



**SAYISAL GÖRÜNTÜLEME DESTEKLİ
RED CHIEF ELMA REKOLTE TAHMİNİ**

Onur CÖMERT

**Y.Lisans Tezi
Mekatronik Mühendisliği Anabilim Dalı
Yrd. Doç. Dr. Mahmut HEKİM
Yrd. Doç. Dr. Umut ORHAN
2013
Her hakkı saklıdır**

T.C.
GAZİOSMANPAŞA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
MEKATRONİK ANABİLİM DALI

Y.LİSANS TEZİ

SAYISAL GÖRÜNTÜLEME DESTEKLİ
RED CHIEF ELMA REKOLTE TAHMİNİ

Onur CÖMERT

TOKAT
2013

Her hakkı saklıdır

Yrd. Doç. Dr. Mahmut HEKİM danışmanlığında, Onur CÖMERT tarafından hazırlanan bu çalışma, 17.06.2013 tarihinde aşağıdaki jüri tarafından oy birliği ile Mekatronik Mühendisliği Anabilim Dalı'nda Yüksek Lisans Tezi olarak kabul edilmiştir.

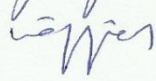
Başkan: Yrd. Doç. Dr. Mahmut HEKİM

İmza: 


Üye: Yrd. Doç. Dr. Zafer DOĞAN

İmza: 

Üye: Yrd. Doç. Dr. M. Metin ÖZGÜVEN

İmza: 

Yukarıdaki sonucu onaylarım



Doc. Dr. Naim ÇAGMAN

Enstitü Müdürü



TEZ BEYANI

Tez yazım kurallarına uygun olarak hazırlanan bu tezin yazılmasında bilimsel ahlak kurallarına uyulduđunu, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduđunu, tezin içerdđi yenilik ve sonuçların başka bir yerden alınmadıđını, kullanılan verilerde herhangi bir tahrifat yapılmadıđını, tezin herhangi bir kısmının bu üniversite veya başka bir üniversitedeki başka bir tez çalışması olarak sunulmadıđını beyan ederim.

Onur CÖMERT

ÖZET

Y. Lisans Tezi

SAYISAL GÖRÜNTÜLEME DESTEKLİ RED CHIEF ELMA REKOLTE TAHMİNİ

Onur CÖMERT

Gaziosmanpaşa Üniversitesi

Fen Bilimleri Enstitüsü

Mekatronik Anabilim Dalı

Danışman: Yrd. Doç. Dr. Mahmut HEKİM

İkinci Danışman: Yrd. Doç. Dr. Umut ORHAN

Bu çalışmada, görüntü işleme teknikleri kullanılarak elma ağaçlarında rekolte tahmini yapılmıştır. Materyal olarak hem Türkiye hem de dünya elma üretiminde önemli yere sahip Red Chief elma türü seçilmiştir. Görüntü verisi, içerisinde Red Chief elma ağaçlarının da yer aldığı Tokat Kazova'da bulunan bir meyve bahçesinden toplanmıştır. Çalışmada kullanılan elma ağacı görüntüleri, yüksek çözünürlüklü bir kamera vasıtasıyla elde edilmiştir. Çeşitli görüntü işleme tekniklerinden yararlanılarak renk tabanlı bir bölütleme yazılımı geliştirilmiştir. Yazılımın geliştirilmesi aşamasında RGB, CIE Lab, HSV ve CIE Luv renk uzaylarına taşınan görüntü verisi üzerinde deneyler yapılmıştır. Öznitelik olarak seçilen görünür elma alanları verisi ile doğrusal regresyon, ÇKA, RBF ve Elman sinir ağı modeli kullanılarak tahminleme yapılmıştır. CIE Luv renk uzayında yapılan bölütleme işlemi ile elde edilen özellikler, ÇKA sinir ağı modeline verilerek tahminleme yapılmış, OKHK değeri 4,36 kg olarak bulunmuştur. Ortalama elma rekoltesi 58,37 kg iken 4,36 kg gibi düşük bir hata oranı ile Red Chief elmasının rekoltesi tahmin edilebilmiştir.

