat{\mu}_k)(x_n - \hat{\mu}_k)^T}{N-K} \quad (3.57)$$

Ağırlıklar toplamının 1 olduğu varsayımıyla kovaryans matrisinin ağırlıklı veri için tarafsız tahmin eşitliği eşitlik 3.58'de verilmiştir.

$$\hat{\Sigma} = \frac{\sum_{n=1}^N \sum_{k=1}^K M_{nk} w_n (x_n - \hat{\mu}_k)(x_n - \hat{\mu}_k)^T}{1 - \sum_{k=1}^K \frac{w_k^{(2)}}{w_k}} \quad (3.58)$$

Burada $w_k = \sum_{n=1}^N M_{nk} w_n$ k sınıfı için ağırlıklar toplamı ve $w_k^{(2)} = \sum_{n=1}^N M_{nk} w_n^2$ her sınıf için ağırlıkların kareleri toplamıdır. LDA sınıflandırıcısı eğitildiğinde sınıflandırma işlemi, eşitlik 3.58'de tanımlanan beklenen sınıflandırma değerini minimize eden değerin tahmini şeklinde yapılmaktadır.

$$\vec{y} = \operatorname{argmin}_{y=1,\dots,K} \sum_{k=1}^K \hat{P}(k|x) C(y|k) \quad (3.59)$$

Burada \vec{y} tahmin edilen sınıflandırma, K sınıf sayısı, $\hat{P}(k|x)$ k sınıfının x gözleminden sonraki olasılığı (posterior probability), $C(y|k)$ ise bir gözlemi y olarak sınıflandırmanın değeridir.

3.2.7.3. Naive Bayes

Naive Bayes sınıflandırıcısı istatistiksel sınıflandırma teknikleri arasında yer alan Bayes teoremi esaslı parametrik bir sınıflandırıcıdır. Bu sınıflandırıcı öğrenme görevlerini her örnek x 'in öznitelik değerlerinin bir arada tanımlandığı ve hedef fonksiyonu $f(x)$ 'in sonlu V setinde herhangi bir değer alabileceği durumlarda uygulamaktadır. Yeni bir örneği sınıflandırmak örneği tanımlayan öznitelik değerlerinden $(a_1, a_2 \dots a_n)$ eşitlik 3.60'da ifade edilen en olası hedef değeri (v_{MAP}) tayin etmek demektir (Mitchell 1997).

$$v_{MAP} = \operatorname{argmax}_{v_j \in V} P(v_j | a_1, a_2 \dots a_n) \quad (3.60)$$

Bu tanımlama, en olası hedef değeri tahmin etmek için Bayes teoremi kullanılarak yeniden yazılırsa eşitlik 3.61 elde edilir.

$$v_{MAP} = \operatorname{argmax}_{v_j \in V} P(a_1, a_2 \dots a_n | v_j) P(v_j) \quad (3.61)$$

Naive Bayes sınıflandırıcısı, öznitelik değerlerinin sınıftan koşullu olarak bağımsız olması varsayımını basitleştirir. Diğer bir ifadeyle $a_1, a_2 \dots a_n$ öznitelik değerlerinin birlikte gözlemlerinin olasılığı her bir özneliğin çarpımlarıdır ($P(a_1, a_2 \dots a_n | v_j) = \prod_i P(a_i | v_j)$). Bu ifade en olası hedef değer eşitliğinde yerine konulursa naive Bayes sınıflandırıcısı eşitlik 3.62'deki gibi ifade edilir.

$$v_{NB} = \operatorname{argmax}_{v_j \in V} P(v_j) \prod_i P(a_i | v_j) \quad (3.62)$$

Burada v_{NB} sınıflandırıcının hedef değeri çıktısı, $P(a_i | v_j)$ öznitelik a_i 'nin sınıf etiketiyle belirlenen olasılığı, v_j ise bağımsız sınıf değişkenidir. Verinin Gaussian dağılımı varsayımıyla naive Bayes sınıflandırıcısı, sınıf içerisindeki en yüksek olasılığı kullanarak ve eğitim verisinin ortalama ve standart sapmasını her sınıf için hesaplayarak ayrı bir normal dağılım tahmin eder. Naive Bayes sınıflandırıcısını oluştururken sınıflara ait önsel olasılıkların (prior probability) belirlenmesi gerekmektedir. Bu çalışmada meyve ve arka plan piksellerinin eğitim seti üzerindeki dağılımları incelenerek sınıfların önsel olasılık değerleri belirlenmiştir. Meyve ve arka plan sınıfları için sırasıyla 0.06 ve 0.94 önsel olasılık değerleri kullanılmıştır. Sınıflandırıcı, daha önceden bilmediği bir örneği tahmin etmesi için her sınıfa ait olan örneğin sonsal olasılığını (posterior probability) hesaplar. Sınıflandırma işleminde en yüksek sonsal olasılık dikkate alınır.

3.2.7.4. K-en-yakın komşular

Bu çalışmada kullanılan diğer bir sınıflandırıcı parametrik olmayan K-en-yakın komşular sınıflandırıcısıdır. K değeri komşu sayısını temsil etmektedir. Bu sınıflandırma yöntemi örnekleri, eğitim setindeki örneklere olan noktasal uzaklıklara göre kategorize etmektedir. K-en-yakın komşu karar kuralını uygulamak için verilen test örüntüsü ve eğitim verisi arasındaki tüm uzaklıklar ölçülür. Herhangi bir test örüntüsünü bir sınıfa dahil etmek için örüntüdeki minimum mesafe dikkate alınır (Kavdır ve Guyer 2004). Bu çalışmada bu mesafenin ölçümünde eşitlik 3.63'te tanımlanan Mahalonobis mesafesi kullanılmıştır.

$$d_M(p, r) = (x_p - x_r)^T C^{-1} (x_p - x_r) \quad (3.63)$$

Burada d_M eğitim örüntüsü r ve test örüntüsü p arasındaki Mahalonobis uzaklık indeksi, x_p ve x_r sırasıyla test ve eğitim örüntüleri arasındaki mesafedir. T transpoze işlemini temsil ederken C özniteliklerin kovaryans matrisidir. Bu çalışmada 1 ve daha yüksek K

değerleri en uygun komşu sayısını bulmak amacıyla ön çalışmalarla denenerek 1 değerinin çok az daha iyi performanslar verdiği saptandığından denemelerde 1 komşulu sınıflandırıcı kullanılmıştır.

3.2.7.5. Sınıflandırma ve regresyon ağaçları

Breiman ve ark. (1984) tarafından ortaya konan sınıflandırma ve regresyon ağaçları parametrik olmayan istatistiksel sınıflandırma yöntemleridir. Bu sınıflandırıcılar farklı açıklayıcı değişkenlerin bir fonksiyonu olarak bir cevap değişkenini tanımlayan bir karar ağacı oluştururlar. Ağaç yapısındaki bu sınıflandırıcılar eğitim verisinde bulunan alt setleri soy ağacı gibi 2 dala ayırarak tekrarlı olarak dallandırılmasıyla oluşturulur. Her ayırım tek bir açıklayıcı değişken esas alınarak yapılır (Deconinck ve ark. 2012, Questier ve ark. 2004).

Bu sınıflandırıcıları oluşturmak için önce tüm nesnelere tek bir ana kök üzerinde toplanır. Daha sonra her açıklayıcı değişken tüm muhtemel ayrılma noktalarından ayrılır. Bu ayrılmalarda açıklayıcı değişkenin bir eşik değerinden düşük ya da yüksek olması dikkate alınır. Bir düğümün safsızlık (impurity) ölçüsü, düğümlerin nerelerde ve nasıl ayrılacağını belirlemede kullanılır. Safsızlığın en çok azaldığı yerlerdeki değişken ve ayrılma noktaları seçilmektedir. Regresyon ağacı sınıflandırması için n adet nesnesi olan bir düğüm için safsızlık hesaplaması eşitlik 3.64'e göre yapılır.

$$\text{safsızlık} = \sum_{i=1}^n (y_i - \bar{y})^2 \quad (3.64)$$

Burada y_i cevap değişkeni \bar{y} ise düğüm ortalamasıdır.

Sınıflandırma ve regresyon ağaçları arasındaki fark düğüm ayrımlarının seçilmesindedir. Sınıflandırma ağacı sınıflandırıcısı için bir ayırımın seçilmesi yaygın olarak kullanılan Gini'nin çeşitlilik indeksi, twoing indeksi ve bilgi indeksi yöntemlerinden birisiyle yapılır. Bu çalışmada bu amaçla Gini'nin çeşitlilik indeksi kullanılmıştır. Eşitlik 3.65'te n adet nesnesi, c adet muhtemel sınıfı olan bir düğümün Gini'nin çeşitlilik indeksi hesaplaması tanımlanmıştır.

$$\text{Gini} = 1 - \sum_{j=1}^c \left(\frac{n_j}{n}\right)^2 \quad (3.65)$$

Burada n_j düğümde j sınıfındaki nesne sayısıdır.

Ayrım seçildikten sonra ana düğüm, seçilen ayırım noktasına göre iki alt düğüme ayrılmaktadır. Bu adımlar ağaç maksimum boyutlarına ulaşana dek tekrarlanmaktadır.

3.2.7.6. Destek vektör makinası

Destek vektör makinası (Support Vector Machine, SVM) istatistiksel öğrenme teoremi esaslı en yüksek marjın sınıflandırıcısıdır (Vapnik 1995). Parametrik olmayan SVM'ler eğitim verisinin olasılık dağılımını modellemek yerine eğitim vektörleri arasındaki uygun sınırları doğrudan araştırarak farklı sınıfları belirlerler (Keuchel ve ark. 2003). SVM sınıflandırıcısını oluşturmak için en yüksek marjindeki sınıfların öznelik uzayında en uygun bir hiperdüzlem (hyperplane) bulunur (Kecman 2001). Şekil 3.15'te en yüksek marjın ve en uygun ayırıcı hiperdüzleme ait bir örnek temsil görülmektedir (Bottou ve Lin, 2007). Bu çalışmada eğitim seti kullanılarak meyve ve arka plan alt-pencerelerini sınıflandırmak için iki sınıflı doğrusal esaslı bir SVM oluşturularak kullanılmıştır. Örnek sayısı n olan bir eğitim seti St ele alındığında ve hedef sınıf etiketleri x ve y ile gösterilirse eğitim seti St eşitlik 3.66 ile tanımlanır.

$$St = ((x_1, y_1), \dots, (x_n, y_n)) \quad (3.66)$$

Pozitif ne negatif sınıflar için ayırıcı hiperdüzlem eşitlik 3.67 ile ifade edilir.


$$\langle w, x \rangle + b = 0 \quad (3.67)$$

En uygun hiperdüzlem için eğitim noktalarının ağırlıklı ortalaması w ve yönelimi b (bias) eşitlik 3.68 ve 3.69 kullanılarak hesaplanır.

$$w = \sum_i \alpha_i y_i x_i \quad (3.68)$$

$$b = -0.5\langle w, x_r + x_s \rangle \quad (3.69)$$

Burada α_i Lagrange çarpanı, x_r ve x_s ise $\alpha_r > 0, y_r = -1; \alpha_s > 0, y_s = 1$ koşullarını karşılayan her sınıfın destek vektörleridir.




Şekil 3.15. En uygun ayırıcı hiperdüzlem ve en yüksek marjin

3.2.7.7. Yapay sinir ağları

Çalışmada kullanılan diğer bir parametrik olmayan sınıflandırıcı; biyolojik nöronların çalışma şeklini taklit eden, bilgisayarlı öğrenme ve sınıflandırma yöntemleri içinde en yaygın yöntemlerden birisi olan yapay sinir ağlarıdır (YSA). Bu yöntem şeftali alt-pencerelerini ayırt etmek amacıyla bu çalışmada kullanılan yöntemlerden birisidir. Bir YSA, nöronlardan oluşan katmanlardan meydana gelmektedir. Giriş ve çıkış katmanları arasında kalan katmanlar gizli katman olarak adlandırılırlar. Katmanlar birbirlerine giriş nöronlarından çıkış nöronlarına kadar sinir bağlantılarıyla bağlanmıştır. Nöronların eğitim sürecinde sürekli değişen ve ağın çıkışını etkileyen transfer veya bir başka yaygın tabiriyle aktivasyon fonksiyonları bulunur. Bir YSA sınıflandırıcısı oluşturmak için gizli katman sayısı, katmanlardaki nöron sayısı, öğrenme algoritması, transfer fonksiyonları ve performans fonksiyonları gibi neredeyse sayısız olasılıkta ihtimal söz konusudur. Bu çalışmada alt-pencereleri sınıflandırmak amacıyla birçok olasılık önçalışmalarla denenmiştir. YSA sınıflandırıcısının öğrenimini genelleştirme becerisini artırmak ve aşırı öğrenmeyi (overfitting) engellemek amacıyla düşük sayıda nöron ve gizli katman sayılarından başlanarak en uygun ağ yapısı elde edilerek kullanılmıştır. Bu çalışmada kullanılan algoritmalara göre farklı YSA'lar eğitilmiştir. Bu ağlar ve eğitim performansları çalışmanın bulgular ve tartışma kısmında ayrıntılarıyla verilmiştir. Şekil

3.16’da bu çalışmada kullanılan YSA yapılarından biri görülmektedir. Şekildeki YSA yapısı iki gizli katmanlı, her gizli katmanında 15 nöron bulunduran, eğitim fonksiyonu gradyan azalımlı momentum geri yayımlı (gradient descent with momentum back-propagation) ve MATLAB ortamında oluşturulan bir ağıdır.



Şekil 3.16. Örnek bir yapay sinir ağı

Çalışmada kullanılan YSA’ların eğitimi için MATLAB programının araç kutularından birisi olan neural network toolbox kullanılmıştır. Çalışmada kullanılan YSA’ların giriş katmanlarındaki nöron sayıları algorithmada kullanılan öznelik sayısı kadardır. Çıkış katmanlarındaki nöron sayıları ise meyve ve arka planı temsil eden iki adet nörondan oluşmaktadır. Bu nöronlar çalışmada kullanılan diğer sınıflandırıcıların açıklanmasında bahsedilen etiketler ya da hedeflerdir. YSA eğitiminde meyveyi temsil eden alt pencereler için iki nöronlu çıkış katmanı [1,0] ve arka planı temsil eden pencereler için [0,1] olarak kodlanmıştır. Çalışmada kullanılan bütün YSA’ların eğitiminde performans fonksiyonu olarak MSE ve arzu edilen hata değeri olarak 0,001 kullanılmıştır. Eğitimlerde izin verilen en yüksek yinelenme (iteration) veya devir sayısı, 10 000 olarak ayarlanmıştır. Eğitim işlemi, ağ arzu edilen hata değerine ulaşmaya kadar devam etmiştir. Eğitim işlemi tamamlandığında ağ dosyası meyve tanıma denemelerinde kullanılmak üzere saklanmıştır.

3.2.8. Çalışmada kullanılan öznelik setlerinin oluşturulması

Geliştirilen algoritmalarda meyve ve arka plan alt-pencerelerini sınıflandırmak amacıyla farklı öznelik setleri oluşturulmuştur. Bu çalışmada geliştirilen ve denemeleri yapılan olgunlaşmamış şeftaliyi renkli görüntülerde saptayan algoritmalarda kullanılan öznelik setlerinin oluşturulmasında istatistiksel ve deneysel yöntemlerden yararlanılmıştır. Bu öznelik setlerinin farklılıkları, çalışmada geliştirilen algoritmaları çeşitlendiren unsurlardan birisidir.

3.2.8.1. İkili lojistik regresyon kullanılarak GLCM özniteliklerinin olgunlaşmamış şeftaliyi ayırt etmede istatistiksel anlamlılık analizi

Çalışmada GLCM ve *özmeyve* özniteliklerinin ayrı sınıflandırıcılarda ele alındığı algoritmalarda kullanılmak üzere olgunlaşmamış şeftali meyvesini ayırt etmede istatistiksel olarak anlamlı özniteliklerin bulunması amacıyla ikili lojistik regresyon analizi yapılmıştır. Regresyon modelinin bağımlı değişkeni arka plan ve meyveyi temsil eden sınıf etiketleridir. Bu değişkenin kategorileri '1' ve '0' olarak sırasıyla pozitif ve negatif örnekleri temsil etmektedir. Mevcut çok sayıdaki bağımsız değişken (GLCM öznitelikleri) arasından istatistiksel olarak en anlamlılarını belirlemek amacıyla korelasyon matrisi SPSS paket programıyla elde edilmiştir. Korelasyon matrisinde bağımlı değişken ile yüksek korelasyonlu, bağımsız değişkenler ile düşük korelasyonlu bağımsız değişkenler belirlenmiştir. Bu değişkenler tek tek kullanılarak bir bağımlı bir bağımsız değişkenden oluşan çok sayıda ikili lojistik regresyon modelleri tahmin edilmiştir. Bu sayede bir bağımlı, birden çok bağımsız değişkenden oluşan ikili lojistik regresyon modeline aday en önemli bağımsız değişkenler belirlenmiştir. Bir bağımlı, birden çok bağımsız değişkenden oluşan çeşitli ikili lojistik regresyon model denemeleri sonucunda en uygun model belirlenmiştir.

Bu çalışma kapsamında geliştirilerek denemeleri yapılan *özmeyve* ve GLCM özniteliklerinin birbirini takip eden sınıflandırıcılar olarak ele alındığı algoritmalarda doku ayırımı yapan sınıflandırıcıların eğitilmesinde bu analizle belirlenen GLCM özniteliklerinden yararlanılmıştır. Analize ait bulgular ve belirlenen öznitelik seti, bulgular kısmında verilmiştir.

3.2.8.2. Özmeyve ve Gabor doku özniteliklerinin birlikte oluşturduğu set

Önceki bir çalışmada Kurtulmuş ve ark. (2011), olgunlaşmamış portakalları doğal ortamda alınmış renkli görüntülerde saptamak üzere *özmeyve* ve dairesel Gabor doku özniteliklerini kullanmışlardır. Olgunlaşmamış portakalları renkli görüntülerde saptama görevinin bu çalışmaya benzer yönleri düşünülerek, olgunlaşmamış şeftaliyi saptamak amacıyla yararlanılan öznitelik setlerinden biri olarak bu öznitelik seti kullanılmıştır. Bu öznitelik seti, dairesel Gabor doku özniteliği, HSI renk uzayında S bileşeninden

hesaplanan *özmeyve* özneliği ve I bileşeninden hesaplanan *özmeyve* özneliğinden oluşmaktadır.

3.2.8.3. Şeftali tanımada anlamlı özneliklerin tespiti için SAS adımlı diskriminant (STEPDISC) analizi

Bu çalışmada *özmeyve* ve GLCM doku özneliklerinin birlikte değerlendirildiği algoritmalarda kullanılmak üzere meyve ve arka planı ayırmada ayırt edici öznelik setinin oluşturulmasında kullanılan bir yöntem de SAS STEPDISC olarak ifade edilen adımlı diskriminant analizidir. Bu yöntemde değişken seçimi ileriye doğru veya geriye doğru olmak üzere iki şekilde de yapılabilir. İleriye doğru seçimde ilk başta modelde hiçbir değişken yer almaz. Her adımda modele anlamlı bir değişken ilave edilir. Geriye doğru seçimde ise ilk başta modelde bütün değişkenler yer alır. Her adımda modelden anlamsız bir değişken çıkarılır. Her iki durumda da modele ilave edilecek veya modelden çıkarılacak değişkene karar vermede F testi veya kısmi korelasyon katsayısı dikkate alınır. Bu çalışmada STEPDISC analizini uygularken ileriye doğru seçim yöntemi kullanılmıştır. Analiz sonuçları bulgular kısmında sunulmuştur.

3.2.8.4. Deneme-yanılma yoluyla belirlenen öznelik seti

Bu çalışma kapsamında geliştirilen *özmeyve* ve GLCM doku özneliklerinin birlikte değerlendirildiği algoritmalarda kullanılan öznelik setlerinden birisi de (STEPDISC analiziyle belirlenen öznelik seti dışında), eğitim seti görüntüleri üzerinde deneme yanılma yoluyla GLCM ve *özmeyve* özneliklerinin çeşitli eşleşmelerinin performanslarının gözlemlenmesi ile elde edilmiştir. Bu yolla istatistiksel yöntem dışında kullanıcı tecrübesiyle belirlenen öznelik setinin performanslarının ortaya konulması hedeflenmiştir. Sınıflandırıcıların eğitiminde kullanılan öznelikler, 4 adet GLCM özneliği (kontrast, homojenlik, toplam ortalama, korelasyon bilgi ölçüsü 1) ve gri seviye *özmeyve* özneliği olmak üzere 5 adet özneliktir.


3.2.9. Çoklu saptamaların tekilleştirilmesi ve meyve sayımı

Bu çalışmada kullanılan sınıflandırıcıların meyve tarama ve alt-pencereleri sınıflandırma işlemlerinde aynı meyveye karşılık gelen birbirine çok yakın aday alt-pencereleri meyve olarak sınıflandırmaları nedeniyle aynı meyveye ait çoklu saptamalar

gerçekleşmiştir. Aynı meyveye karşılık gelen bu çoklu saptamaların tekilleştirilmesi için bir blob analizi yönteminden yararlanılmıştır. Bu amaçla denemelerde sınıflandırıcıların her bir saptama merkezi bir ikili görüntü üzerine kullanılan eğitim setine uygun olarak bulunan 20 piksel çapında bloblarla markalanmıştır. Bu bloblar içi dolu daireler ile oluşturmuştur. Bir görüntüye ait meyve tarama işlemi sonlandığında oluşan bu ikili görüntü üzerinde blob analizi yapılmış, temas eden bloblardan oluşan yeni bloblar tek bir meyve olarak kabul edilmiştir. Bulunan meyveleri temsil eden yeni blobların ana eksenlerinin orta noktaları meyve merkezleri olarak belirlenmiştir. Blob analizi yöntemiyle bu bloblar sayılarak görüntüdeki meyve sayıları ortaya konulmuştur. Geliştirilen bu yönteme ait sonuç görüntüleri çalışmanın bulgular ve tartışma kısmında verilmiştir.

3.2.10. Geliştirilen algoritmaların genel yapısı, eğitim ve test setleri üzerinde yapılan denemeler

Bu çalışmada geliştirilen algoritmaların eğitimleri; meyve tarama ve kullanılan öznelik çıkarma işlemlerinde kullanılan eşik parametrelerin belirlenmesi, özneliklerin eğitim setinden kırılarak oluşturulan örnekler üzerinde hesaplanması ve normalizasyonu ile eğitim verisinin oluşturulması işlemlerini kapsamaktadır. Ayrıca meyve ve arka plan alt-pencerelerini ayırmada istatistiksel olarak etkili öznelik gruplarının oluşturulması için SPSS ve SAS programlarıyla yapılan analizler algoritma eğitimi kapsamındadır. Algoritma eğitimleri tamamlandıktan sonra eğitim ve test setleri üzerinde meyve saptama denemeleri gerçekleştirilmiştir. Genel olarak geliştirilen algoritmalar bir renkli görüntüyü alıp yeniden boyutlandırma ve aydınlanma zenginleştirilmesi gibi ön işlemler uygulamakta, kullanılan meyve tarama yöntemine göre sırasıyla alt-pencereleri çıkararak algoritmanın çeşidine göre o alt-pencerenin özneliklerini hesaplamakta ve önceden eğitilmiş sınıflandırıcıyı kullanarak sınıflandırmaktadır. Algoritmaların meyve olarak sınıflandırdığı alt-pencereler blob analiziyle tekilleştirilip meyve sayıları tespit edilmektedir. Çalışmada geliştirilen her algoritmanın akış diyagramları bireysel olarak sunulmuş olsa da geliştirilen algoritmaların genel işleyişleri Şekil 3.17’de görülmektedir.



Şekil 3.17. Çalışmada geliştirilen algoritmaların genel işleyişleri

Denemelerde öznitelikler hesaplanarak ayrıntıları bundan önceki kısımlarda açıklanan 7 farklı yapay sınıflandırıcı eğitilerek denenmiştir. Farklı meyve tarama yöntemleri, farklı öznitelik birleşimleri, farklı yapay sınıflandırıcılarının kullanımıyla değişik algoritmalar türetilmiş, eğitim ve test setleri üzerinde denemeler gerçekleştirilmiştir. Geliştirilen algoritmaların performansları karşılaştırılmıştır.

Çizelge 3.2’de eğitim ve test setlerinde denemeleri yapılan GLCM doku ve özmeve özniteliklerinin karar verici olarak kademeli değerlendirildiği algoritmalar özetlenmiştir.

