

**T.C.
İNÖNÜ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**MALATYA'DAKİ KAYISI REKOLTESİNİN BİLGİSAYAR GÖRMESİ
TEKNİKLERİYLE HESAPLANMASI**

Mahdi HATAMI VARJOVI

**YÜKSEK LİSANS TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI**

**AĞUSTOS 2017
MALATYA**

Tezin Bařlıđı: Malatya'daki Kayısı Rekoltesinin Bilgisayar Grmesi Teknikleriyle Hesaplanması

Tezi Hazırlayan: Mahdi HATAMI VARJOVI

Sınav Tarihi: 02.08.2017

Yukarıda adı geen tez jrimizce deđerlendirilerek Bilimleri Mhendisliđi Ana Bilim Dalında Yksek Lisans Tezi olarak kabul edilmiřtir.

Sınav Jri yeleri

Tez Danıřmanı: Do. Dr. Muhammed Fatih TALU
İnn niversitesi

Prof. Dr. Ali KARCI
İnn niversitesi

Do. Dr. İlhan AYDIN
Fırat niversitesi

Prof. Dr. Halil İbrahim ADIGZEL
Enstit Mdr

ONUR SÖZÜ

Yüksek Lisans Tezi olarak sunduđum “Malatya’daki Kayısı Rekoltesinin Bilgisayar Görmesi Teknikleriyle Hesaplanması” başlıklı çalışmanın bilimsel ahlak ve geleneklere aykırı düşecek bir yardıma başvurmaksızın tarafımdan yazıldığını ve yararlandığım bütün kaynakların, hem metin içinde hem de kaynakçada yöntemine uygun biçimde gösterilenlerden oluştuđunu belirtir, bunu onurumla doğrularım.

Mahdi HATAMI VARJOVI

ÖZET

Yüksek Lisans Tezi

MALATYA'DAKİ KAYISI REKOLTESİNİN BİLGİSAYARA GÖRMESİ TEKNİKLERİ İLE HESAPLANMASI

Mahdi Hatami Varjovi

İnönü Üniversitesi

Fen Bilimleri Enstitüsü

Bilgisayar Mühendisliği Ana Bilim Dalı

60 + xi sayfa

2017

Danışman: Doç. Dr. Muhammed Fatih Talu

Kayısı, fındık, üzüm ve incir gibi ürünlerde ülkemiz, dünya genelinde önemli bir üretim potansiyeline sahiptir. Örneğin dünya kuru kayısı üretiminin yaklaşık %74'ü ülkemizde yapılmakta ve bu üretimin %85'i sadece Malatya ilinde gerçekleşmektedir. İhraç ettiğimiz bu ürünlerin hasat zamanından önce yıllık üretim miktarlarının (rekolte) doğru tahmin edilebilmesi birçok açıdan büyük önem arz etmektedir. Rekoltenin doğru tahmin edilmesi, ürün piyasası üzerinde yapılacak manipülasyonların ortadan kalkmasına, arz-talep dengesinin oluşmasına ve buna bağlı lojistik desteğin sağlıklı bir şekilde yürütülmesine neden olacaktır. Bununla birlikte Fırat Kalkınma Ajansı tarafından yapılan kayısı araştırma raporunda kayısı

üretimini tehdit eden unsurların başında fiyat istikrarsızlığı ve rekolte tahminlerinin istenilen doğrulukta yapılamaması yer almaktadır.

Mevcut rekolte tahmin yöntemleri, belirli bölgedeki kayısı bahçelerindeki ağaçların gözlemci tarafından incelenmesi, toplam kayısı miktarının tahmin edilmesi, son olarak genel tahmin yapılması aşamalarını içermektedir. İnsan faktöründen kaynaklanan yanılmalar, yapılan rekolte tahminleri arasında kabul edilemez oranda farklılık oluşturmaktadır. Bu olumsuz durum kayısı haricindeki diğer tarımsal ürünler içinde geçerlidir. Örneğin 2014 yılında beş farklı kurum tarafından yapılan fındık rekolte tahminleri arasında yaklaşık %25 (183 bin ton) oranında fark bulunmaktadır.

Bu tez çalışmasında, kayısı ağacı bölütlenmesi için üç farklı bölütleme yöntemi yani örme, kenar tabanlı ve bölge tabanlı yöntemler ile sonuçlar elde edilerek en iyi performansı olan yöntem seçilmiştir. Bu çalışmada kayısı ağacı görüntüleri bir kayısı bahçesi üzerinde test edilmiştir. Elde edilen tahmin sonuçları yaklaşık %90 başarı oranı elde edilmiştir.

Bu tez çalışması, TÜBİTAK tarafından proje olarak desteklenmiştir. Ayrıca bir adet yayın İDAP uluslararası konferansta sunulmuştur.

ANAHTAR KELİMELER: Hasat tahmini, görüntü yakalama, bölütleme, yapay sinir ağları

ABSTRACT

Master Thesis

ESTIMATION OF APRICOT HARVEST IN MALATYA WITH COMPUTER VISION TECHNIQUES

Mahdi Hatami Varjovi

Inonu University
Graduate School of Natural and Applied Sciences
Department of Computer Engineering

60 + xi page

2017

Supervisor: Asst. Prof. Muhammed Fatih Talu

In our country the products such as apricot, hazelnut, grape and fig has an important production potential all over the world. For example, approximately 74% of the world's dried apricot production is made in our country, and 85% of this production takes place only in the province of Malatya. It is very important in many respects that these products we exported can be estimated correctly before harvesting the annual production quantities (harvest). Accurate forecasting of revenues will result in the elimination of manipulations on the product market, the creation of a supply-demand balance and the associated logistical support to be carried out in a healthy manner. However, according to the apricot research report made by Euphrates Development Agency, uncertainty of price and yield estimations are the main factors of threatening the apricot production.

Existing methods of estimating yields include examining the trees in the apricot gardens in the specific area by the observer, estimating the total amount of apricots, and finally making general estimations. Misconceptions arising from the human factor are unacceptably different between the yield estimates made. This negative situation applies to other agricultural products other than apricots. For example, there is a difference of about 25% (183 thousand tons) among the hazelnut harvest estimates made by five different institutions in 2014.

In this thesis study, three different segmentation methods were used for apricot tree segmentation, namely Matting, edge-based and zone-based methods, and the method with the best performance was selected. In this study apricot tree images were tested on an apricot garden. The estimated results obtained about 90% success rate.

This thesis study was supported by TUBITAK as a project. In addition, one of the broadcast IDAPs was presented at the international conference.

KEYWORDS: Harvest estimation, Computer vision, Segmentation techniques, Artificial neural networks

TEŐEKKÜR

Yüksek Lisans Tezi çalışmamda önerileri ve yönlendirmeleri ile akademik gelişmeme büyük katkı sağlayan, bana değerli zamanını ayıran danışman hocam Sayın Doç. Dr. Muhammed Fatih Talu'a;

Tez çalışmasının gerçekleştirilmesinde önemli payı olan ve çalışmayı 114E916 nolu 3001-Arge başlangıç desteęi programı olarak kabul edip maddi destek sunan Türkiye Bilim, Sanayi ve Teknoloji Bakanlığı'na;

Tez yazarken desteklerini esirgemeyen Hasan Yetiő'e,

Ayrıca bu uzun tez yolculuęunda kendilerine yeterince zaman ayıramadıęım halde benden desteklerini esirgemeyen değerli AİLEM'e

Teőekkür ederim.

İÇİNDEKİLER

ÖZET	ii
ABSTRACT.....	iv
TEŞEKKÜR.....	vi
İÇİNDEKİLER.....	vii
ŞEKİLLER DİZİNİ	ix
ÇİZELGELER	x
1. GİRİŞ.....	1
1.1. Tez Çalışmasının Amaç ve Kapsamı.....	1
1.2. Tezin Organizasyonu	4
1.3. Literatür Taraması ve Değerlendirilmesi.....	4
2. GÖRÜNTÜ BÖLÜTLEME YÖNTEMLERİ.....	11
2.1. Örme Yöntemleri	13
2.1.1. Terminoloji	14
2.1.2. Bayes Örme	15
2.1.3. Kapalı Biçimli Örme.....	18
2.1.4. KNN Örme.....	19
2.2. Eşikleme	21
2.2.1. Eşik değeri seçme	21
2.3. Kenar Tabanlı Bölütleme.....	25
2.3.1. Kenar bağlama	25
2.4. Alan Tabanlı Bölütleme.....	28
2.4.1. Alan büyüme.....	30
2.4.2. Alan Birleştirme.....	33
2.4.3. Bölme ve birleştirme yöntemleri	33
2.4.4. Doku ölçüsünü almak	34
2.5. Grafiğe dayalı bölütleme	36
3. KAYISI AĞACI BÖLÜTLEME UYGULAMALARI	37
3.1. Kayıt Sisteminin Kurulumu ve Veri Elde Etme	37
3.2. Kayısı Ağacının Bölütlenmesi.....	39
3.2.1. Kenar algılama.....	42
3.2.2. KNN Örme Yöntemi.....	45

3.2.3.	Alan Büyüme Algoritması.....	46
3.3.	Sarı/Yeşil Oranı Özneliği.....	48
3.4.	Rekolte Tahmin Doğruluęu.....	49
3.5.	Yöntemlerin karşılaştırılması.....	50
4.	SONUÇ.....	53
	KAYNAKLAR.....	55
	ÖZGEÇMİŞ.....	60



ŞEKİLLER DİZİNİ

Şekil 1.1. Ananas meyve tespitinin şematik gösterimi	4
Şekil 1.2. Ananas meyvesine ait bölütleme sonuçları	5
Şekil 1.3. Mango meyve tespitinin şematik gösterimi.....	5
Şekil 1.4. Mango meyvesine ait bölütleme sonucu	6
Şekil 1.5. Portakal meyve tespitinin şematik gösterimi.....	7
Şekil 1.6. Portakal meyvesine ait bölütleme sonucu	7
Şekil 1.7. Üzüm meyvesine ait bölütleme sonucu	8
Şekil 1.8. Portakal meyvesinin bölütleme sonucu	9
Şekil 2.1. Aşırı ve yetersiz bölütlemenin bir örneğini gösterilmiştir.....	13
Şekil 2.2. Resmin örme yöntemindeki parçalar [29]	14
Şekil 2.3. Resim üç farklı şekilde arka plandan ayrıştırılması [29].....	15
Şekil 2.4. Trimap için örnek resim	17
Şekil 2.5. Sol tarafta Şekil 2.4'deki resmin Trimap'i ve sağda kullanıcı tarafından belirlenen renklerin 3-b ortamdaki yoğunluğu.	17
Şekil 2.6. Arka plan ve ön plan 3-b düzlemde gösterimi.....	18
Şekil 2.7. K-D ağacı algoritması, ikili ağaç üzerinde.....	20
Şekil 2.8. K-D ağacı, uzay düzleminde	21
Şekil 2.9. Tipik bir arka plan ve nesneden oluşan görüntü için iki tepeli histogram	22
Şekil 2.10. Minimum ve ortalama eşik değeri belirleme yöntemleri.	23
Şekil 2.11. Hough dönüşümü kullanılarak kenar bağlama örneği.....	26
Şekil 2.12. Kenar algılama yönteminin bazı uygulamaları [42].....	27
Şekil 2.13. Alan genişleme yönteminin sahte kodu.....	30
Şekil 2.14. Piramit yöntemi [47].....	31
Şekil 2.15. Alan büyüme yöntemi akış diyagramı.....	32
Şekil 2.16. Fourier doku tanımında kullanılan maske örnekleri.....	35
Şekil 2.17. Grafiğe dayalı bölütleme	36
Şekil 3.1. Kayısı bahçelerinin üstten görünüşleri.....	37
Şekil 3.2. Kopter'in ağaç üzerinde pozisyonu	38
Şekil 3.3. Kayısı bahçesindeki ağaçların dizilimleri ve indekslenmeleri	39
Şekil 3.4. Kullanılan örnek görüntüler	40
Şekil 3.5. Kullanılan örnek görüntülerin Ground Truth resimleri	40
Şekil 3.6. Kenar tabanlı bölütleme	43
Şekil 3.7. Kenar tabanlı bölütleme (eksik bölütleme)	44
Şekil 3.8. KNN Örme yöntemini kullanarak bölütleme sonucu.....	45
Şekil 3.9. Alan genişleme yöntemi kullanılarak kayısı meyvesinin bölütlenmesi (sol üst) Orijinal resim (sağ üst) Ağaç bölütleme sonucu (alt) Kayısı bölütleme sonucu	46
Şekil 3.10. Alan genişleme yöntemi kullanılarak kayısı meyvesinin bölütlenmesi (sol üst) Orijinal resim (sağ üst) Ağaç bölütleme sonucu (alt) Kayısı bölütleme sonucu	47
Şekil 3.11. Kayısı ağacının kuş bakışı görüntüsü	50

ÇİZELGELER

Çizelge 3.1. Algoritma maliyeti (süre) kıyaslaması	40
Çizelge 3.2. Algoritma doğruluk oranı kıyaslaması (piksel genişliği)	40
Çizelge 3.3. Çizelge 3.1 'deki görüntülerin performans kıyaslaması.....	41
Çizelge 3.4. Ağaçlardan çıkarılan özellikler.....	49
Çizelge 3.5. Rekolte tahmini için yapılan çalışmalar	51
Çizelge 4.1. Elde edilen tahmin sonuçları	54



1. GİRİŞ

Tarımda, bir yılda derlenen ürün miktarı “rekolte” olarak adlandırılmakta ve bu miktarın hasat zamanından önce belirli kurumlar tarafından öngörülmesine “rekolte tahmini” denmektedir. Bir başka deyişle rekolte tahmini, daha önceden belirlenmiş bir kaç bahçede bulunan ağaçları gözlemleyerek, bir yıl içerisindeki üretilecek tahmini ürün miktarının belirlenmesi işlemidir. Bir yıl içerisinde hasat edilecek olan ürün miktarı ürün fiyatlarını doğrudan etkilediğinden, rekolte tahminlerinin doğru bir şekilde gerçekleşmesi oldukça önem arz etmektedir. Günümüzde rekolte tahmini işlemi beşeri kaynaklar yardımı ile belirlenmektedir. İnsanlar tarafından yapılan nicel gözlemler, bu işlemin temelini oluşturduğundan dolayı görecelilik ve buna bağlı hatalar sık sık meydana gelmektedir. Bu tarz bilinçli veya bilinçsiz yapılan hatalar spekülasyonlara yol açtığından, ürünler için sağlıklı fiyatlar belirlenmemektedir.