2013, 72 sayfa

Anahtar Kelimeler: Hassas tarım, red chief elma, rekolte tahmini, sayısal görüntü işleme.

ABSTRACT

Ms Thesis

DIGITAL IMAGING AIDED RED CHIEF APPLE HARVEST ESTIMATION

Onur CÖMERT

Gaziosmanpaşa University
Graduate School of Natural and Applied Sciences
Department of Mechatronic Engineering

Supervisor: Asst. Prof. Dr. Mahmut HEKİM
Second Supervisor: Asst. Prof. Dr. Umut ORHAN

In this study, the harvest for apple trees was estimated by using the image processing techniques. The Red Chief apple that has an important place in apple production of both Turkey and the world was chosen as the material. The image data was collected from an orchard in which there are Red Chief apple trees in Tokat Kazova. The apple tree images used in the study were obtained with a high resolution camera. A color-based segmentation software was developed by making use of various image processing techniques. During the process of developing software, experiments were carried out on the image data having been transmitted to color spaces of RGB, CIE Lab, HSV, and CIE Luv. The harvest was estimated by using the data of visible apple fields chosen as a feature and linear regression, ÇKA, RBF, and Elman neural network models. The features obtained with the segmentation process that was carried out on CIE Luv color space was given to the CKA neural network model, so that estimation was carried out and OKHK value was found to be 4.36 kg. While the average apple harvest is 58,37, Red Chief apple harvest could be estimated with a low error rate of 4,36. 2013, 72 pages

Keywords: Digital image processing, harvest estimation, Precision agriculture, red chief apple.

ÖNSÖZ

Yüksek lisans çalışmam boyunca, her türlü konuda yardımlarını esirgemeyen, değerli fikirleriyle çalışmama yön veren kıymetli hocalarım Sayın Yrd. Doç. Dr. Mahmut HEKİM ve Sayın Yrd. Doç. Dr. Umut ORHAN'a sonsuz teşekkürler. Ayrıca çalışmalarım da kullandığım materyalin elde edilmesini sağlayan Dimes firması çalışanlarına, çalışmalarım boyunca her konuda yardımlarını esirgemeyen Mekatronik Mühendisliği Bölümünün tüm öğretim elemanlarına sonsuz teşekkürlerimi sunarım.

Onur CÖMERT

Haziran, 2013

İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	i
ABSTRACT.....	ii
ÖNSÖZ	iii
İÇİNDEKİLER	iv
SİMGE VE KISALTMALAR DİZİNİ.....	v
ŞEKİLLER DİZİNİ	vi
ÇİZELGELER DİZİNİ	viii
1. GİRİŞ	1
2. KAYNAK ÖZETLERİ.....	3
3. MATERYAL VE YÖNTEM.....	9
3.1. Kullanılan Veri	9
3.2. Sayısal Görüntü İşleme	13
3.2.1. Sayısal Görüntü	13
3.2.2. Sayısal Görüntü İşlemenin Temel Basamakları	13
3.2.3. Sayısal Görüntü İşlemede Kullanılan Bazı Teknikler	15
3.2.4. Renkli Görüntü İşleme.....	26
3.3. Kullanılan Tahminleme Yöntemleri	36
3.3.1. Doğrusal Regresyon.....	36
3.3.2. Çok Katmanlı Algılayıcı Sinir Ağı	37
3.3.3. RBF Sinir Ağı	39
3.3.4. Elman Sinir Ağı	40
4. BULGULAR VE TARTIŞMA.....	42
5. SONUÇ	65
KAYNAKLAR	66
ÖZGEÇMİŞ	71

SİMGE VE KISALTMALAR DİZİNİ

Simgeler	Açıklama
\ominus	Aşındırma işleci
\oplus	Genişletme işleci
ϕ	Aktivasyon fonksiyonu
w	Ağırlık katsayısı
\emptyset	Haritalama fonksiyonu
Kısaltmalar	Açıklama
RGB	Red Green Blue
BPI	Blue Pixels Index
OKH	Ortalama Karesel Hata
OKHK	Ortalama Karesel Hata Karekökü
ÇKA	Çok Katmanlı Algılayıcı
HSI	Hue Saturation Intensity
IHLS	Improved Hue Luminance Saturation
CIE	Commission Internationale De L'éclairage
HSV	Hue Saturation Value
RBF	Radial Basis Function