Çizelge 3.2. Eğitim ve test setlerinde denemeleri yapılan GLCM doku ve özmeve özniteliklerinin karar verici olarak kademeli değerlendirildiği algoritmalar

Görüntü tarama yöntemi	Öznitelikler	Sınıflandırıcı
1	GLCM (ikili lojistik regresyon), özmeve	Diskriminant analizi
1	GLCM (ikili lojistik regresyon), özmeve	K-en-yakın komşular
1	GLCM (ikili lojistik regresyon), özmeve	Sınıflandırma ağacı
1	GLCM (ikili lojistik regresyon), özmeve	Naive Bayes
1	GLCM (ikili lojistik regresyon), özmeve	Regresyon Ağacı
1	GLCM (ikili lojistik regresyon), özmeve	YSA
1	GLCM (ikili lojistik regresyon), özmeve	SVM
2	GLCM (ikili lojistik regresyon), özmeve	Diskriminant analizi
2	GLCM (ikili lojistik regresyon), özmeve	K-en-yakın komşular

Çizelge 3.2. Eğitim ve test setlerinde denemeleri yapılan GLCM doku ve özmeyve özniteliklerinin karar verici olarak kademeli değerlendirildiği algoritmalar (devam)

Görüntü tarama yöntemi	Öznitelikler	Sınıflandırıcı
2	GLCM (ikili lojistik regresyon), <i>özmeyve</i>	Sınıflandırma ağacı
2	GLCM (ikili lojistik regresyon), <i>özmeyve</i>	Naive Bayes
2	GLCM (ikili lojistik regresyon), <i>özmeyve</i>	Regresyon Ağacı
2	GLCM (ikili lojistik regresyon), <i>özmeyve</i>	YSA
2	GLCM (ikili lojistik regresyon), <i>özmeyve</i>	SVM
3	GLCM (ikili lojistik regresyon), <i>özmeyve</i>	Diskriminant analizi
3	GLCM (ikili lojistik regresyon), <i>özmeyve</i>	K-en-yakın komşular
3	GLCM (ikili lojistik regresyon), <i>özmeyve</i>	Sınıflandırma ağacı
3	GLCM (ikili lojistik regresyon), <i>özmeyve</i>	Naive Bayes
3	GLCM (ikili lojistik regresyon), <i>özmeyve</i>	Regresyon Ağacı
3	GLCM (ikili lojistik regresyon), <i>özmeyve</i>	YSA
3	GLCM (ikili lojistik regresyon), <i>özmeyve</i>	SVM

Çizelge 3.3’de bu çalışmada geliştirilerek eğitim ve test setlerinde denemeleri yapılan doku ve *özmeyve* özniteliklerinin bir arada değerlendirildiği algoritmalar listelenmiştir.

Çizelge 3.3. Eğitim ve test setlerinde denemeleri yapılan doku ve *özmeyve* özniteliklerinin bir arada değerlendirildiği algoritmalar

Görüntü tarama yöntemi	Öznitelik seti	Sınıflandırıcı
1	Gabor, <i>özmeyve</i>	Diskriminant analizi
1	Gabor, <i>özmeyve</i>	K-en-yakın komşular
1	Gabor, <i>özmeyve</i>	Sınıflandırma ağacı
1	Gabor, <i>özmeyve</i>	Naive Bayes
1	Gabor, <i>özmeyve</i>	Regresyon ağacı
1	Gabor, <i>özmeyve</i>	YSA
1	Gabor, <i>özmeyve</i>	SVM
2	Gabor, <i>özmeyve</i>	Diskriminant analizi
2	Gabor, <i>özmeyve</i>	K-en-yakın komşular
2	Gabor, <i>özmeyve</i>	Sınıflandırma ağacı
2	Gabor, <i>özmeyve</i>	Naive Bayes
2	Gabor, <i>özmeyve</i>	Regresyon Ağacı
2	Gabor, <i>özmeyve</i>	YSA
2	Gabor, <i>özmeyve</i>	SVM
3	Gabor, <i>özmeyve</i>	Diskriminant analizi
3	Gabor, <i>özmeyve</i>	K-en-yakın komşular
3	Gabor, <i>özmeyve</i>	Sınıflandırma ağacı
3	Gabor, <i>özmeyve</i>	Naive Bayes
3	Gabor, <i>özmeyve</i>	Regresyon ağacı

Çizelge 3.3. Eğitim ve test setlerinde denemeleri yapılan doku ve özmeyve özniteliklerinin bir arada değerlendirildiği algoritmalar (devam)

Görüntü tarama yöntemi	Öznitelik seti	Sınıflandırıcı
3	Gabor, <i>özmeyve</i>	YSA
3	Gabor, <i>özmeyve</i>	SVM
1	GLCM(stepdisc), <i>özmeyve</i>	Diskriminant analizi
1	GLCM(stepdisc), <i>özmeyve</i>	K-en-yakın komşular
1	GLCM(stepdisc), <i>özmeyve</i>	Sınıflandırma ağacı
1	GLCM(stepdisc), <i>özmeyve</i>	Naive Bayes
1	GLCM(stepdisc), <i>özmeyve</i>	Regresyon ağacı
1	GLCM(stepdisc), <i>özmeyve</i>	YSA
1	GLCM(stepdisc), <i>özmeyve</i>	SVM
2	GLCM(stepdisc), <i>özmeyve</i>	Diskriminant analizi
2	GLCM(stepdisc), <i>özmeyve</i>	K-en-yakın komşular
2	GLCM(stepdisc), <i>özmeyve</i>	Sınıflandırma ağacı
2	GLCM(stepdisc), <i>özmeyve</i>	Naive Bayes
2	GLCM(stepdisc), <i>özmeyve</i>	Regresyon ağacı
2	GLCM(stepdisc), <i>özmeyve</i>	YSA
2	GLCM(stepdisc), <i>özmeyve</i>	SVM
3	GLCM(stepdisc), <i>özmeyve</i>	Diskriminant analizi
3	GLCM(stepdisc), <i>özmeyve</i>	K-en-yakın komşular
3	GLCM(stepdisc), <i>özmeyve</i>	Sınıflandırma ağacı
3	GLCM(stepdisc), <i>özmeyve</i>	Naive Bayes
3	GLCM(stepdisc), <i>özmeyve</i>	Regresyon ağacı
3	GLCM(stepdisc), <i>özmeyve</i>	YSA
3	GLCM(stepdisc), <i>özmeyve</i>	SVM
1	GLCM(deneme-yanılma), <i>özmeyve</i>	Diskriminant analizi
1	GLCM(deneme-yanılma), <i>özmeyve</i>	K-en-yakın komşular
1	GLCM(deneme-yanılma), <i>özmeyve</i>	Sınıflandırma ağacı
1	GLCM(deneme-yanılma), <i>özmeyve</i>	Naive Bayes
1	GLCM(deneme-yanılma), <i>özmeyve</i>	Regresyon ağacı
1	GLCM(deneme-yanılma), <i>özmeyve</i>	YSA
1	GLCM(deneme-yanılma), <i>özmeyve</i>	SVM
2	GLCM(deneme-yanılma), <i>özmeyve</i>	Diskriminant analizi
2	GLCM(deneme-yanılma), <i>özmeyve</i>	K-en-yakın komşular
2	GLCM(deneme-yanılma), <i>özmeyve</i>	Sınıflandırma ağacı
2	GLCM(deneme-yanılma), <i>özmeyve</i>	Naive Bayes
2	GLCM(deneme-yanılma), <i>özmeyve</i>	Regresyon ağacı
2	GLCM(deneme-yanılma), <i>özmeyve</i>	YSA
2	GLCM(deneme-yanılma), <i>özmeyve</i>	SVM
3	GLCM(deneme-yanılma), <i>özmeyve</i>	Diskriminant analizi
3	GLCM(deneme-yanılma), <i>özmeyve</i>	K-en-yakın komşular
3	GLCM(deneme-yanılma), <i>özmeyve</i>	Sınıflandırma ağacı


Çizelge 3.3. Eğitim ve test setlerinde denemeleri yapılan doku ve özmeyve özniteliklerinin bir arada değerlendirildiği algoritmalar (devam)

Görüntü tarama yöntemi	Öznitelik seti	Sınıflandırıcı
3	GLCM(deneme-yanılma), <i>özmeyve</i>	Naive Bayes
3	GLCM(deneme-yanılma), <i>özmeyve</i>	Regresyon ağacı
3	GLCM(deneme-yanılma), <i>özmeyve</i>	YSA
3	GLCM(deneme-yanılma), <i>özmeyve</i>	SVM


3.2.10.1. Özmeyve ve GLCM özniteliklerinin kademeli değerlendirildiği algoritmalar

Çalışmada kapsamında geliştirilen bu algoritma türlerinde ikili lojistik regresyon analizi sonucu elde edilen GLCM doku öznitelik seti kullanılarak eğitilmiş 7 adet sınıflandırıcı ilk olarak alt pencereyi dokusuna göre sınıflandırmakta, daha sonra doku sınıflamasında meyve olarak değerlendirilen alt-pencerelerin *özmeyve* öznitelikleri hesaplanmaktadır. *Özmeyve* özniteliklerinin eşiklenmeleri sonucu alt-pencereler son olarak sınıflandırılmışlardır. Burada GLCM doku ve *özmeyve* öznitelikleri sırayla birbirini izleyen seri bağlanmış karar vericiler olarak düşünülebilir. Algoritmanın herhangi bir sınıflandırma adımında sınıflandırıcının negatif cevabı algoritmanın durarak bir sonraki aday alt-pencereden yeniden başlamasına neden olmaktadır. Algoritmaların meyve olarak sınıflandırdığı alt-pencereler blob analiziyle tekilleştirilip, meyve sayıları tespit edilmektedir. Eğitim ve test seti üzerinde gerçekleştirilen denemeler, çalışma kapsamında geliştirilen her üç görüntü tarama yöntemi için gerçekleştirilmiştir. Doku sınıflandırması için kullanılan GLCM doku öznitelikleri de 7 adet sınıflandırıcıyla ayrı ayrı denenmiştir.


Şekil 3.18'de görüntü tarama yöntemi 1 kullanımıyla GLCM ve *özmeyve* özniteliklerinin birbirini takip eden sınıflandırıcılar olarak ele alındığı algoritmaların akış diyagramı verilmiştir. Şekil 3.19 ve 3.20'de de sırasıyla görüntü tarama yöntemi 2 ve 3 kullanımıyla GLCM ve *özmeyve* özniteliklerinin birbirini takip eden sınıflandırıcılar olarak ele alındığı algoritmaların akış diyagramı verilmiştir. Şekillerde doku sınıflandırmasında kullanılan 7 farklı sınıflandırıcının kullanıldığı algoritmalar tek bir akış diyagramında ifade edilmiştir.



Şekil 3.18. Görüntü tarama yöntemi 1 ile GLCM ve özmeve özneliklerinin kademeli değerlendirildiği algoritmaların akış diyagramı



Şekil 3.19. Görüntü tarama yöntemi 2 ile GLCM ve özmeve özneliklerinin kademeli değerlendirildiği algoritmaların akış diyagramı




Şekil 3.20. Görüntü tarama yöntemi 3 ile GLCM ve özmeve özneliklerinin kademeli değerlendirildiği algoritmaların akış diyagramı


3.2.10.2. Özmeyve ve Gabor doku özniteliklerinin birlikte değerlendirildiği algoritmalar

Olgunlaşmamış şeftali meyvesini bitkinin doğal ortamında renkli görüntüler üzerinde saptayacak algoritmaların geliştirilmesi kapsamında çıkarılan öznitelikler ile tek bir sınıflandırıcının eğitimi de denenmiştir. *Özmeyve* ve Gabor doku özniteliklerinin algoritmada birlikte değerlendirildiği algoritmalarda geliştirilen meyve tarama yöntemleri ve yedi adet sınıflandırıcı kullanılmıştır. Bu algoritmalarda kullanılan yapay sınıflandırıcılar diskriminant analizi, K-en-yakın komşu, naive Bayes, regresyon ağaçları, sınıflandırma ağaçları, YSA ve SVM'dir. Meyve saptama denemelerinde görüntü tarama yöntemleriyle elde edilen alt-pencereler, eğitilmiş sınıflandırıcılar tarafından meyve veya arka plan olarak sınıflandırılmıştır. Kullanılan bu algoritma türünde öznitelik seti Gabor doku özniteliği, HSI renk uzayında S bileşeninden hesaplanan *özmeyve* özniteliği ve I bileşeninden hesaplanan *özmeyve* özniteliğinden oluşmaktadır. Sınıflandırıcıların karar verme adımından sonra çoklu saptamaların tekilleştirilmesi ve meyve sayımı daha önce açıklanan algoritmalarınkiyle aynıdır.

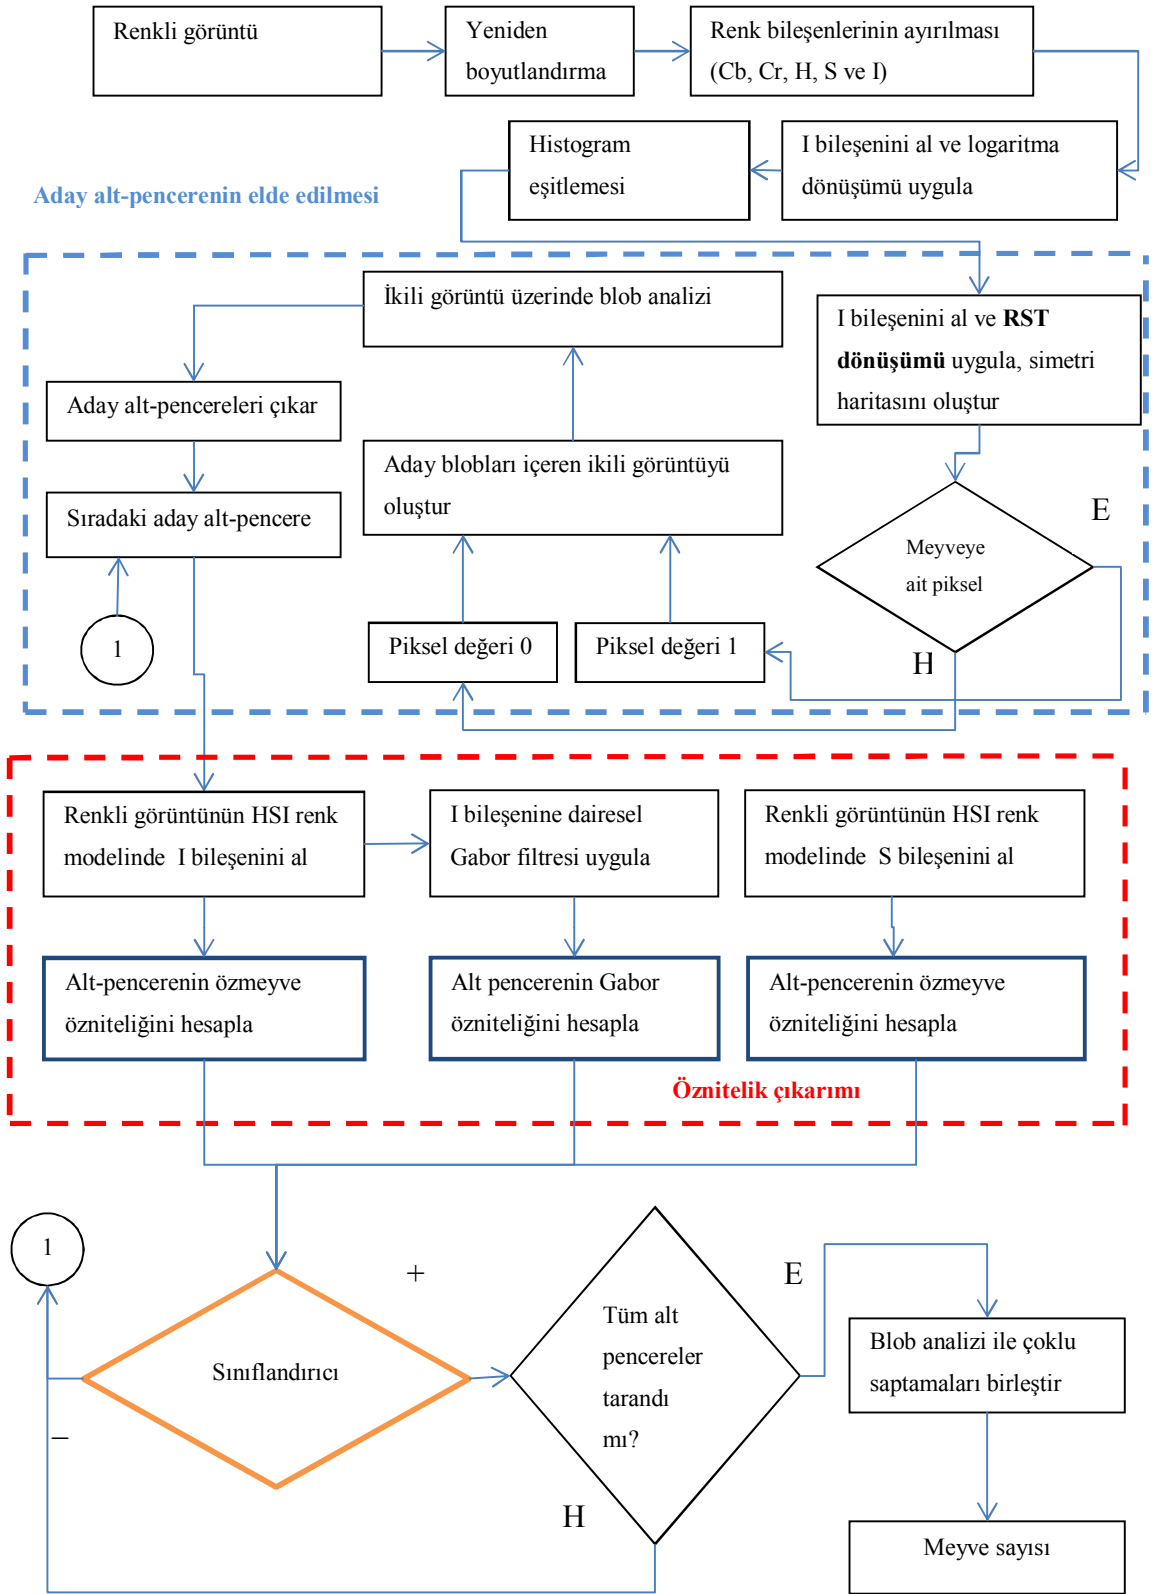
Şekil 3.21'de görüntü tarama yöntemi 1 ile Gabor ve *özmeyve* özniteliklerinin tek bir sınıflandırıcıda kullanıldığı algoritmaların akış diyagramı verilmiştir. Şekil 3.22 ve 3.23'da da görüntü tarama yöntemi 2 ve 3'ün kullanımıyla Gabor ve *özmeyve* özniteliklerinin tek bir sınıflandırıcıda kullanıldığı algoritmaların akış diyagramları görülmektedir. Şekillerde 7 farklı sınıflandırıcının kullanıldığı algoritmalar tek bir akış diyagramında ifade edilmiştir.



Şekil 3.21. Görüntü tarama yöntemi 1 ile özneyve ve Gabor doku özniteliklerinin birlikte değerlendirildiği algoritmaların akış diyagramı



Şekil 3.22. Görüntü tarama yöntemi 2 ile özneyve ve Gabor doku özneliklerinin birlikte değerlendirildiği algoritmaların akış diyagramı




Şekil 3.23. Görüntü tarama yöntemi 3 ile özmeve ve Gabor doku özneliklerinin birlikte değerlendirildiği algoritmaların akış diyagramı


3.2.10.3. STEPDISC analiziyle belirlenen özniteliklerin birlikte değerlendirildiği algoritmalar

Bu algoritma türlerinde *özmeyve* ve GLCM doku özniteliklerinin birlikte değerlendirildiği algoritmalarla geliştirilen meyve tarama yöntemleri ve yedi adet sınıflandırıcı kullanılmıştır. Sınıflandırıcıların eğitiminde kullanılan öznitelikler, SAS STEPDISC analizi ile belirlenen *özmeyve* ve GLCM özniteliklerinden oluşan 9 adet özniteliktir. Bu algoritmalarla kullanılan yapay sınıflandırıcılar diskriminant analizi, K-en-yakın komşu, naive Bayes, regresyon ağaçları, sınıflandırma ağaçları, YSA ve SVM'dir. Meyve saptama denemelerinde görüntü tarama yöntemleriyle elde edilen alt-pencereler, eğitilmiş sınıflandırıcılar tarafından meyve veya arka plan olarak sınıflandırılmıştır. Sınıflandırıcıların karar verme adımından sonra çoklu saptamaların tekilleştirilmesi ve meyve sayımı daha önce açıklanan algoritmalarınkiyle aynıdır.


Şekil 3.24'te görüntü tarama yöntemi 1 ile STEPDISC analiziyle belirlenen özniteliklerin tek bir sınıflandırıcıda kullanıldığı algoritmaların akış diyagramı verilmiştir. Şekil 3.25 ve 3.26'de ise sırasıyla görüntü tarama yöntemi 2 ve 3 ile STEPDISC analiziyle belirlenen özniteliklerin tek bir sınıflandırıcıda kullanıldığı algoritmaların akış diyagramları görülmektedir. Şekillerde 7 farklı sınıflandırıcının kullanıldığı algoritmalar tek bir akış diyagramında ifade edilmiştir.



Şekil 3.24. Görüntü tarama yöntemi 1 ile STEPDISC analiziyle belirlenen özneliklerin birlikte değerlendirildiği algoritmaların akış diyagramı



Şekil 3.25. Görüntü tarama yöntemi 2 ile STEPDISC analiziyle belirlenen özniteliklerin birlikte değerlendirildiği algoritmaların akış diyagramı



Şekil 3.26. Görüntü tarama yöntemi 3 ile STEPDISC analiziyle belirlenen özniteliklerin birlikte değerlendirildiği algoritmaların akış diyagramı

3.2.10.4. Deneme-yanılma yoluyla belirlenen özniteliklerin birlikte değerlendirildiği algoritmalar

Bu algoritma türlerinde *özmeyve* ve GLCM doku öznitelikleri birlikte değerlendirilerek geliştirilen meyve tarama yöntemleri ve yedi adet sınıflandırıcı kullanılmıştır. Sınıflandırıcıların eğitiminde kullanılan öznitelikler, 4 adet GLCM özniteliği (kontrast, homojenlik, toplam ortalama, korelasyon bilgi ölçüsü 1) ve gri seviye *özmeyve* özniteliği olmak üzere 5 adet özniteliktir. Bu algoritmalarda kullanılan yapay sınıflandırıcılar diskriminant analizi, K-en-yakın komşu, naive Bayes, regresyon ağaçları, sınıflandırma ağaçları, YSA ve SVM'dir. Meyve saptama denemelerinde görüntü tarama yöntemleriyle elde edilen alt-pencereler, eğitilmiş sınıflandırıcılar tarafından meyve veya arka plan olarak sınıflandırılmıştır. Sınıflandırıcıların karar verme adımından sonra çoklu saptamaların tekilleştirilmesi ve meyve sayımı daha önce açıklanan algoritmalarinkine aynıdır. Çalışmada bu algoritma türlerine ait akış diyagramları sunulmamıştır. Bunun nedeni, bu algoritmalarındaki farklılığın, kısım 3.2.10.3'de verilen algoritmaların öznitelik setinde yer alan GLCM özniteliklerinden ibaret olmasıdır.

3.2.11. Algoritmaların performans değerlendirmeleri

Çalışmada geliştirilen algoritmaların performanslarını değerlendirmek amacıyla görüntülerdeki saptama sayıları üzerinden başarıyla saptanan, yanlış saptanan ve saptanamayan meyve oranları hesaplanmıştır. Görüntülerdeki meyvelerin sayımında kesin olarak meyve olup olmadığı kestirilemeyecek kadar kaplanmış nesnelere arka plan olarak değerlendirilmiştir. Başarıyla saptanan meyve oranı eşitlik 3.70 ile tanımlanan başarıyla sınıflandırılmış ve bulunması gereken meyveleri içeren alt-pencere sayısının görüntüde gerçekte bulunan toplam meyve sayısına yüzde oranıdır. Yanlış saptanan meyve oranı ise eşitlik 3.71'de ifade edildiği üzere meyve içermeyen alt-pencere sayısının algoritmanın toplam saptama sayısı üzerine oranıdır. Herhangi bir alt-pencere tarafından saptanmamış meyve sayısının görüntüde bulunan toplam meyve sayısına oranıdır. Ayrıca eğitim ve test seti üzerinde gerçekleştirilen denemelerde algoritmaların performans sonuçları, şeftali ağaçlarının güneşli ve gölgede kalan kısımlarından alınmış görüntüler için ayrı ayrı değerlendirilmiştir.

$$\text{Başarıyla saptanan meyve oranı} = \frac{\text{başarıyla saptanan meyve sayısı}}{\text{toplam gerçek meyve sayısı}} \quad (3.70)$$

$$\text{Yanlış saptanan meyve oranı} = \frac{\text{yanlış saptanan meyve sayısı}}{\text{başarıyla saptanan} + \text{yanlış saptanan}} \quad (3.71)$$

$$\text{Saptanamayan meyve oranı} = \frac{\text{saptanamayan meyve sayısı}}{\text{toplam gerçek meyve sayısı}} \quad (3.72)$$

Bu çalışmada odak noktası algoritma performansları olmasına rağmen, denemelerde algoritmaların işlem süreleri de ölçülerek algoritmalar arası karşılaştırma amacıyla sunulmuştur. Denemeler, algoritma geliştirme aşamalarında oldukça kullanışlı araçlar sağlayan Matlab geliştirme ortamında yürütülmüştür. Uygulamada C/C++ gibi daha düşük seviyeli programlama dilleriyle ve daha profesyonel bellek ayırma iyileştirmeleriyle daha düşük işlem süreleri elde edilebilir.