Dünya tarım sektöründe özellikle fındık, üzüm, kayısı ve incir gibi ürünlerde, ülkemiz önemli bir üretici rolünü üstlenmektedir. Kayısı üretiminin yüzde 74 Türkiye’de gerçekleşmektedir. Kayısı üretimini tehdit eden unsurların başında, diğer ürünlerde olduğu gibi fiyat istikrarsızlığı ve yanlış rekolte tahminleri yer almaktadır. Bu ürünlerin yıllık üretim miktarlarının doğru tahmin edilmesi hem ulusal hem de uluslar arası ürün piyasasını önemli ölçüde etkilemektedir. Bu tez çalışmasında kayısı rekolte tahmininin bilgisayar aracılığıyla gerçekleştirilmesi ve bu sayede ürün fiyatlarının daha sağlıklı belirlenmesi hedeflenmektedir.

1.1. Tez Çalışmasının Amaç ve Kapsamı

Fırat Kalkınma Ajansı raporunda kayısı üretimini tehdit eden unsurların başında fiyat istikrarsızlığı ve rekolte tahminlerinin yapılamaması yer almaktadır [1]. Mevcut rekolte tahmin yöntemleri, belirli bölgedeki kayısı bahçelerinin gözlemci tarafından incelenmesi ve elde edilen tahmini sonucun genel üretime yansıtılması şeklinde yapılmaktadır. Örnekleme usulüyle yapılan bu tahminlerde insan faktöründen kaynaklanan yanılmalar, yanlışlıklar yapılan tahminler arasında kabul edilemez oranda bir farklılık oluşturmaktadır.

Günümüzde rekolte tahmini, ürün piyasası üzerindeki yüksek etkisinden dolayı birden fazla kurum ve birlik tarafından bağımsız bir şekilde yapılmaktadır. Örneğin farklı kurumların 2014 ve 2015 yılında yapmış oldukları fındık rekolte tahminleri aşağıda belirtildiği gibidir [1] [2] [3]:

- Bakanlık komisyonu (411 bin ton)
- Fiskobirlik (430 bin ton)
- Ziraat Odaları Birliği (417 bin ton)
- İhracatçı birlikleri (514 bin ton)
- Trabzon Ticaret Borsası (600 bin ton)

Yapılan tahminler arasında tolere edilmeyecek oranda (yaklaşık %25) büyük farklılıkların bulunduğu açıkça görülmektedir. Oysa yapılan bu tahminler arasında ancak %1-3 gibi bir farklılığın olması normal karşılanabilir. Rekolte tahminlerindeki bu tutarsızlık ulusal basında geniş bir şekilde yer bulmakta ve fiyat istikrarsızlığına neden olmakta ve yukarıda bahsedilen olumsuzlukların ortaya çıkmasını tetiklemektedir [4]. Fındık rekolte tahminindeki durum, üzüm, kayısı ve incir sektörlerinde de yaşanmaktadır.

Doğru olmayan rekolte tahminleri aşağıda listelenen olumsuz durumların ortaya çıkmasına yol açmaktadır:

- 1- Üründeki arz-talep dengesi bozulmaktadır. Çünkü, rekolte tahmin değeri ile ürün satış fiyatı arasında ters orantı bulunmaktadır. Yüksek tahminler ürün fiyatının düşmesine, düşük tahminler ise yükselmesine neden olmaktadır. Ürün fiyatındaki bu değişimler ürüne karşı olan iç ve dış pazar talebini doğrudan etkilemektedir.
- 2- Üretim arzı miktarının yanlış tahmin edilmesi, arz ve talep ilişkisinde zamanlama krizinin oluşmasına neden olmaktadır.

- 3- Sezonun geneline yayılan talep koşullarına göre pazarlama ve lojistik bağlantıların sağlıklı bir şekilde yürütülebilmesini engellemektedir. Çünkü sağlıklı lojistik desteğin sağlanabilmesi, üretim arzının en gerçekçi şekilde bilinmesiyle mümkün olmaktadır.
- 4- Ürünün pazar piyasasını düzenlemek maksadıyla manipüle edilmesine neden olmaktadır.
- 5- Ürün paydaşları arasında gerilim ve çatışmaların çıkmasına neden olmaktadır.

Mevcut rekolte tahmin yöntemlerinin bilimsel olmaması ve insan faktöründen kaynaklanan yanlışlıkların elimine edilmesi ihtiyacı araştırmacıların ilgisinin bu alana yoğunlaşmasını sağlamıştır [5] [6] [7]. Yapmış olduğum tez çalışmada kayısı bahçelerindeki rekolte miktarını yüksek doğrulukta tahmin edebilen bir sistem gerçekleştirerek, bu olumsuz etkileri en aza indirmek amaçlanmıştır.

Bu tez kapsamında Malatya ilindeki belirli kayısı bahçelerinden video görüntülerinin elde edilmesi ve bu videoların görüntü işleme teknikleriyle bilimsel olarak değerlendirilmesi sonucu güvenilir rekolte tahmininin yapılması için yeni bir sistem geliştirilmiştir. Bu amaçla yapılan işlemler kısaca aşağıdaki gibi özetlenebilir:

- 1- Kayısı bahçelerinden video kayıtlarının elde edilmesi.
- 2- Elde edilen video görüntülerinde kayısı ağaçlarının çıkarılması.
- 3- Ağaçlardaki yeşil/sarı oranının elde edilmesi.
- 4- Her bir ağaçtan toplanan toplam kayısı kilogram değerleri ile yeşil/sarı oranı, ağacın alanı, katılık ve eksantriklik gibi özellikleri eşleştirebilen yapay sistemin eğitilmesi.
- 5- Yeni kayısı ağaçlarındaki toplam kayısı miktarının kilogram olarak tahmin edilmesi.

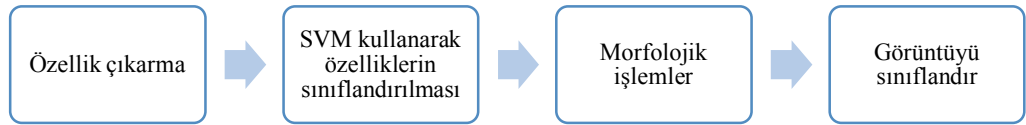
1.2. Tezin Organizasyonu

Tez çalışması dört bölüm altında sunulmuştur. Birinci bölümde tezde kullanılan görüntü işleme tekniklerinin literatür çalışmaları sunulmuştur. İkinci bölümde görüntü bölütleme ile ilgili bilgilere yer verilmiş ve detaylıca anlatılmıştır. Üçüncü bölümde tezde yapılan çalışmanın sistem tasarımı ve yapılan uygulamanın çalışma mantığı anlatılmıştır. Son bölümde ise elde edilen sonuçlar sunulmuştur.

1.3. Literatür Taraması ve Değerlendirilmesi

Otomatik meyve sayımı ve rekolte tahmini problemlerinde görüntü işleme teknikleri sıklıkla kullanılmaktadır [8] [9] [10]. Jednipat Moonrinta (vd.) ananas ağaçlarından elde ettikleri görüntüleri kullanarak rekolte tahmini gerçekleştirmiştir [11]. Rekolte tahmini için ananas meyvelerinin tespiti, izlenmesi ve 3 boyutlu görselleştirilmesi işlemleri sırası ile uygulanmıştır.

Bu çalışmada meyve tespiti için 4 aşamalı bir yol izlenmiştir önerilen yaklaşımın şematik gösterimi şekil 1.1'de verilmiştir. Bu çalışmada özellik noktalarının tespit edilebilmesi için Harris, SIFT ve SURF algoritmaları kullanılmıştır. Bulunan özellik noktalarının tanımlanması sürecinde SIFT ve SURF yöntemlerinden yararlanılmıştır. Bu işlem sonunda tanımlayıcıları oluşturulan özellik noktalarının sınıflandırılması için ise SVM kullanılmıştır. Son olarak tespit edilen meyve bölgelerinin takibi için blob algılama; 3 boyutlu görselleştirme için hareket ve elips tahmini yöntemleri kullanılmıştır. Çalışmaya 20 ananas meyvesi test olarak verilmiş, testin sonucunda yöntemin elde ettiği başarı 50% ile sınırlı kalmıştır. Başarılı tespit edilen bir ağaca ait sonuç şekil 1.2'de gösterilmiştir.




Şekil 1.1. Ananas meyve tespitinin şematik gösterimi



Şekil 1.2. Ananas meyvesine ait bölütleme sonuçları

A.B. Payne (vd.) yaptığı çalışmada iki farklı yaklaşım sunmuştur ve her iki yaklaşımda da renk analizi ve blob yakalama yöntemlerini kullanmıştır [12]. Birinci yaklaşımda mango ağacının 4 farklı açıdan görüntüsü alınarak incelenmiştir. Bu çalışmada renk ve şekil üzerinden meyve tespiti yapılmaya çalışılmış bu işlemin şematik görüntüsü şekil 1.3’de verilmiştir. Dört farklı açıdan alından dört görüntünün analiz edilmesi sonucunda 91% başarı elde edilmiştir. İkinci yaklaşımda ise mango ağacının sadece tek bir yönden elde edilen görüntüsü kullanılmıştır. Tek bir açıdan alınan görüntünün incelenmesi sonucunda elde edilen doğruluk oranı ise 74% ile sınırlı kalmıştır. İkinci yaklaşım ile tespit edilen meyveler Şekil 1.4 üzerinde işaretlenmiştir.




Şekil 1.3. Mango meyve tespitinin şematik gösterimi



Şekil 1.4. Mango meyvesine ait bölütleme sonucu

Malik (vd.) portakal bahçelerinden elde ettikleri görüntüleri kullanarak bir rekolte tahmin sistemi önermiştir [13]. K-ortalama kümeleme yönteminin kullanıldığı bu çalışmada, portakal rengine benzer görüntü pikselleri bağımsız bir küme içerisine alınmaktadır. Daha sonra bu küme içerisindeki piksellerden sadece portakala ait olanların ayıklanabilmesi için morfolojik özellikler (blob yakalama ve şekil analizi) kullanılmıştır. Portakal sayımı yapıldıktan sonra elde edilen tahmini sonuçlar ile gerçek değerlerin eşleştirilebilmesi için doğrusal regresyon yöntemi kullanılmıştır. Çalışma sonucunda, oldukça yüksek bir eşleşme (korelasyon) katsayısının elde edildiği görülmektedir.

H. N. Patel (vd.) renk ve şekil analizi yaparak elma, nar, portakal, şeftali ve erik gibi meyvelerin bölütlenmesi ve sayılması işlemlerini farklı ışık ortamlarında gerçekleştirmiştir [14]. Bu çalışmada izlenen algoritmayı şematik görüntüsü şekil 1.5’de verilmiştir. Bu yöntemin şüana kadar incelediğimiz diğer yöntemlerden farkı ise son aşamada daire tespiti için kullanılan Newton [14] algoritmasıdır. Önerilen yöntemin test edildiği örnekler üzerindeki meyve tespit başarısı 98% olarak belirlenmiştir. Yöntemin, yıllık ürün miktarının tahmininde ise 31.4%’lük bir hataya sahip olduğu ortaya çıkmıştır. Yöntemin portakal ağacına ait örnek görüntüler üzerinde çalıştırılması ile şekil 1.6 ile gösterilen sonuç elde edilmiştir.




Şekil 1.5. Portakal meyve tespitinin şematik gösterimi



Şekil 1.6. Portakal meyvesine ait bölütleme sonucu

Stephen Nuske (vd.) çalışmasında Bağlardaki üzüm çekirdeğini tespit etmek ve saymak için bilgisayar görmesi kullanan otomatik bir yöntem sunmuştur [15]. Yöntem, büyük üzüm bağları arasında, ilk önce radyal bir simetri dönüşümü ile olası üzüm tanelerinin yerlerini tespit etmek daha sonra üzüm bağlarında benzer görünüme sahip olası üzüm tanelerinin yerlerinin belirlenmesi ve en son aşamada ise tespit edilen üzüm tanelerinin yakın komşulukları ile bir kümeye dahil edilmesi sonucu tahmin işlemini gerçekleştirmişlerdir.

Stephen Nuske (vd.) yöntemlerinde hem şekli hem de görsel dokuyu kullanır ve yeşil çileklerin yeşil bir yaprak arka planına karşı tespitini gösterebiliriz. Meyve alıntıları sayılır ve nihai hasat verimi tahmin edilir. Sonuçlar, iki farklı üzüm çeşidinden 224 üzüm (450 metre üzeri) için sunulmuştur ve asıl hasat verimi ile gerçek veri karşılaştırılmıştır. Tahmin edilen üzüm sayısını verim ile kıyasladıktan sonra fiili ürün ağırlığının% 98'inde doğru tahmin edebilmişlerdir. Sonuçlar şekil 1.7 de gösterilmiştir.



Şekil 1.7. Üzüm meyvesine ait bölütleme sonucu

Yukarıdaki çalışmalarda meyve tespiti, sayma ve tahmin işlemleri, renk ve şekil özelliklerini kullanarak gerçekleştirilmiştir. Ancak Calvin Hung (vd.) çalışmalarında farklı bir yöntem kullanmıştır [16]. Bu çalışmada yazılımsal çözümün yanında bazı sensörler (Stereo renk kamera, Panospheric renkli kamera) meyvelerin tespiti için kullanmışlardır. Bu yöntemin bir avantajı meyve rengi, yaprak rengi ile aynı olan ağaçlarda örneğin yeşil elma tespitinde iyi sonuç vermesidir. Önerdikleri sınıflandırma sistemi otomatik olarak çeşitli meyveler için kullanılabilir. Elma üzerinde elde ettikleri sonuç ile 81%'lik bir başarı yakalamışlardır. Yapılan çalışmanın sonucu tespit edilen portakallar şekil 1.8 ile gösterilmiştir.



Şekil 1.8. Portakal meyvesinin bölütleme sonucu

Maalesef, ele aldığımız görüntü tabanlı rekolte tahmini ile ilgili iki hata kaynağı vardır. İlk olarak, gün ışığındaki görüntü temelli meyve sayımı, gölgelerden ve hataları ortaya çıkaran olaylardan zarar görür. İkincisi, kamera yalnızca yapraklar tarafından gizlenmeyen meyveleri görebilir ve doğru sayımı elde etmek için mevcut teknikle meyve suyu sayımı ile yer-özel kalibrasyonuna ihtiyaç duyulur [17].

Bizim önerdiğimiz yöntemde ise ağacın alanını doğru bir şekilde elde edip, şekil analizi yaparak karakteristik özellikler çıkarılır. Daha sonra çıkarılan bu özellikleri giriş verisi olarak Yapay Sinir Ağına (YSA)'ya verilir ve önceden elde edilmiş her ağacın mahsulü ile eşleştirilerek bu çıkışı vermesi beklenir. Belirli ağaçlar için eğitim işlemine tabii tutulan YSA yeni ağaçlar için tahminde bulunmaya hazır hale gelir.