ŞEKİLLER DİZİNİ

Şekil	<u>Sayfa</u>
Şekil 3.1. Bahçeden seçilen ağaçların krokisi	9
Şekil 3.2. Numaralandırmada kullanılan etiketli plastik bağlar	10
Şekil 3.3. Kasaların numaralandırılması	11
Şekil 3.4. Görüntü işlemenin temel basamakları	14
Şekil 3.5. Gri tonlamalı görüntü üzerinde eşikleme işlemi	17
Şekil 3.6. RGB görüntü üzerinde eşikleme işlemi	18
Şekil 3.7. Fit olma durumu	20
Şekil 3.8. Hit olma durumu	20
Şekil 3.9. Görüntü üzerinde aşındırma işlemi	22
Şekil 3.10. Görüntü üzerinde genişletme işlemi	23
Şekil 3.11. Görüntü üzerinde açma işlemi	24
Şekil 3.12. Görüntü üzerinde kapama işlemi	25
Şekil 3.13. Görüntü üzerinde doldurma işlemi	26
Şekil 3.14. Görülebilir renklerin dalga boyları	27
Şekil 3.15. Görülebilir renk alanları	27
Şekil 3.16. Renk uzayları	28
Şekil 3.17. RGB renk uzayı	29
Şekil 3.18. CIE XYZ renk uzayı	30
Şekil 3.19. CIE Lab renk uzayı	30
Şekil 3.20. CIE Luv renk uzayı	31
Şekil 3.21. HSV renk uzayı	32
Şekil 3.22. Yapay nöron yapısı	37
Şekil 3.23. ÇKA sinir ağının genel yapısı	39
Şekil 3.24. RBF sinir ağının genel yapısı	40
Şekil 3.25. Elman sinir ağının genel yapısı	41
Şekil 4.1. Rekolte tahmin yazılımının çalışma adımları	42
Şekil 4.2. Resimlerin kırılması	43
Şekil 4.3. Elma alanlarını gösteren ikili görüntü	45
Şekil 4.4. RGB renk uzayında eşikleme işlemi	46
Şekil 4.5. CIE Lab renk uzayında eşikleme işlemi	47

Şekil 4.6. HSV renk uzayında eşikleme işlemi	49
Şekil 4.7. CIE Luv renk uzayında eşikleme işlemi	50
Şekil 4.8. Doğrusal regresyon ile elde edilen tahminleme sonuçları (RGB)	53
Şekil 4.9. Doğrusal regresyon ile elde edilen tahminleme sonuçları (CIE Lab)	54
Şekil 4.10. Doğrusal regresyon ile elde edilen tahminleme sonuçları (HSV)	54
Şekil 4.11. Doğrusal regresyon ile elde edilen tahminleme sonuçları (CIE Luv)	55
Şekil 4.12. ÇKA sinir ağı ile elde edilen tahminleme sonuçları (RGB)	56
Şekil 4.13. ÇKA sinir ağı ile elde edilen tahminleme sonuçları (CIE Lab)	57
Şekil 4.14. ÇKA sinir ağı ile elde edilen tahminleme sonuçları (HSV)	57
Şekil 4.15. ÇKA sinir ağı ile elde edilen tahminleme sonuçları (CIE Luv)	58
Şekil 4.16. RBF sinir ağı ile elde edilen tahminleme sonuçları (RGB).....	59
Şekil 4.17. RBF sinir ağı ile elde edilen tahminleme sonuçları (CIE Lab)	59
Şekil 4.18. RBF sinir ağı ile elde edilen tahminleme sonuçları (HSV).....	60
Şekil 4.19. RBF sinir ağı ile elde edilen tahminleme sonuçları (CIE Luv)	60
Şekil 4.20. Elman sinir ağı ile elde edilen tahminleme sonuçları (RGB).....	61
Şekil 4.21. Elman sinir ağı ile elde edilen tahminleme sonuçları (CIE Lab)	62
Şekil 4.22. Elman sinir ağı ile elde edilen tahminleme sonuçları (HSV).....	62
Şekil 4.23. Elman sinir ağı ile elde edilen tahminleme sonuçları (CIE Luv)	63