4. BULGULAR ve TARTIŞMA

4.1. Aydınlanma Değişimleri ve Zenginleştirilmesi Sonuçları

Bu çalışmada görüntüler farklı aydınlanma koşullarında alınmıştır. Farklı aydınlanma koşullarında ve dış ortamda sayısız değişkenin etkilediği görüntülerin hepsinin aynı görüntü işleme adımlarıyla ele alınmanın oldukça zor bir görev olduğu görülmüştür. Çalışmada farklı aydınlanma koşullarının etkilerini temsil edebilmek için görüntüler şeftali ağaçlarının güneşli ve gölgede kalan kısımlarından alınmıştır. Alınan bu görüntülere ait birer örnek Şekil 4.1’de görülmektedir.



a) Şeftali ağacının güneşli tarafı



b) Şeftali ağacının gölge tarafı

Şekil 4.1. Farklı aydınlanma koşullarındaki görüntüler

Çalışmada kullanılan aydınlanma zenginleştirme yöntemi görüntülerdeki karanlık bölgeleri açmıştır. Kullanılan logaritma dönüşümü ve histogram eşitlemesine ait sonuç görüntüsü Şekil 4.2’de görülmektedir. Şekilde orijinal görüntüde bulunan karanlık bölgeler görüntü zenginleştirilmesi sonucu daha belirgindirler. Karanlık bölgelerdeki gizli detaylar zenginleştirilmiş görüntüde açığa çıkarılmıştır.



a) Orijinal görüntü




b) Görüntü zenginleştirilmesi sonrası


Şekil 4.2. Bu çalışmada kullanılan görüntü zenginleştirmesinin etkisi: logaritma dönüşümü ve histogram eşitleme kullanımının öncesi (a) ve sonrası (b).

4.2. Renk Histogramı Esaslı Görüntü İkileştirme Sonuçları

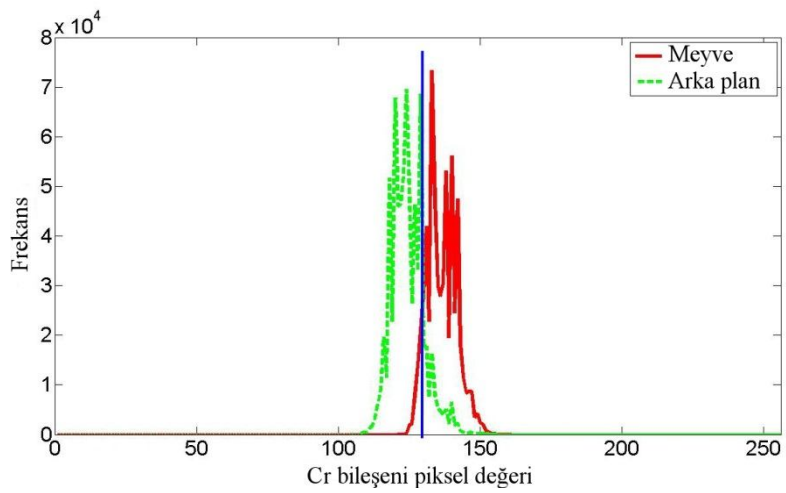
Bu çalışmada geliştirilen görüntü tarama yöntemleri 1 ve 2, histogram esaslı eşik belirleme sonucu oluşan ikili görüntüleri esas almışlardır. Şekil 4.3'te genç şeftali ve arka plan örneklerinden oluşturulmuş mozaik görüntülerin eşik değerini araştırmak için elde edilen H, Cb ve Cr histogramları görülmektedir. Şekillerde meyve örnekleri renk dağılımları sürekli kırmızı çizgi ile ifade edilirken, arka plan örnekleri renk dağılımları kesikli yeşil çizgiyle temsil edilmiştir. Grafiklerde H, Cb ve Cr renk bileşenleri için tespit edilen eşik değerleri mavi ayırma çizgisi ile gösterilmiştir. Bu renk bileşenleri için tespit edilen eşik değerleri H, Cb ve Cr bileşenleri için sırasıyla 52, 120 ve 130'dur. Bu eşik değerlerinin kullanımıyla elde edilen ikili görüntülere ait örnekler ise Şekil 4.4'te görülmektedir.



a) Meyve ve arka plan mozaik görüntülerin H bileşenine ait histogram eğrileri




b) Meyve ve arka plan mozaik görüntülerin Cb bileşenine ait histogram eğrileri



c) Meyve ve arka plan mozaik görüntülerin Cr bileşenine ait histogram eğrileri

Şekil 4.3. Meyve ve arka plan mozaik görüntülerin histogram eğrileri



Şekil 4.4. Eşikleme yoluyla elde edilen ikili görüntülere ait örnekler

4.3. Dairesel Gabor Doku Analizi Sonuçları


Çalışmada dairesel Gabor doku analizi için farklı ölçeklerde elde edilen dairesel Gabor filtreleme işlemleri sonuçları deneme seti üzerinde görsel olarak incelenerek doku ayırımı için en etkili ölçek ve frekans parametreleri araştırılmıştır. Şekil 4.5'te frekans olarak 2 değeri alınarak hesaplanmış Gabor filtresinin birinci, üçüncü ve beşinci ölçeklerinde elde edilmiş sonuç görüntüleri verilmiştir. Şekilde meyve dokusunun görsel olarak en iyi algılandığı ölçeğin üçüncü ölçek olduğu görülmektedir. Meyve tarama denemelerinde dairesel Gabor özneteliğinin hesaplanmasında üçüncü ölçekten yararlanılmıştır.



a) Orijinal renkli görüntü



b) Birinci ölçekte Gabor filtresi çıktısı



c) Üçüncü ölçekte Gabor filtresi çıktısı



d) Beşinci ölçekte Gabor filtresi çıktısı

Şekil 4.5. Orijinal renkli görüntü ve farklı ölçeklerde Gabor filtresi uygulanmış versiyonları

4.4. İkili Lojistik Regresyon Kullanılarak GLCM Özneliklerinin Olgunlaşmamış Şeftaliyi Ayırt Etmede İstatistiksel Anlamlılık Analizi Bulguları

Çalışmada GLCM ve *özmeyve* özneliklerinin ayrı sınıflandırıcılarda ele alındığı algoritmalarda kullanılmak üzere olgunlaşmamış şeftali meyvesini ayırt etmede istatistiksel olarak anlamlı özneliklerin bulunması amacıyla ikili lojistik regresyon analizi yapılarak belirlenen en uygun model, Çizelge 4.1’de verilmiştir.

Çizelge 4.1. İkili Lojistik Regresyon Model Tahmin Sonuçları

		B	Standart Hata	Wald	SD	p	Exp(B)
Adım 1	Kontrast	53,715	28,079	3,660	1	0,056**	2,129E23
	Yığılım belirginliği	689,902	140,875	23,983	1	0,000*	4,176E299
	Varyans farkı	27,761	8,836	9,872	1	0,002*	1,138E12
	Korelasyon bilgi ölçüsü 1	38,986	15,092	6,673	1	0,010*	8,541E16
	Korelasyon bilgi ölçüsü 2	239,389	56,881	17,712	1	0,000*	9,232E103
	En büyük korelasyon katsayısı	115,165	49,294	5,458	1	0,019**	1,037E50
	Sabit	-709,297	143,230	24,524	1	0,000*	0,000

Not: * simgesi ile işaretli p değerleri ilgili değişkenin katsayısının yüzde bir anlamlılık düzeyinde ($\alpha=0,01$) istatistikî olarak anlamlı olduğunu göstermektedir. ** simgesi ile işaretli p değerleri ilgili değişkenin katsayısının yüzde beş anlamlılık düzeyinde ($\alpha=0,05$) istatistiksel olarak anlamlı olduğunu göstermektedir. *** simgesi ile işaretli p değerleri ilgili değişkenin katsayısının yüzde on anlamlılık düzeyinde ($\alpha=0,10$) istatistikî olarak anlamlı olduğunu göstermektedir.

Çizelge 4.2’de tahmine edilen ikili lojistik regresyon modelinin R^2 ve model uyum iyiliği görülmektedir.

Çizelge 4.2. Tahmine edilen ikili lojistik regresyon modelinin R^2 ve model uyum iyiliği

	Cox & Snell R^2	Nagelkerke R^2	Hosmer ve Lemeshow Testi		
			Ki-kare	SD	p
MODEL	0,562	0,760	4,394	8	0,820

Cox & Snell ve Nagelkerke R^2 istatistikleri, bağımsız değişkenlerin bağımlı değişkendeki değişimi açıklama gücünün sırasıyla %56.2 ve %76 olduğunu göstermiştir. Hosmer ve Lemeshow istatistiğine ilişkin p değeri ($0,820>0,30$) modelin uyumunun iyi olduğunu göstermektedir.

İkili lojistik regresyon analizi sonucunda Çizelge 4.1’de elde edilen bulgular, meyve dokusu ile arka plan dokusu arasında ayırt edici altı GLCM özneliğinin olduğunu göstermiştir.

4.5. Şeftali Tanımda Anlamlı Özneliklerin Tespiti İçin STEPDISC Analizi Bulguları

Çizelge 4.3’te analiz sonucu belirlenen öznelikler görülmektedir. *Özmeve* ve GLCM doku özneliklerinin birlikte değerlendirildiği algoritmalarda 9 adet öznelikten oluşan bu öznelik seti, sınıflandırıcıların eğitimi ve gerçekleştirilen denemelerde kullanılan settir.

Çizelge 4.3. Stepdisc analizi ile belirlenen öznelikler

Öznelik kodu	Öznelik adı	Kanonik korelasyon*
f23	<i>Özmeve</i>	0,361
f5	Yığılım belirginliği	0,479
f10	Homojenlik	0,489
f18	Entropi farkı	0,568
f2	Kontrast	0,583
f6	Yığılım gölgesi	0,589
f14	Toplam ortalama	0,596
f13	Kareler toplamı	0,602
f1	Oto-korelasyon	0,614

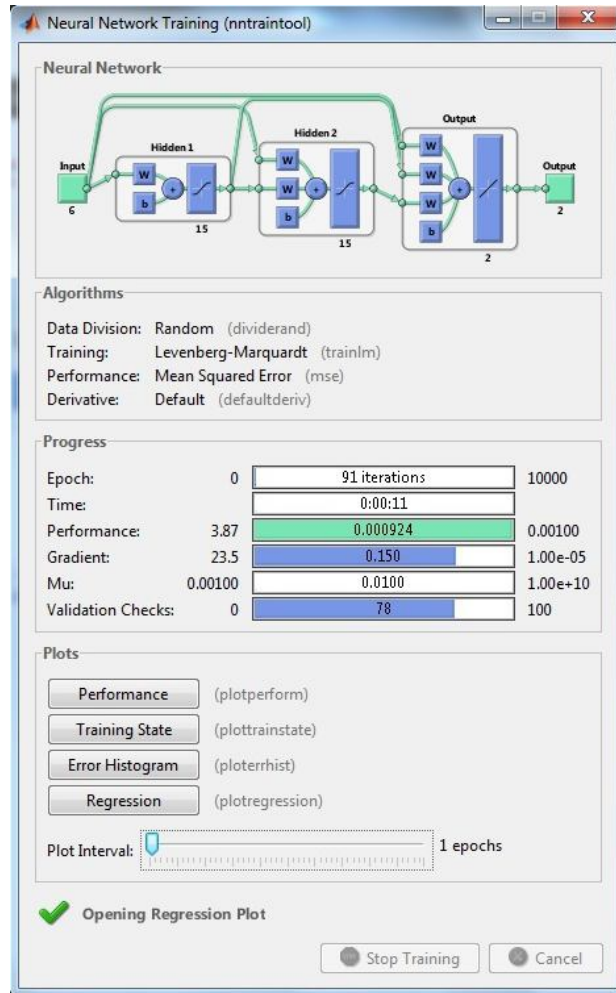
*Çizelgede yer alan kanonik korelasyon değerleri, değişkenin modele dahil olduğu adımda modelde önceden yer alan değişkenlerin oluşturduğu set ile modele ilave edilecek değişken arasındaki korelasyonu ifade etmektedir.

4.6. Çalışmada kullanılan YSA’ların eğitim sonuçları


4.6.1. GLCM özneliklerinin YSA eğitimi

GLCM özneliklerinin ayrı olarak değerlendirildiği algoritmalarda kullanmak üzere oluşturulan ağ yapısı, Matlab YSA eğitimi penceresi şeklinde Şekil 4.6’da görülmektedir. En iyi ağ yapısını bulmak üzere denenen ağlar arasında 2 gizli katmanlı, her bir gizli katmanında 15 adet nöron bulunan ve ‘cascadeforwardnet’ Matlab

fonksiyonu ile üretilen ileri-kademeli ağ yapısı seçilmiştir. İleri kademeli YSA'lar geleneksel ileri-beslemeli ağlara benzemektedir. Bu ağları geleneksel ileri-beslemeli ağlardan ayıran özellik, her katmanla girdi katmanı arasında fazladan bir bağlantı bulundurmasıdır. Ağın gizli katmanlarında aktivasyon fonksiyonları olarak tanjant-sigmoid, çıktı katmanında ise lineer bir fonksiyon kullanılmıştır. Ağın eğitim fonksiyonu Levenberg-Marquardt geri yayımlı (Levenberg-Marquardt backpropagation) fonksiyondur. Ağın eğitimi 91. yinelemede istenen hata değerine (0,001) ulaşılması sonucu durmuştur. Eğitim işlemi 11 saniye sürmüştür. Şekil 4.7'de ağ eğitimine ait performans grafiği görülmektedir.




Şekil 4.6. GLCM özneliklerinin eğitiminde kullanılan YSA'nın Matlab YSA eğitim penceresinde görünümü



Şekil 4.7. GLCM özniteliklerinin eğitiminde kullanılan YSA'nın ağ eğitimine ait performans grafiği

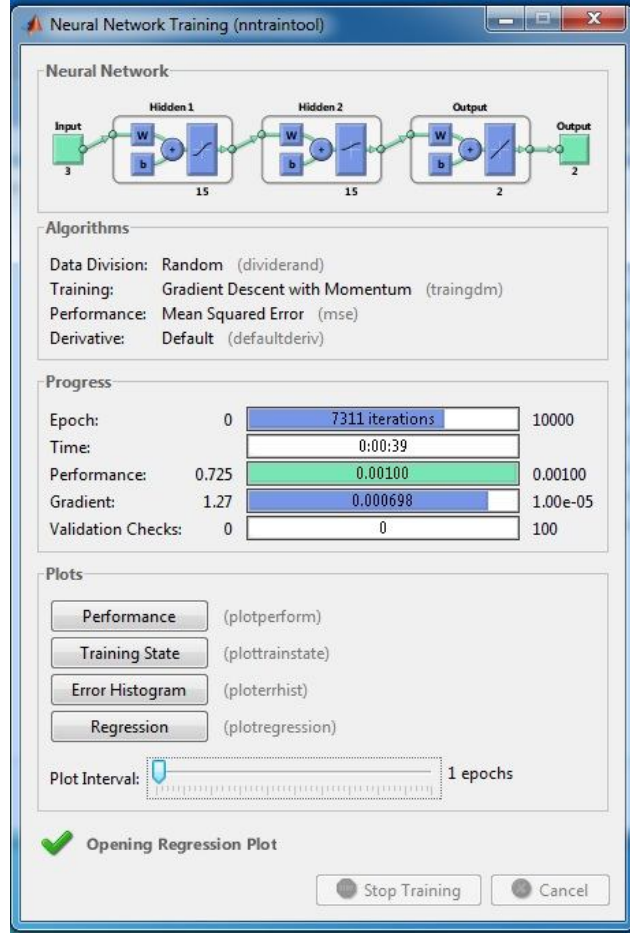
Ağ eğitimine ait performans eğrileri incelendiğinde yeşil sürekli çizgiyle gösterilen doğrulama eğrisinin ve kırmızı sürekli çizgiyle gösterilen test eğrisinin eğitim yinelemeleri (epochs/iteration) boyunca benzer bir hata (MSE) seyri izledikleri görülmektedir. Bu durum, ağ eğitiminde istenmeyen bir durum olan aşırı öğrenme (overfitting)'nin gerçekleşmediğini göstermektedir. Şekil 4.8'de ise ağın çıktılarıyla hedefler (etiketlenen sınıf değerleri) arasındaki ilişkiyi gösteren regresyon eğrileri görülmektedir. Teorik olarak mükemmel bir eğitimde ağın çıktılarıyla hedefler kesin olarak birbirlerine eşittir. Uygulamada ise iyi eğitilmiş bir ağ için bu değerlerin birbirine mümkün olduğunca yakın olması beklenmektedir. Şekil 4.8 incelendiğinde ağ çıktısı ve hedef değerlerin birbirlerine yakınlığını ifade eder şekilde eğitime ait regresyon eğrilerinin 45°'ye yakın olduğu görülmektedir.




Şekil 4.8. GLCM özniteliklerinin eğitiminde kullanılan YSA'nın ağ eğitimine ait regresyon eğrileri

4.6.2. Gabor ve özmeve özniteliklerinin birlikte YSA eğitimi

Gabor ve özmeve özniteliklerinin birlikte değerlendirildiği algoritmalarda kullanılan YSA yapısı ve Matlab öğrenme penceresi Şekil 4.9'da görülmektedir. En iyi YSA yapısını tespit etmek için gerçekleştirilen ağ yapılandırma çalışmaları sonucunda 2 gizli katmanlı, her bir gizli katmanında 15 adet nöron bulunan ve 'feedforwardnet' Matlab fonksiyonu ile üretilen ileri-beslemeli ağ yapısı seçilmiştir. Ağın gizli katmanlarında aktivasyon fonksiyonları olarak sırasıyla tanjant-sigmoid ve logaritmik sigmoid, çıktı katmanında ise linear bir fonksiyon kullanılmıştır. Ağın eğitim fonksiyonu gradyan azalımlı momentum geri yayımlı fonksiyondur. Ağın eğitimi 7311. yinelemede istenen hata değerine (0,001) ulaşılması sonucu durmuştur. Eğitim işlemi 39 saniye sürmüştür. Şekil 4.10'da ağ eğitimine ait performans grafiği görülmektedir.




Şekil 4.9. GLCM özneliklerinin eğitiminde kullanılan ağın Matlab YSA eğitim penceresinde görünümü



Şekil 4.10. Gabor ve özmevye özneliklerinin birlikte eğitiminde kullanılan YSA'nın ağ eğitimine ait performans grafiği


YSA eğitimi performans grafiğinde doğrulama eğrisi ve test eğrisi eğitim yinlemeleri boyunca benzer bir hata (MSE) seyri izlemişlerdir. Bu durum, öğrenmenin istenilen düzeyde gerçekleştiğini göstermiştir. YSA'nın çıktılarıyla hedefler arasındaki ilişkiyi gösteren regresyon eğrileri Şekil 4.11'de görülmektedir. Regresyon ilişkisi (0,99) 1'e oldukça yakındır.



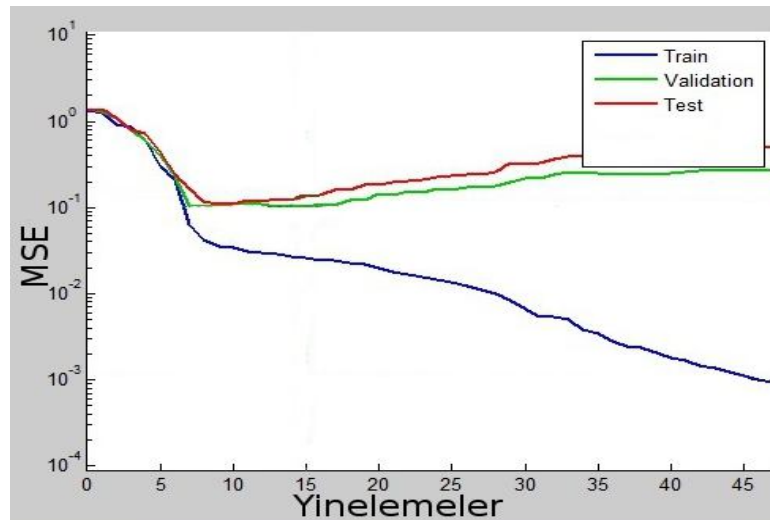
Şekil 4.11. Gabor ve özmeyve özniteliklerinin birlikte eğitiminde kullanılan YSA'nın ağ eğitimine ait regresyon eğrileri

4.6.3. Stepdisc analiziyle elde edilen öznitelik setinin YSA eğitimi

Stepdisc analiziyle elde edilen öznitelik setinin eğitilmesinde kullanılan YSA yapısı ve Matlab öğrenme penceresi Şekil 4.12'de görülmektedir. En iyi YSA yapısını tespit etmek için gerçekleştirilen ağ yapılandırma çalışmaları sonucunda 2 gizli katmanlı, her bir gizli katmanında 20 adet nöron bulunan ve 'feedforwardnet' Matlab fonksiyonu ile üretilen ileri-beslemeli ağ yapısı seçilmiştir. Ağın gizli katmanlarında aktivasyon fonksiyonları olarak sırasıyla lineer ve tanjant-sigmoid, çıktı katmanında da lineer bir fonksiyon kullanılmıştır. Ağın eğitim fonksiyonu Levenberg-Marquardt geri yayımlı fonksiyondur. Ağın eğitimi 47. yinelemede istenen hata değerine (0,001) ulaşılması sonucu durmuştur. Eğitim işlemi 3 saniye sürmüştür. Şekil 4.13'de ağ eğitimine ait performans grafiği görülmektedir.




Şekil 4.12. Stepdisc analiziyle elde edilen öznelilik setinin eğitiminde kullanılan ağırlık Matlab YSA eğitim penceresinde görünümü



Şekil 4.13. Stepdisc analiziyle elde edilen öznelilik setinin eğitiminde kullanılan YSA'nın ağırlık eğitimine ait performans grafiği

YSA eğitimi performans grafiğinde doğrulama eğrisi ve test eğrisi eğitim yinelemeleri boyunca benzer bir hata (MSE) seyri izlemişlerdir. Öğrenme istenilen düzeyde gerçekleşmiştir. YSA'nın çıktlarıyla hedefler arasındaki ilişkiyi gösteren regresyon eğrileri Şekil 4.14'de görülmektedir.

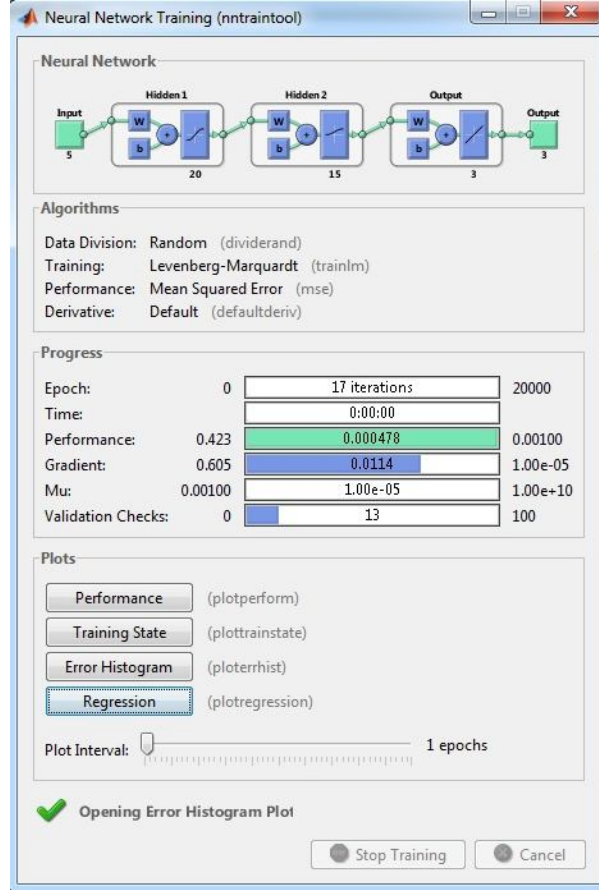


Şekil 4.14. Stepdisc analiziyle elde edilen öznelik setinin eğitiminde kullanılan YSA'nın ağ eğitimine ait regresyon eğrileri


4.6.4. Deneme-yanılma yoluyla elde edilen öznelik setinin YSA eğitimi

Stepdisc analiziyle elde edilen öznelik setinin eğitilmesinde kullanılan YSA yapısı ve Matlab öğrenme penceresi Şekil 4.15'de görülmektedir. En iyi YSA yapısını tespit etmek için gerçekleştirilen ağ yapılandırma çalışmaları sonucunda 2 gizli katmanlı, birinci gizli katmanında 20 adet, ikincisinde 15 adet nöron bulunan ve 'feedforwardnet' Matlab fonksiyonu ile üretilen ileri-beslemeli ağ yapısı seçilmiştir. Ağın gizli katmanlarında aktivasyon fonksiyonları olarak sırasıyla tanjant-sigmoid ve logaritmik-sigmoid, çıktı katmanında da lineer bir fonksiyon kullanılmıştır. Ağın eğitim fonksiyonu Levenberg-Marquardt geri yayımlı fonksiyondur. Ağın eğitimi 17. yinelemede istenen hata değerine (0,001) ulaşılması sonucu durmuştur. Eğitim işlemi 1

saniyenin altında gerçekleşmiştir. Şekil 4.16’da ağ eğitimi ait performans grafiği görülmektedir.