Gerçekleştirilen çalışmada kayısı bahçelerindeki rekolteyi tahmin edebilen bir sistem geliştirilmiştir. Geliştirilen sistem, bir insansız araç ve zeki bir yazılımdan oluşmaktadır. İnsansız araç, kayısı bahçesine ait video görüntülerinin elde edilmesinde kullanılmaktadır. Belirli bir yükseklikte (17m veya 22m) ve önceden

girilen GPS rotasını takip edebilen insansız araç gezinti yaparken elde ettiği yüksek çözünürlükteki video görüntülerini dâhili hafızasına kaydetmektedir.

Zeki yazılım ise gezinti sonucunda kaydedilen video görüntülerini işlemekte ve rekolte tahmini yapmaktadır. Bu yazılım, video görüntülerinin işlenmesi, öğrenme ve test süreçleri içermektedir. Veri işleme aşaması, video ön işlemler (gürültü temizleme), görüntü dengeleme, ağaç bölütleme ve ağaçtaki yeşil/sarı oranlarının tespit edilmesi işlemlerini kapsamaktadır. Öğrenme aşamasında, her bir ağaç görüntüsünden elde edilen öznelik bilgileri ile kayısı üreticisinden alınan kilogram bilgileri yapay sinir ağı yöntemiyle eşleştirilmektedir. Test sürecinde, eğitim verisinde yer almayan yeni kayısı ağaçlarının kaç kilo kayısı vereceği tahmin edilmiştir.

Sonuç olarak bilgisayar görmesi ve yapay öğrenme tekniklerinin birlikte kullanıldığı yüksek doğrulukta zeki bir kayısı rekoltesi tahmin sistemi gerçekleştirilmiştir.

Bu çalışmanın özgün yönleri aşağıdaki gibi listelenebilir.

- a) İnsan gözlemine dayanan ve tolere edilemeyecek seviyelerde farklılık içeren rekolte tahminlerinin bilimsel yöntemlerle yapılması ve farklılıkların tolere edilebilir bir seviyeye indirilmesi.
- b) Fındık, üzüm ve incir gibi diğer tarımsal ürünlerinde bilimsel olarak rekolte tahminlerinin yapılabilmesi için önsel bir çalışma mahiyetinde olması.
- c) Geniş bir kitle üzerinde (üretici, tüketici, ihracatçı) büyük bir öneme sahip ve gerçek hayat problemi olan rekolte tahminlerinin imge işleme tekniklerini kullanacak yerli yazılım çözümlerinin üretilmesi.

2. GÖRÜNTÜ BÖLÜTLEME YÖNTEMLERİ

Bir görüntünün anlamlı yapılara bölünmesi olarak tanımlanan bölütleme, genellikle görüntü analizi, nesne gösterimi, görselleştirme ve diğer birçok görüntü işleme uygulamaları için önemli bir adımdır.

Son on yılda çok çeşitli bölütleme yöntemleri önerilmiştir. Bu yöntemlerin doğru bir şekilde değerlendirilebilmesi için kategorilere ayrılması gerekmektedir [18]. Bu bölümde sunulan bölütleme yöntemleri, keskin bir sınıflandırmadan ziyade kullanılan genel yaklaşıma göre kategorize edilmiştir.

- **Eşik tabanlı bölütleme.** Histogram eşikleme ve dilimleme teknikleri, görüntüyü bölütleme için kullanılır. Doğrudan bir görüntüye uygulanabileceği gibi bazı ön işlemler sonucu elde edilen görüntüye de uygulanabilir [19].

- **Kenara dayalı bölümeleme.** Bu teknikte, bir görüntüdeki algılanan kenarların, nesne sınırlarını temsil ettiği varsayılır ve bu nesnelere tanımlamak için kenar tespit algoritmalarından yararlanır [20].


- **Alan tabanlı bölümeleme.** Kenar tabanlı yöntemlerde nesne sınırları bulunmaya çalışılırken, alan tabanlı yöntemler nesnenin içerisinde bir noktayı seçerek (örneğin orta nokta), kenarlara ulaşana kadar genişlemeye devam etmesine dayanır [21].

- **Kümeleme teknikleri.** Kümeleme amacı bakımından bölütleme ile oldukça benzerlik göstermektedir [22]. Bu bağlamda, kümeleme yöntemleri, bir bakıma benzer olan kalıpları bir araya getirmeye çalışmaktadır. Bir görüntüyü bölgelere ayırmak için bazı kümeleme teknikleri kolayca uygulanabilir.

- **Eşleştirme.** Bir görüntüde tanımlamak istediğimiz bir nesnenin yaklaşık olarak neye benzediğini bildiğimizde, bu bilgiyi bir resimdeki nesneyi bulmak için kullanabiliriz [23].

Görüntünün mükemmel bir şekilde bölütlenmesi, yani her pikselin doğru nesne bölümüne atanmış olması genellikle elde edilemeyen bir hedeftir. Aslında dijital görüntünün elde edilme biçiminden dolayı bu mümkün olmayabilir. Çünkü bir piksel, nesnelerin gerçek sınırını kısmi olarak birden fazla nesneye ait olacak şekilde barındırabilir. Burada sunulan yöntemlerin çoğu bir pikseli yalnızca tek bir bölüme atamaya çalışmaktadır. Bir çok uygulama için bu yeterli bir yaklaşımdır [24] [25]. Her bir pikselin bölümlere olan aitliğinin olasılıksal olarak ifade edildiği yöntemlere olasılıksal bölütleme yöntemleri denir. Olasılıksal yöntemler teorik olarak daha doğrudur ve uygulamada da olasılık değerlerini belirlemede kullanılan yaklaşımın doğru bir şekilde belirlenmesi ile iyi sonuçlar vermektedir. Bununla birlikte, olasılıksal teknikler bölütleme hem kavram hem de uygulama açısından önemli ölçüde karmaşıklık getirir ve bu nedenle daha az kullanılırlar.

Görüntünün tam anlamı ile doğru bir şekilde bölütlenmesine engel olan iki durum söz konusudur. Bunlardan birincisi aşırı bölütleme, ikincisi yetersiz bölütlemedir [26]. Birinci durumda, aynı nesneye ait pikseller farklı bölümlere ait olarak sınıflandırılabilirler. Yani tek bir nesne, iki veya daha fazla bölüm ile temsil edilebilir. İkinci durumda ise bunun tam aksine farklı nesnelere ait pikseller aynı nesneye aitmiş gibi sınıflandırılır. Yani tek bir bölümde birden fazla nesne bulunabilir. Şekil 2.1 Sol üstte orijinal bir resim gösteriliyor, sağ üstteki resim doğru bölütleme sonuçlarını göstermektedir. Burada her bölüm benzersiz bir gri değerle gösterilmiştir. Sol ve sağ alt görüntüler, sırasıyla aşırı ve yetersiz bölütlemeye örnek olarak verilmiştir [27].



Şekil 2.1. Aşırı ve yetersiz bölütlemenin bir örneğini gösterilmiştir.

2.1. Örme Yöntemleri

Ön planı fotoğraftaki arka plandan ayırmak için kullanılan yöntemin ismi Örme (Matting) diye adlandırılır. Bu yöntemin normal bölütleme ile olan farkı ise, bölütleme genel olarak görüntüyü farklı bölümlere ayırır, Örme ise ön planı arka plandan ayırmak için kullanılan bir yöntemdir [28].

Bitkiler ve ağaçlar farklı mevsimlerde yaprak renkleri farklı olduğundan dolayı bölütleme yöntemi ile ayırmak oldukça zor olacaktır, ama örme yöntemi için bu parametreler geçerli değildir. Dolayısıyla örme yöntemi ile ağaçları kompleks arka plandan ayırmak daha verimli olacaktır. Algoritmalar karmaşıklığı açısından örme yöntemi daha zordur. Örme yönteminde kullanıcının dahil olması gerekiyor ama bölütlemeye gerek yoktur.


2.1.1. Terminoloji

Tez boyunca I renkli görüntüyü 3 boyutlu ayrık dizi olarak kabul edeceğiz öyleki $I(x, y)$ kırmızı, yeşil, mavi den oluşan bir üçlü vektör gösterecek. Genelde örme yöntemi problemlerinde I imgesini ön plan F ve arka plan B diye isimlendirilir. Örme yönteminin parçaları şekil 2.2’de verilmiştir. Örme yönteminde üç görüntü ile denklem oluşturulur:

$$I(x, y) = \alpha(x, y)F(x, y) + (1 - \alpha(x, y))B(x, y) \quad (2.1)$$


Burada $\alpha(x, y)$ $[0,1]$ arasında bir değerdir. Eğer $\alpha(x, y)$ sıfıra yakınsa piksel yaklaşık tüm rengini arka plandan alıyordur, halbuki eğer $\alpha(x, y)$ bire yakınsıyorsa piksel hemen hemen tüm rengini ön planda alıyor olacak. 2.1 denklemini kısaltırsak aşağıdaki denklemi elde ederiz:

$$I = \alpha F + (1 - \alpha)B \quad (2.2)$$



Şekil 2.2. Resmin örme yöntemindeki parçalar [29]

Ön plan kestirimi işlemini zorlaştıran nedenlerden biri, orijinal görüntünün birden fazla farklı yol ile ön ve arka piksel görüntülerine ayrışabiliyor olmasıdır. Örneğin Şekil 2.3’de orijinal görüntü üç farklı şekilde ön ve arka plan görüntülerine ayrıştırılabilir.



Şekil 2.3. Resim üç farklı şekilde arka plandan ayrıştırılması [29]

2.1.2. Bayes Örne

Bahsedilen örne algoritmalarında görüntünün yanında kullanıcı Trimap (0 ve 1 den oluşan resim) görüntüyü de yanında vermesi gerekiyordu ve bu görüntüde hangi pikselin arka plan yada ön plan olduğu belli oluyordu. Bu algoritmanın ana fikri her pikselin olasılık yoğunluk fonksiyonunu belirlemek ve böylece α, F ve B değerleri bilinmeyen piksellerden hesaplamaktır.

Chuang et al [30] örne problemini olasılık çerçevesinde değerlendirmektedir ve önerdiği yöntemle Bayes Örne adını vermiştir. Her pikselde ön plan rengi, arka plan rengi ve alfa değerlerini maksimize eden olasılıkları verilen renkli görüntüden hesaplamaya çalışıyor. Buna göre amaç fonksiyonu aşağıdaki gibi tanımlanmaktadır:

$$\arg \max_{F, B, \alpha} P(F, B, \alpha | I) \quad (2.3)$$

Bu problemin basit iteratif yöntemle çözümüne gelince, ilk olarak Denklem (2.3)'e Bayes kuralı uygulanır;

$$P(F, B, \alpha | I) = \max \frac{P(I|F, B, \alpha) P(F, B, \alpha)}{P(I)} \quad (2.4)$$

$P(I)$, hesaplanacak parametrelere bağılı olmadığı için denklemden kaldırılabilir. Denklemdaki çarpımları toplama dönüştürmek ve işlem maliyeti yüksek olan \exp gibi ifadeleri ortadan kaldırmak için doğrusal bir operatör olan logaritma kullanıldığında aşağıdaki denklem elde edilir;

$$\arg \max_{F,B,\alpha} \log (P(I|F, B, \alpha) + \log P(F) + \log P(B) + \log P(\alpha)) \quad (2.5)$$

$\log (P(I|F, B, \alpha))$ veri kısmıdır ve mevcut görüntünün F, B, α değerleriyle elde edilen görüntüye ne kadar benzediğini ifade eder. Aşağıdaki gibi hesaplanabilir:

$$P(I|F, B, \alpha) = \exp \left(-\frac{1}{\sigma^2} \|I - (\alpha F + (1 - \alpha)B)\|^2 \right) \quad (2.6)$$

Denklemdaki σ sapma parametresi kullanıcı tarafından ayarlanabilir ve mevcut görüntü ile model arasındaki benzerlik değerlerinin ne ölçüde yumuşatılması gerektiğini ifade eder. Denklemin ikinci kısmı, ön plan, arka plan ve alfa parametrelerinin önsel olasılığını göstermektedir. $P(B)$ değeri aşağıdaki gibi hesaplanmaktadır:

$$P(B) = \frac{1}{2\pi^{3/2} |\Sigma_B|^{1/2}} \exp \left(-\frac{1}{2} (B - \mu_B)^T \Sigma_B^{-1} (B - \mu_B) \right) \quad (2.7)$$


Denklemdaki μ_B vektörü ve Σ_B matrisi siyah renkle tanımlanan piksellerin sırayla ortalama renk vektörü ve kovaryans matrisini ifade etmektedir.

Önsel olasılık değerleri kullanıcı tarafından belirlenen piksellerin renk dağılımları modellenerek hesaplanır. Bu modelin inşası için, algoritma başlamadan önce kullanıcı tarafından görüntüde kesin ön plan ve arka plan olacak pikseller ve belirsiz sayılabilecek bazı pikseller işaretlenir. Üç farklı renk kullanılarak yapılan bu işaretleme literatürde üçlü harita (trimap) çıkarımı olarak bilinir. Şekil 2.4'da kayısı ağacı görüntüsü üzerinde kullanıcı tarafından belirlenen trimap gösterilmektedir. Buna göre siyah renkli bölge arka planı, gri renkli bölge belirsizliği, beyaz renkli bölge ise kesin ön plan olan bölgeyi ifade etmektedir.



Şekil 2.4. Trimap için örnek resim

Trimap olarak belirlenen piksellerin 3-b ortamda belirli alanda yoğunlaştığını görebilmek için Şekil 2.5’de örnek bir görüntüden elde edilen trimap piksellerinin çizimi yapılmıştır, Siyah noktalar arka plan beyazlar ise ön planı göstermektedir.

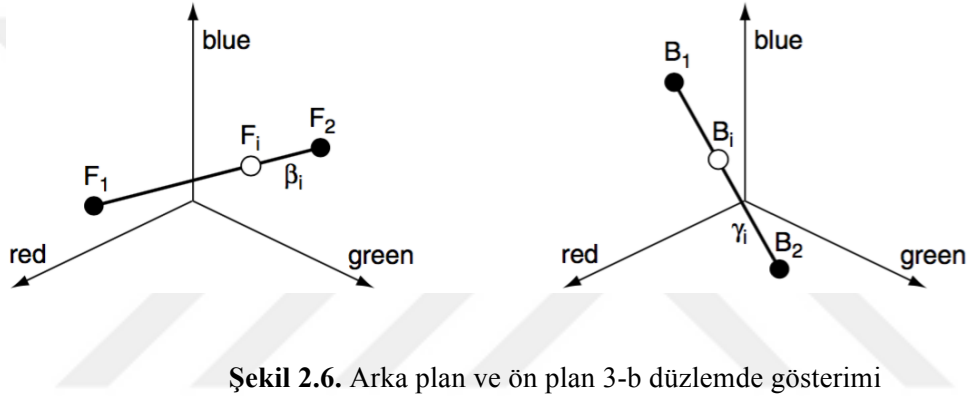


Şekil 2.5. Sol tarafta Şekil 2.4’deki resmin Trimap’i ve sağda kullanıcı tarafından belirlenen renklerin 3-b ortamdaki yoğunluğu.