ÇİZELGELER DİZİNİ

Çizelge	<u>Sayfa</u>
Çizelge 3.1. Ağaçların tartı verisi	12
Çizelge 3.2. RGB'den CIE XYZ renk uzayına dönüşüm değerleri	33
Çizelge 3.3. CIE XYZ'den RGB renk uzayına dönüşüm değerleri	33
Çizelge 4.1. Doğu yönünden alınan görüntülerin elma alanı karşılaştırması	44
Çizelge 4.2. Çapraz geçerlilik yönteminin uygulanması	52
Çizelge 4.3. Tahminleme ve özellik çıkartım yöntemlerinin karşılaştırması	64

1. GİRİŞ

İnsanlığın büyük hayallerinden birisi olan geleceğe yönelik tahminler yapabilmek halen üzerinde en çok çalışma yapılan alanlardan birisidir. Her alanda olduğu gibi tarımda da ileriye yönelik doğru kestirimler yapabilmek çok büyük faydalar sunabilmektedir. Özellikle hasat veriminin önceden tespit edilebilmesi hem üretici hem tüketici açısından önemli avantajlar sağlamaktadır. İleriki zamanlara yönelik verim, kalite ve ekonomik sorunların doğru tahmin edilmesi, tüm meyve yetiştiriciliklerinde olduğu gibi elma üreticileri için de önemli bir sorun olmaktadır (Winter, 1986).

Hasat zamanından önce meyvelerin boyut ve sayısı üzerine tahminler yapabilmek, gelecekteki verimin ve dolayısıyla gelirin hesaplanmasına, zirai planlamaya ve ekolojik parametreleri belirlemeye yardımcı olmaktadır (Welte, 1990). Ayrıca meyveler hasat edilmeden önce yapılan rekolte tahminleri “kabala satış” adıyla da bilinen satışlarda en önemli parametredir. Kabala satışlar, göz kararı kestirimler üzerinden yapıldığı için tahminlerin tutarlılığı son derece önemlidir. Kabala satışta alıcı taraf genellikle meyve rekolte tahmini için gözle kestirimde uzman kişilerin görüşlerine başvurmaktadır. Uzman kişilerin yaptığı ürün miktarı tahminlerine dayanarak alıcı ve satıcı arasında anlaşma sağlanmaktadır. Uzmanlardan farklı kalite düzeylerinde rekolte tahminleri yapmaları da istenebilmektedir. Fakat bu uzman kişilerin her zaman objektif olamaması veya yeterli deneyime sahip olmaması en büyük dezavantaj olarak karşımıza çıkmaktadır. Rekolte tahmini için ihtiyaç duyulan uzman kişilerin az oluşu bu kişilerin istihdamının maliyetli olmasına sebep olmaktadır. Ayrıca tahmin sonuçlarında insan kaynaklı faktörler nedeniyle de tutarsızlıklar söz konusu olabilmektedir. Farklı uzmanlar farklı tahminlerde bulunabilmektedir. Bu da hem alıcı hem de satıcı açısından maddi zararlara ve anlaşmazlıklara sebep olabilmektedir.

Meyve rekolte tahmininin yapılmasındaki temel amaç, insan gözü ile yapılan toplam ürün miktarı kestiriminin makine görmesi denilen bilgisayarlı görüntü işleme yardımıyla yapılabilmesidir (Brosnan ve Sun, 2004). Makine görmesi, sayısal görüntü verisine dayanarak nesnelerin fiziksel yapısını kesin ve anlamlı bir biçimde

tanımlamaya yaramaktadır (Ballard ve Brown, 1982). Günümüzde meyve ve sebze rekoltesinin tahmini için geliştirilen makine görmesi yöntemleri çoğunlukla meyvelerin renk ve şekil özelliklerinin işlenmesine dayanmaktadır. İşlenecek görüntüler bir görüntüleme aygıtı ile elde edilmekte ve bu görüntüler çeşitli ön işlemlerden geçirildikten sonra bir bilgisayar yazılımı vasıtası ile işlenerek tahminler yapılmaktadır.