Şekil 4.15. Deneme-yanılma yoluyla elde edilen öznelik setinin eğitiminde kullanılan ağın Matlab YSA eğitim penceresinde görünümü



Şekil 4.16. Deneme-yanılma yoluyla elde edilen öznelik setinin eğitiminde kullanılan YSA'nın ağ eğitimi ait performans grafiği


YSA eğitimi performans grafiğinde doğrulama eğrisi ve test eğrisi eğitim yinlemeleri boyunca benzer bir hata (MSE) seyri izlemişlerdir. Öğrenme istenilen düzeyde gerçekleşmiştir. YSA'nın çıktılarıyla hedefler arasındaki ilişkiyi gösteren regresyon eğrileri Şekil 4.17'de görülmektedir.




Şekil 4.17. Deneme-yanılma yoluyla elde edilen öznelik setinin eğitiminde kullanılan YSA'nın ağ eğitimine ait regresyon eğrileri

4.7. Çoklu Saptamaların Tekilleştirilmesi Sonuçları

Denemelerde kullanılan sınıflandırıcıların saptama merkezleri bir ikili görüntü üzerine markalanmıştır. Şekil 4.18'de sınıflandırıcıların çoklu saptama sonuçlarının tekilleştirilmesi işlemine ait bir örnek verilmiştir. Şekil 4.18c'de gösterilen son saptama çemberleri saptama merkezleri esas alınarak oluşturulmuştur. Kullanılan bu yöntem asimetric blob şekilleri nedeniyle meyve konumlarını çok hassas belirleyememesine rağmen meyve sayılarını başarıyla sağlamıştır. Çalışmanın odak noktası olgunlaşmamış meyve sayılarının belirlenmesidir. Olgun meyvelerin hasadına yönelik robotla hasat gibi bir uygulama için meyve konumlamada daha hassas bir yöntem geliştirilebilir.



a) Çoklu saptamalar



b) Herhangi bir sınıflandırıcı tarafından elde edilen ikili görüntü



c) Sonuç görüntüsü

Şekil 4.18. Çoklu saptamaların birleştirilmesi adımları: (a) çoklu saptamalar, (b) saptama merkezlerini temsil eden ikili görüntü ve (c) sonuç görüntüsü.

4.8. Özmeyve ve GLCM Özniteliklerinin Kademeli Değerlendirildiği Algoritma Denemelerinin Sonuçları

4.8.1. Görüntü tarama yöntemi 1 ile özmeyve ve GLCM özniteliklerinin kademeli değerlendirildiği algoritma denemelerinin sonuçları

Eğitim ve deneme setlerinde gerçekleştirilen denemelerde algoritmalar görüntülerde bulunan bütün meyveleri saptayamamıştır. Yanlış saptamalar olarak ifade edilen arka plana ait alt-pencerenin şeftali meyvesi olarak sınıflandırıldığı durumlar da gerçekleşmiştir. Şekil 4.19'da görüntü tarama yöntemi 1 ile *özmeyve* ve GLCM doku özniteliklerinin kademeli değerlendirildiği algoritmaların deneme sonuçlarına ilişkin bazı sonuç görüntüleri görülmektedir. Şekilde görülen görüntüler, algoritmaların saptama başarılarını yüksek ve düşük (yanlış saptamalar ve saptanmayan meyveler içeren) sonuç görüntülerini içermektedir.



Şekil 4.19. Görüntü tarama yöntemi 1 ile GLCM ve özmeve özniteliklerinin kademeli değerlendirildiği algoritmaların deneme sonuçlarına ilişkin bazı sonuç görüntüleri

Görüntü tarama yöntemi 1'in kullanıldığı, özmeve ve GLCM özniteliklerinin kademeli değerlendirildiği algoritmaların deneme sonuçlarına ilişkin başarı oranları Çizelge 4.4'te verilmiştir.

Çizelge 4.4. Özmeyve ve GLCM doku özneliklerinin kademeli değerlendirildiği görüntü tarama yöntemi 1'in kullanıldığı algoritmaların eğitim ve test setleri deneme sonuçları

Yöntem 1	Eğitim seti (toplam meyve sayısı: 58)			Test seti (toplam meyve sayısı: 104)		
	Başarıyla saptanan	Yanlış pozitifler	Saptanamayan	Başarıyla saptanan	Yanlış pozitifler	Saptanamayan
Doku sınıflandırıcısı	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)
Diskriminant analizi	50 (0,86)	7 (0,12)	8 (0,14)	79 (0,76)	17 (0,18)	25 (0,24)
K-en-yakın komşu	47 (0,81)	3 (0,06)	11 (0,19)	77 (0,74)	54 (0,41)	27 (0,26)
Sınıflandırma ağacı	42 (0,72)	5 (0,11)	16 (0,28)	77 (0,74)	46 (0,37)	27 (0,26)
Naive Bayes	54 (0,93)	6 (0,10)	4 (0,07)	90 (0,87)	83 (0,48)	14 (0,13)
Regresyon ağacı	39 (0,67)	3 (0,07)	19 (0,33)	66 (0,63)	32 (0,33)	38 (0,37)
YSA	49 (0,84)	6 (0,11)	9 (0,16)	88 (0,85)	50 (0,36)	16 (0,15)
SVM	49 (0,84)	3 (0,06)	9 (0,16)	87 (0,84)	39 (0,31)	17 (0,16)

Kullanılan görüntü yöntemi 1 için eğitim ve test setlerinin algoritma başarılarını gösteren Çizelge 4.4 incelendiğinde test seti için en yüksek başarı (%87) doku sınıflandırıcısı olarak naive Bayes kullanıldığı algoritmada sağlanmıştır. Bunu %85 ve %84'lük değerlerle YSA ve SVM'nin GLCM doku özniteliklerinin eğitimde kullanıldığı diğer algoritmalar takip etmektedir. Bu algoritmalarda görüntü tarama yöntemi 1'in kullanımıyla %70'lerin üzerinde başarıyla saptanan meyve oranları elde edilmesine karşın, istenmeyen bir durum olan yanlış pozitif yüzdeleri oldukça yüksektir. Yanlış pozitif oranları incelendiğinde doku sınıflandırıcısı olarak naive Bayes kullanan algoritmanın en yüksek değere (%48) sahip olduğu görülmektedir. YSA ve SVM'nin GLCM özniteliklerinin eğitimde kullanıldığı diğer algoritmalar sırasıyla %36 ve %31'lik yanlış pozitif yüzdelerine sahiptir.

Görüntü tarama yöntemi 1'in kullanıldığı, Çizelge 4.4'te yer alan algoritmaların bir görüntü için işlem zamanları 75,8 ile 342,2 saniye arasındadır. İşlem zamanlarının görüntülere göre değişiminde renk elemesinin büyük ölçüde etkisi olmuştur. Denemelerde renk özellikleri bakımından daha ayırt edici meyveler içeren görüntülerde arka plan elemesi daha iyi yapıldığından bu görüntülerin taranması daha hızlı olmuştur.

Görüntülerin farklı aydınlanma koşullarına göre değerlendirildiği, görüntü tarama yöntemi 1'in kullanıldığı algoritmaların meyve ağaçlarının gölge ve güneşli taraflarından alınmış görüntülere ait deneme sonuçları Çizelge 4.5'te görülmektedir. Test seti için başarıyla saptanan en yüksek meyve yüzdesi %88'lik değeriyle naive Bayes kullanılan algoritmanın güneşli tarafı için elde edilmiştir. Doku sınıflandırıcısı olarak diskriminant analizi, YSA ve SVM'nin kullanıldığı algoritmaların gölge tarafından alınan görüntüler üzerinde gerçekleştirilen denemelerde daha yüksek başarı yüzdelerine sahip oldukları görülmektedir. Bununla birlikte tüm algoritma denemelerinde gölge taraftan alınan görüntülerde daha düşük yanlış pozitif yüzdeleri elde edilmiştir.

Çizelge 4.5. Özmeyve ve GLCM doku özneliklerinin kademeli değerlendirildiği görüntü tarama yöntemi 1'in kullanıldığı algoritmaların test setine ait güneşli ve gölgeli taraflardan alınan görüntülere göre deneme sonuçları

Yöntem 1 (Test seti)	Gölge taraf (toplam meyve sayısı: 45)			Güneşli taraf (toplam meyve sayısı:59)		
	Başarıyla saptanan	Yanlış pozitifler	Saptanamayan	Başarıyla saptanan	Yanlış pozitifler	Saptanamayan
	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)
Doku sınıflandırıcısı						
Diskriminant analizi	36 (0,80)	3 (0,08)	9 (0,20)	43 (0,73)	14 (0,25)	16 (0,27)
K-en-yakın komşu	32 (0,71)	12 (0,27)	13 (0,29)	45 (0,76)	42 (0,48)	14 (0,24)
Sınıflandırma ağacı	32 (0,71)	11 (0,26)	13 (0,29)	45 (0,76)	35 (0,44)	14 (0,24)
Naive Bayes	38 (0,84)	11 (0,22)	7 (0,16)	52 (0,88)	72 (0,58)	7 (0,12)
Regresyon ağacı	27 (0,60)	4 (0,13)	18 (0,40)	39 (0,66)	28 (0,42)	20 (0,34)
YSA	39 (0,87)	15 (0,28)	6 (0,13)	49 (0,83)	35 (0,42)	10 (0,17)
SVM	38 (0,84)	10 (0,21)	7 (0,16)	49 (0,83)	29 (0,37)	10 (0,17)

4.8.2. Görüntü tarama yöntemi 2 ile özmeve ve GLCM özneliklerinin kademeli değerlendirildiği algoritma denemelerinin sonuçları

Şekil 4.20’de görüntü tarama yöntemi 2 ile doku ve özmeve özneliklerinin birbirini takip eden sınıflandırıcılar olarak ele alındığı algoritma sonuçlarına örnek olarak tüm görüntü işleme adımlarını içeren bir örnek verilmiştir.




a) Şeftali bitki örtüsü görüntüsü



b) Aydınlanma zenginleştirilmesi



c) Histogram esaslı ikilileştirme.



d). Morfolojik açınımdan sonraki meyve adayları



e) Meyve saptama sonuçları.



f) Blob analizi sonrası son saptama sonuçları.

Şekil 4.20. Görüntü tarama yöntemi 2 kullanımıyla GLCM (YSA ile) ve özmeve özneliklerinin kademeli değerlendirildiği algoritmaya ait örnek meyve saptama adımları

Şekil 4.21’de görüntü tarama yöntemi 2 ile *özmeyve* ve GLCM doku özniteliklerinin kademeli değerlendirildiği algoritmaların deneme sonuçlarına ilişkin bazı sonuç görüntüleri görülmektedir. Şekilde görülen görüntüler, algoritmaların saptama başarıları yüksek ve düşük (yanlış saptamalar ve saptanmayan meyveler içeren) sonuç görüntülerini içermektedir.



Şekil 4.21. Görüntü tarama yöntemi 2 ile GLCM ve *özmeyve* özniteliklerinin kademeli değerlendirildiği algoritmaların deneme sonuçlarına ilişkin bazı sonuç görüntüleri

Görüntü tarama yöntemi 2’in kullanıldığı, *özmeyve* ve GLCM özniteliklerinin kademeli değerlendirildiği algoritmaların deneme sonuçlarına ilişkin başarı oranları Çizelge 4.6’da verilmiştir.

Çizelge 4.6. Özmeyve ve GLCM doku özneliklerinin kademeli değerlendirildiği görüntü tarama yöntemi 2'in kullanıldığı algoritmaların eğitim ve test setleri deneme sonuçları

Yöntem 2	Eğitim seti (toplam meyve sayısı: 58)			Test seti (toplam meyve sayısı: 104)		
	Başarıyla saptanan	Yanlış pozitifler	Saptanamayan	Başarıyla saptanan	Yanlış pozitifler	Saptanamayan
Doku sınıflandırıcısı	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)
Diskriminant analizi	24 (0,41)	0 (0,00)	34 (0,59)	37 (0,36)	1 (0,03)	67 (0,64)
K-en-yakın komşu	24 (0,41)	1 (0,04)	34 (0,59)	32 (0,31)	1 (0,03)	72 (0,69)
Sınıflandırma ağacı	19 (0,33)	0 (0,00)	39 (0,67)	28 (0,27)	3 (0,10)	76 (0,73)
Naïve Bayes	31 (0,53)	0 (0,00)	27 (0,47)	47 (0,45)	5 (0,10)	57 (0,55)
Regresyon ağacı	21 (0,36)	0 (0,00)	37 (0,64)	20 (0,19)	2 (0,09)	84 (0,81)
YSA	42 (0,72)	0 (0,00)	16 (0,28)	64 (0,62)	5 (0,07)	40 (0,38)
SVM	39 (0,67)	1 (0,03)	19 (0,33)	60 (0,58)	2 (0,03)	44 (0,42)

Çizelge 4.6’da kullanılan görüntü yöntemi 2 için eğitim ve test setlerinin algoritma başarılarını gösteren çizelge verilmiştir. Çizelge incelendiğinde test seti için en yüksek başarı (%62) GLCM özniteliklerinin YSA ile eğitildiği algoritmada sağlanmıştır. Görüntü tarama yöntemi 1 ile kıyaslandığında bu yöntemin kullanımıyla elde edilen başarıyla saptanan meyve yüzdeleri çarpıcı bir şekilde düşmüştür. Ancak yanlış pozitif yüzdelerinin de çarpıcı bir şekilde azaldığı görülmektedir. Bu algoritmaların kullanımıyla elde edilen en yüksek yanlış pozitif yüzdesi (%10) sınıflandırma ağacı ve naive Bayes sınıflandırıcılarının kullanıldığı algoritmalara ait olurken, en düşük yanlış pozitif yüzdesi (%3) diskriminant analizi, K-en-yakın komşu ve SVM’nin kullanıldığı algoritmalar tarafından sağlanmıştır. Bunların ışığında daha düşük saptama yüzdelerine karşın görüntü tarama yöntemi 2’nin yanlış pozitifleri önemli ölçüde azalttığı söylenebilir.

Çizelge 4.6’da yer alan görüntü tarama yöntemi 2’in kullanıldığı algoritmaların bir görüntü için işlem zamanları 2,8 ile 6,6 saniye arasındadır. Bu yöntemde de ölçülen işlem zamanlarının görüntülere göre değişiminde renk görüntülerin renk özelliğinin büyük ölçüde etkisi vardır. Denemelerde renk özellikleri bakımından daha ayırt edici meyveler içeren görüntülerin taranması daha hızlı olmuştur.

Görüntü tarama yöntemi 2’in kullanıldığı, görüntülerin farklı aydınlanma koşullarına göre değerlendirildiği, algoritmaların meyve ağaçlarının gölge ve güneşli taraflarından alınmış görüntülere ait deneme sonuçları Çizelge 4.7’de görülmektedir. Test seti için başarıyla saptanan en yüksek meyve yüzdesi YSA kullanılan algoritmaya ait olan %64’lük değer, meyve bahçelerinin gölge tarafından alınan görüntüler için elde edilmiştir. Doku sınıflandırıcısı olarak SVM kullanan algoritmanın güneşli taraf için başarı yüzdesi gölge taraftan biraz daha fazladır. Başarıyla saptanan meyve yüzdelerinin güneşli ve gölge taraflarda bu algoritmalar için birbirine oldukça yakın olduğu göze çarpmaktadır. Ancak yanlış pozitif yüzdelerine bakıldığında algoritmaların daha değişken aydınlanma koşullarına sahip güneşli taraftan alınan görüntülerde daha fazla yanlış pozitif görülmektedir.

Çizelge 4.7. Özmeyve ve GLCM doku özneliklerinin kademeli değerlendirildiği görüntü tarama yöntemi 2'in kullanıldığı algoritmaların test setine ait güneşli ve gölgeli taraflardan alınan görüntülere göre deneme sonuçları

Yöntem 2 (Test seti)	Gölge taraf (toplam meyve sayısı: 45)			Güneşli taraf (toplam meyve sayısı:59)		
	Başarıyla saptanan Meyve sayısı (%)	Yanlış pozitifler Meyve sayısı (%)	Saptanamayan Meyve sayısı (%)	Başarıyla saptanan Meyve sayısı (%)	Yanlış pozitifler Meyve sayısı (%)	Saptanamayan Meyve sayısı (%)
Doku sınıflandırıcısı						
Diskriminant analizi	17 (0,38)	0 (0,00)	28 (0,62)	20 (0,34)	1 (0,05)	39 (0,66)
K-en-yakın komşu	14 (0,31)	1 (0,07)	31 (0,69)	18 (0,31)	0 (0,00)	41 (0,69)
Sınıflandırma ağacı	13 (0,29)	1 (0,07)	32 (0,71)	15 (0,25)	2 (0,12)	44 (0,75)
Naïve Bayes	21 (0,47)	1 (0,05)	24 (0,53)	26 (0,44)	4 (0,13)	33 (0,56)
Regresyon ağacı	9 (0,20)	1 (0,10)	36 (0,80)	11 (0,19)	1 (0,08)	48 (0,81)
YSA	29 (0,64)	1 (0,03)	16 (0,36)	35 (0,59)	4 (0,10)	24 (0,41)
SVM	25 (0,56)	1 (0,04)	20 (0,44)	35 (0,59)	1 (0,03)	24 (0,41)

4.8.3. Görüntü tarama yöntemi 3 ile özmeve ve GLCM özneliklerinin kademeli değerlendirildiği algoritma denemelerinin sonuçları

Şekil 4.22’de görüntü tarama yöntemi 3 ile özmeve ve GLCM doku özneliklerinin kademeli değerlendirildiği algoritmaların deneme sonuçlarına ilişkin bazı sonuç görüntüleri görülmektedir. Şekilde görülen görüntüler, algoritmaların saptama başarıları yüksek ve düşük (yanlış saptamalar ve saptanmayan meyveler içeren) sonuç görüntülerini içermektedir.



Şekil 4.22. Görüntü tarama yöntemi 3 ile GLCM ve özmeve özneliklerinin kademeli değerlendirildiği algoritmaların deneme sonuçlarına ilişkin bazı sonuç görüntüleri

Görüntü tarama yöntemi 3'ün kullanıldığı, *özmeyve* ve GLCM özneliklerinin kademeli değerlendirildiği algoritmaların deneme sonuçlarına ilişkin başarı oranları Çizelge 4.8'de verilmiştir.

Çizelge 4.8. Özmeşve ve GLCM doku özniteliklerinin kademeli değeriendirildiđi görüntü tarama yöntemi 3'ün kullanıldıđı algoritmaların eğitiş ve test setleri deneme sonuçları

Yöntem 3	Eđitim seti (toplam meyve sayısı: 58)			Test seti (toplam meyve sayısı: 104)		
	Başarıyla saptanan	Yanlış pozitifler	Saptanamayan	Başarıyla saptanan	Yanlış pozitifler	Saptanamayan
Doku sınıflandırıcısı	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)
Diskriminant analizi	25 (0,43)	28 (0,53)	33 (0,57)	40 (0,38)	23 (0,37)	64 (0,62)
K-en-yakın komşu	28 (0,48)	30 (0,52)	30 (0,52)	43 (0,41)	31 (0,42)	61 (0,59)
Sınıflandırma ağacı	20 (0,34)	15 (0,43)	38 (0,66)	42 (0,40)	18 (0,30)	62 (0,60)
Naïve Bayes	31 (0,53)	58 (0,65)	27 (0,47)	57 (0,55)	56 (0,50)	47 (0,45)
Regresyon ağacı	15 (0,26)	14 (0,48)	43 (0,74)	30 (0,29)	14 (0,32)	74 (0,71)
YSA	43 (0,74)	38 (0,47)	15 (0,26)	74 (0,71)	61 (0,45)	30 (0,29)
SVM	40 (0,69)	36 (0,47)	18 (0,31)	68 (0,65)	36 (0,35)	36 (0,35)

Kullanılan görüntü yöntemi 3 için eğitim ve test setlerinin algoritma başarılarını gösteren Çizelge 4.8 incelendiğinde test seti için en yüksek başarı (%71) doku sınıflandırıcısı olarak YSA kullanılan algoritmada sağlanmıştır. Bunu %65'lik saptama başarısı yüzdesiyle SVM kullanılan algoritma takip etmektedir. Yanlış pozitif oranlarına bakıldığında doku sınıflandırıcısı olarak YSA sınıflandırıcısını kullanan algoritmanın en yüksek değere (%45) sahip olduğu görülmektedir.

Çizelge 4.8'de yer alan görüntü tarama yöntemi 3'ün kullanıldığı, birinci algoritmanın bir görüntü için işlem süreleri 7,7 ile 19,4 saniye arasındadır. Bu yöntemde ölçülen işlem zamanlarının görüntülere göre değişiminde RST dönüşümünün görüntülerde bulunan meyveler ile arka plan bölgeleri arasındaki simetri farklılıklarını açıklama gücü etkili olmuştur.


Görüntü tarama yöntemi 3'ün kullanıldığı, görüntülerin farklı aydınlanma koşullarına göre değerlendirildiği, algoritmaların meyve ağaçlarının gölge ve güneşli taraflarından alınmış görüntülere ait deneme sonuçları Çizelge 4.9'da görülmektedir. Test seti için başarıyla saptanan en yüksek meyve yüzdesi (%71), doku sınıflandırıcısı olarak SVM'nin kullanıldığı algoritmanın meyve bahçelerinin gölge ve güneşli tarafından alınan görüntüleri için aynı olarak elde edilmiştir.

Çizelge 4.9. Özmeyve ve GLCM doku özneliklerinin kademeli değerlendirildiği görüntü tarama yöntemi 3'ün kullanıldığı algoritmaların test setine ait güneşli ve gölgeli taraflardan alınan görüntülere göre deneme sonuçları

Yöntem 3 (Test seti)	Gölge taraf (toplam meyve sayısı: 45)			Güneşli taraf (toplam meyve sayısı:59)		
	Başarıyla saptanan	Yanlış pozitifler	Saptanamayan	Başarıyla saptanan	Yanlış pozitifler	Saptanamayan
	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)
Diskriminant analizi	18 (0,40)	11 (0,38)	27 (0,60)	22 (0,37)	12 (0,35)	37 (0,63)
K-en-yakın komşu	16 (0,36)	10 (0,38)	29 (0,64)	27 (0,46)	21 (0,44)	32 (0,54)
Sınıflandırma ağacı	16 (0,36)	6 (0,27)	29 (0,64)	26 (0,44)	12 (0,32)	33 (0,56)
Naïve Bayes	23 (0,51)	24 (0,51)	22 (0,49)	34 (0,58)	32 (0,48)	25 (0,42)
Regresyon ağacı	11 (0,24)	5 (0,31)	34 (0,76)	19 (0,32)	9 (0,32)	40 (0,68)
YSA	32 (0,71)	27 (0,46)	13 (0,29)	42 (0,71)	34 (0,45)	17 (0,29)
SVM	28 (0,62)	18 (0,39)	17 (0,38)	40 (0,68)	18 (0,31)	19 (0,32)

4.8.4. Özmeyve ve GLCM özniteliklerinin kademeli değerlendirildiği algoritma performanslarına genel bakış


Şekil 4.23’de *özmeyve* ve GLCM özniteliklerinin kademeli değerlendirildiği algoritmaların meyve saptama yüzdeleri verilmiştir. Görüntü tarama yöntemi 1’in kullanıldığı algoritmaların bu algoritma grubu içerisinde daha yüksek meyve saptama başarısına sahip olduğu görülmektedir.



Şekil 4.23. Özmeyve ve GLCM özniteliklerinin kademeli değerlendirildiği algoritmaların meyve saptama yüzdeleri

Şekil 4.24’te ise *özmeyve* ve GLCM özniteliklerinin kademeli değerlendirildiği algoritmaların yanlış pozitif yüzdeleri görülmektedir. Yanlış pozitif yüzdeleri açısından en iyi performansı meyve tarama yöntemi 2’nin kullanıldığı algoritmalar göstermiştir. Yöntem 1 ve 3’ün yanlış pozitif dağılımlarının birbirlerine yakın oldukları görülmektedir.

Özmeyve ve GLCM özniteliklerinin kademeli değerlendirildiği algoritma grupları içerisinde bazı meyve saptama yüzdeleri %80’lerin üzerinde olmasına rağmen bu algoritmaların yanlış pozitif yüzdelerinin de yüksek olduğu görülmektedir. Yanlış pozitif yüzdeleri bakımından en başarılı olan yöntem 2’nin kullanıldığı algoritmaların meyve saptama başarıları %60’ın altındadır.