Ortak piksel gruplarının çoklu Gaussian modeliyle modellenmesi ve olasılık değerinin Bayes kat sayısı ile maksimize edilmesi sonucunda yüksek doğrulukta sınıflama başarısı elde edilebilmektedir.

2.1.3. Kapalı Biçimli Örme

Bayes örme yönteminde, arka plan ve ön plan piksellerinin Gauss dağılıma sahip olduğu farz edilmektedir. Ancak doğal görüntülerde bu dağılım genellikle bir çizgi şekline veya sigara şekline benzer bir dağılım sergilemektedir. Levin et al. [31] bu fikre dayalı olarak renkli çizgi varsayımını önermiştir. Buna göre, çerçeve içerisindeki herhangi bir j pikselinin komşu pikselleri 3-b RGB uzayında sigara veya çizgi şeklinde olan ön plan ve arka plan çizgileri üzerinde olacağı farz edilmektedir. Böylece görüntüdeki her bir piksel bu çizgiler üzerindeki renklerin doğrusal birleşiminden meydana gelmektedir.



Şekil 2.6. Arka plan ve ön plan 3-b düzlemde gösterimi

Şekil 2.6 (sol)'da gösterilen F_1 ve F_2 pikselleri ön plan çizgisi, Şekil 2.6 (sağ)'da gösterilen B_1 ve B_2 pikselleri arka plan çizgisi üzerindeki herhangi iki noktadır. Buna göre görüntüdeki herhangi bir pikselin rengi ön ve arka plan karışımı ile elde edilebilir.

$$I_i = a_i(\beta_i F_1 + (1 - \beta_i)F_2) + (1 - a_i)(\gamma_i B_1 + (1 - \gamma_i)B_2) \quad (2.8)$$

$$F_i = \beta_i F_1 + (1 - \beta_i)F_2$$

$$B_i = \gamma_i B_1 + (1 - \gamma_i)B_2$$

2.1.4. KNN Örne

KNN örme tekniđi, yerel renk çizgisi modelini varsaymaz, sofistike örnekleme stratejilerine ihtiyaç duymaz ve herhangi bir boyuttaki herhangi bir renk veya özellik alanına genel bir bakış sağlamaktadır. Bu yöntem K-En yakın komşular tekniđini kullanarak yerel olmayan ilkeyi kullanır ve seyrek kullanıcı işaretlemeleri ile rekabetçi sonuçlar veren basit ve hızlı bir algoritmaya katkıda bulunur. Bu yöntemin aşamaları aşağıda verilmiştir [32].

1. İlk önce her piksele ait özellikler hesaplanır

$$X(i) = (\cos(h), \sin(h), s, v, x, y)_i \quad (2.9)$$

2. Bu özelliklere göre K-D-Tree algoritmasından yararlanarak en yakın k (3) nokta seçilir
3. Çekirdek fonksiyonu kullanarak bu noktaların yakınlıkları hesaplanır.

$$k(j, j) = 1 - \frac{\|X(i) - X(j)\|}{c} \quad (2.10)$$


4. Simetrik olarak tekrar eden değerler için yakınlıklar toplanır. $p(1,2) = P(1,2) + p(2,1)$
5. Bir noktaya olan en yakın k(3) noktanın yakınlıkları toplanarak yeni bir matris elde edilir $D(1) = D(1,1) + D(1,3000) + D(1,2500) + D(1,1500)$
6. daha sonra D matrisinden A matrisi çıkarılır. İşaretlenen noktalar için lamda oranında ekleme yapılır ($M = D - A + lamda * map$)
7. Çölseki fonksiyonu ile $L * L' = M$ eşitliğini sağlayan L değeri bulunur.
8. Bulunan L matrisi kullanılarak Conjugate gradiaent metodu ile orijinal resme eşdeğer geçiş matrisi hesaplanır.

KNN örme tekniğinin ikinci aşamasında kullanılan K-D-Tree algoritması (aynı zamanda K-Boyutlu Ağaç olarak da adlandırılır), her düğümdeki verilerin uzayda K-boyutlu bir noktası olduğu bir ikili arama ağacıdır. Kısacası, K-boyutlu uzayda noktaları organize etmek için bir alan bölme yapısıdır.


K-D ağacında yaprak olmayan bir düğüm alanı, yarım-boşluk olarak adlandırılan iki kısma bölünür. Sol alt ağaçta, koordinatları kök düğümün koordinatlarından daha küçük olan tüm noktalar bulunur. Benzer şekilde, sağ alt ağaç, koordinatları kök düğümüne eşit veya büyük olan tüm noktaları içerecektir. Şekil 2.7’de ikili ağaç ve Şekil 2.8’de uzay düzlemindeki bölünmesi gösterilmiştir.

K-D ağacın özellikleri:

- İlk eklenen nokta kök olarak eklenir.
- Her düğüm dikdörtgen bir bölge ile ilişkilendirilir.
- Ağaç “Dengeli” bir ağaçtır. Noktalar rastgele sırayla verilirse de ağaç dengelenir.
- Veya tüm noktalar önceden verilirse



Şekil 2.7. K-D ağacı algoritması, ikili ağaç üzerinde.



Şekil 2.8. K-D ağacı, uzay düzleminde

2.2. Eşikleme

Eşikleme, görüntü bölütlenmesinde kullanılan basit bir yöntemdir. Gri tonlu bir görüntü eşikleme kullanılarak ikili görüntüler oluşturmak mümkündür. Bölütleme işlemi birden fazla nesne içeren görüntülerde, görüntüyü bölgelere ayırmak için kullanılır [33]. Genellikle bölgelere ayırma işlemi, ya bölge içindeki benzer olan özelliklere göre, ya da bölgeler arasındaki farklı olan özelliklere göre gerçekleştirilir. Bir bölgede piksellerin paylaşabileceği en basit özellik yoğunluktur. Yani, bu gibi bölgelere bölütleme işlemi uygulamanın doğal yolu eşikleme ile aydınlık ve karanlık bölgelerin ayrılmasıdır. Eşikleme bir eşik değerinin üzerinde yoğunluğa sahip pikselleri 1, eşik değeri altındaki piksel yoğunluklarını ise 0 yaparak gri-seviye görüntülerden ikili görüntüler oluşturur. Eşik değeri belirlemek için en çok kullanılan yöntemlerin başında Otsu ve k-means algoritmaları gelmektedir [34].


2.2.1. Eşik değeri seçme

Bölütleme için uygun bir eşik bulmak için birçok yöntem vardır. En basit yöntem, eşik değerinin kullanıcı tarafından etkileşimli olarak seçilmesidir. Bu işlem görüntü histogramının yardımıyla kullanıcıya belirli bir eşik seçiminin sonucunu değerlendirebilen grafiksel bir araç eşliği ile yapılabilir. Otomatik yöntemler, uygun

bir eşik bulmak için genellikle görüntü histogramını kullanırlar. Bu yöntemlerin bazıları aşağıda detaylandırılmıştır.

- **Histogram uç noktaları**

Şekil 2.9'da Sol üstte sadece iki gri değer içeren bir resim gösterilmektedir. Histogram (yanındaki) sadece iki pik gösterir. Uygulamada, görüntü eşyaları görüntüye ve histogramına bu ideal durumdan düşmesine neden olur. Özellikle, histogram, sağdaki histogram ve resimde gösterildiği gibi bulanıklaştırır. Uygulamada, histogramdaki iki eğrinin çakışmaya başlaması mümkündür. Histogramın doğrulukları, gürültü, aydınlatma fazlalığı ve kısmi hacim efekti gibi görüntü bozucu faktörlerin etkisi nedeniyle, olmasını istediğimiz kadar keskin olmayacaktır.



Şekil 2.9. Tipik bir arka plan ve nesneden oluşan görüntü için iki tepeli histogram


Uygulamada, belirli nesnelere karşılık gelen histogramdaki eğriler çakışabilir. Bu nedenle, global eşiklemeye dayalı hatasız bir bölütleme mümkün olmayabilir. Histogramda örtüşme olup olmadığına bakılmaksızın, bir bölütleme eşiği oluşturmak için histogramın maksimumlarını (zirveleri) kullanabiliriz. Bu eşik t , gri değerlerin zirvesi olan p_1 ve p_2 değerlerinin ortalaması olabilir:

$$t = \frac{p_1 + p_2}{2} \quad (2.11)$$

Veya t eşik değeri daha sağlıklı bir şekilde iki zirve olan p_1 ve p_2 arasında kalan asgari değer olarak belirlenebilir:

$$t = \arg \min H(v) \quad v \in [p_1, p_2] \quad (2.12)$$

Bu formülde $H(v)$ 'deki gri değer histogramını verir ve $P1$ 'in $P2$ 'den küçük olduğunu varsayalım. Şekil 2.10, t 'yi belirlemek için ortalama yöntemin minimum yöntemden daha iyi olduğunu göstermektedir.



Şekil 2.10. Minimum ve ortalama eşik değeri belirleme yöntemleri.

Doruklar arasındaki yarıdaki eşiğin ve tepelerin arasındaki minimum eşiğin karşılaştırılması örneği şekil 2.10'te verilmiştir. Histogram, resimde görüldüğü gibi istediğiniz kadar pürüzsüz değildir. Birçok histogram analizi görevleri için genel uç noktalara ihtiyaç duyulur, bu nedenle histogramın düzeltilmesi gerekir. Bunun için bir Gaussian veya ayrık ortalama çekirdeği ile konvolüsyon işlemi uygulanabilir. Şekil 2.10'da bir histogram örneği gösterilmiştir. Şekil 2.10'da sağda ise doruk noktaları arasındaki ortalama değer ve minimum eşik değeri bu histogramın pürüzsüzleştirilmiş hali üzerinde sırası ile soldaki ve sağdaki oklar ile gösterilmektedir. Sağdaki ok piksellerin yanlış sınıflandırmasına neden olacaktır.

- **Bölütlemenin minimum varyans**

Bir bölütlemenin homojen gri değerlere sahip olması gerektiğini varsayarsak, bölütlemeye orijinal gri değerlerin varyansını en aza indirgeyen veya nesnelere ve arka plan arasındaki varyansı en yükseğe çıkaran bir eşik seçmek gerekir. Alternatif olarak, bu iki yöntemin birlikte kullanılması ile en iyi sonucu veren eşik değeri elde edilmeye çalışılır.

Bir eşiğin, yani iki farklı bölümün kullanıldığı bir örnek verelim. Basitlik için görüntünün histogramı $H(v)$ 'yi $h(v)$, yani $\sum h(v) = 1$ olarak normalize ederiz. Bunun için $h(v) = H(v) / n$ formülü her v için uygulanır. Burada n resimdeki

toplam piksel sayısını ifade etmektedir. Görüntüdeki gri değerlerin varyansı (σ^2) denklem 2.13'te verildiği gibi hesaplanır.

$$\sigma^2 = \sum_v (v - \mu)^2 h(v) \quad (2.13)$$

Bu denklemde $\mu = \sum_v v h(v)$ görüntünün ortalama gri değeridir. Eşik değeri t olan görüntüyü 0 ile ifade edilen bir arka plan, ve 1 ile ifade edilen nesne olarak ikiye bölersek, her bölge içindeki gri değerlerin varyansı sırasıyla aşağıdaki gibidir.

$$\sigma_0^2 = \sum_{v < t} (v - \mu_0)^2 h(v) \quad (2.14)$$

$$\sigma_1^2 = \sum_{v \geq t} (v - \mu_1)^2 h(v) \quad (2.15)$$

2.14 ve 2.15 deki μ_0 ve μ_1 aşağıda verildiği gibidir.

$$\mu_0 = \frac{1}{h_0} \sum_{v < t} v h(v) \quad (2.16)$$

$$\mu_1 = \frac{1}{h_1} \sum_{v \geq t} v h(v) \quad (2.17)$$

Bu iki bölgenin olasılık dağılımı ise:

$$h_0 = \sum_{v < t} h(v) \quad (2.18)$$

$$h_1 = \sum_{v \geq t} h(v) \quad (2.19)$$

Tüm bölümlerin toplam varyans ise $\sigma_w^2(t) = h_0 \sigma_0^2 + h_1 \sigma_1^2$ formülü ile hesaplanabilir. Bu varyans sadece t eşik değerine bağlıdır. Bu da σ_0^2 değerini minimize ederek optimal t eşik değerini bulabileceğimiz anlamına gelmektedir. Arka plan ve nesne bölümleri arasındaki varyans 2.20'da verildiği gibi hesaplanır.

$$\sigma_b^2 = h_0 (\mu_0 - \mu)^2 + h_1 (\mu_1 - \mu)^2 \quad (2.20)$$

2.3. Kenar Tabanlı Bölütleme

İkili nesne kenarlarıyla temsil edildiğinden, bir görüntünün ayrı nesnelere bölünmesi bu nesnelere kenarlarının bulunması ile gerçekleştirilebilir. Kenarları kullanarak bölütlemeye yönelik tipik bir yaklaşım aşağıda verildiği gibidir:

1. Orijinal görüntünün makul kenarlarını içeren bir kenar görüntüsü hesaplanır. Bunun için herhangi bir gradient tabanlı yöntemler kullanılabilir.
2. Kenar görüntüsünde yalnızca kapalı nesne sınırları olanlar bırakılır.
3. Nesne sınırları doldurularak bir parçalı görüntü sonucu döndürülür.

Bu adımlar incelendiğinde üçüncü adım yani sınırların doldurulması işleminin algoritmik olarak bir zorluğu bulunmamaktadır. Zorluk genellikle imajın kapalı sınırlara dönüştürülmesini içeren ikinci aşamadır. Bu aşamada kapalı sınırlara sahip olmayan ve gürültüye sebep olan kenarların elenmesi gerekmektedir. Ayrıca büyük ölçüde kapalı olan ancak kenar bulma algoritmalarının yetersizliği sebebiyle tam olarak çıkarılamayan kenarların uç noktalarının bağlanarak kapalı bir şekil elde edilmesi gerekir [35].