Bu çalışmada, Red Chief elma ağaçlarının elmalar hasat edilmeden önce rekoltesinin tahmin edilmesi amacıyla kırpma, eşikleme, açma, kapama ve doldurma gibi işlemlerden oluşan geleneksel görüntü işleme tekniklerinden faydalanılmıştır.

Çalışmanın ilk bölümü olan “Giriş” bölümünde, hasat tahminin önemi ve tez çalışmasından kısaca bahsedilmiştir. “Kaynak Özetleri” bölümünde tez konusu ile ilgili kaynak araştırması yapılmış ve daha önceden yapılmış bilimsel çalışmaların kullandığı yöntemler verilmiştir. “Materyal ve Yöntem” bölümünde çalışmada kullanılacak verinin elde edilme aşamaları ve elde edilen verinin işlenmesinde kullanılan görüntü işleme teknikleri, özellik çıkartma ve tahminlemede kullanılan yöntemler açıklanmıştır. “Bulgular ve Tartışma” bölümünde elde edilen veri kümesi üzerinde yapılan tahminlemenin sonuçları verilmiştir. “Sonuç” bölümünde ise elde edilen sonuçlar yorumlanmış, sonraki çalışmalar için önerilerde bulunulmuştur.

2. KAYNAK ÖZETLERİ

Tarımsal ürünler üzerinde yapılan otomatik hasat, meyve-sebze sınıflandırma, kusur tespiti ve rekolte tahmin sistemleri, makinelerle otomatik olarak ürün görüntülerinin işlenmesi yoluyla yapılmaktadır. Bu sistemler kullanılarak yapılan çalışmaların birçoğunda bilgisayarlı görüntüleme sistemi olarak ta bilinen makine görmesinden yararlanılmaktadır (Rehkugler ve Throop, 1986; Thomas ve Connoly, 1986; Morrisey, 1988; Baoping, 1999; Li ve ark., 2002; Bennedsen ve ark., 2005; Swain ve ark., 2010; Qazi ve ark., 2011). Bu çalışmalar genellikle tarımsal ürünlerin renkleri üzerinden gidilerek gerçekleştirilmektedir.

Rehkugler ve Throop (1986), siyah-beyaz kamera kullanarak oluşturdukları makine görme sistemleri ile “Red Delicious” elma kusurlarını tespit etmeye çalışılmışlar fakat siyah-beyaz kamera kullandıklarından dolayı yanmış veya buruşuk bölgeleri tespit edememişlerdir.

Thomas ve Connoly (1986), RGB (Red, Green, Blue) değerleri ile oluşturulan renkli resimler kullanarak yaptıkları çalışma sonucunda RGB'nin görüntü işleme işlemleri için etkin olmadığını fakat bu değerlerin daha etkin olabileceği başka renk uzaylarına çevrilebileceğini bildirmişlerdir.

Morrisey (1988), HSI (Hue, Saturation, Intensity) renk özelliklerinin insan gözünün gördüğü renk değerlerine çok yakın olduğunu belirtmiştir. Ayrıca, HSI renk değerlerinin öznitelikleri bağımsız, hızlı ve basit işlenebilir olduğundan programcılar tarafından renkli görüntü işlemede alternatif bir seçim olarak kullanılabilceğini belirtmiştir.

Miller ve Delwiche (1991) ve Alchanatis ve ark. (1993) yaptıkları çalışmalarda renkli görüntü parametreleri ile kızılötesi ve ultraviyole parametrelerini birleştirerek sadece renk uzayları kullanılarak yapılan çalışmalardan daha iyi sonuçlar elde etmişlerdir.