Şekil 4.24. Özmeyve ve GLCM özniteliklerinin kademeli değerlendirildiği algoritmaların yanlış pozitif yüzdeleri

4.9. Özmeyve ve Gabor Doku Özniteliklerinin Birlikte Değerlendirildiği Algoritma Denemelerinin Sonuçları

4.9.1. Görüntü tarama yöntemi 1 ile özmeyve ve Gabor doku özniteliklerinin algoritmada birlikte değerlendirildiği denemeler

Şekil 4.25'te Gabor ve *özmeyve* özniteliklerinin birlikte değerlendirildiği ve görüntülerin görüntü tarama yöntemi 1 ile tarandığı algoritma deneme sonuçlarına örnek olarak tüm görüntü işleme adımlarını içeren bir örnek verilmiştir.



a) Şeftali bitki örtüsü görüntüsü



b) Aydınlanma zenginleştirilmesi



c) Histogram esaslı ikilileştirme



d) Meyve saptama sonuçları



e) Blob analizi sonrası son saptama sonuçları.

Şekil 4.25. Görüntü tarama yöntemi 1 ile Gabor ve özmeve özniteliklerinin birlikte değerlendirildiği sınıflandırıcı olarak diskriminant analizinin kullanıldığı algoritmaya ait örnek meyve saptama adımları

Şekil 4.26'de özmeve ve Gabor doku özniteliklerinin birlikte değerlendirildiği algoritmaların deneme sonuçlarına ilişkin bazı sonuç görüntüleri görülmektedir. Şekilde görülen görüntüler, algoritmaların saptama başarıları yüksek ve düşük (yanlış saptamalar ve saptanmayan meyveler içeren) sonuç görüntülerini içermektedir.



Şekil 4.26. Görüntü tarama yöntemi 1 ile Gabor ve özmeyle özneliklerinin birlikte değerlendirildiği algoritmaların deneme sonuçlarına ilişkin bazı sonuç görüntüleri

Görüntü tarama yöntemi 1'in kullanıldığı, *özmeyle* ve doku özneliklerinin birlikte değerlendirildiği algoritmaların deneme sonuçlarına ilişkin başarı oranları Çizelge 4.10'da verilmiştir.

Çizelge 4.10. Özmeyve ve Gabor doku özneliklerinin birlikte değerlendirildiği görüntü tarama yöntemi 1'in kullanıldığı algoritmaların eğitim ve test setleri deneme sonuçları

Yöntem 1	Eğitim seti (toplam meyve sayısı: 58)			Test seti (toplam meyve sayısı: 104)		
	Başarıyla saptanan	Yanlış pozitifler	Saptanamayan	Başarıyla saptanan	Yanlış pozitifler	Saptanamayan
	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)
Diskriminant analizi	56 (0,97)	14 (0,20)	2 (0,03)	88 (0,85)	34 (0,28)	16 (0,15)
K-en-yakın komşu	51 (0,88)	6 (0,11)	7 (0,12)	85 (0,82)	24 (0,22)	19 (0,18)
Sınıflandırma ağacı	51 (0,88)	6 (0,11)	7 (0,12)	81 (0,78)	29 (0,26)	23 (0,22)
Naïve Bayes	40 (0,69)	1 (0,02)	18 (0,31)	50 (0,48)	17 (0,25)	54 (0,52)
Regresyon ağacı	51 (0,88)	6 (0,11)	7 (0,12)	81 (0,78)	28 (0,26)	23 (0,22)
YSA	52 (0,90)	10 (0,16)	6 (0,10)	88 (0,85)	26 (0,23)	16 (0,15)
SVM	53 (0,91)	7 (0,12)	5 (0,09)	88 (0,85)	32 (0,27)	16 (0,15)

Çizelge 4.10 incelendiğinde test seti için en yüksek başarı (%85) sınıflandırıcı olarak diskriminant analizi, YSA ve SVM'nin kullanıldığı algoritmalarda sağlanmıştır. K-en-yakın komşu sınıflandırıcısının kullanıldığı algoritma test setinde yer alan meyvelerin %82'sini başarıyla saptayabilmiştir. Sınıflandırma ve regresyon ağacı kullanan algoritmaların başarıyla saptanan meyve yüzdesi %78'dir. Bu algoritmalar arasında test seti için en düşük saptama başarısı yüzdesi (%48) naive Bayes sınıflandırıcısını kullanan algoritmanındır. Algoritmalar %22 ile %28 arasında değişen yanlış pozitif yüzdelere sahiptir. Yanlış pozitif değerlerinin doku ve *özme*ye özneliklerinin kademeli sınıflandırıcılarda ele alındığı, görüntü tarama yöntemi 1'in kullanıldığı algoritmalara göre çok daha az oldukları görülmektedir. Görüntü tarama yöntemi 1'in kullanıldığı, Çizelge 4.10'de yer alan algoritmaların bir görüntü için işlem zamanları 80,2 ile 130,5 saniye arasındadır.

Görüntü tarama yöntemi 1'in kullanıldığı algoritmaların farklı aydınlanma koşullarına göre değerlendirildiği, meyve ağaçlarının gölge ve güneşli taraflarından alınmış görüntülere ait deneme sonuçları Çizelge 4.11'de görülmektedir. Test seti için başarıyla saptanan en yüksek meyve yüzdesi %91'lik değeriyle SVM sınıflandırıcısı kullanılan algortmada gölge taraf için elde edilmiştir. Diskriminant analizi, YSA ve K-en-yakın komşu sınıflandırıcılarının kullanıldığı algoritmaların güneş ve gölge taraflar için başarıyla saptanan meyve yüzdelерinin birbirine yakın olduğu göze çarpmaktadır. Bu, algoritmaların aydınlanma değişimlerinden daha az etkilendiğine işaret eden bir durumdur. Yanlış pozitif yüzdelерinin de benzer şekilde güneş ve gölge taraflar için yakın değerlere sahip olduğu görülmektedir.

Çizelge 4.11. Özmeyve ve Gabor doku özneliklerinin birlikte değerlendirildiği görüntü tarama yöntemi 1'in kullanıldığı algoritmaların test setine ait güneşli ve gölgeli taraflardan alınan görüntülere göre deneme sonuçları

Yöntem 1 (Test seti)	Gölge taraf (toplam meyve sayısı: 45)			Güneşli taraf (toplam meyve sayısı:59)		
	Başarıyla saptanan	Yanlış pozitifler	Saptanamayan	Başarıyla saptanan	Yanlış pozitifler	Saptanamayan
	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)
Diskriminant analizi	39 (0,87)	17 (0,30)	6 (0,13)	49 (0,83)	17 (0,26)	10 (0,17)
K-en-yakın komşu	38 (0,84)	12 (0,24)	7 (0,16)	47 (0,80)	12 (0,20)	12 (0,20)
Sınıflandırma ağacı	38 (0,84)	11 (0,22)	7 (0,16)	43 (0,73)	18 (0,30)	16 (0,27)
Naïve Bayes	17 (0,38)	4 (0,19)	28 (0,62)	33 (0,56)	13 (0,28)	26 (0,44)
Regresyon ağacı	38 (0,84)	11 (0,22)	7 (0,16)	43 (0,73)	17 (0,28)	16 (0,27)
YSA	39 (0,87)	11 (0,22)	6 (0,13)	49 (0,83)	15 (0,23)	10 (0,17)
SVM	41 (0,91)	15 (0,27)	4 (0,09)	47 (0,80)	17 (0,27)	12 (0,20)

4.9.2. Görüntü tarama yöntemi 2 ile özmeyve ve Gabor doku özneliklerinin algoritmada birlikte değerlendirildiği denemeler

Şekil 4.27’de özmeyve ve doku özneliklerinin birlikte değerlendirildiği, görüntü tarama yöntemi 2’nin kullanıldığı algoritmaların deneme sonuçlarına ilişkin bazı sonuç görüntüleri görülmektedir. Şekilde görülen görüntüler, algoritmaların saptama başarılarını yüksek ve düşük (yanlış saptamalar ve saptanmayan meyveler içeren) sonuç görüntülerini içermektedir.



Şekil 4.27. Görüntü tarama yöntemi 2 ile Gabor ve özmeyve özneliklerinin birlikte değerlendirildiği algoritmaların deneme sonuçlarına ilişkin bazı sonuç görüntüleri

Görüntü tarama yöntemi 2'in kullanıldığı, *özmeyve* ve doku özneliklerinin birlikte değerlendirildiği algoritmaların deneme sonuçlarına ilişkin başarı oranları Çizelge 4.12'de verilmiştir.

Çizelge 4.12. Özmeyve ve Gabor doku özneliklerinin birlikte değerlendirildiği görüntü tarama yöntemi 2’ in kullanıldığı algoritmaların eğitim ve test setleri deneme sonuçları

Yöntem 2	Eğitim seti (toplam meyve sayısı: 58)			Test seti (toplam meyve sayısı: 104)		
	Başarıyla saptanan	Yanlış pozitifler	Saptanamayan	Başarıyla saptanan	Yanlış pozitifler	Saptanamayan
	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)
Diskriminant analizi	54 (0,93)	1 (0,02)	4 (0,07)	81 (0,78)	6 (0,07)	23 (0,22)
K-en-yakın komşu	42 (0,72)	1 (0,02)	16 (0,28)	61 (0,59)	5 (0,08)	43 (0,41)
Sınıflandırma ağacı	40 (0,69)	1 (0,02)	18 (0,31)	50 (0,48)	4 (0,07)	54 (0,52)
Naïve Bayes	33 (0,57)	0 (0,00)	25 (0,43)	28 (0,27)	1 (0,03)	76 (0,73)
Regresyon ağacı	40 (0,69)	1 (0,02)	18 (0,31)	44 (0,42)	5 (0,10)	60 (0,58)
YSA	52 (0,90)	1 (0,02)	6 (0,10)	78 (0,75)	8 (0,09)	26 (0,25)
SVM	48 (0,83)	1 (0,02)	10 (0,17)	58 (0,56)	5 (0,08)	46 (0,44)

Çizelge 4.12 incelendiğinde test seti için en yüksek başarı (%78) sınıflandırıcı olarak diskriminant analizi, kullanılan algoritmada sağlanmıştır. En yüksek ikinci saptama performansı (%75) YSA kullanılan algoritmaya aittir. En düşük meyve saptama performansı naive Bayes sınıflandırıcısının kullanıldığı algoritmada elde edilmiştir. Görüntü tarama yöntemi 1'in kullanıldığı algoritmalarla kıyasla yanlış saptama yüzdelerinin bu yöntemin kullanımıyla %10 ve daha düşük değerlere azaldığı görülmektedir. Çizelge 4.12'de yer alan algoritmaların bir görüntü için işlem zamanları 9,6 ile 13,8 saniye arasındadır.

Görüntü tarama yöntemi 2'in kullanıldığı algoritmaların farklı aydınlanma koşullarına göre değerlendirildiği, meyve ağaçlarının gölge ve güneşli taraflarından alınmış görüntülere ait deneme sonuçları Çizelge 4.13'te görülmektedir. Test seti için başarıyla saptanan en yüksek meyve yüzdesi %84'lük değer YSA ve diskriminant analizi sınıflandırıcılarının kullanıldığı algoritmalarda gölge taraf için elde edilmiştir. Yanlış pozitif yüzdelerinin gölge taraf görüntüleri için değerleri bu algoritmalarda daha düşüktür.

Çizelge 4.13. Özmeyve ve Gabor doku özneliklerinin birlikte değerlendirildiği görüntü tarama yöntemi 2'in kullanıldığı algoritmaların test setine ait güneşli ve gölgeli taraflardan alınan görüntülere göre deneme sonuçları

Yöntem 2 (Test seti)	Gölge taraf (toplam meyve sayısı: 45)			Güneşli taraf (toplam meyve sayısı:59)		
	Başarıyla saptanan	Yanlış pozitifler	Saptanamayan	Başarıyla saptanan	Yanlış pozitifler	Saptanamayan
	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)
Diskriminant analizi	38 (0,84)	2 (0,05)	7 (0,16)	43 (0,73)	4 (0,09)	16 (0,27)
K-en-yakın komşu	29 (0,64)	2 (0,06)	16 (0,36)	32 (0,54)	3 (0,09)	27 (0,46)
Sınıflandırma ağacı	23 (0,51)	1 (0,04)	22 (0,49)	27 (0,46)	3 (0,10)	32 (0,54)
Naïve Bayes	11 (0,24)	0 (0,00)	34 (0,76)	17 (0,29)	1 (0,06)	42 (0,71)
Regresyon ağacı	22 (0,49)	2 (0,08)	23 (0,51)	22 (0,37)	3 (0,12)	37 (0,63)
YSA	38 (0,84)	3 (0,07)	7 (0,16)	40 (0,68)	5 (0,11)	19 (0,32)
SVM	30 (0,67)	2 (0,06)	15 (0,33)	28 (0,47)	3 (0,10)	31 (0,53)

4.9.3. Görüntü tarama yöntemi 3 ile özmeyve ve Gabor doku özniteliklerinin algoritmada birlikte değerlendirildiği denemeler

Şekil 4.28’de *özmeyve* ve doku özniteliklerinin birlikte değerlendirildiği, görüntü tarama yöntemi 3’ün kullanıldığı algoritmaların deneme sonuçlarına ilişkin bazı sonuç görüntüleri görülmektedir. Şekilde görülen görüntüler, algoritmaların saptama başarıları yüksek ve düşük (yanlış saptamalar ve saptanmayan meyveler içeren) sonuç görüntülerini içermektedir.



Şekil 4.28. Görüntü tarama yöntemi 3 ile Gabor ve özmeyve özniteliklerinin birlikte değerlendirildiği algoritmaların deneme sonuçlarına ilişkin bazı sonuç görüntüleri

Görüntü tarama yöntemi 3'in kullanıldığı, *özmeyve* ve doku özneliklerinin birlikte değerlendirildiği algoritmaların deneme sonuçlarına ilişkin başarı oranları Çizelge 4.14'de verilmiştir.

Çizelge 4.14. Özmeyve ve Gabor doku özneliklerinin birlikte değerlendirildiği görüntü tarama yöntemi 3'ün kullanıldığı algoritmaların eğitim ve test setleri deneme sonuçları

Yöntem 3	Eğitim seti (toplam meyve sayısı: 58)			Test seti (toplam meyve sayısı: 104)		
	Başarıyla saptanan	Yanlış pozitifler	Saptanamayan	Başarıyla saptanan	Yanlış pozitifler	Saptanamayan
	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)
Diskriminant analizi	45 (0,78)	7 (0,13)	13 (0,22)	74 (0,71)	36 (0,33)	30 (0,29)
K-en-yakın komşu	34 (0,59)	5 (0,13)	24 (0,41)	47 (0,45)	14 (0,23)	57 (0,55)
Sınıflandırma ağacı	33 (0,57)	5 (0,13)	25 (0,43)	37 (0,36)	16 (0,30)	67 (0,64)
Naïve Bayes	27 (0,47)	1 (0,04)	31 (0,53)	19 (0,18)	4 (0,17)	85 (0,82)
Regresyon ağacı	33 (0,57)	6 (0,15)	25 (0,43)	37 (0,36)	14 (0,27)	67 (0,64)
YSA	45 (0,78)	9 (0,17)	13 (0,22)	74 (0,71)	52 (0,41)	30 (0,29)
SVM	35 (0,60)	7 (0,17)	23 (0,40)	58 (0,56)	26 (0,31)	46 (0,44)

Çizelge 4.14 incelendiğinde test seti için en yüksek başarı (%71) sınıflandırıcı olarak diskriminant analizi ve YSA kullanılan algoritmalarda sağlanmıştır. En yüksek ikinci saptama performansı (%56) SVM kullanılan algoritmaya aittir. En düşük meyve saptama performansı (%18) naive Bayes sınıflandırıcısının kullanıldığı algortmada elde edilmiştir. Algoritmaların yanlış pozitif yüzdelerinin görüntü tarama yöntemi 2'nin kullanıldığı algoritmalara göre daha yüksek oldukları görülmektedir. Çizelge 4.14'te yer alan algoritmaların bir görüntü için işlem zamanları 11,1 ile 19 saniye arasındadır.


Görüntü tarama yöntemi 3'ün kullanıldığı algoritmaların farklı aydınlanma koşullarına göre değerlendirildiği, meyve ağaçlarının gölge ve güneşli taraflarından alınmış görüntülere ait deneme sonuçları Çizelge 4.15'te görülmektedir. Test seti için başarıyla saptanan en yüksek meyve yüzdesi %82'lik değer YSA sınıflandırıcısının kullanıldığı algortmada gölge taraf için elde edilmiştir. Yanlış pozitif yüzdeleri, gölge taraf görüntüleri için YSA, SVM ve diskriminant analizi sınıflandırıcılarının kullanıldığı algoritmalarda daha yüksektir.

Çizelge 4.15. Özmeyve ve Gabor doku özneliklerinin birlikte değerlendirildiği görüntü tarama yöntemi 3'ün kullanıldığı algoritmaların test setine ait güneşli ve gölgeli taraflardan alınan görüntülere göre deneme sonuçları

Yöntem 3 (Test seti)	Gölge taraf (toplam meyve sayısı: 45)			Güneşli taraf (toplam meyve sayısı:59)		
	Başarıyla saptanan	Yanlış pozitifler	Saptanamayan	Başarıyla saptanan	Yanlış pozitifler	Saptanamayan
	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)
Diskriminant analizi	36 (0,80)	21 (0,37)	9 (0,20)	38 (0,64)	15 (0,28)	21 (0,36)
K-en-yakın komşu	19 (0,42)	4 (0,17)	26 (0,58)	28 (0,47)	10 (0,26)	31 (0,53)
Sınıflandırma ağacı	15 (0,33)	5 (0,25)	30 (0,67)	22 (0,37)	11 (0,33)	37 (0,63)
Naïve Bayes	4 (0,09)	0 (0,00)	41 (0,91)	15 (0,25)	4 (0,21)	44 (0,75)
Regresyon ağacı	14 (0,31)	5 (0,26)	31 (0,69)	23 (0,39)	9 (0,28)	36 (0,61)
YSA	37 (0,82)	39 (0,51)	8 (0,18)	37 (0,63)	13 (0,26)	22 (0,37)
SVM	28 (0,62)	18 (0,39)	17 (0,38)	30 (0,51)	8 (0,21)	29 (0,49)

4.9.4. Özmeyve ve Gabor doku özniteliklerinin birlikte değerlendirildiği algoritma performanslarına genel bakış

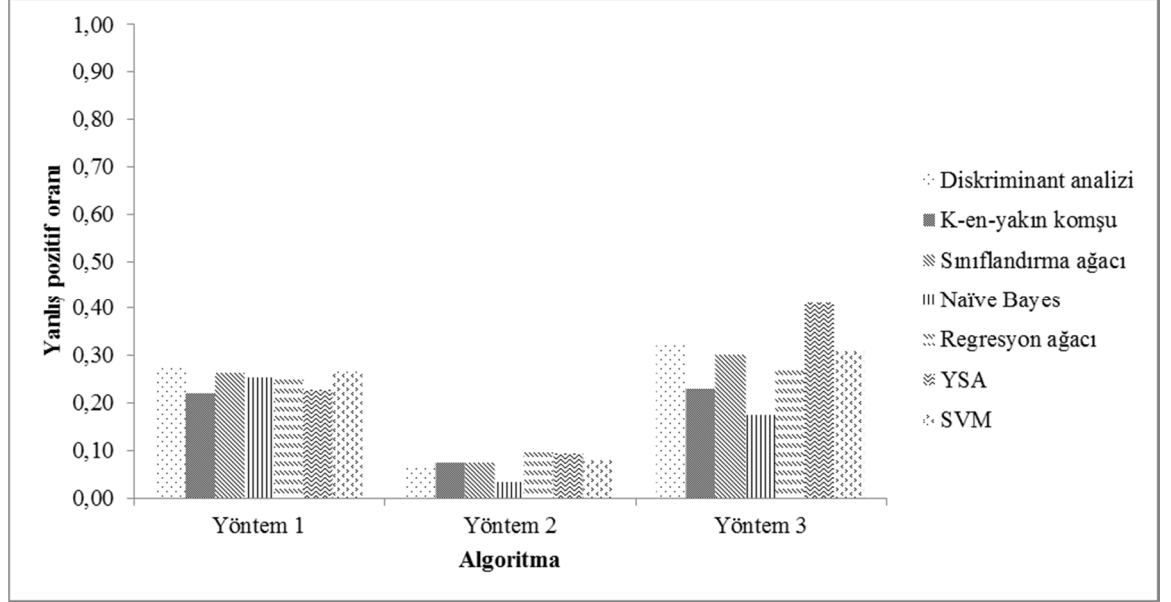
Şekil 4.29’da *özmeyve* ve Gabor doku özniteliklerinin birlikte değerlendirildiği algoritmaların meyve saptama yüzdeleri verilmiştir. Meyve tarama yöntemi 1’in kullanıldığı algoritmaların bu algoritma grubu içerisinde daha yüksek meyve saptama başarısına sahip olduğu görülmektedir. Bu grup içerisinde ikinci olarak en başarılı algoritmalar meyve tarama yöntemi 2’nin kullanıldığı algoritmalar. Ancak yöntem 3’ün kullanıldığı algoritma grubu içerisindeki sınıflandırıcı olarak diskriminant analizi ve YSA’nın kullanıldığı algoritmaların diğer yöntemlerin kullanıldığı algoritma gruplarına yakın başarı yüzdelerine sahip olduğu da görülmektedir.



Şekil 4.29. Özmeyve ve Gabor doku özniteliklerinin birlikte değerlendirildiği algoritmaların meyve saptama yüzdeleri

Şekil 4.30’da ise *özmeyve* ve doku özniteliklerinin birlikte değerlendirildiği algoritmaların yanlış pozitif yüzdeleri görülmektedir. Yanlış pozitif yüzdeleri açısından en iyi performansı meyve tarama yöntemi 2’nin kullanıldığı algoritmalar, en kötüsünü ise yöntem 3’ün kullanıldığı algoritmalar göstermiştir. Yöntem 1’in kullanıldığı algoritmaların daha yüksek yanlış pozitif yüzdeleri dikkate alındığında, *özmeyve* ve Gabor doku özniteliklerinin birlikte değerlendirildiği algoritmalar içerisinde şeftali

meyvesini saptamada optimum algoritmalar yöntem 2 ile sınıflandırıcı olarak YSA ve diskriminant analizinin kullanıldığı algoritmalar olduğu önerilmektedir.



Şekil 4.30. Özmeyve ve Gabor doku özniteliklerinin birlikte değerlendirildiği algoritmaların yanlış pozitif oranları

4.10. STEPDISC Analiziyle Belirlenen Özniteliklerin Birlikte Değerlendirildiği Algoritma Denemelerinin Sonuçları

4.10.1. Görüntü tarama yöntemi 1 ile STEPDISC analiziyle belirlenen özniteliklerin algoritmada birlikte değerlendirildiği denemeler

Şekil 4.31’de STEPDISC analiziyle belirlenen özniteliklerin birlikte değerlendirildiği algoritmaların deneme sonuçlarına ilişkin bazı sonuç görüntüleri görülmektedir. Şekilde görülen görüntüler, algoritmaların saptama başarıları yüksek ve daha düşük (yanlış saptamalar ve saptanmayan meyveler içeren) sonuç görüntülerini içermektedir.



Şekil 4.31. Görüntü tarama yöntemi 1 kullanımıyla STEPDISC analiziyle belirlenen özneliklerin birlikte değerlendirildiği algoritmaların deneme sonuçlarına ilişkin bazı sonuç görüntüleri

Görüntü tarama yöntemi 1'in kullanıldığı, STEPDISC analiziyle belirlenen özneliklerin birlikte değerlendirildiği algoritmaların deneme sonuçlarına ilişkin başarı oranları Çizelge 4.16'da verilmiştir.

Çizelge 4.16. STEPDISC analiziyle belirlenen özneliklerin birlikte değerlendirildiği görüntü tarama yöntemi 1'in kullanıldığı algoritmaların eğitim ve test setleri deneme sonuçları

Yöntem 1	Eğitim seti (toplam meyve sayısı: 58)			Test seti (toplam meyve sayısı: 104)		
	Başarıyla saptanan	Yanlış pozitifler	Saptanamayan	Başarıyla saptanan	Yanlış pozitifler	Saptanamayan
	Meyve sayısı	Meyve sayısı	Meyve sayısı	Meyve sayısı	Meyve sayısı	Meyve sayısı
	(%)	(%)	(%)	(%)	(%)	(%)
Diskriminant analizi	49 (0,84)	5 (0,09)	9 (0,16)	72 (0,69)	21 (0,23)	32 (0,31)
K-en-yakın komşu	42 (0,72)	3 (0,07)	16 (0,28)	68 (0,65)	7 (0,09)	36 (0,35)
Sınıflandırma ağacı	44 (0,76)	3 (0,06)	14 (0,24)	63 (0,61)	13 (0,17)	41 (0,39)
Naïve Bayes	38 (0,66)	1 (0,03)	20 (0,34)	54 (0,52)	1 (0,02)	50 (0,48)
Regresyon ağacı	23 (0,40)	0 (0,00)	35 (0,60)	9 (0,09)	2 (0,18)	95 (0,91)
YSA	49 (0,84)	15 (0,23)	9 (0,16)	78 (0,75)	33 (0,30)	26 (0,25)
SVM	45 (0,78)	5 (0,10)	13 (0,22)	69 (0,66)	8 (0,10)	35 (0,34)

Çizelge 4.16 incelendiğinde test seti için en yüksek başarı (%75) sınıflandırıcı olarak YSA kullanıldığı algortmada elde edilmiştir. En iyi ikinci başarı yüzdesine %69'luk değeriyle diskriminant analizi sınıflandırıcısının kullanıldığı algortma sahiptir. Bu algortmalar arasında test seti için en düşük saptama başarısı yüzdesi (%9) regresyon ağacı sınıflandırıcısını kullanan algortmanındır. Test seti için en yüksek yanlış pozitif yüzdesi (%30) YSA sınıflandırıcısının kullanıldığı algortmada gözlemlenmiştir. Görüntü tarama yöntemi 1'in kullanıldığı, Çizelge 4.16'da yer alan algortmaların bir görüntü için işlem zamanları 75,7 ile 143,2 saniye arasındadır.