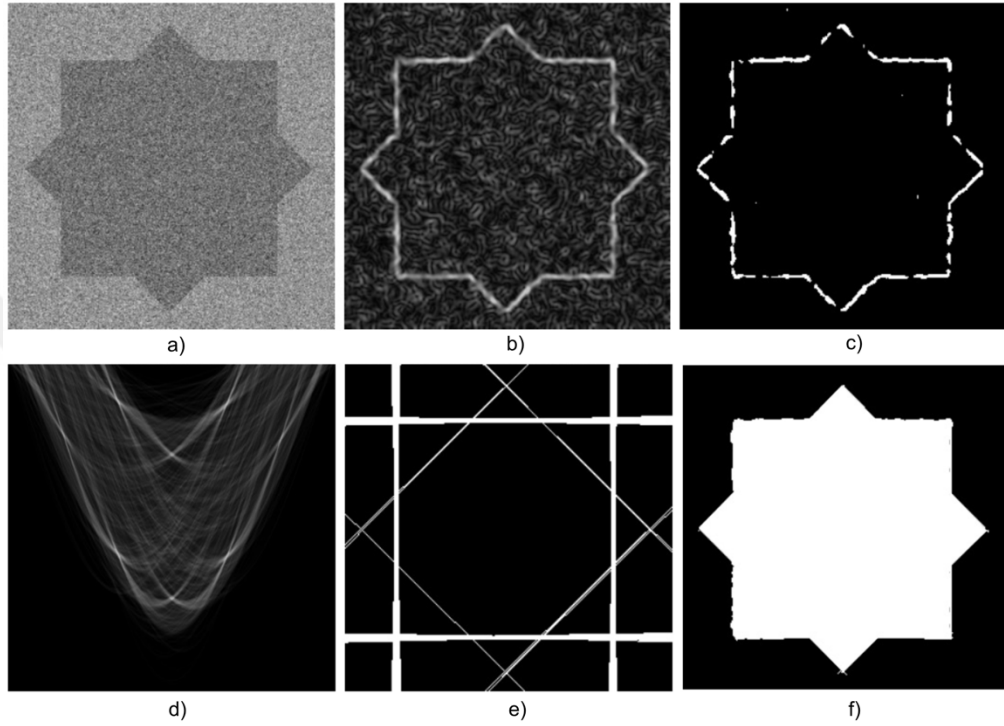
2.3.1. Kenar bağlama

Kenar algılama yöntemleri, bize bölütleme için ihtiyaç duyduğunuz mükemmel ve net sınırları nadiren verir [36]. Genellikle olmaması gerektiği yerde sahte kenarlar algılanır ve kenar olması gereken yerlerde boşluklar oluşur. Tam bir kapalı şekil oluşturmayan kısmi kenarların en büyük problemi, bir nesne sınırını oluşturması için bazı kenar bağlama yöntemlerine ihtiyaç duymasıdır.

- **Hough dönüşümü**

Kenarların neye benzeyeceğine dair bir fikrimiz varsa (örn. çizgisel, dairesel vb.), kısmi kenarlardan en uygun kenarları elde etmek için Hough dönüşümü kullanılabilir [37]. Bu yaklaşım, görüntüdeki nesnelere basitse yani az sayıda parametreye sahip şekiller içerdiğinde daha iyi sonuçlar verir. Hough dönüşümü ile karmaşık şekilleri bulmak genellikle zaman alan bir yöntemdir [38]. Bir diğer dezavantaj ise, Hough dönüşümünün nesne şekillerinde beklenmedik değişikliklerin

üstesinden gelmede genellikle yetersiz kalmasıdır. Şekil 2.11’de Hough dönüşümünü kullanarak bölütleme işlemi gerçekleştirilmiştir. Şekil 2.11’de a) orijinal görüntü b) kenar algılama yöntemi c) eşik değer uygulandıktan sonra d) Hough dönüşüm e) Hough dönüşümden elde edilen maksimum hatlar f) bölütleme sonucu olarak elde edilmiştir.




Şekil 2.11. Hough dönüşümü kullanılarak kenar bağlama örneği

- **Komşuluk arama**

Kenar bağlantılarını tamamlamak için kullanılan yerel bir yöntemdir. Bir kenar pikseli etrafında küçük bir alanda muhtemel kenar piksellerini bulmak için komşuluk taraması yapılır. Bu tarama sırasında kenar pikseli ile komşu piksel arasında bir ilişki bulunması amaçlanır [39]. Bu yöntem için tipik bir prosedür, bir başlangıç kenar pikseli seçme ile başlar. Ardından küçük bir komşuluk çerçevesinde en uygun bağlantı adayı bulunarak bu piksel asıl piksele bağlanır. Son olarak, birleştirilmiş piksel etrafında yeni bir arama başlatılarak önceki adımlar tekrar edilir [40]. Aşağıdakilerden biri gerçekleştirildiğinde işlem durdurulur:

- a) uygun bağlama aday bulunmaz,
- b) görüntü sınırına ulaşılır
- c) bağlanacak piksel şimdiki bağlantılı sınırın bir parçası haline gelir. Mevcut piksel A'nın komşuluğunda bağlanabileceği uygun bir B pikselini seçmek için birçok kriter kullanılabilir.

Kenar algılamanın bazı yöntemleri aşağıda kısaca bahsedilmiştir. Sobel kenar algılama algoritması görüntü işleme algoritmaları arasında en çok bilinenlerdendir. Sobel algoritmasında iki adet konvolüsyon çekirdek kullanılır. Bunlardan birisi yatay kenarları bulmaya yararken diğeri dikey kenarları bulmaya yarar. Bu çekirdekler görüntü içerisinde ışık yoğunluk değişiminin ani olduğu yerleri belirlememize yarar. Bir nevi türev yaklaşımıdır [41]. Eğimler (çekirdek uygulamasından sonraki yoğunluk değerleri) herhangi bir piksel için hesaplandıktan sonra büyüklükleri hesaplanarak kenarlar bulunmuş olur. Eğim büyüklüğü iki eğimin kareleri toplamının karekökü olarak hesaplanır. Şekil 2.12.b'de örnek resim üzerinde Sobel algoritmasının ve şekil 2.12.c'de Canny algoritmasının sonuçları verilmiştir.



Şekil 2.12. Kenar algılama yönteminin bazı uygulamaları [42]

Görüntülerdeki geniş kenar aralığını algılamak için çok aşamalı algoritma kullanan bir kenar algılama operatörüdür. 1986 yılında John F. Canny tarafından geliştirildi. Canny, tekniğin neden işlediğini açıklayan, hesaplamalı bir kenar algılama teorisi de hazırladı [43].

Canny kenar algılama algoritması 5 adımda özetlenebilir:

1. Gürültüyü gidermek için ve görüntüyü düzleştirmek için Gauss filtresini uygulanır
2. Görüntünün eğim yoğunluğunu bulunur
3. Algılanan sahte kenarlardan kurtulmak için azami bastırma uygulanır
4. Olası kenarları belirlemek için çift eşik uygulanır
5. Zayıf ve güçlü kenarlara bağlı olmayan diğer tüm kenarları bastırarak kenarların taranması tamamlanır.

2.4. Alan Tabanlı Bölütleme

Teoride, bir nesnenin sınırını belirleyerek, kapsadığı bölgeyi bulmak bize o nesnenin alanını verecektir. Yani sınır ve alan aynı nesnenin farklı gösterimleridir [44]. Bununla birlikte uygulamada, bölütleme için kenar temelli bir yaklaşımda bulunmak, bölgeye dayalı yaklaşımı kullanmaktan radikal olarak farklı sonuçlar verebilir. Dolayısıyla, bir nesne sınırının konumlandırılmasının pratik sonucu bölgenin yerini belirlemekten farklı olabilir.

Bölge tabanlı bölütleme yöntemlerinin bölme ve birleştirme olarak yalnızca iki temel işlemi vardır. Birçok yöntem bunlardan yalnızca birine sahiptir. Birleştirmeyi kullanarak görüntü parçalanmasına temel yaklaşım aşamaları aşağıda verilmiştir:

1. Başlangıç olarak resmin kaba bölütleme hali bulunur.
2. Aynı nesneye ait bölümleri oluşturmak için benzerlik gösteren komşu bölgeleri birleştirilir.
3. Birleştirilecek hiçbir bölüm kalmayana kadar 2. adım tekrarlanır.

İlk bölütleme için tüm pikseller ayrı bir bölge gibi kabul edilebilir, diğer bir deyişle her piksel kendiliğinden bir bölümdür. Birleştirme yaklaşımının temeli, iki parçanın birleştirilip veya birleştirilmeyeceğine karar vermek için kullanılan

benzerlik ölçüttür [45]. Bu kriter, gri değer benzerliği (örneğin, ortalama gri değerler arasındaki fark veya bölgeler arasındaki maksimum veya minimum gri değer farkı), bölümler arasındaki sınırın kenar kuvveti, bölümlerin dokusu gibi unsurlardan birine dayanabilir. Diğer birçok olasılık bölütlemeyi kullanarak görüntü parçalanmasının temel şekli şöyledir:

1. Başlangıç olarak resmin eksik bölütlenmesi elde edilir,
2. Bir bakıma homojen olmayan her bir bölüm (her bölüm gerçekten tek bir bölüm olmadığından) bölünür.
3. Tüm bölümler homojen olana kadar 2. adım tekrarlanır.

İlk aşamada aslında bölütleme işlemi gerçekleşmeyebilir, diğer bir deyişle tüm görüntü tek bir bölüm olarak algılanır. Bir parçanın homojen olmama kriteri, gri değerlerinin varyansı, dokusunun varyansı, güçlü iç kenarların oluşumu veya diğer kriterler olabilir. Temel birleştirme ve bölme yöntemleri, aynı bölütleme yöntemine göre yukarıdan aşağıya ve aşağıdan yukarıya doğru benzer bir yaklaşım gibi görünür. Buna rağmen parçaların birleştirilmesi basittir, ancak bir bölümün bölütlenmesi yani uygun alt bölümlere ayrılması daha karmaşık bir işlem gerektirir. Bölmeye dayalı yöntemlerde, en başında sahip olduğumuz bölütleme problemi şekil değiştirerek yerel bir düzeyde tekrar karşımıza çıkmaktadır. Bu sorundan kaçınmak için, temel bölme yaklaşımı, genellikle, homojen olmayan bölümlerin basit geometrik formlara (genellikle dört kareye bölünmesi) yinelemeli olarak bölünmüş olduğu birleştirilmiş bölme ve birleştirme yaklaşımıyla geliştirilir. Bu işlem için genelde rasgele bölge sınırları (gerçekçi sınırlarla ilişkilendirilmemiş olabilir) oluşturur ve yanlış sınırları kaldırmak için birleştirme adımları sürece dahil edilir.

Başlangıç pikselinin renk benzerliğini kullanarak yayılmasını ve tüm nesneyi oluşturan piksellere ulaşabilmeyi sağlayan bir yöntemdir. Bu yöntemin sınır tabanlı yöntemlere göre avantajı tutarlı bölgelerin bulmasını garanti etmesidir. Kenar tabanlı algoritmalarda, kenar kayıpları nesnenin (örneğin kayısı ağacı) kaybolması anlamına gelmektedir. Diğer bir avantaj, içten dışa doğru çalışan bir yöntem olduğu için, başlangıç nokta doğru seçildiğinde iyi sonuçlar elde ediliyor olmasıdır.

Dezavantajları ise başlangıç noktası belirleme zorluğudur. Ancak bu çalışmada kayısı ağacı için başlangıç noktası rahatlıkla tespit edilmektedir.

Algoritmanın temel prensibi şu şekildedir: Tek bir p pikselinden başlayarak tutarlı bir bölgeyi doldurabilmek için benzerlik ölçüsüne ihtiyaç duyulmaktadır. p pikseline bitişik q pikseli olsun. q pikselin p pikseline bağlanabilmesi için $S(p, q) > T$ ise ekleyebiliriz. Bu işlem öz yinelemeli devam ettirilirse bitişik komşu piksellerden yakın olanları nesneye eklenecektir. Burada S fonksiyonunun nasıl tanımlanacağı ve T eşik değerini ne olacağının bilinmesi gerekmektedir.


2.4.1. Alan büyüme

Bölme işleminin birçok birleştirme yöntemi, bitişik tek piksel bölümlerini tek bir bölümlerle birleştirmek için bölge büyüyen bir yöntem kullanır. Bölge büyütme için başlangıç nokta adı verilen bir dizi başlangıç pikseli gerekir. Bölge büyüme süreci, nesne içerisindeki bir pikseli başlangıç noktası olarak, bu noktanın 4 bağlantılı komşusunun tümünü araştırmaktan ve uygun komşuları noktayla birleştirmekten oluşur. İlk nokta, başlangıç noktalar kümesinden çıkarılır ve birleştirilmiş komşular kümesine eklenir. Bu noktanın komşulukları daha önceden incelenmediyse başlangıç noktalar kümesine eklenir. Bölge büyütme süreci başlangıç noktalar kümesi boşalanıncaya kadar devam eder [46]. Bu yöntemin sahte kodu şekil 2.13'de verilmiştir.

1	<code>map = zeros(size(I))</code>
2	<code>while (uzaklik < tolerans)</code>
3	<code> komsuPikseller = secilmemisKomsuluklariBul(x, y)</code>
4	<code> komsuPiksellerListesi.add(komsuPikseller)</code>
5	<code> $[P_{x,y}, uzaklik] = \mathbf{min}$ (komsuPiksellerListesi – ortalama)</code>
6	<code> map(P_x, P_y) = 1</code>
7	<code> update(ortalama)</code>
8	<code> $x = (P_x)$ $y = (P_y)$</code>
9	<code> komsuPiksellerListesi.remove($P_{x,y}$)</code>
10	<code>end</code>


Şekil 2.13. Alan genişleme yönteminin sahte kodu

Alan büyüme yöntemini kullanarak ilk önce kayısı ağacı bölütlenir. Bu işlemlerin video çerçeveleri üzerinde performanslı çalışması için piramit yöntemi kullanılarak çerçeve boyutu makul seviyelere indirgenmiştir. Piramit yönteminin boyutlandırma prensibi şekil 2.14’de verilmiştir.



Şekil 2.14. Piramit yöntemi [47]

Kayısı meyve bölgelerini bölütleyebilmek için ilk olarak ağaç ön plan nesnesini arka plandan ayırmak gerekir. Daha sonra tekrar bir bölütleme işlemi gerçekleştirilerek ayıklanan ağaç nesnesi üzerindeki kayısı meyvesine ait bölgeler tespit edilmektedir. Bu işlemin akış diyagramı şekil 2.15’de verilmiştir.