Görüntü tarama yöntemi 1'in kullanıldığı algortmaların farklı aydınlanma koşullarına göre değerlendirildiği, meyve ağaçlarının gölge ve güneşli taraflarından alınmış görüntülere ait deneme sonuçları Çizelge 4.17'de görülmektedir. Test seti için başarıyla saptanan en yüksek meyve yüzdesi %76'lık değeriyle YSA sınıflandırıcısı kullanılan algortmada güneşli taraf için elde edilmiştir. Ancak bu değer, algortmanın gölge taraftan alınan görüntüler için başarı yüzdesi olan %73 değerine oldukça yakın bir değerdir. Benzer şekilde diğer sınıflandırıcıların kullanıldığı algortmaların da güneşli ve gölge taraftan alınan görüntüler için başarı yüzdeleri birbirine oldukça yakındır. Bu, algortmaların aydınlanma değişimlerinden daha az etkilendiğine işaret eden bir durumdur. Yanlış pozitif yüzdesi olarak aydınlanma değişimlerinden en çok etkilenen algortmalar, YSA ve diskriminant analizi sınıflandırıcılarının kullanıldığı algortmalardır.

Çizelge 4.17. STEPDISC analiziyle belirlenen özneliklerin birlikte değerlendirildiği görüntü tarama yöntemi 1'in kullanıldığı algoritmaların test setine ait güneşli ve gölgeli taraflardan alınan görüntülere göre deneme sonuçları

Yöntem 1 (Test seti)	Gölge taraf (toplam meyve sayısı: 45)			Güneşli taraf (toplam meyve sayısı:59)		
	Başarıyla saptanan	Yanlış pozitifler	Saptanamayan	Başarıyla saptanan	Yanlış pozitifler	Saptanamayan
	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)
Diskriminant analizi	33 (0,73)	5 (0,13)	12 (0,27)	39 (0,66)	16 (0,29)	20 (0,34)
K-en-yakın komşu	31 (0,69)	4 (0,11)	14 (0,31)	37 (0,63)	3 (0,08)	22 (0,37)
Sınıflandırma ağacı	29 (0,64)	5 (0,15)	16 (0,36)	34 (0,58)	8 (0,19)	25 (0,42)
Naïve Bayes	23 (0,51)	1 (0,04)	22 (0,49)	31 (0,53)	0 (0,00)	28 (0,47)
Regresyon ağacı	3 (0,07)	1 (0,25)	42 (0,93)	6 (0,10)	1 (0,14)	53 (0,90)
YSA	33 (0,73)	7 (0,18)	12 (0,27)	45 (0,76)	26 (0,37)	14 (0,24)
SVM	32 (0,71)	2 (0,06)	13 (0,29)	37 (0,63)	6 (0,14)	22 (0,37)

4.10.2. Görüntü tarama yöntemi 2 ile STEPDISC analiziyle belirlenen özniteliklerin algoritmada birlikte değerlendirildiği denemeler

Şekil 4.32’de STEPDISC analiziyle belirlenen özniteliklerin birlikte değerlendirildiği algoritmaların deneme sonuçlarına ilişkin bazı sonuç görüntüleri görülmektedir. Şekilde görülen görüntüler, algoritmaların saptama başarıları yüksek ve daha düşük (yanlış saptamalar ve saptanmayan meyveler içeren) sonuç görüntülerini içermektedir.



Şekil 4.32. Görüntü tarama yöntemi 2 ile STEPDISC analiziyle belirlenen özniteliklerin birlikte değerlendirildiği algoritmaların deneme sonuçlarına ilişkin bazı sonuç görüntüleri

Görüntü tarama yöntemi 2’nin kullanıldığı, STEPDISC analiziyle belirlenen özniteliklerin birlikte değerlendirildiği algoritmaların deneme sonuçlarına ilişkin başarı oranları Çizelge 4.18’de verilmiştir.

Çizelge 4.18. STEPDISC analiziyle belirlenen öz niteliklerin birlikte değerlendirildiği görüntü tarama yöntemi 2'nin kullanıldığı algoritmaların eğitim ve test setleri deneme sonuçları

Yöntem 2	Eğitim seti (toplam meyve sayısı: 58)			Test seti (toplam meyve sayısı: 104)		
	Başarıyla saptanan	Yanlış pozitifler	Saptanamayan	Başarıyla saptanan	Yanlış pozitifler	Saptanamayan
	Meyve sayısı	Meyve sayısı	Meyve sayısı	Meyve sayısı	Meyve sayısı	Meyve sayısı
	(%)	(%)	(%)	(%)	(%)	(%)
Diskriminant analizi	49 (0,84)	2 (0,04)	9 (0,16)	78 (0,75)	6 (0,07)	26 (0,25)
K-en-yakın komşu	42 (0,72)	1 (0,02)	16 (0,28)	58 (0,56)	2 (0,03)	46 (0,44)
Sınıflandırma ağacı	39 (0,67)	1 (0,03)	19 (0,33)	45 (0,43)	3 (0,06)	59 (0,57)
Naïve Bayes	37 (0,64)	0 (0,00)	21 (0,36)	29 (0,28)	0 (0,00)	75 (0,72)
Regresyon ağacı	14 (0,24)	0 (0,00)	44 (0,76)	5 (0,05)	0 (0,00)	99 (0,95)
YSA	55 (0,95)	2 (0,04)	3 (0,05)	87 (0,84)	20 (0,19)	17 (0,16)
SVM	42 (0,72)	1 (0,02)	16 (0,28)	55 (0,53)	2 (0,04)	49 (0,47)

Çizelge 4.18 incelendiğinde test seti için en yüksek başarı (%84) sınıflandırıcı olarak YSA kullanıldığı algoritmada elde edilmiştir. En iyi ikinci başarı yüzdesine %75'lik değeriyle diskriminant analizi sınıflandırıcısının kullanıldığı algoritma sahiptir. Bu algoritmalar arasında test seti için en düşük saptama başarısı yüzdesi (%5) regresyon ağacı sınıflandırıcısını kullanan algoritmanındır. Test seti için en yüksek yanlış pozitif yüzdesi (%19) YSA sınıflandırıcısının kullanıldığı algoritmada gözlemlenmiştir. STEPDISC analiziyle belirlenen özneliklerin birlikte değerlendirildiği algoritmalarda görüntü tarama yöntemi 2'nin yöntem 1'e kıyasla oldukça az yanlış pozitif yüzdelere sahip olduğu göze çarpmaktadır. Görüntü tarama yöntemi 2'nin kullanıldığı, Çizelge 4.18'de yer alan algoritmaların bir görüntü için işlem zamanları 2,6 ile 10,3 saniye arasındadır.

Görüntü tarama yöntemi 2'nin kullanıldığı algoritmaların farklı aydınlanma koşullarına göre değerlendirildiği, meyve ağaçlarının gölge ve güneşli taraflarından alınmış görüntülere ait deneme sonuçları Çizelge 4.19'da görülmektedir. Test seti için başarıyla saptanan en yüksek meyve yüzdesi %87'lik değeriyle YSA sınıflandırıcısı kullanılan algoritmada gölge taraf için elde edilmiştir. Meyve saptama başarıları oldukça düşük olan naive Bayes ve regresyon ağacı sınıflandırıcıları dışındaki diğer sınıflandırıcıların kullanıldığı algoritmalar, gölge taraftan alınan görüntülerde daha iyi saptama performansı göstermişlerdir. Yanlış pozitif yüzdelere bakıldığında YSA sınıflandırıcısının kullanıldığı algoritma hariç, algoritmaların güneş ve gölge taraflar için yakın yüzde değerlerine sahip olduğu görülmektedir.

Çizelge 4.19. STEPDISC analiziyle belirlenen öz niteliklerin birlikte değerlendirildiği görüntü tarama yöntemi 2'nin kullanıldığı algoritmaların test setine ait güneşli ve gölgeli taraflardan alınan görüntülere göre deneme sonuçları

Yöntem2 (Test seti)	Gölge taraf (toplam meyve sayısı: 45)			Güneşli taraf (toplam meyve sayısı:59)		
	Başarıyla saptanan	Yanlış pozitifler	Saptanamayan	Başarıyla saptanan	Yanlış pozitifler	Saptanamayan
	Meyve sayısı	Meyve sayısı	Meyve sayısı	Meyve sayısı	Meyve sayısı	Meyve sayısı
	(%)	(%)	(%)	(%)	(%)	(%)
Diskriminant analizi	38 (0,84)	2 (0,05)	7 (0,16)	40 (0,68)	4 (0,09)	19 (0,32)
K-en-yakın komşu	29 (0,64)	1 (0,03)	16 (0,36)	29 (0,49)	1 (0,03)	30 (0,51)
Sınıflandırma ağacı	22 (0,49)	0 (0,00)	23 (0,51)	23 (0,39)	3 (0,12)	36 (0,61)
Naïve Bayes	9 (0,20)	0 (0,00)	36 (0,80)	20 (0,34)	0 (0,00)	39 (0,66)
Regresyon ağacı	2 (0,04)	0 (0,00)	43 (0,96)	3 (0,05)	0 (0,00)	56 (0,95)
YSA	39 (0,87)	4 (0,09)	6 (0,13)	48 (0,81)	16 (0,25)	11 (0,19)
SVM	26 (0,58)	1 (0,04)	19 (0,42)	29 (0,49)	1 (0,03)	30 (0,51)

4.10.3. Görüntü tarama yöntemi 3 ile STEPDISC analiziyle belirlenen özneliklerin algoritmada birlikte değerlendirildiği denemeler

Şekil 4.33'te STEPDISC analiziyle belirlenen özneliklerin birlikte değerlendirildiği algoritmaların deneme sonuçlarına ilişkin bazı sonuç görüntüleri görülmektedir. Şekilde görülen görüntüler, algoritmaların saptama başarıları yüksek ve daha düşük (yanlış saptamalar ve saptanmayan meyveler içeren) sonuç görüntülerini içermektedir.



Şekil 4.33. Görüntü tarama yöntemi 3 ile STEPDISC analiziyle belirlenen özneliklerin birlikte değerlendirildiği algoritmaların deneme sonuçlarına ilişkin bazı sonuç görüntüleri

Görüntü tarama yöntemi 3'ün kullanıldığı, STEPDISC analiziyle belirlenen özneliklerin birlikte değerlendirildiği algoritmaların deneme sonuçlarına ilişkin başarı oranları Çizelge 4.20'de verilmiştir.

Çizelge 4.20. STEPDISC analiziyle belirlenen özniteliklerin birlikte değerlendirildiği görüntü tarama yöntemi 3'ün kullanıldığı algoritmaların eğitim ve test setleri deneme sonuçları

Yöntem 3	Eğitim seti (toplam meyve sayısı: 58)			Test seti (toplam meyve sayısı: 104)		
	Başarıyla saptanan	Yanlış pozitifler	Saptanamayan	Başarıyla saptanan	Yanlış pozitifler	Saptanamayan
	Meyve sayısı	Meyve sayısı	Meyve sayısı	Meyve sayısı	Meyve sayısı	Meyve sayısı
	(%)	(%)	(%)	(%)	(%)	(%)
Diskriminant analizi	46 (0,79)	6 (0,12)	12 (0,21)	76 (0,73)	43 (0,36)	28 (0,27)
K-en-yakın komşu	38 (0,66)	1 (0,03)	20 (0,34)	60 (0,58)	11 (0,15)	44 (0,42)
Sınıflandırma ağacı	33 (0,57)	3 (0,08)	25 (0,43)	43 (0,41)	15 (0,26)	61 (0,59)
Naïve Bayes	30 (0,52)	0 (0,00)	28 (0,48)	29 (0,28)	1 (0,03)	75 (0,72)
Regresyon ağacı	18 (0,31)	0 (0,00)	40 (0,69)	8 (0,08)	0 (0,00)	96 (0,92)
YSA	52 (0,90)	14 (0,21)	6 (0,10)	89 (0,86)	83 (0,48)	15 (0,14)
SVM	36 (0,62)	1 (0,03)	22 (0,38)	57 (0,55)	20 (0,26)	47 (0,45)

Çizelge 4.20 incelendiğinde test seti için en yüksek başarı (%86) sınıflandırıcı olarak YSA kullanıldığı algortmada elde edilmiştir. En iyi ikinci başarı yüzdesine %73'lük değeriyle diskriminant analizi sınıflandırıcısının kullanıldığı algortma sahiptir. Bu algortmalar arasında test seti için en düşük saptama başarıları yüzdesi (%8) regresyon ağacı sınıflandırıcısını kullanan algortmanındır. Görüntü tarama yöntemi 3'ün kullanıldığı, Çizelge 4.20'de yer alan algortmaların bir görüntü için işlem zamanları 8,8 ile 44,9 saniye arasındadır.


Görüntü tarama yöntemi 3'ün kullanıldığı algortmaların farklı aydınlanma koşullarına göre değerlendirildiği, meyve ağaçlarının gölge ve güneşli taraflarından alınmış görüntülere ait deneme sonuçları Çizelge 4.21'de görülmektedir. Test seti için başarıyla saptanan en yüksek meyve yüzdesi %91'lik değeriyle YSA sınıflandırıcısı kullanılan algortmada gölge taraf için elde edilmiştir. Sınıflandırma ağacı ve regresyon ağacı sınıflandırıcıları dışındaki diğer sınıflandırıcıların kullanıldığı algortmalar, gölge taraftan alınan görüntülerde daha iyi saptama performansı göstermişlerdir. Yanlış pozitif yüzdelere bakıldığında diskriminant analizi, K-en-yakın komşu, YSA ve SVM sınıflandırıcılarının kullanıldığı algortmaların gölge taraf görüntüleri için daha yüksek yanlış pozitif değerlerine sahip oldukları görülmektedir.

Çizelge 4.21. STEPDISC analiziyle belirlenen özneliklerin birlikte değerlendirildiği görüntü tarama yöntemi 3'ün kullanıldığı algoritmaların test setine ait güneşli ve gölgeli taraflardan alınan görüntülere göre deneme sonuçları

Yöntem 3 (Test seti)	Gölge taraf (toplam meyve sayısı: 45)			Güneşli taraf (toplam meyve sayısı:59)		
	Başarıyla saptanan	Yanlış pozitifler	Saptanamayan	Başarıyla saptanan	Yanlış pozitifler	Saptanamayan
	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)
Diskriminant analizi	34 (0,76)	35 (0,51)	11 (0,24)	42 (0,71)	8 (0,16)	17 (0,29)
K-en-yakın komşu	29 (0,64)	8 (0,22)	16 (0,36)	31 (0,53)	3 (0,09)	28 (0,47)
Sınıflandırma ağacı	17 (0,38)	6 (0,26)	28 (0,62)	26 (0,44)	9 (0,26)	33 (0,56)
Naïve Bayes	11 (0,24)	0 (0,00)	34 (0,76)	18 (0,31)	1 (0,05)	41 (0,69)
Regresyon ağacı	2 (0,04)	0 (0,00)	43 (0,96)	6 (0,10)	0 (0,00)	53 (0,90)
YSA	41 (0,91)	44 (0,52)	4 (0,09)	48 (0,81)	39 (0,45)	11 (0,19)
SVM	29 (0,64)	19 (0,40)	16 (0,36)	28 (0,47)	1 (0,03)	31 (0,53)


4.10.4. STEPDISC analiziyle belirlenen özniteliklerin algoritmada birlikte değerlendirildiği algoritmaların performanslarına genel bakış

Şekil 4.34'te STEPDISC analiziyle belirlenen özniteliklerin algoritmada birlikte değerlendirildiği algoritmaların meyve saptama yüzdeleri verilmiştir. Kullanılan her bir görüntü tarama yöntemi için meyve saptama yüzdeleri en az %70'den yüksek algoritmaların olduğu görülmektedir. Yöntem 2 ve 3'ün kullandığı algoritma grupları içerisinde yer alan sınıflandırıcı olarak YSA'nın kullandığı algoritmaların başarıyla saptanan meyve yüzdeleri %80'in üzerindedir.



Şekil 4.34. STEPDISC analiziyle belirlenen özniteliklerin birlikte değerlendirildiği algoritmaların meyve saptama yüzdeleri

Şekil 4.35'te STEPDISC analiziyle belirlenen özniteliklerin algoritmada birlikte değerlendirildiği algoritmaların yanlış pozitif yüzdeleri görülmektedir. Yanlış pozitif yüzdeleri açısından en iyi performansı, meyve tarama yöntemi 2'nin kullandığı algoritmalar en kötüsünü ise yöntem 3'ün kullandığı algoritmalar göstermiştir. STEPDISC analiziyle belirlenen özniteliklerin birlikte değerlendirildiği algoritmalar içerisinde şeftali meyvesini saptamada optimum algoritma olarak, sahip olduğu nispeten düşük yanlış pozitif yüzdesi (%19) ve %84'lük meyve saptama başarısı dikkate alındığında yöntem 2 ile YSA sınıflandırıcının kullandığı algoritma önerilmektedir.



Şekil 4.35. STEPDISC analiziyle belirlenen özniteliklerin birlikte değerlendirildiği algoritmaların yanlış pozitif oranları

4.11. Deneme-Yanılma Yoluyla Belirlenen Özniteliklerin Birlikte Değerlendirildiği Algoritma Denemelerinin Sonuçları

4.11.1. Görüntü tarama yöntemi 1 ile ve deneme-yanılma yoluyla belirlenen özniteliklerin algoritmada birlikte değerlendirildiği denemeler

Şekil 4.36'da deneme-yanılma yoluyla belirlenen özniteliklerin birlikte değerlendirildiği algoritmaların deneme sonuçlarına ilişkin bazı sonuç görüntüleri görülmektedir. Şekilde görülen görüntüler, algoritmaların saptama başarıları yüksek ve düşük (yanlış saptamalar ve saptanmayan meyveler içeren) sonuç görüntülerini içermektedir.



Şekil 4.36. Görüntü tarama yöntemi 1 ile deneme-yanılma yoluyla belirlenen özniteliklerin birlikte değerlendirildiği algoritmaların deneme sonuçlarına ilişkin bazı sonuç görüntüleri

Görüntü tarama yöntemi 1'in kullanıldığı, deneme-yanılma yoluyla belirlenen özniteliklerin birlikte değerlendirildiği algoritmaların deneme sonuçlarına ilişkin başarı oranları Çizelge 4.22'de verilmiştir.

Çizelge 4.22. Deneme-yanılma yoluyla belirlenen özniteliklerin birlikte değerlendirildiği görüntü tarama yöntemi 1'in kullanıldığı algoritmaların eğitim ve test setleri deneme sonuçları

Yöntem 1	Eğitim seti (toplam meyve sayısı: 58)			Test seti (toplam meyve sayısı: 104)		
	Başarıyla saptanan	Yanlış pozitifler	Saptanamayan	Başarıyla saptanan	Yanlış pozitifler	Saptanamayan
	Meyve sayısı	Meyve sayısı	Meyve sayısı	Meyve sayısı	Meyve sayısı	Meyve sayısı
	(%)	(%)	(%)	(%)	(%)	(%)
Diskriminant analizi	50 (0,86)	2 (0,04)	8 (0,14)	78 (0,75)	13 (0,14)	26 (0,25)
K-en-yakın komşu	46 (0,79)	1 (0,02)	12 (0,21)	65 (0,63)	3 (0,04)	39 (0,38)
Sınıflandırma ağacı	45 (0,78)	3 (0,06)	13 (0,22)	62 (0,60)	10 (0,14)	42 (0,40)
Naïve Bayes	38 (0,66)	1 (0,03)	20 (0,34)	45 (0,43)	1 (0,02)	59 (0,57)
Regresyon ağacı	19 (0,33)	0 (0,00)	39 (0,67)	9 (0,09)	1 (0,10)	95 (0,91)
YSA	50 (0,86)	4 (0,07)	8 (0,14)	80 (0,77)	18 (0,18)	24 (0,23)
SVM	44 (0,76)	3 (0,06)	14 (0,24)	64 (0,62)	11 (0,15)	40 (0,38)

Çizelge 4.22 incelendiğinde test seti için en yüksek başarı (%77), sınıflandırıcı olarak YSA'nın kullanıldığı algoritmada elde edilmiştir. En iyi ikinci başarı yüzdesine %75'lik değeriyle diskriminant analizi sınıflandırıcısının kullanıldığı algoritma sahiptir. Bu algoritmalar arasında test seti için en düşük saptama başarısı yüzdesi (%9) regresyon ağacı sınıflandırıcısını kullanan algoritmanındır. Test seti için en yüksek yanlış pozitif yüzdesi (%18) YSA sınıflandırıcısının kullanıldığı algoritmada gözlemlenmiştir. K-en-yakın komşu ve naive Bayes sınıflandırıcılarının kullanıldığı algoritmalar en düşük yanlış pozitif yüzdelerinden (%4 ve %2) sorumludurlar. Görüntü tarama yöntemi 1'in kullanıldığı, Çizelge 4.22'de yer alan algoritmaların bir görüntü için işlem zamanları 72,4 ile 99,5 saniye arasındadır.


Görüntü tarama yöntemi 1'in kullanıldığı algoritmaların farklı aydınlanma koşullarına göre değerlendirildiği, meyve ağaçlarının gölge ve güneşli taraflarından alınmış görüntülere ait deneme sonuçları Çizelge 4.23'de görülmektedir. Test seti için başarıyla saptanan en yüksek meyve yüzdesi %78'lik değeriyle YSA sınıflandırıcısı kullanılan algoritmada güneşli taraf için elde edilmiştir. Ancak bu değer, algoritmanın gölge taraftan alınan görüntüler için başarı yüzdesi olan %76 değerine oldukça yakın bir değerdir. Benzer şekilde diğer sınıflandırıcıların kullanıldığı algoritmaların da güneşli ve gölge taraftan alınan görüntüler için başarı yüzdeleri birbirine oldukça yakındır. Bu, algoritmaların aydınlanma değişimlerinden daha az etkilendiğini göstermektedir.

Çizelge 4.23. Deneme-yanılma yoluyla belirlenen özneliklerin birlikte değerlendirildiği görüntü tarama yöntemi 1'in kullanıldığı algoritmaların test setine ait güneşli ve gölgeli taraflardan alınan görüntülere göre deneme sonuçları

Yöntem 1 (Test seti)	Gölge taraf (toplam meyve sayısı: 45)			Güneşli taraf (toplam meyve sayısı:59)		
	Başarıyla saptanan	Yanlış pozitifler	Saptanamayan	Başarıyla saptanan	Yanlış pozitifler	Saptanamayan
	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)
Diskriminant analizi	34 (0,76)	3 (0,08)	11 (0,24)	44 (0,75)	10 (0,19)	15 (0,25)
K-en-yakın komşu	37 (0,63)	3 (0,08)	22 (0,37)	28 (0,62)	0 (0,00)	17 (0,38)
Sınıflandırma ağacı	33 (0,56)	8 (0,20)	26 (0,44)	29 (0,64)	2 (0,06)	16 (0,36)
Naïve Bayes	29 (0,49)	1 (0,03)	30 (0,51)	16 (0,36)	0 (0,00)	29 (0,64)
Regresyon ağacı	6 (0,10)	1 (0,14)	53 (0,90)	3 (0,07)	0 (0,00)	42 (0,93)
YSA	45 (0,76)	17 (0,27)	14 (0,24)	35 (0,78)	1 (0,03)	10 (0,22)
SVM	36 (0,61)	9 (0,20)	23 (0,39)	28 (0,62)	2 (0,07)	17 (0,38)

4.11.2. Görüntü tarama yöntemi 2 ile deneme-yanılma yoluyla belirlenen özneliklerin algoritmada birlikte değerlendirildiği denemeler

Şekil 4.37’de deneme-yanılma yoluyla belirlenen özneliklerin birlikte değerlendirildiği algoritmaların deneme sonuçlarına ilişkin bazı sonuç görüntüleri görülmektedir. Şekilde görülen görüntüler, algoritmaların saptama başarıları yüksek ve daha düşük (yanlış saptamalar ve saptanmayan meyveler içeren) sonuç görüntülerini içermektedir.