Şekil 2.15. Alan büyüme yöntemi akış diyagramı

2.4.2. Alan Birleřtirme

Bitiřik blmleri birleřtirmek daha iyi bir bltleme sonucu verebilir. İki bitiřik paranın birleřtirilmesi ortak sınırlarını kaldırarak gerekleřtirilebilir [46]. İki kesimin birleřtirilmesi gerekip gerekmediđine karar vermek iin iki tr kriter bulunmaktadır. Bunlar ortak sınırın kenar dayanımını deđerlendirme ve iki kesimin blge zelliklerini karřılařtırmadır.

2.4.3. Blme ve birleřtirme yntemleri

Alan birleřtirme aglomeratif bir yaklařım iken, alan blme ayrıklařtırıcı bir yaklařımdır. Daha nce de belirttiđimiz gibi yntemlerdeki bu farklılık iki yaklařımın birbirinin zıddı olduđu anlamına gelmez. Ancak temelde farklı sorunlar ortaya ıkmasına neden olur. İki paranın birleřtirilmesi basittir, ancak bir blmn blnmesi, orijinal blgeyi blme iin uygun alt blmlerin belirlenmesini gerektirir [48]. Bir paranın nasıl blnebileceđi probleminin kendisinin bir bltleme problemi olduđunu ve bunu byle kabul edebildiđimizi varsayalım. Herhangi bir bltleme yntemi, alt blmleri oluřturmak iin uygulanabilir. Hiyerarřik seviyenin yanı sıra isel bir fark yoktur. Bir blgenin blnmeye ihtiya olup olmadıđına karar vermek iin ařađıdaki Őartları yerine getirip getirmediđine bakılır [49]:

- a) Gri deđer deđiřimi bir eřiđi ařıyor veya
- b) Bir dokunun varyansı bir eřiđi ařıyor veya
- c) Histogram entropisi (veya bařka bir histogram ls) bir eřiđi ařıyorsa veya
- d) Yksek kenarlı piksel mevcut.

Bir blmn bltlenmesi gerektiđinde, blm zerinde bltleme bařlatmaktan daha hızlı bir yaklařım, onu sadece drt kadrana blmektir. Bu durumda blge sınırlarını gereki olmayan konumlara yerleřtirme ihtimali elbette yksektir. Bu sorun, birleřtirme iřlemleri bltleme iřlemine eklenerek azaltılır [50].

2.4.4. Doku ölçüsünü almak

Doku önlemleri, diğer ölçütlerle tamamen aynı şekilde bölütleme için kullanılır. Benzer ölçüye sahip bölgeler, birleştirme için adaydır ve bir ölçünün yüksek varyansı olan bir bölge, bölünme için bir adaydır.

Literatürde dokunun tespiti ve ölçülmesini konu alan birçok makale bulunabilir [51] [52] [53]. Çoğunlukla, sunulan yaklaşımlar yerel görüntü istatistiklerine, bir (Fourier) görüntü dönüşümüne veya görüntü modellerinin sözdizimine dayanmaktadır. Aşağıda bun yöntemlerden bazılarına değinilmiştir.

I. Otokorelasyon


Bir görüntünün kendisinin çevrilmiş versiyonlarıyla korelasyonu, bize bir dokunun desen boyutu hakkında bilgi verebilir. Bu otokorelasyon, çevrilmiş gri değer $f(x + k, y + 1)$ ile belirli bir bölgedeki her gri değer $f(x, y)$ çarpımı ile hesaplanır. Pratikte, 0 ile 1 arasında normalize edilmiş bir değeri hesaplayan biraz daha karmaşık bir formül kullanmak çoğu zaman uygundur. R bölgesinin (resmin bütünü de olabilir) otokorelasyon katsayısı $r(k, l)$ (dönüşüm katsayısı k ve l ile) denklem 2.11'de verildiği gibi tanımlanır [54].

$$r(k, l) = \frac{\sum_{(x,y) \in R} f(x,y)f(x+k,y+l)}{\sum_{(x,y) \in R} f^2(x,y)} \quad (2.21)$$

Zirvelerin arasındaki mesafe desen boyutuna eşit ise tekrarlayan bir desen, otokorelasyon işlevinde piklere yol açar. Zirveleri kesin bir şekilde ayırt edemezsek, (0,0) noktasındaki fonksiyon eğimi bize bilgi verebilir. Bu nokta etrafındaki nispeten küçük bir eğim, büyük bir deseni gösterirken; büyük bir eğim küçük bir deseni ifade eder. Kendiliğinden ilişkilendirme fonksiyonunun şekli, elde edilen uygun skala şekli ölçümlerinin bir vektörü ile karakterize edilmiştir. Elde edilen karakteristikler doku ölçümü için kullanılabilir. Genel olarak, otokorelasyon fonksiyonundan hesaplanan momentler (özellikle ikinci dereceden) vektör dahil edilir ancak sabit yerlerde otokorelasyon fonksiyonunun türevleri veya örnekleri gibi diğer bilgiler de dahil edilebilir.

I. Fourier tekniđi

Pek çok doku örüntüsü farklı periyodiklik ve yönlendirme sergilediđinden, Fourier teknikleri bu kalıpları karakterize etmek için uygun bir çerçeve sunabilir. Yukarıdaki teknikler benzer şekilde, bir doku genellikle skaler doku ölçümleri vektörü ile karakterize edilir. Bu bağlamda, her ölçüm genellikle bir bölgenin Fourier büyüklüğü resminin maskelenmiş bir versiyonundan elde edilir [55]. Ölçümün kendisi genellikle enerji, yani maskelenmiş Fourier görüntüsündeki kare değerlerin toplamı veya maskelenmiş Fourier görüntüsünde meydana gelen maksimum değerdir. Genel maske şekilleri, Şekil 2.16'daki gibi halkalar (desen boyutu ile ilgili ölçümler için) sadece belirli bir frekans aralığına (band geçişi) ve kamalar (oryantasyonla ilgili ölçümler için) sınırlı kamera açılarında yönlendirilen frekansları geçmesine izin veren şeklindeki maskelerdir.



Şekil 2.16. Fourier doku tanımında kullanılan maske örnekleri

2.5. Grafiğe dayalı bölütleme

Pek çok birleştirme algoritması, pikselleri ve bölgeleri gruplayan sabit bir kural uygularken Felzenszwalb ve Huttenlocher (2004) birlikte [56], Hangilerinin birleştirileceğini belirlemek için bölgeler arasında göreceli benzerlikleri kullanan bir birleştirme algoritması sundular; Büyük olasılıkla genel bir gruplandırma metriğini en iyi duruma getiren bir algoritma ürettiler. Piksel farklılık ölçüsü $w(e)$ ile başlar, örneğin, arasındaki 8 komşusunun yoğunluk farklarını ölçer. Alternatif olarak, Comaniciu ve Meyer'in (2002) tanıtıldığı ortak özellik uzayı mesafelerini kullanabilirler. Herhangi bir R bölgesi için iç farkı, bölgenin minimum kapsayan ağacındaki en büyük kenar ağırlığı denklem 2.22'de verilmiştir.

$$Int(R) = \min_{e \in R} w(e) \quad (2.22)$$

En az bir kenarı köşelerini birbirine bağlayan bitişik iki bölge için, bu bölgeler arasındaki fark, iki bölgeyi birleştiren asgari ağırlık kenarı aşağıda verilmiştir.

$$Dif(R_1, R_2) = \min_{e=(v_1, v_2) | v_1 \in R_1, v_2 \in R_2} w(e) \quad (2.23)$$

Onların algoritması, farkları bu iki bölgenin minimum iç farkından daha küçük herhangi iki komşu bölgeyi aşağıdaki gibi birleştirir.

$$MInt(R_1, R_2) = \min (Int(R_1) + \tau(R_1), Int(R_2) + \tau(R_2)) \quad (2.24)$$

Burada $\tau(R)$ sezgisel bölge cezasıdır ve her uygulamaya özel değerler verilebilir. Şekil 2.17'de bu yöntemin örnek bölütleme sonucu verilmiştir.



Şekil 2.17. Grafiğe dayalı bölütleme

3. KAYISI AĞACI BÖLÜTLEME UYGULAMALARI

Tez kapsamında 3 farklı yöntem ile ağacın alanını elde etmeye çalışılmıştır. Bu yöntemler kenar tabanlı (Canny), alan tabanlı (alan büyümesi), ve örme olarak belirlenmiştir. Bu yöntemler aşağıdaki görüntüler üzerinde çalıştırılmış ve elde edilen sonuçlar Çizelge 3.1’de sunulmuştur.

3.1. Kayıt Sisteminin Kurulumu ve Veri Elde Etme

Kamera verisinin yanında, 5 adet kayısı bahçesinden (Hekimhan Zigerli, Kale, Taşolar1, Taşolar, Kayısı Yetiştiricilik) Kopter yardımıyla havadan video kayıtları elde edilmiştir. İki farklı bahçenin kuş bakışı görüntüleri şekil 3.1’de verilmiştir. 4K görüntü çözünürlük kalitesine sahip olan video verileri 17m yükseklikten elde edilmiştir şekil 3.2’de Video kayıtları, kayısı hasat döneminde ve manuel uçuş gerçekleştirilerek elde edilmiştir. Video kaydı elde etmeden önce bahçelerin üstten görünümü fotoğraflanmıştır:




Şekil 3.1. Kayısı bahçelerinin üstten görünümü

Manuel elde edilen video verileri, kopter kontrolündeki ani durmalar, hızlanmalar, ağacı göremeyen alanlara kaymalar nedeniyle birçok problemin ortaya çıkmasını sağlamıştır. Stabil görüntü elde etme sıkıntısı yaşadığımız o günlerde,

Kopter firması tarafından otonom uçuş özelliği içeren yeni bir yazılım versiyonu yayınlanmıştır. Ancak kayısı sezonunun sona ermesi ve bahçelerde kayısının kalmamasından dolayı, sadece tek bir kayısı bahçesinden (Kayısı Yetiştiricilik) otonom uçuş gerçekleştirilerek video görüntüleri elde edilmiştir. Uçuş esnasında Kopter'in yerden yüksekliği önceden ayarlanan değere göre otomatik olarak sabit kalmaktadır. Kopter'in GPS desteğinin olması ve kopter yazılımında otonom uçuş özelliğinin bulunması nedeniyle tablet PC kullanılarak kayısı bahçesi üzerinde belirli seyahat noktaları tayin edilmiş ve Kopter'in otonom uçuşu sağlanmıştır.

Şekil 3.3'de örnek bir kayısı bahçesi krokisi gösterilmektedir. 108 kayısı ağacının bulunduğu ve her bir ağacın indekslenerek gelişiminin düzenli takip edildiği bu bahçe Kayısı Yetiştirme Enstitüsüne aittir. Bu bahçenin Kopter aracılığı ile havadan video görüntüleri elde edilmiştir. Kopter'in bahçe üzerindeki seyahat güzergâhı ilk dört sıra üzerinde yönlü kırmızı şerit ile gösterilmiştir.



Şekil 3.2. Kopter'in ağaç üzerinde pozisyonu




Şekil 3.3. Kayısı bahçesindeki ağaçların dizilimleri ve indekslenmeleri

3.2. Kayısı Ağacının Bölütlenmesi

Tez kapsamında 3 farklı yöntem ile ağacın alanı bulunmaya çalışılmıştır. Bu yöntemlerin avantaj ve dezavantajları doğruluk ve hız açısından karşılaştırılmıştır. Performans ve hız verileri göz önüne alınarak kayısı ağacını tespit etmek için en uygun bölütleme yöntemi seçilmiştir. Çizelge 3.1’de algoritmanın süre açısından ve 3.2’de algoritmanın kalite performansı 2.2 GHz işlemci ve 16 GB hafıza kartı özelliklere sahip bilgisayarda MATLAB ortamında gerçekleştirilen test sonuçları verilmiştir.



Şekil 3.4. Kullanılan örnek görüntüler



Şekil 3.5. Kullanılan örnek görüntülerin Ground Truth resimleri

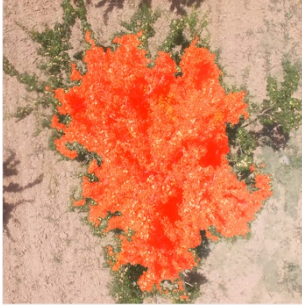

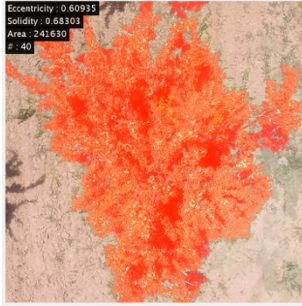






Çizelge 3.1. Algoritma maliyeti (süre) kıyaslaması

No	Kenar tabanlı	Alan Tabanlı	KNN Örne Yöntemi
Ağaç 1	0.92 sn	2.85 sn	17.43 sn
Ağaç 2	0.85 sn	2.65 sn	16.75 sn
Ağaç 3	1.11 sn	2.95 sn	17.21 sn

Çizelge 3.2. Algoritma doğruluk oranı kıyaslaması (piksel genişliği)

No	Ground Truth	Kenar tabanlı	Alan Tabanlı	KNN Örne Yöntemi
Ağaç 1	241700	232237 (%96)	242449 (%97)	241660 (%99)
Ağaç 2	224700	11286 (%5)	224684 (%99)	235015 (%97)
Ağaç 3	240150	227270 (%94)	226557 (%94)	240043 (%99)

Çizelge 3.3. Çizelge 3.1’deki görüntülerin performans kıyaslaması

No	Kenar tabanlı	Alan Tabanlı	KNN Örme Yöntemi
1			
2			
3			

Yapılan çalışmalarda, kenar tabanlı algoritmaların çalışma süresi bakımından hızlı sonuçlar ürettiği görülmüştür. MATLAB ortamında gerçekleştirilen testlerde sonuçların elde edilmesi ve ekranda görüntülenmesi için geçen süre yaklaşık olarak 0.7 – 0.9 saniye arasındadır. Ancak kenar tabanlı algoritmaların verdiği sonuçlara bakıldığında, bölütleme kalitesi çizelge 3.2’de görüldüğü gibi pek de iyi sayılmaz. Bölütlemenin yetersiz kaldığı bir örnek şekil 3.6’da verilmiştir.

Örme yönteminde kenar tabanlı algoritmaya göre çok daha yüksek kalitede sonuçlar elde edilmektedir. Ancak bu algoritmanın tamamlanması için geçen süre yaklaşık olarak 17 saniye olarak tespit edilmiştir. Bu da kenar tabanlı yöntemden yaklaşık 20 kat daha fazla süre gerektirdiği anlamına gelmektedir. Ayrıca örme yönteminin uygulanması için gereken giriş parametrelerin belirlenmesi de bu yöntemin uygulanmasının önünde engel teşkil etmektedir.