Şekil 4.37. Görüntü tarama yöntemi 2 ile deneme-yanılma yoluyla belirlenen özneliklerin birlikte değerlendirildiği algoritmaların deneme sonuçlarına ilişkin bazı sonuç görüntüleri

Görüntü tarama yöntemi 2'nin kullanıldığı, deneme-yanılma yoluyla belirlenen özneliklerin birlikte değerlendirildiği algoritmaların deneme sonuçlarına ilişkin başarı oranları Çizelge 4.24’de verilmiştir. Çizelge incelendiğinde test seti için en yüksek

başarı (%81) sınıflandırıcı olarak YSA kullanıldığı algoritmada elde edilmiştir. En iyi ikinci başarı yüzdesine %75'lik değeriyle diskriminant analizi sınıflandırıcısının kullanıldığı algoritma sahiptir. Bu algoritmalar arasında test seti için en düşük saptama başarısı yüzdesi (%6) regresyon ağacı sınıflandırıcısını kullanan algoritmanındır. Test seti için en yüksek yanlış pozitif yüzdesi (%23) K-en-yakın komşu sınıflandırıcısının kullanıldığı algoritmada gözlemlenmiştir. Görüntü tarama yöntemi 2'nin kullanıldığı, Çizelge 4.24'de yer alan algoritmaların bir görüntü için işlem zamanları 1,8 ile 12,8 saniye arasındadır.

Görüntü tarama yöntemi 2'nin kullanıldığı algoritmaların farklı aydınlanma koşullarına göre değerlendirildiği, meyve ağaçlarının gölge ve güneşli taraflarından alınmış görüntülere ait deneme sonuçları Çizelge 4.25'te görülmektedir. Test seti için başarıyla saptanan en yüksek meyve yüzdesi %84'lük değeriyle YSA sınıflandırıcısı kullanılan algoritmada güneşli taraf için elde edilmiştir. Aynı sınıflandırıcının kullanıldığı algoritmanın gölge taraftan alınan görüntüler için başarı yüzdesi olan %78'dir.

Çizelge 4.24. Deneme-yanılma yoluyla belirlenen özniteliklerin birlikte değerlendirildiği görüntü tarama yöntemi 2'in kullanıldığı algoritmaların eğitim ve test setleri deneme sonuçları

Yöntem 2	Eğitim seti (toplam meyve sayısı: 58)			Test seti (toplam meyve sayısı: 104)		
	Başarıyla saptanan	Yanlış pozitifler	Saptanamayan	Başarıyla saptanan	Yanlış pozitifler	Saptanamayan
	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)
Diskriminant analizi	54 (0,93)	1 (0,02)	4 (0,07)	78 (0,75)	6 (0,07)	26 (0,25)
K-en-yakın komşu	44 (0,76)	1 (0,02)	14 (0,24)	72 (0,69)	21 (0,23)	32 (0,31)
Sınıflandırma ağacı	39 (0,67)	1 (0,03)	19 (0,33)	43 (0,41)	3 (0,07)	61 (0,59)
Naïve Bayes	34 (0,59)	1 (0,03)	24 (0,41)	30 (0,29)	1 (0,03)	74 (0,71)
Regresyon ağacı	14 (0,24)	0 (0,00)	44 (0,76)	6 (0,06)	0 (0,00)	98 (0,94)
YSA	53 (0,91)	1 (0,02)	5 (0,09)	84 (0,81)	12 (0,13)	20 (0,19)
SVM	39 (0,67)	1 (0,03)	19 (0,33)	43 (0,41)	2 (0,04)	61 (0,59)

Çizelge 4.25. Deneme-yanılma yoluyla belirlenen özneliklerin birlikte değerlendirildiği görüntü tarama yöntemi 2'nin kullanıldığı algoritmaların test setine ait güneşli ve gölgeli taraflardan alınan görüntülere göre deneme sonuçları

Yöntem 2 (Test seti)	Gölge taraf (toplam meyve sayısı: 45)			Güneşli taraf (toplam meyve sayısı:59)		
	Başarıyla saptanan	Yanlış pozitifler	Saptanamayan	Başarıyla saptanan	Yanlış pozitifler	Saptanamayan
	Meyve sayısı	Meyve sayısı	Meyve sayısı	Meyve sayısı	Meyve sayısı	Meyve sayısı
	(%)	(%)	(%)	(%)	(%)	(%)
Diskriminant analizi	43	5	16	35	1	10
	0,73	0,10	0,27	0,78	0,03	0,22
K-en-yakın komşu	39	16	20	33	5	12
	0,66	0,29	0,34	0,73	0,13	0,27
Sınıflandırma ağacı	22	2	37	21	1	24
	0,37	0,08	0,63	0,47	0,05	0,53
Naïve Bayes	19	1	40	11	0	34
	0,32	0,05	0,68	0,24	0,00	0,76
Regresyon ağacı	3	0	56	3	0	42
	0,05	0,00	0,95	0,07	0,00	0,93
YSA	46	10	13	38	2	7
	0,78	0,18	0,22	0,84	0,05	0,16
SVM	23	2	36	20	0	25
	0,39	0,08	0,61	0,44	0,00	0,56

4.11.3. Görüntü tarama yöntemi 3 ile deneme-yanılma yoluyla belirlenen özniteliklerin algoritmada birlikte değerlendirildiği denemeler

Şekil 4.38’de deneme-yanılma yoluyla belirlenen özniteliklerin birlikte değerlendirildiği algoritmaların deneme sonuçlarına ilişkin bazı sonuç görüntüleri görülmektedir. Şekilde görülen görüntüler, algoritmaların saptama başarıları yüksek ve daha düşük (yanlış saptamalar ve saptanmayan meyveler içeren) sonuç görüntülerini içermektedir.



Şekil 4.38. Görüntü tarama yöntemi 3 ile deneme-yanılma yoluyla belirlenen özniteliklerin birlikte değerlendirildiği algoritmaların deneme sonuçlarına ilişkin bazı sonuç görüntüleri

Görüntü tarama yöntemi 3’ün kullanıldığı, deneme yanılma yoluyla belirlenen özniteliklerin birlikte değerlendirildiği algoritmaların deneme sonuçlarına ilişkin başarı oranları Çizelge 4.26’da verilmiştir. Çizelge incelendiğinde test seti için en yüksek

başarı (%71) sınıflandırıcı olarak YSA kullanıldığı algoritmada elde edilmiştir. En iyi ikinci başarı yüzdesine %67'lik değeriyle diskriminant analizi sınıflandırıcısının kullanıldığı algoritma sahiptir. Bu algoritmalar arasında test seti için en düşük saptama başarısı yüzdesi (%9) regresyon ağacı sınıflandırıcısını kullanan algoritmanındır. Test seti için en yüksek yanlış pozitif yüzdesi (%34) diskriminant analizi sınıflandırıcısının kullanıldığı algoritmada gözlemlenmiştir. Görüntü tarama yöntemi 3'ün kullanıldığı, Çizelge 4.26'da yer alan algoritmaların bir görüntü için işlem zamanları 8 ile 35,8 saniye arasındadır.

Görüntü tarama yöntemi 3'ün kullanıldığı algoritmaların farklı aydınlanma koşullarına göre değerlendirildiği, meyve ağaçlarının gölge ve güneşli taraflarından alınmış görüntülere ait deneme sonuçları Çizelge 4.27'de görülmektedir. Test seti için başarıyla saptanan en yüksek meyve yüzdesi %73'lük değeriyle YSA sınıflandırıcısı kullanılan algoritmada güneşli taraf için elde edilmiştir. Aynı sınıflandırıcının kullanıldığı algoritmanın gölge taraftan alınan görüntüler için başarı yüzdesi olan %69'dur.

Çizelge 4.26. Deneme-yanılma yoluyla belirlenen özneliklerin birlikte değerlendirildiği görüntü tarama yöntemi 3'ün kullanıldığı algoritmaların eğitim ve test setleri deneme sonuçları


Yöntem 3	Eğitim seti (toplam meyve sayısı: 58)			Test seti (toplam meyve sayısı: 104)		
	Başarıyla saptanan	Yanlış pozitifler	Saptanamayan	Başarıyla saptanan	Yanlış pozitifler	Saptanamayan
	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)
Diskriminant analizi	46 (0,79)	7 (0,13)	12 (0,21)	70 (0,67)	36 (0,34)	34 (0,33)
K-en-yakın komşu	37 (0,64)	1 (0,03)	21 (0,36)	36 (0,35)	3 (0,08)	68 (0,65)
Sınıflandırma ağacı	33 (0,57)	5 (0,13)	25 (0,43)	37 (0,36)	14 (0,27)	67 (0,64)
Naïve Bayes	32 (0,55)	0 (0,00)	26 (0,45)	21 (0,20)	3 (0,13)	83 (0,80)
Regresyon ağacı	19 (0,33)	0 (0,00)	39 (0,67)	9 (0,09)	0 (0,00)	95 (0,91)
YSA	48 (0,83)	2 (0,04)	10 (0,17)	74 (0,71)	32 (0,30)	30 (0,29)
SVM	34 (0,59)	4 (0,11)	24 (0,41)	44 (0,42)	10 (0,19)	60 (0,58)

Çizelge 4.27. Deneme-yanılma yoluyla belirlenen özneliklerin birlikte değerlendirildiği görüntü tarama yöntemi 3'ün kullanıldığı algoritmaların test setine ait güneşli ve gölgeli taraflardan alınan görüntülere göre deneme sonuçları

Yöntem 3 (Test seti)	Gölge taraf (toplam meyve sayısı: 45)			Güneşli taraf (toplam meyve sayısı:59)		
	Başarıyla saptanan	Yanlış pozitifler	Saptanamayan	Başarıyla saptanan	Yanlış pozitifler	Saptanamayan
	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)	Meyve sayısı (%)
Diskriminant analizi	38 (0,64)	14 (0,27)	21 (0,36)	32 (0,71)	22 (0,41)	13 (0,29)
K-en-yakın komşu	22 (0,37)	3 (0,12)	37 (0,63)	14 (0,31)	0 (0,00)	31 (0,69)
Sınıflandırma ağacı	23 (0,39)	11 (0,32)	36 (0,61)	14 (0,31)	3 (0,18)	31 (0,69)
Naïve Bayes	17 (0,29)	3 (0,15)	42 (0,71)	4 (0,09)	0 (0,00)	41 (0,91)
Regresyon ağacı	7 (0,12)	0 (0,00)	52 (0,88)	2 (0,04)	0 (0,00)	43 (0,96)
YSA	41 (0,69)	11 (0,21)	18 (0,31)	33 (0,73)	21 (0,39)	12 (0,27)
SVM	30 (0,51)	9 (0,23)	29 (0,49)	14 (0,31)	1 (0,07)	31 (0,69)


4.11.4. Deneme-yanılma yoluyla belirlenen özniteliklerin algoritmada birlikte değerlendirildiği algoritmaların performanslarına genel bakış

Şekil 4.39’da deneme-yanılma yoluyla belirlenen özniteliklerin algoritmada birlikte değerlendirildiği algoritmaların meyve saptama yüzdeleri verilmiştir. Şekilde algoritmaların meyve saptama yüzdelerinin kullanılan görüntü tarama yöntemleri üzerine kısmen eşit dağıldığı görülmektedir. Yöntem 1 ve 2’nin kullanıldığı algoritma gruplarının meyve saptama yüzdelerinin yöntem 3’ün kullanıldığı algoritma gruplarınınkinden daha yüksek oldukları görülmektedir.



Şekil 4.39. Deneme-yanılma yoluyla belirlenen özniteliklerin birlikte değerlendirildiği algoritmaların meyve saptama yüzdeleri

Şekil 4.40’ta Deneme-yanılma yoluyla belirlenen özniteliklerin algoritmada birlikte değerlendirildiği algoritmaların yanlış pozitif yüzdeleri görülmektedir. Yanlış pozitif yüzdeleri açısından en kötü performansı meyve tarama yöntemi 3’ün kullanıldığı algoritmalar göstermiştir. Deneme-yanılma yoluyla belirlenen özniteliklerin birlikte değerlendirildiği algoritmalar içerisinde şeftali meyvesini saptamada optimum algoritmalar olarak, yöntem 2 veya 3 ile YSA sınıflandırıcısının kullanıldığı algoritmalar olduğu önerilmektedir.



Şekil 4.40. Deneme-yanılma yoluyla belirlenen özneliklerin birlikte değerlendirildiği algoritmaların yanlış pozitif oranları

4.12. Başarılı ve Yanlış Saptamalar

Gerçekleştirilen şeftali saptama denemelerinde algoritmalar, eğitim ve test setlerindeki meyvelerin hepsini saptayamamışlardır. İstenmeyen yanlış saptamalar da meydana gelmiştir. Bu hatalı sınıflandırmaların temel nedenlerinden bir tanesi genç şeftali meyveleri ve doğal bitki örtüsü görüntülerindeki arka plan nesneleri arasındaki renk benzerliğidir. Doğal bahçe koşullarında alınan görüntülerde bazı yaprak renklerinin genç meyvelerin renklerine oldukça yakın olduğu görülmüştür. Ancak bu durum, hazırlanan meyve saptama algoritmalarının karşılaştığı tek renk kaynaklı zorluk değildir. Bazı toprak, ağaç gövdesi ve dalların renklerinin de genç şeftali meyvelerinkine oldukça yakın olduğu gözlemlenmiştir. Bu yüzden potansiyel meyve bölgelerini çıkarmak ve arka plan bölgelerini elemek üzere renk bilgisini kullanan görüntü tarama yöntemlerinin renk kaynaklı hatalı sınıflandırmaları gerçekleşmiştir.

Tekdüze olmayan aydınlanma, sınıflandırıcıların başarı oranlarını azaltan diğer bir faktördür. Kullanılan aydınlanma iyileştirme yöntemlerine rağmen özellikle kısmen aydınlanan meyveler nedeniyle şekil ve doku bilgisinde bozulmalar gerçekleşmiştir. Ancak sonuçlar göstermiştir ki; çalışmada denenen algoritmaların şeftali ağaçlarının güneşli ve gölgeli taraflarından alınan görüntülerdeki performansları arasında çok

büyük farklılıklar bulunmamaktadır. Bu, geliştirilen algoritmaların aydınlanma değişimlerinden az etkilendiğini göstermektedir.

Üst üste örtüşen nesnelere, doğal bitki örtüsünde genç şeftali meyveleri saptamada karşılaşılan diğer bir zorluktur. Denemelerde yapraklar ve/veya diğer meyveler tarafından yüksek derecede örtülen bazı meyveler algoritmalar tarafından saptanamamıştır. Üst üste örtüşen nesnelere durumu kısmen aydınlatılan meyvelere benzer bir durum oluşturmuştur. Görüntülerde yer alan bazı meyvelerin yüzeyleri yapraklar tarafından parçalara ayrılmıştır. Özellikle potansiyel meyve merkezlerini esas alan görüntü tarama yöntemi 2 ve 3 bu olumsuz koşullardan yöntem 1'e göre daha fazla etkilenmiştir. Parçalara ayrılan meyve yüzeyleri merkezden kaçık potansiyel merkezler oluşturmuş ve bu yüzden sınıflandırıcılar için meyveler, alt-pencere tarafından iyice kapsanamamıştır. Ayrıca görüntü tarama yöntemi 3'ün esas alındığı radyal simetri, tekdüze olmayan aydınlanma esaslı ve üst üste örtüşen nesnelere esaslı bölünmüş meyve yüzeylerinden etkilenmiştir. Yine de geliştirilen algoritmalar bu meyvelerin bazılarını saptayabilmişlerdir.

Geliştirilen algoritmaların performans değerleri incelendiğinde bir miktar başarıyla saptanan meyve yüzdesi pahasına da olsa, algoritmaların çoğunda görüntü tarama yöntemi 2'nin yöntem 1'e kıyasla daha az yanlış pozitif yüzdelere sahip olduğu görülmüştür. Diğer yandan, bazı yaprak ve yaprak kümelerinin meyvelerin şekillerine benzer yapılar oluşturması nedeniyle geliştirilen görüntü tarama yöntemi 3 kendisinden beklenen düşük yanlış saptama yüzdelere verememiştir.

Çalışmada kullanılan sınıflandırıcıların performansları düşünüldüğünde, sınıflandırıcı tipine ilişkin parametrikliğin meyve saptama performansları üzerinde etkili olmadığı görülmektedir. Parametrik olmayan YSA ve parametrik olan diskriminant analizi sınıflandırıcısının kullanıldığı algoritmalar başarılı meyve saptamaları sağlamıştır.

Herhangi bir sınıflandırma görevinde sınıflandırıcının performansı çoğunlukla onun öznitelikler arasındaki gizli ilişkileri açığa çıkarma kabiliyetine bağlıdır. Bu çalışmada kullanılmış olan öznitelikler, şekil ve doku gibi farklı bilgileri temsil etmektedir. Denemesi yapılmış çoğu algoritma grupları içerisinde naive Bayes ve regresyon ağacı

sınıflandırıcılarının kötü performansları gözlemlenmiştir. Öznitelikler arasındaki karmaşık interaksyonlarla başa çıkamadaki yetersizliğinden dolayı özellikle naive Bayes sınıflandırıcısının diğer danışmanlı öğrenme yöntemlerine göre daha az doğru sonuçlar verdiği bilinen bir gerçektir ve sınıflandırma performansını garanti edememektedir. Bu bağlamda YSA ve diskriminant analizi sınıflandırıcıları bu çalışmada kullanılan özniteliklerle daha iyi sonuçlar vermiştir. Bu çalışmada kullanılan sınıflandırıcıların performansları, onların kullanılan öznitelikler arasındaki interaksyonları açığa çıkarma güçlerini açıklamaktadır.

5. SONUÇ

Bu tez çalışmasında şeftali bahçesinde doğal aydınlanma koşullarında alınmış görüntüler kullanılarak, gelişimlerinin erken safhasındaki olgunlaşmamış şeftali meyvelerini renkli görüntülerde saptayarak sayan bilgisayarlı görü algoritmaları geliştirilmiştir. Çalışmada histogram eşitleme ve logaritma dönüşümü gibi görüntü işleme tekniklerinden yararlanılarak doğal koşullarda alınmış görüntülerin aydınlanma koşulları zenginleştirilmiştir. Görüntü işleme tekniklerinden yararlanarak geliştirilen algoritmalar renk, şekil ve doku bilgisini kullanılan öznitelik çıkarma yöntemleriyle görüntülerden çıkarmışlardır. Bu çalışmada kullanılan öznitelik çıkarma yöntemleri, olgunlaşmamış şeftali bitkisini renkli görüntülerde saptama anlamında yenidirler. Ayrıca bu tez çalışmasının yazıldığı tarih itibariyle, olgun ya da olgunlaşmamış şeftali meyvesini bilgisayarlı görü ve görüntü işleme teknikleriyle saptayarak sayma amaçlı literatürde bir başka çalışmaya rastlanmamıştır.

Bu çalışmada şeftali meyvesini bulmak üzere görüntüler, görüntü işleme teknikleri kullanılarak potansiyel meyve bölgelerini ortaya koymayı da içeren geliştirilen farklı görüntü tarama yöntemleriyle taranmışlardır. Potansiyel meyve bölgelerini temsil eden alt-pencereler diskriminant analizi, K-en-yakın komşu, naive Bayes, regresyon ağaçları, sınıflandırma ağaçları, yapay sinir ağları ve destek vektör makinası sınıflandırıcılarıyla meyve ve arka plan olarak sınıflandırılmışlardır. Çalışmada aynı meyveye ait çoklu saptamalar blob analizi tekniğiyle tekilleştirilerek görüntülerdeki meyvelerin sayımı yapılmıştır.

Farklı öznitelik setleri istatistiksel ve deneysel yollarla belirlenerek farklı görüntü tarama yöntemleriyle birçok algoritma geliştirilmiştir. Geliştirilen algoritmaların eğitim ve test setlerinde denemeleri gerçekleştirilmiştir. Algoritmaların şeftali ağaçlarının güneşli ve gölge tarafından alınmış görüntülerde performansları ortaya konularak değerlendirilmiştir. Olgunlaşmamış şeftaliyi doğal bitki örtüsü görüntülerinde saptama görevinin tek düze olmayan aydınlanma ve nesnelerin üst üste örtüşmesi gibi kendine özgü zorluklarına rağmen, ortaya konulan algoritmaların test seti için %85'ler düzeyinde saptama başarısıyla olgunlaşmamış şeftalileri saptayabildikleri görülmüştür.

Çalışmada GLCM ve *özmeyve* özneliklerinin kademeli değerlendirildiği algoritma denemelerinin performanslarına bakıldığında görüntü tarama yöntemi 1 için başarılı saptama performansları % 85'ler düzeyinde olsa da bu algoritma gruplarında yanlış pozitif yüzdeleri oldukça yüksektir. Daha az yanlış pozitif yüzdelere sahip görüntü tarama yöntemi 2'nin kullanıldığı algoritmaların ise başarılı saptama yüzdeleri oldukça düşük seviyededir. Görüntü tarama yöntemi 3 ise bu algoritma grubunda diğer iki görüntü tarama yöntemine göre hem başarılı saptama hem de yanlış pozitif yüzdeleri açısından daha düşük performanslar göstermişlerdir. Bu yüzden GLCM ve *özmeyve* özneliklerinin kademeli değerlendirildiği algoritma grupları içerisinde herhangi bir algoritma başarılı olarak önerilememektedir.

Özmeyve ve Gabor doku özneliklerinin birlikte değerlendirildiği algoritma denemelerinin performanslarına bakılırsa, %85'lik başarılı saptama yüzdeleri ve yaklaşık %25'lerde olan yanlış pozitif yüzdelere sahip görüntü tarama yöntemi 1 ile diskriminant analizi, YSA ve SVM'nin kullanıldığı algoritmalar ve %78'lik başarılı saptama yüzdeleri ve %7'lik yanlış pozitif yüzdesine sahip görüntü tarama yöntemi 2 ile diskriminant analizinin kullanıldığı algoritma önerilebilir.

STEPDISC analiziyle belirlenen özneliklerin birlikte değerlendirildiği algoritma grubu içerisinde ise görüntü tarama yöntemi 2'nin kullanıldığı algoritmalarda daha başarılı performanslar elde edilmiştir. Bu algoritma grubu içerisinde %84'lük başarılı saptama yüzdesi ve %19'lük yanlış pozitif yüzdesi değerine sahip sınıflandırıcı olarak YSA'nın kullanıldığı algoritma önerilebilir.

Deneme-yanılma yoluyla belirlenen özneliklerin birlikte değerlendirildiği algoritma gruplarında ise en yüksek performansı %81'lik başarılı saptama yüzdesi ve %13'lük yanlış pozitif yüzdesi değerine sahip görüntü tarama yöntemi 2 ile sınıflandırıcı olarak YSA'nın kullanıldığı algoritmada sağlanmıştır. Bu algoritma ile beraber görüntü tarama yöntemi 2 ile diskriminant analizi sınıflandırıcısının kullanıldığı %75'lik başarılı saptama yüzdesi ve %7'lik yanlış pozitif yüzdesi değerine sahip algoritma, görüntü tarama yöntemi 1 ile diskriminant analizi ve YSA'nın kullanıldığı algoritmalar önerilebilir.

Bu tez çalışmasında elde edilen algoritma performanslarının doğrudan karşılaştırılabileceği olgunlaşmamış şeftali meyvesinin doğal bahçe ortamında alınmış renkli görüntülerde saptanması üzerine yapılmış benzer bir çalışmaya rastlanmamıştır. Ancak bazı araştırmacıların multispektral, hiperspektral ve termal görüntüleme gibi oldukça pahalı sistemleri kullanarak portakal ve elma gibi meyveler için yaptıkları çalışmalar mevcuttur. Daha önce yapılan diğer tür çalışmalar ise bu çalışmada kullanılan standart CCD görüntüleme tekniği ile renk ayırımı bariz yapılabilen olgun meyveleri saptayan algoritmaların geliştirilmesini içermektedir. Önceki çalışmalar kısmında özetleri verilmiş olan bu çalışmaların çarpıcı sonuçlar içeren bazılarında yapılanlar kısaca şu şekildedir:

- Bulanon ve ark. (2004) CCD görüntüleme tekniği ile olgun elmaların %80'ini başarıyla saptadıklarını bildirmişlerdir.
- Okamoto ve Lee (2009) hiperspektral görüntüleme kullanarak olgunlaşmamış portakalların %89'unu başarıyla saptadıklarını bildirmişlerdir.
- Mao ve ark. (2009) CCD görüntüleme tekniği ile olgun elmaların %90'ını başarıyla saptadıklarını bildirmişlerdir.
- Wachs ve ark. (2009) termal görüntüleme kullanarak yeşil elmaların %74'ünü başarıyla saptadıklarını bildirmişlerdir.
- Chinchuluun ve Lee (2006) CCD görüntüleme tekniği ile olgun portakalların %83'ünü saptayabilmişlerdir.
- Tabb ve ark. (2006) CCD görüntüleme tekniği ile kırmızı olgun elmaların %90'ını başarıyla saptadıklarını bildirmişlerdir.
- Kane ve Lee (2007) multispektral görüntüleme tekniği kullanarak olgunlaşmamış portakalların %84,5'ini başarıyla saptadıklarını bildirmişlerdir.
- Safren ve ark. (2007) hiperspektral görüntüleme tekniği kullanarak yeşil elmaların %88,1'ini başarıyla saptadıklarını bildirmişlerdir.

Bu çalışmalarda bildirilen meyve saptama performansları ve görüntü işleme ve bilgisayarlı görü teknikleriyle şeftali saptama ve sayımı için gerçekleştirilen bu ilk

alıřmada ortaya konulan algoritmaların %85'lerdeki saptama başarıları dikkate alındığında, olgunlaşmamıř řeftali meyvesinin doęal bahe kořullarında standart CCD grntleme yntemi kullanımıyla saptanabilmesinin umut verici olduęu sonucu ortaya ıkmaktadır. Bir mobil platform zerine monte edilmiř kameralardan oluřan bir erken verim haritalama sistemi, bu tarz algoritma geliřtirme alıřmaları iin en son hedeftir. Eksiksiz bir verim haritalama sistemi oluřturmak iin daha fazla alıřmaya gereksinim duyulmaktadır.

KAYNAKLAR

- Acar, E. 2012.** Yapay zeka yöntemleriyle bitki yaprak imgelerinde pas hastalıklarının tespiti. *Yüksek Lisans Tezi*, DÜ Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği Anabilim Dalı, Diyarbakır.
- Acar, E., Özerdem, M.S. 2012.** Kızıltepe tarımsal alan imgelerinin ekinin ürün gelişimine göre sınıflandırılması. *TBV Bilgisayar Bilimleri ve Mühendisliği Dergisi*, 5:21-30.
- Aggelopoulou, A.D., Bochtis, D., Fountas, S., Swain, K.C., Gemtos, T.A., Nanos, G.D. 2011.** Yield prediction in apple orchards based on image processing. *Precision Agriculture*, 12(3):448-456.
- Akar, F., 2009.** Şablon eşleme yöntemi ile plaka tanıma ve değerlendirme sistemi. *Doktora Tezi*, AÜ Fen Bilimleri Enstitüsü, Matematik Anabilim Dalı, Erzurum.
- Al-Mallahi, A., Kataoka, T., Okamoto, H., Shibata, Y. 2010.** An image processing algorithm for detecting in-line potato tubers without singulation. *Computers and Electronics in Agriculture*, 70:239-244.
- Annamalai, P., Lee, W.S. 2004.** Color vision system for estimating citrus yield in real-time. ASAE/CSAE Annual International Meeting Sponsored by ASAE/CSAE Fairmont Chateau Laurier, 1 - 4 August, 2004, The Westin, Government Centre Ottawa, Ontario, Canada.
- Anonim, 2012a.** Converting color data between color spaces. http://www.mathworks.com/help/images/converting-color-data-between-color-spaces.html#brcr25t?s_tid=doc_12b – (Erişim tarihi: 26.10.2012)
- Anonim, 2012b.** Classifiers and discriminants. http://computervision.wikia.com/wiki/Classifiers_and_Discriminants. – (Erişim tarihi: 26.10.2012).
- Arivazhagan, S., Ganesan, L., Priyal, S.P. 2006.** Texture classification using Gabor wavelets based rotation invariant features. *Pattern Recognition Letters*, 27:1976–1982.
- Bae, H., Kim, S. 2005.** Real-time face detection and recognition using hybrid information extracted from face space and facial features. *Image and Vision Computing*, 23:1181–1191.
- Baykan, Ö.K. 2007.** Bilgisayar destekli un kalite izleme sistemi tasarımı. *Doktora Tezi*, SÜ Fen Bilimleri Enstitüsü, Elektrik – Elektronik Mühendisliği Anabilim Dalı, Konya
- Bottou, L., Lin, C.J., 2007.** Support vector machine solvers. In: Bottou, L., Chapelle, O., DeCoste, D., Weston, J. (Eds.), *Large-Scale Kernel Machines*. Neural Information Processing. MIT Press, Cambridge, MA, USA, 1-28 pp.
- Bovik, A. 2009.** The essential guide to image processing. Elsevier Inc., 853 pp.
- Breiman, L., Friedman, J., Olshen, R., Stone, C. 1984.** Classification and regression trees. Chapman & Hall, Belmont, California, 95pp.
- Buemi, F., Massa M., Sandini, G. 1995.** Agrobot: a robotic system for greenhouse operations. 4th Workshop on robotics in Agriculture, IARP, Toulouse, 172-184.
- Bulanon, D.M., Burks, T.F., Alchanatis, V. 2009.** Fruit visibility analysis for robotic citrus harvesting. *Transactions of the ASABE*, 52(1):277-283.
- Bulanon, D.M., Kataoka, T. 2010.** Fruit detection system and an end effector for robotic harvesting of Fuji apples. *Agric Eng Int: CIGR Journal*, 12(1):203–210.
- Bulanon, M., Kataoka, T., Okamoto, H., Hata, S. 2004.** Development of a real-time machine vision system for the apple harvesting robot, SICE 2004 Annual Conference, 4-6 August, 2004, Japan.

- Chamelat, R., Rosso, E., Choksuriwong, A., Rosenberger, C., Laurent, H., Bro, P. 2006.** Grape detection by image processing. ECON 2006 - 32nd Annual Conference on IEEE Industrial Electronics, 7-10 November, 2006, Paris, France.
- Chen, W., Er, M.J., Wu, S., 2006.** Illumination compensation and normalization for robust face recognition using discrete cosine transform in logarithm domain. *IEEE Transactions on Systems, Man, and Cybernetics B*, 36(2):458-466.
- Cheng, Y., Hou, Y., Zhao, C., Li, Z., Hu, Y., Wang, C. 2010.** Robust face recognition based on illumination invariant in nonsubsampling contourlet transform domain. *Neurocomputing*, 73:2217–2224.
- Childers, N.F., Morris, J.R., Sibbett, G.S. 1995.** Modern fruit science orchard and small fruit culture. Horticultural Publications, Gainesville FL, 583 pp.
- Chinchuluun, R., Lee, W.S. 2006.** Citrus yield mapping system in natural outdoor scenes using the watershed transform. 2006 ASABE Annual International Meeting Sponsored by ASABE, 9 - 12 July, 2006, Portland, Oregon.
- Clausi, D.A. 2002.** An analysis of co-occurrence texture statistics as a function of grey level quantization. *Can. J. Remote Sensing*, 28(1):45-62.
- Çulha, S. 1996.** Sayısallaştırılmış bilgisayarlı tomografi ve magnetik rezonans tomogramları üzerinde görüntü işleme tekniği uygulamaları. *Yüksek Lisans Tezi*, AÜ Fen Bilimleri Enstitüsü, Elektronik Mühendisliği Anabilim Dalı, Ankara.
- Deconinck, E., Sacréa, P.Y., Coomans, D., De Beer J. 2012.** Classification trees based on infrared spectroscopic data to discriminate between genuine and counterfeit medicines. *Journal of Pharmaceutical and Biomedical Analysis*, (57):68– 75.
- Ess, D., Morgan, M.M. 2003.** The precision-farming guide for agriculturists: the nuts and bolts guide to "getting up to speed" fast and effectively with this exciting new management tool. Moline, Ill, Deere & Co, 137 pp.
- FAO 2010.** <http://faostat.fao.org/site/567/DesktopDefault.aspx?PageID=567#ancor>
- Forsyth, D.A., Ponce, J. 2003.** Computer vision: a modern approach. Prentice Hall, 813 pp.
- Gabor, D. 1946.** Theory of communication. *Journal of the Institution of Electronics and Engineers*, 93: 429–457.
- Gonzalez, R.C., Woods, R.E. 2002.** Digital image processing. Prentice-Hall, Inc. Upper Saddle River, New Jersey, 793 pp.
- Gonzalez, R.C., Woods, R.E., Eddins, S.L. 2004.** Digital image processing using Matlab. Dorling Kindersley, 2004.
- Guo, Y., Hastie, T., & Tibshirani, R. 2005.** Regularized discriminant analysis and its application in microarrays. *Biostatistics*, 1(1):1–18.
- Gupta, V., Singh, G., Mittal, M., Pahuja, S.K. 2010.** Fourier transform of untransformable signals using pattern recognition technique. The 2nd International Conference on Advances in Computing, Control, and Telecommunication Technologies (ACT 2010), 2-3 Dec, 2010, Washington, DC, USA.
- Han, J., Ma, K.K. 2007.** Rotation-invariant and scale-invariant Gabor features for texture image retrieval. *Image and Vision Computing*, 25:1474–1481.
- Hannan, M.W., Burks, T.F., Bulanon, D.M., 2009.** A machine vision algorithm combining adaptive segmentation and shape analysis for orange fruit detection. *Agricultural Engineering International: CIGR Journal XI*, Manuscript 1281.
- Haralick, R.M., Shanmugam, K., Dinstein, I. 1973.** Textural features of image classification, *IEEE Transactions on Systems, Man and Cybernetics*, 3(6):610–621.

- Hayashi, S., Ganno, K., Ishii, Y., Tanaka, I. 2002.** Robotic harvesting system for eggplants. *JARQ* 36(3): 163 – 168.
- Jaehne, B. 1997.** Practical handbook on image processing for scientific and technical applications, CRC-Press, 608 pp.
- Kane, K.E., Lee W.S. 2007.** Multispectral imaging for in-field green citrus identification. 2007 ASABE Annual International Meeting Sponsored by ASABE, 17 - 20 June, 2007, Minneapolis, Minnesota.
- Karakuş, D. 2006.** Görüntü analiz yöntemleri ile kayaçların yapısal özelliklerinin tanımlanması. *Doktora Tezi*, DEÜ Fen Bilimleri Enstitüsü, Maden İşletme Anabilim Dalı, İzmir.
- Kavdır, İ., Guyer, D.E. 2004.** Comparison of artificial neural networks and statistical classifiers in apple sorting using textural features, *Biosystems Engineering*, 89(3):331–344.
- Kecman, V. 2001.** Learning and soft computing, MIT Press, Cambridge, MA, 541 pp.
- Keuchel, J., Naumann, S., Heiler, M., Siegmund, A. 2003.** Automatic land cover analysis for teneife by supervised classification using remotely sensed data. *Remote Sensing of Environment*, 86(4):530-541.
- Kirişçi, V., Keskin, M., Say, S.M., Keskin, S.G. 1999.** Hassas uygulamalı tarım teknolojisi. Nobel Yayın Dağıtım, Ankara, 186 s.
- Kitamura, S., Oka, K. 2005.** Recognition and cutting system of sweet pepper for picking robot in greenhouse horticulture. Proceedings of the IEEE International Conference on Mechatronics & Automation, 29 July-1 Aug. 2005, Niagara Falls, Canada.
- Kurtulmuş, F., Lee, W.S., Vardar, A. 2011.** Green citrus detection using eigenfruit, color and circular Gabor texture features under natural outdoor conditions. *Computers and Electronics in Agriculture*, 78(2): 140-149.
- Lei, B.J., Hendriks, E.A., Reinders, M.J.T. 1999.** On feature extraction from images. Technical Report, MCCWS Project, Information and Communication Theory Group, Tudeft.
- Levi P., Falla, R., Pappalardo, R. 1988.** Image controled robotics applied to citrus fruit harvesting. Procedures ROVISEC-VII, Zurich.
- Li, M., Staunton, R.C. 2008.** Optimum Gabor filter design and local binary patterns for texture segmentation. *Pattern Recognition Letters*, 29:664–667.
- Linker, R., Cohen, O., Naor, A. 2012.** Determination of the number of green apples in RGB images recorded in orchards. *Computers and Electronics in Agriculture*, 81:45–57.
- Linker, R., Kelman, E. 2011.** Fruit localization using artificial vision and shape analysis. 2011 ASABE Annual International Meeting Sponsored by ASABE, 7 – 10 August, 2011, Kentucky.
- Loy, G., Zelinsky, A. 2003.** Fast Radial symmetry for detecting points of interest. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 25(8): 959-973.
- Mao, W., Jia, B., Zhang, X., Hub, X. 2009.** Detection and position method of apple tree image. *Computer and Computing Technologies in Agriculture II, IFIP Advances in Information and Communication Technology* 294:1039-1048.
- Mathworks 2012.** Discriminant Analysis. <http://www.mathworks.com/help/stats/discriminant-analysis.html> - (Erişim tarihi: 26.10.2012).
- Mitchell, T.M. 1997.** Machine learning. McGraw Hill, New York, 432 pp.

- Mohideen, S.K., Perumal, S.A., Sathik, M.M. 2008.** Image de-noising using discrete wavelet transform. *IJCSNS International Journal of Computer Science and Network Security*, January 2008, Korea.
- Moonrinta, J., Chaivivatrakul, S., Dailey, M.N., Ekpanyapong, M. 2010.** Fruit detection, tracking, and 3D reconstruction for crop mapping and yield estimation. 11th International Conference on Control, Automation, Robotics and Vision (ICARCV), 7-10 December 2010, Singapore.
- Morimoto, T., Takeuchi, T., Miyata, H., Hashimoto, Y. 2000.** Pattern recognition of fruit shape based on the concept of chaos and neural networks. *Computers and Electronics in Agriculture*, 26:171–186.
- Nixon, M.S., Aguado, A.S. 2002.** Feature extraction and image processing. Newnes, 350 pp.
- Nuske, S., Achar, S., Bates, T., Narasimhan, S., Singh, S. 2011.** Yield estimation in vineyards by visual grape detection. International Conference on Intelligent Robots and Systems (IROS 2011), 25-30 September, 2011, Piscataway, NJ, USA.
- Okamoto, H., Lee, W.S. 2009.** Green citrus detection using hyperspectral imaging. *Computers and Electronics in Agriculture*, 66(2): 201-208.
- Özbek, S. 1978.** Özel meyvecilik (kışın yaprağını döken meyve türleri). Çukurova Üniversitesi, Ziraat Fakültesi Yayınları, Ders Kitabı No: 128, 485 s.
- Parrish, E., Goksel A.K. 1977.** Pictorial pattern recognition applied to fruit harvesting. *Transactions of the ASAE*, 20:822-827.
- Patel, H.N., Jain, R.K., Joshi, M.V. 2011.** Fruit detection using improved multiple features based algorithm. *International Journal of Computer Applications*, 13(2):1–5.
- Pla F., Juste, F., Ferri, F. 1993.** Feature extraction of spherical objects in image analysis: an application to robotic citrus harvesting. *Computers and Electronics in Agriculture*, 8:57-72.
- Pratt, W.K. 2007.** Digital image processing: PIKS scientific inside. John Wiley & Sons, 812 pp.
- Qiang, L., Huazhu, L., Jianrong, C., Jiewen, Z., Yongping, L., Fang, Z. 2010.** Feature extraction of near-spherical fruit with partial occlusion for robotic harvesting. *Maejo Int. J. Sci. Technol.*, 4(03):435-445.
- Qingbing, Z., Chengliang, L., Yubin, M., Shiping, W., Danfeng, H. 2009.** Non-destructive measurement of diameter of overlapping grape fruit based on morphological image processing. *Transactions of the Chinese Society of Agricultural Engineering*, 25(9):356-360.
- Questier, F., Put, R., Coomans, D., Walczak, B., Heyden, Y.V. 2005.** The use of CART and multivariate regression trees for supervised and unsupervised feature selection. *Chemometrics and Intelligent Laboratory Systems*, (76): 45– 54.
- Rakun, J., Stajko, D., Zazula, D. 2011.** Detecting fruits in natural scenes by using spatial-frequency based texture analysis and multiview geometry. *Computers and Electronics in Agriculture* 76 (1):80-88.
- Regunathan, M., Lee, W.S. 2005.** Citrus yield mapping and size determination using machine vision and ultrasonic sensors. ASAE Annual International Meeting Sponsored by ASAE, 17 - 20 July, 2005, Tampa Convention Center Tampa, Florida.
- Reis, M.J.C.S., Morais, R., Peres, E., Pereira, C., Contente, O., Soares, S., Valente, A., Baptista, J., Ferreira, P.J.S.G., Cruz, J.B. 2012.** Automatic detection of bunches of grapes in natural environment from color images. *Journal of Applied Logic*, In Press.
- Russ, J.C. 2011.** The image processing handbook. CRC Press, 838 pp.

- Safren, O., Alchanatis, V., Ostrovsky, V., Levi, O. 2007.** Detection of green apples in hyperspectral images of apple-tree foliage using machine vision. *Transactions of the ASABE* 50(6):2303-2313.
- Savvides, M., Kumar, V. 2003.** Illumination normalization using logarithm transforms for face authentication. *In: Proc. IAPR AVBPA*, 2688:549–556.
- Sengupta, S., Lee, W.S. 2012.** Recognition of immature green citrus fruit under different outdoor conditions. International Conference of Agricultural Engineering CIGR-AgEng2012, 8-12 July, 2012, Valencia, Spain.
- Sharma, A., Dubey, A., Tripathi, P., Kumar, V. 2010.** Pose invariant virtual classifiers from single training image using novel hybrid-eigenfaces. *Neurocomputing*, 73:1868–1880.
- Sirovich, L., Kirby, M. 1987.** Low-dimensional procedure for the characterization of human faces. *Journal of the Optical Society of America A: Optics, Image Science, and Vision*, 4:519–524.
- Smith, B. 2012.** Bicubic, bilinear and nearest neighbour image interpolation. <http://www.engr.mun.ca/~baxter/Publications/ImageZooming.pdf> - (Erişim tarihi: 26.10.2012).
- Soh, L., Tsatsoulis, C. 1999.** Texture analysis of SAR sea ice imagery using gray level co-occurrence matrices. *IEEE Transactions on Geoscience and Remote Sensing*, 37(2):780–795.
- Stajnik, D., Lakota, M., Hovear, M. 2004.** Estimation of number and diameter of apple fruits in an orchard during the growing season by thermal imaging. *Computers and Electronics in Agriculture*, 42:31–42.
- Swanson, M., Dima, C., Stentz, A. 2010.** A multi-modal system for yield prediction in citrus trees. 2010 ASABE Annual International Meeting Sponsored by ASABE, 20-23 June, 2010, Pittsburgh, Pennsylvania.
- Tabb, A.L., Peterson, D.L., Park, J. 2006.** Segmentation of apple fruit from video via background modeling. 2006 ASABE Annual International Meeting Sponsored by ASABE, 9 - 12 July, 2006, Portland, Oregon.
- Turk, M., Pentland, A. 1991.** Eigenfaces for recognition. *Journal of Cognitive Neuroscience*, 3:71–86.
- Vapnik, V. 1995.** The nature of statistical learning theory. Springer-Verlag, New York, 314 pp.
- Vatandaş, M., Güner, M., Türker, U. 2005.** Hassas tarım teknolojileri. TMMOB Ziraat Mühendisleri Odası VI. Teknik Kongresi, 3-7 Ocak, 347-365, Milli Kütüphane, Ankara.
- Vishwakarma, V.P., Pandey, S., Gupta, M.N. 2009.** Adaptive histogram equalization and logarithm transform with rescaled low frequency DCT coefficients for illumination normalization. *International Journal of Recent Trends in Engineering*, Issue on Computer Science, 1:318–322.
- Vural, H., Turhan, Ş. 2011.** Bursa ilinde şeftali üretiminin ekonometrik analizi. *Uludağ Üni. Ziraat Fakültesi Dergisi*, 25:(2), 1-6.
- Wachs, J.P., Stern, H.I., Burks, T., Alchanatis, V. 2009.** Apple detection in natural tree canopies from multimodal images. 7th ECPA, European Conference on Precision Agriculture, 6-8 July, 2009, Wageningen, Netherlands.
- Wang, Q., Nuske, S., Bergerman, M., Singh, S., 2012a.** Design of crop yield estimation system for apple orchards using computer vision. 2012 ASABE Annual International Meeting Sponsored by ASABE, 29 July – 1 August, 2012, Dallas, Texas.

- Weldon, T.E., Higgins, W.E., Dunn, D.E. 1996.** Efficient Gabor filter design for texture segmentation. *Pattern Recognition*, 29:2005–2015.
- Whittaker, A.D., G. E. Miles, G.E., Mitchell, O.R., Gaultney, L.D. 1987.** Fruit location in a partially occluded image. *Transactions of the ASAE*, 30:591-597.
- Wong, K.W., Lam, K.M., Siu, W.C. 2001.** An efficient algorithm for human face detection and facial feature extraction under different conditions. *Pattern Recognition*, 34:1993–2004.
- Xiang, D., Tian, J., Deng, K., Zhang, X., Yang, F., Wan, X. 2011.** Retinal vessel extraction by combining radial symmetry transform and iterated graph cuts. 3rd Annual International Conference of the IEEE EMBS, 30 August - 3 September, 2011, Boston, Massachusetts USA.
- Xiaohua, L., Lam, K.M., Lansun, S., Jiliu, Z. 2009.** Face detection using simplified Gabor features and hierarchical regions in a cascade of classifiers. *Pattern Recognition Letters*, 30:717–728.
- Yakar, E. 2006.** SAR görüntülerinde benek gürültüsünün giderilmesi için çoklu-dalgacık dönüşümüne dayalı yeni bir yaklaşım. *Yüksek Lisans Tezi*, İTÜ Fen Bilimleri Enstitüsü, Elektronik ve Haberleşme Mühendisliği Anabilim Dalı, İstanbul.
- Yang, C., Lee, W.S. 2012.** Blueberry fruit detection by Bayesian classifier and support vector machine based on visible to near-infrared multispectral imaging. 2012 ASABE Annual International Meeting Sponsored by ASABE, 29 July – 1 August, 2012, Dallas, Texas.
- Yang, L., Dickinson, J., Wu, Q.M.J., Lang, S. 2007.** A fruit recognition method for automatic harvesting. 14th International Conference on Mechatronics and Machine Vision in Practice, 3 - 5 December, 2007, Xiamen, China.
- Yongsheng, S., Jun, Q., Gang, L., Zhaoxiang, L., Rui, G. 2009.** Recognition and shape features extraction of apples based on machine vision. *Transactions of the Chinese Society for Agricultural Machinery* 40(8):161-165.
- Yuan, T., Li, W., Feng, Q., Zhang, J. 2010.** Spectral imaging for greenhouse cucumber fruit detection based on binocular stereovision. 2010 ASABE Annual International Meeting Sponsored by ASABE, 20-23 June, 2010, Pittsburgh, Pennsylvania.
- Zhang, D.S., Lu, G. 2000.** Content-based image retrieval using gabor texture features. The first IEEE Pacific-Rim Conference on Multimedia, 13-15 December, 2000, NSW, Australia.
- Zhang, J., Tan, T., Ma, Li., 2002.** Invariant texture segmentation via circular Gabor filters. 16th International Conference on Pattern Recognition (ICPR 2002), 11-15 August 2002, Quebec, Canada.
- Zhao, J., Tow, J., Katupitiya, J. 2005.** On-tree fruit recognition using texture properties and color data. Intelligent Robots and Systems (IROS 2005), IEEE/RSJ International Conference, 2-6 Aug. 2005, Edmonton, Alberta, Canada.
- Zhang, L., Yang, Q., Xun, Y., Chen, X., Ren, Y., Yuan, T., Tan, Y., Li, W. 2007.** Recognition of greenhouse cucumber fruit using computer vision. *New Zealand Journal of Agricultural Research*, 50:1293–1298.
- Zhou, R., Damerow, L., Sun, Y., Blanke, M.M. 2012.** Using colour features of cv. ‘Gala’ apple fruits in an orchard in image processing to predict yield. *Precision Agriculture*, 13(5):568-580.

ÖZGEÇMİŞ

Adı Soyadı : Ferhat KURTULMUŞ
Doğum Yeri ve Tarihi : Bursa 14.12.1980
Yabancı Dili : İngilizce

Eğitim Durumu (Kurum ve Yıl)

Lise : Bursa Erkek Lisesi 1997
Lisans : U.Ü. Ziraat Fakültesi 2002
Yüksek Lisans : U.Ü. Ziraat Fakültesi 2007
Çalıştığı Kurum/Kurumlar ve Yıl : U.Ü. Ziraat Fakültesi 2006-....
İletişim (e-posta) : ferhatk@uludag.edu.tr
Yayımları :

Izli, N., Vardar, A., Kurtulmus, F. 2007. A study on aerodynamic properties of some naca profiles used on wind turbine blades. *Journal of Applied Science*, 7(3): 426-433.

Kurtulmus, F., Vardar, A., Izli, N. 2007. Aerodynamic analyses of different wind turbine blade profiles. *Journal of Applied Science*, 7(5): 663-670.

Vardar, A., İzli, N., Kurtulmuş, F. 2010. Aerodynamic Performance of Some Wind Turbine Rotor Models. *U.Ü. Ziraat Fakültesi Dergisi*, 24(2): 1-9.

Kurtulmuş, F., Lee, W.S., Vardar, A. 2011. Green citrus detection using ‘eigenfruit’, color and circular Gabor texture features under natural outdoor conditions. *Computers and Electronics in Agriculture*, 78: 140–149.

Kurtulmuş, F., Lee, W.S., Vardar, A. 2011. An advanced green citrus detection algorithm using color images and neural networks. *Tarım Makinaları Bilimi Dergisi (Journal of Agricultural Machinery Science*, 7 (2): 145-151.

Vardar, A., Kurtulmuş, F., Darga, A., 2011. Local indications of climate changes in Turkey: Bursa as a case example. *Climatic Change*. 106: 255-266.

Vardar, A., Eker, B., Durgut, M.R., Okur, E., Kurtulmuş, F. 2011. Modeling studies on the relation between wind speed and height: Tekirdag sample. *Energy Education Science and Technology Part A: Energy Science and Research*, 27(2): 383-388.