Alan büyüme algoritmasına geldiğimizde ise her iki faktör yani hız ve doğruluk açısından ikna edici sonuçlar elde edilmiştir. Doğru sonuçlar veren bu yöntem için gereken işlem süresi yaklaşık 2 ile 4 saniye arasında tespit edilmiştir. Bu süre kenar tabanlı algoritmanın yaklaşık 4 katına karşılık gelmektedir. Örme yöntemi için geçen süre ile kıyaslandığında ise uygulamada kullanılması için daha kabul edilebilir bir süredir.

Düzensizlik : Görüntü yoğunluk değerlerindeki ani değişimlere (kenar gibi) göre bölümlere ayrılır. Kenar tabanlı bölütleme algoritmaları bu kategoride yer alır ve kenar içine 1 dışına 0 değeri atanarak bölütleme işlemi gerçekleştirilir.

Benzerlik : Nesnelere karmaşık görsel dokulara sahip olabilirler. Bu durumda aşırı kenar bilgisi elde edileceğinden bölütleme yapmak oldukça güçleşir. Kenar bilgisinin kullanılmadığı durumlarda ön tanımlı kriterler (örneğin standart sapma) kullanılarak bölütleme gerçekleştirilir. Bu yaklaşım alan tabanlı bölütleme olarak bilinmektedir. Eşikleme (thresholding), alan genişlemesi (region growing), alan bölme (region splitting) ve birleştirme (merging) yöntemleri alan bölütleme yöntemlerine örnek olarak verilebilir.

Ön Plan Ayıklama, piksel rengine göre değil ön planda hareket eden nesnenin özelliklerine göre görüntü piksellerinin ön plan ve arka plan şeklinde gruplandırılması işlemine denir. Dolayısıyla bölütleme işleminde görüntü farklı bölgelere ayrılabilirken ön plan ayıklama işleminde sadece ön/arka şeklinde iki seviyeli bir çıktı vermektedir. Ön plan ayıklama yöntemleri, bölütleme işleminden daha karmaşık ve algoritma maliyeti daha yüksektir. Ayrıca kullanıcı tarafından görüntü üzerinde ön ve arka plana ait bölgelerden seçimlerin yapılma zorunluluğu bulunmaktadır.

3.2.1 Kenar algılama

Bölüm 2.3 de bahsedilen kenar bulma algoritmasının kayısı ağacı için elde edilen sonuçları çizelge 3.2’de ve şekil 3.6’da verilmiştir. Kenar tabanlı bölütlemenin birleşik olmayan ağaçlarda eksik bölütleme ile sonuçlanabileceği şekil 3.7’de verilmiştir.




Şekil 3.6. Kenar tabanlı bölütleme



Şekil 3.7. Kenar tabanlı bölütleme (eksik bölütleme)

3.2.2 KNN Örne Yöntemi

Bölüm 2.1.4 de bahsedilen KNN örme yönteminin kayısı ağacı için elde edilen sonucu şekil 3.8’de verilmiştir. Şekil 3.8.a’da orijinal resim, 3.8.b’de KNN örme için gerekli olan trimap görüntüsü, 3.8.c’de bölütleme sonucu elde edilen siyah beyaz görüntüsü, 3.8.d’de bölütleme sonucunun orijinal resim üzerinde gösterimi yapılmıştır.




Şekil 3.8. KNN Örme yöntemini kullanarak bölütleme sonucu.

3.2.3 Alan Büyüme Algoritması

Bölüm 2.4.1’de bahsedilen alan büyüme yöntemini kullanarak kayısı meyve bölgelerini bölütleyebilmek için ilk olarak ağaç ön plan nesnesini arka plandan ayırmak gerekir. Daha sonra tekrar bir bölütleme işlemi gerçekleştirilerek ayıklanan ağaç nesnesi üzerindeki kayısı meyvesine ait bölgeler tespit edilmektedir. Elde edilen sonuçlar şekil 3.9 ve 3.10 da gösterilmiştir.



Şekil 3.9. Alan genişleme yöntemi kullanılarak kayısı meyvesinin bölütlenmesi (sol üst) Orijinal resim (sağ üst) Ağaç bölütleme sonucu (alt) Kayısı bölütleme sonucu



Şekil 3.10. Alan genişleme yöntemi kullanılarak kayısı meyvesinin bölütlenmesi (sol üst) Orijinal resim (sağ üst) Ağaç bölütleme sonucu (alt) Kayısı bölütleme sonucu

3.3 Sarı/Yeşil Oranı Özniteliği

Görüntü elde etme aygıtı (Quad-Kopter kamerası) ile zemin arasındaki uzaklık değerinin uçuş esnasında sürekli değişim gösterebilmesi, bölütlenen ağaç alanı bilgisinin ve ağaç üzerindeki toplam kayısı bilgisinin sürekli değişmesine neden olmaktadır. Bu durum alan bilgileriyle kg bilgisinin tutarlı eşleşmesini engellemektedir.

Güncel kopter yazılımında “aygıt yüksekliğini sabitle” özelliği olmasına rağmen kayısı bahçelerindeki tepecikler, çukurlar ve eğimli yüzeylerden dolayı istenilen başarımda z-ekseninde sabitleme mümkün olmamaktadır. Bu dezavantajı ortadan kaldırmak ve tutarlı bir tahmin gerçekleştirebilmek için z-ekseninde değişmeyecek bir özniteliğe ihtiyaç duyulmaktaydı.

Sarı/yeşil özniteliğinin kullanımı önerilmiştir. Yeşil değeri, bölütlenen ağacın alanını, sarı değeri, bu alan içerisinde kayısının kapladığı toplam alanı ifade etmektedir. Bir kayısı ağacı hakkında elde edilen sarı/yeşil oranı kopterin ağaca yaklaşım uzaklaşmasıyla önemsenmeyecek kadar küçük değişimler göstermektedir.

Böylelikle tek bir kayısı ağacının tepeden çekilen yaklaşık 10-20 görüntüsündeki sarı/yeşil oranları aynı kilogram değerini ifade etmektedir. Bu nedenle yapay sinir ağının eşleme kabiliyeti oldukça yüksek değerler üretebilmektedir.

Sarı/yeşil oranının elde edilme adımlarının daha iyi anlaşılabilmesi için Şekil 3.9 ve 3.10’de iki farklı kayısı ağacı üzerinden elde edilen sonuçlar gösterilmektedir. Elde edilen özellikler Çizelge 3.4’de 10 ağaç için verilmiştir.

Çizelge 3.4. Ağaçlardan çıkarılan özellikler

Ağaç	Katılık	Dış Merkezlik	Yeşil Alan	Sarı Alan	Sarı/Yeşil	Gerçek KG
1	0,7536	0,2823	1018	102	0,1001	170
2	0,7514	0,6125	701	84	0,1198	102
3	0,7991	0,3887	879	88	0,1001	110
4	0,7218	0,3142	958	95	0,0991	150
5	0,7203	0,7717	1096	110	0,1003	162
6	0,6862	0,6736	1212	105	0,0866	120
7	0,7391	0,5245	1084	143	0,1319	182
9	0,7198	0,5253	807	130	0,1610	195
10	0,7235	0,4608	983	170	0,1729	225

3.4 Rekolte Tahmin Doğruluğu

Kayısı Yetiştiriciliğinde bulunan bahçeden elde edilen video görüntüleri kullanılarak YSA'nın eğitim işlemi gerçekleştirilmiştir. Giriş katmanında üç, orta katmanında sekiz ve çıkış katmanında bir hücre bulunan üç katmanlı bir YSA kullanılmıştır. Giriş katmanındaki hücrelere katılık, eğrilik, yeşil alanı, sarı alanı ve sarı/yeşil öznitelikleri verilmiştir. Orta katmanda bulunan hücrelerin aktivasyon fonksiyonları sigmoid, çıkış katmandaki hücrenin aktivasyon fonksiyonu doğrusal olarak belirlenmiştir. Çıkış katmanına bu ağaçtan elde edilen kayısı miktarı (kilogram) şeklinde verilmiştir. Öğrenme yöntemi olarak Levenberg-Marquard ve geriye yayılım tercih edilmiştir. Toplanan verinin %70 eğitim, %15 çapraz doğrulama ve %15'i test verisi olarak kullanılmıştır.

3.5 Yöntemlerin karşılaştırılması

Bu çalışmada meyve tespiti için literatürde farklı yöntemler sunulmuştur. Sunulan yöntemlerin çoğunda temel olarak renk ve şekil tabanlı bir yöntem kullanılmıştır [12] [11]. Renk ve şekil tabanlı yöntem kullanan farklı çalışmaların başarımları sırası ile 91% ve 50 % olarak bildirilmiştir. [14] çalışmasında ise portakal meyvesi için bizim yöntemle yakın bir yöntem sunmuştur ve 98% başarı oranı elde etmiştir. Fakat bu çalışmada elde edilen görüntüler şekil 1.6'de görüldüğü gibi portakal ağacına çok yakın bir şekilde elde edilmiştir. Kullanılan görüntülerin elde edilmesinde zorluk, yöntemin otomatikleşmiş bir şekilde uygulanmasının önünde engel oluşturmaktadır. Yine de nihai sonuca baktığımız zaman çalışmada iyi bir başarı oranı elde edilmiştir.

Bizim önerdiğimiz yöntemde görüntüler kuş bakışı ve 17 metre yükseklikten elde edilmiştir. Bölütleme için kullanacağımız ağacın örnek görüntüsü şekil 3.11 ile verilmiştir. Çalışmamızda kullanılan görüntülerde kayısı meyvesinin net görüntüleri olmadığından, bu meyvelerin özelliklerinin çıkarımı oldukça zordur. Bu sebepten dolayı önerdiğimiz yöntemde sadece meyvenin tespiti değil, kayısı ağacının öznelikleri (düzensizlik, benzerlik, ağacın alanı) ve ağaç üzerindeki toplam kayısı alanı çıkarılarak bir rekolte tahmin sistemi geliştirilmiştir.



Şekil 3.11. Kayısı ağacının kuş bakışı görüntüsü

Geliştirilen yöntemin uygulanmasında doğruluk oranı 90% olarak tespit edilmiştir. Bu oranın YSA'nın eğitimi için kullanılan örneklerin çoğaltılması ile arttırılacağı öngörülmektedir. Yani eğitim verisinin artması ile sistemin daha dakik sonuçlar vermesi beklenmektedir.

Çizelge 3.5. Rekolte tahmini için yapılan çalışmalar

No	Çalışma Adı	Tespit Edilen Meyve	Çalışma yılı	Rapor edilen başarı oranı	Referans No
1	Fruit Detection, Tracking, and 3D Reconstruction for Crop Mapping and Yield Estimation	Ananas	2010	%50	[11]
2	Estimation of mango crop yield using image analysis – Segmentation method	Mango	2012	%91	[12]
3	Automatic Segmentation and Yield Measurement of Fruit using Shape Analysis	Portakal	2012	%98	[14]
4	Yield Estimation in Vineyards by Visual Grape Detection	üzüm	2011	%98	[15]
5	A Feature Learning Based Approach for Automated Fruit Yield Estimation	Elma	2015	%81	[16]
6	Yield estimation in citrus with SUAVs	Portakal	2016	%81	[17]

Literatürdeki bazı yöntemler tespit ettikleri meyve ve elde ettikleri başarı oranları çizelge 3.5’de kıyaslanmıştır. Ancak kullanılan görüntülerin kalitesinin görüntü bölütlenmesi doğrudan etkisi olduğu gözlemlenmektedir. Bu sebeple yukardaki çalışmalarının başarımının karşılaştırılması için kullandıkları görüntüleri de hesaba katmak gerekir. Yukardaki çalışmalarda kullanılan örnek görüntüler şekil 1.4, 1.6 ve 1.7’de verilmiştir.



4. SONUÇ

Bu Tez çalışmasında, yıl içerisindeki kayısı ürünü fiyatını belirlemede önemli etkiye sahip olan kayısı rekolte tahmini işlemi yazılımlar aracılığıyla gerçekleştirilmiştir. Geliştirilen sistem Malatya'daki kayısı bahçesinden Quad-Kopter ile kuşbakışı görüntüsü alınan kayısı ağaçları üzerinde uygulanmıştır. Uygulama kayısı görüntülerinin elde edilmesi ve bu görüntülere bakarak rekolte tahmininde bulunulması olarak iki aşamalı gerçekleşmektedir. Kopter aracılığı ile kayısı bahçesi görüntüleri edilmekte ve zeki yazılım yardımıyla bu görüntüler analiz edilip rekolte tahmini yapılmaktadır.

Uygulanan zeki yazılım bilgisayar görme, görüntü işleme ve makine öğrenmesi tekniklerini birlikte kullanmaktadır. Yapay sinir ağına verilmesi için öncelikle görüntüye ait öz nitelikler çıkarılması gerekmektedir. Bundan dolayı ilk olarak elde edilen görüntüdeki farklı nesnelere birbirinden ayıran bölütleme işlemi uygulanmıştır. Ağaç bölütleme için üç farklı yöntem denenmiştir, süre ve kalite bakımından en uygun yöntemlerin alan tabanlı algoritmalar olduğu tespit edilmiştir. Ağaç ve çimlerin birleştiği noktaların denen 3 yöntem için de bölütleme negatif etki oluşturduğu gözlemlenmiştir.

Bir kayısı bahçesinde bulunan 108 ağaçtan elde edilen toplam 879 görüntü üzerinden sistem geliştirilmiştir. Tahmin işlemini gerçekleştirmek için YSA kullanılmıştır. Öğrenme yöntemi olarak Levenberg-Marquard yöntemi ve geriye yayılım algoritması tercih edilmiştir. Toplanan verinin %70'i eğitim, %15'i çapraz doğrulama ve %15'i test verisi olarak kullanılmıştır. Test için kullanılan görüntülere ait sonuçların bir kaçı çizelge 4.1'de verilmiştir. Çizelge 4.1 göz önüne alındığında geliştirilen sistemin yaklaşık 30 kg tolerans dahilinde doğru sonuçlar verdiği görülmektedir. Ağaçtan elde edilmesi beklenen ürün miktarı arttıkça uygulamanın göstermiş olduğu başarı artmaktadır. Test aşamasında kullanılan toplam 131 veri için tahmin başarı oranı elde edilmiş ve sonuç olarak bu başarımların ortalaması alınarak genel başarı oranı elde edilmiştir. Bu oranlar çizelge 4.1'de belirtilmiştir.

Çizelge 4.1. Elde edilen tahmin sonuçları

Ağaç	Gerçek KG	Tahmini KG	Fark	Başarı oranı
1	81	55	26	0.67
2	162	150	12	0.92
3	162	183	-21	0.88
4	149	130	19	0.87
5	162	175	-13	0.92
6	266	253	13	0.95
...				
131	220	195	25	0.88
Ortalama Başarı Oranı				0.90

Yapılan tez çalışmasında gerçekleştirilen bölütleme ve sınıflandırma işlemlerini içeren yazılım düzenli yapıya sahip iç içe geçmemiş bir kayısı bahçesinden rekolte miktarını %90 civarında doğru tahmin edebilmektedir. Yapılan çalışmalar sonucu yöntemin rekolte tahmini için pratik, uygulanabilir ve ekonomik bir yöntem olduğuna kanaat getirilmiştir.

Ancak kayısı hasat döneminin kısıtlı bir süreye sahip olması, önerilen sistemin genelleşebilmesi için yeterli video kaydı elde edilmesini engellemiştir. Bu nedenle bir sonraki kayısı hasat döneminde otonom uçuş gerçekleştirilerek yeni video kayıtları elde edilecek ve yöntemin geliştirilmesi sağlanacaktır. Ayrıca düzenli yapılı bir bahçe üzerinde başarılı çalışan sistemin düzensiz, iç içe geçmiş ağaçlara sahip bir bahçedeki sağlamlığı test edilecektir. Genelleştirme ve sağlamlaştırma çalışmalarından sonra önerilen sistemin ürüne dönüşmesi ve Malatya geneline yayılması çalışmalarının yapılması hedeflenmektedir. Eğitim verisinin artması ile sistemin başarı oranının artması öngörülmektedir.

KAYNAKLAR

- [1] M. R. Ünal, *Kayısı araştırma raporu*, Fırat Kalkınma Ajansı, Malatya, 2010.
- [2] IHA, Milliyet, (2014). <http://www.milliyet.com.tr/kib-in-2014-yili-tahmini-findik-rekoltesi-giresun-yerelhaber-304689/>. (Erişildi: 15 05 2017).
- [3] S. ARSLAN. (2013) *Kuru Kayısı Sektör Raporları*, T.C. Ekonomi Bakanlığı , Malatya.
- [4] Ö.AVCI, Hürriyet, (2014). <http://www.hurriyet.com.tr/findikta-rekolte-tartismasi-buyuyor-26850267>. (Erişildi: 15 05 2017).
- [5] S. Puttemans, Y. Vanbrabant, L. Tits, *Automated visual fruit detection for harvest estimation and robotic harvesting*, Image Processing Theory Tools and Applications (IPTA) Belgium, 2016.
- [6] U. Verma, D. R. Aneja ve B. K. Hooda, *Principal component technique for pre harvest estimation of cotton yield based on plant biometrical characters.*, **J. Cotton Res.**, 29:2 (2015) 339-343.
- [7] F. Orlandi, F. Aguilera, C. GalÁN, M. Msallem, *Olive Yields Forecasts and Oil Price Trends In Mediterranean Areas: A Comprehensive Analysis of The Last Two Decades*, **Experimental Agriculture**, 53:1 (2017) 71-83.
- [8] D. Font, T. Pallejà, M. Tresanchez, M. Teixidó, *Counting red grapes in vineyards by detecting specular spherical reflection peaks in RGB images obtained at night with artificial illumination*, **Comput. Electron. Agric.**, 108:1 (2014) 105–111.
- [9] W. Maldonado, JC. Barbosa, *Automatic green fruit counting in orange trees using digital images*, **Comput. Electron. Agric.**, 127:1 (2016) 572–581.
- [10] S. W. Chen, S. S. Shivakumar, S. Dcunha, J. Das, E. Okon, C. Qu, C. J. Taylor ve V. Kumar, *Counting Apples and Oranges With Deep Learning: A Data-Driven Approach*, **IEEE Robot. Autom. Lett.**, 2:2 (2017) 781-788.
- [11] J. Moonrinta, S. Chaivivatrakul, *Fruit Detection, Tracking, and 3D Reconstruction for Crop Mapping and Yield Estimation*, Computer Science and Information Management Asian Institute of Technology Pathumthani, 2010.
- [12] AB. Payne, KB. Walsh, PP. Subedi, D. Jarvis, *Estimation of mango crop yield using image analysis – Segmentation method*, **Comput. Electron. Agric.**, 91:57 (2013) 64.

- [13] Z. Malik, S. Ziauddin, AR. Shahid, *Detection and Counting of On-Tree Citrus Fruit for Crop Yield Estimation*, **IJACT**, 7:5 (2016) 519-523.
- [14] Z. Malik, S. Ziauddin, AR. Shahid, *Automatic Segmentation and Yield Measurement of Fruit using Shape Analysis*, India, 2012.
- [15] S. Nuske, S. Achar, T. Bates, Stephen Nuske, *Yield Estimation in Vineyards by Visual Grape Detection*, Proceedings of the IEEE/RSJ International Conference on Intelligent Robots and Systems (Rep U S), San Francisco, 2011.
- [16] C. Hung, J. Underwood, J. Nieto, S. Sukkarieh, *A Feature Learning Based Approach for Automated Fruit Yield Estimation*, **Springer Int. Pub.**, (2015) 485-498.
- [17] U. E Paulo, C. A Jaboticabal, S Paulo, *Estimation of orange yield in citrus orchard based on digital photography*, **AJAR**, 10:31 (2015) 3086-3092.
- [18] M. W. Khan, *A Survey: Image Segmentation Techniques*, **IJFCC**, 3:2 (2014) 89-93.
- [19] S. Taheri, SH. Ong, VFH. Chong, *Level-set segmentation of brain tumors using a threshold-based speed function*, **Image Vis. Comput.**, 28:1 (2010) 26-37.
- [20] T. Kancharla, P. Kharade, S. Gindi, K. Kutty ve V. G. Vaidya, *Edge based segmentation for pedestrian detection using NIR camera*, Image Information Processing (ICIIP), Shimla, India, 2011.
- [21] J. Tang, *A color image segmentation algorithm based on region growing*, Computer Engineering and Technology (ICCET), 2nd International Conference on, Chengdu, China, 2010.
- [22] P. Rai, S. Singh, *A Survey of Clustering Techniques*, **Int. J. Comput. Appl. T.**, 7:12 (2010) 0975–8887.
- [23] M. Dellepiane, *Archeological excavation monitoring using dense stereo matching techniques*, **J. Cult. Herit.**, 14:3 (2013) 201–210.
- [24] A. Papazoglou, V. Ferrari, *Fast Object Segmentation in Unconstrained Video*, The IEEE International Conference on Computer Vision (ICCV), Darling Harbour, Sydney, 2013.
- [25] RE. Kennedy, Z. Yang, WB. Cohen, *Detecting trends in forest disturbance and recovery using yearly Landsat time series: 1. LandTrendr Temporal segmentation algorithms*, **Remote Sens. Environ.**, 114:12 (2010) 2897–2910.
- [26] C.-M. Pun, X.-C. Yuan ve X.-L. Bi, *Image Forgery Detection Using Adaptive Oversegmentation and Feature Point Matching*, **IEEE Trans. Inf. Forensics**

Security, 10:8 (2015) 1705-1716.

- [27] M. Srivastava, MK. Arora, *Selection of critical segmentation-A prerequisite for Object based image classification*, National Conference on Recent Advances in Electronics & Computer Engineering, Roorkee, India, 2015.
- [28] M. M. O. Eduardo S. L. Gastal, *Shared Sampling for Real-Time Alpha Matting*, **Comput. Graph Forum**, 29:2 (2010) 575–584.
- [29] R. J. Radke, *Computer Vision for Visual Effects*, Cambridge: Cambridge University Press, 2012.
- [30] Y.-Y. Chuang, B. Curless, D. H. Salesin ve R. Szeliski, *A Bayesian Approach to Digital Matting*, Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, Kauai, HI, United States, 2001.
- [31] A. Levin, D. Lischinski ve Y. Weiss, *A Closed Form Solution to Natural Image Matting*, **IEEE Trans. Parallel Distrib. Syst.**, 30:2 (2008) 228-242.
- [32] Q. Chen, D. Li ve C.-K. Tang, *KNN Matting*, **IEEE Trans. Pattern Anal. Mach. Intell.**, 35:9 (2013) 2175-2188.
- [33] P. A. B. Miss Hetal J. Vala, *A Review on Otsu Image Segmentation Algorithm*, **IJARCET**, 2:2 (2013) 387-389.
- [34] S. S. Al-amri, N. Kalyankar ve K. S.D., *Image Segmentation by Using Threshold Techniques*, **J. Comput. Inf.**, 2:5 (2010) 83-86.
- [35] S. Derivaux, G. Forestier, C. Wemmert, *Supervised image segmentation using watershed transform, fuzzy classification and evolutionary computation*, **Pattern Recognit Lett.**, 31:15 (2010) 2364–2374.
- [36] H. Z. Zhijie Wang, *Edge linking using geodesic distance and neighborhood information*, Proceedings of the IEEE/ASME International Conference on Advanced Intelligent Mechatronics, Xi'an, China, 2008.
- [37] D. Ballard, *Generalizing the Hough transform to detect arbitrary shapes*, **Pattern Recognition**, 13:2 (1981) 111-122.
- [38] L. Xu, E. Oja, P. Kultanen, *A new curve detection method: Randomized Hough transform (RHT)*, **Pattern Recognition Lett.**, 11:5 (1990) 331-338.
- [39] A. D. Sappa ve B. X. Vintimilla, *Edge Point Linking by Means of Global and Local Schemes*, Computer Vision Center Edifici O Campus UAB, Bellaterra, Barcelona, Spain, 2006.

- [40] Q. Abbas, ME. Celebi, IF. García, *Breast mass segmentation using region-based and edge-based methods in a 4-stage multiscale system*, **Biomed. Signal Process Control**, 8:2 (2013) 204–214.
- [41] MRM. Razali, NS. Ahmad, R. Hassan, *Sobel and Canny Edges Segmentations for the Dental Age Assessment*, International Conference on Computer Assisted System in Health, Kuala Lumpur, Malaysia, 2015.
- [42] S. Singh, A. Datar, *EDGE Detection Techniques Using Hough Transform* **IJETAE**, 3:6 (2013) 333-337.
- [43] W. Rong, Z. Li ve W. Zhang, *An improved Canny edge detection algorithm*, Second International Workshop on Computer Science and Engineering, Tianjin, China, 2009.
- [44] P. Choudhary, R. Khandekar, A. Borkar, P. Chotaliya, *Image processing algorithm for fruit identification*, **Int. Res. J. Eng. Tech.**, 4:3 (2017) 2741-2743.
- [45] A. Sawatzky, D. Tenbrinck, X. Jiang ve M. Burger, *A Variational Framework for Region-Based Segmentation Incorporating Physical Noise Models*, **J. Math. Imaging Vision**, 47:3 (2013) 179–209.
- [46] MA. Mohammed, MKA. Ghani, RI. Hamed, *Automatic segmentation and automatic seed point selection of nasopharyngeal carcinoma from microscopy images using region growing based approach*, **J. Comput. Sci.**, 20:1 (2017) 61-69.
- [47] Q. Zhu, N. Garg, K. Pulli, A. Meixner, *Image pyramid processor and method of multi-resolution image processing*. US Patent: US20140225902 A1, 14 Aug 2014.
- [48] JC. Tilton, Y. Tarabalka, PM. Montesano, *Best Merge Region-Growing Segmentation With Integrated Nonadjacent Region Object Aggregation*, **IEEE Geosci. Remote Sens. Soc.**, 50:11 (2012) 4454-4467.
- [49] M. D. Kelkar ve M. S. Gupta, *Improved Quadtree Method for Split Merge Image Segmentation*, First International Conference on Emerging Trends in Engineering and Technology, Nagpur, Maharashtra, India, 2008.
- [50] D. Chaudhuri ve A. Agrawal, *Split-and-merge Procedure for Image Segmentation using Bimodality Detection Approach*, **Def. Sci. J.**, 60:3 (2010) 290-301.
- [51] M. Lia ve R. Stauntonb, *Optimum Gabor filter design and local binary patterns for texture segmentation*, **Pattern Recognition Lett.**, 29:5 (2008) 664–672.

- [52] T. Ahonen, A. Hadid ve M. Pietikainen, *Face Description with Local Binary Patterns: Application to Face Recognition*, **IEEE Trans. Pattern Anal. Mach. Intell.**, 28:12 (2012) 2037-204.
- [53] J. Xie, Y. Jiang, H. Tsui, *Segmentation of Kidney From Ultrasound Images Based on Texture and Shape Priors*, **IEEE Trans. Med. Imag.**, 24:1 (2005) 45-57.
- [54] S. Selvarajah, SR. Kodituwakku, *Analysis and Comparison of Texture Features for Content Based Image Retrieval*, **IJLTC**, 2:1 (2011) 207–218.
- [55] IA. Eckley, GP. Nason, RL. Treloar, *Locally stationary wavelet fields with application to the modelling and analysis of image texture*, **J. Roy. Statist. Soc. Ser. C**, 59:4 (2010) 595–616.
- [56] PF. Felzenszwalb, DP. Huttenlocher, *Efficient graph-based image segmentation*, **Int. J. Comput. Vision**, 59:2 (2004) 167-181.
- [57] J. M. D. Judith E. Dayhoff Ph.D., *Artificial neural networks*, **Cancer**, 91:8 (2001) 1615–1635.

ÖZGEÇMİŞ

Adı Soyadı: Mahdi HATAMI VARJOVI

Doğum Yeri ve Tarihi: Tebriz/Iran-1985

Adres: Teknoloji Geliştirme Bölgesi, İnönü Üniversitesi Karşısı, Teknopark C Blok
1/1, Battalgazi/MALATYA

E-Posta: iz.hatami@gmail.com

Lisans: İnönü Üniversitesi Bilgisayar Mühendisliği Bölümü (2010-2014)

Mesleki Deneyim: İmleç Yazılım, Malatya (2013-2015)

Tuga Yazılım, Malatya (2015-Devam Ediyor)

TEZDEN TÜRETİLEN YAYINLAR/SUNUMLAR/PROJELER

- **Mahdi Hatami Varjovi**, Muhammed Fatih Talu, “Kayısı İçin Otomatik Rekolte Tahmin Sistemi” *International Artificial Intelligence and Data Processing Symposium (IDAP)*, 2016.
- Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK) tarafından 3001 - Arge Başlangıç Desteği Programı (114E916) – “*Malatya’daki kayısı rekoltesinin bilgisayar görmesi teknikleriyle hesaplanması*” başlıklı proje.