Leemans ve ark. (1998), renk tabanlı makine görmesi ile “Golden Delicious” türü elmaların kusur tespiti üzerine bir çalışma yapmışlardır. Görüntülerin alınması için 3-CCD matris tipi kamera kullanmışlar ve görüntülerdeki renk bilgisine dayanan bir yöntem önermişlerdir. İlk adımda normal renk değişkenlerine bağlı bir renk modeli tarif etmişlerdir. Elma üzerindeki kusurların tespiti için, bir elma resminin her pikseli kusurlu piksel modeli ile karşılaştırmışlardır. Eğer bu pikseller eşleşirse, bir kusur olarak, aksi takdirde sağlıklı olarak kabul etmişlerdir. Çalışmada farklı kusurların farklı kontrast değerlerine sahip olduğunu tespit etmişler ve her kusur grubu için farklı eşik değerlerinde bölütleme algoritmaları geliştirmişlerdir. Bu algoritmaların çeşitli kombinasyonları üzerinde yaptıkları analizler neticesinde seçilen bir bölütleme algoritmasının tek başına sınıflandırma başarısı ve hız oranı açısından en ideal eşik değerine sahip olduğunu saptamışlardır.

Baoping (1999), renkli makine görme sistemleri kullanarak %90 oranında doğruluk ile elmaları renklerine göre sınıflandırabilmiştir.

Stajenko ve ark. (2004), termal görüntüleme kullanılarak büyüme dönemindeki bir meyve bahçesinde elma sayısının ve çapının tahmin edilmesi üzerine bir çalışma yapmışlardır. Bu çalışmada elma sayısının tahmin edilmesi için bir yöntem geliştirmişler ve bu yöntemi test etmişlerdir. Bir termal kamera yardımıyla ağaçların görüntülerini haziran-eylül ayları arasında beş kez almışlardır. Her seferinde 120 elma ağacından 120 görüntü alınmışlardır. Görüntüleri, meyve ve arka plan arasında bir sıcaklık farkı yakalamak için öğleden sonra kaydetmişlerdir. Kaydettikleri bu görüntüleri çeşitli görüntü işleme yöntemleri ile işlemişlerdir. Elle ölçülen ve geliştirilen meyve algılama algoritmasına dayalı olarak tahmin edilen meyve sayıları arasında 0,83-0,88 aralığında korelasyon katsayıları elde etmişler, ayrıca bu değerlerin büyüme dönemi boyunca arttığını saptamışlardır.

Bennedsen ve ark. (2005), çeşitli türlerde elma kusurlarının tespit edilmesi üzerine çalışmışlardır. Bunun için bir kamera önünde elmanın dönmesini sağlayan bir sistem geliştirmişlerdir. Bu şekilde elde edilen görüntülerin analiz edilmesi ile doğrusal

regresyon kullanarak %90-92 doğruluk oranında sınıflandırma işlemlerini tamamlamışlardır.

Miranda ve ark. (2007), elma ağaçlarından alınan rastgele örneklerden meyvelerin ortalama boyut ve renk tahminleri üzerine bir çalışma yapmışlardır. Meyve rengi tayininde objektif veri seti elde etmek için görüntü işleme tabanlı bir araç önermişlerdir.

Xing ve ark. (2007), kemometrik araçlar (PCA ve PLSDA) ve görüntü işleme kullanarak elma üzerindeki çürüklerin tespiti üzerine bir çalışma yapmışlardır. “Golden Delicious” türü elma üzerindeki çürük tespitine yönelik yaptıkları bu çalışmada bir hiperspektral görüntüleme sistemi kullanmışlardır. PCA ve PLSDA gibi kemometrik araçları, hiperspektral görüntülerden spektral bilgileri ayıklamak ve özetlemek için kullanmışlardır. Böylece bir kaç ana bileşen aracılığıyla, yüksek boyutlu spektral veriyi daha düşük boyutlara indirgeyebilmişlerdir. Görüntü işleme tekniği olarak ise bölge tabanlı iki farklı bölütleme algoritması geliştirmişlerdir. Bu algoritmalarda ortalama değer yöntemi ile bir eşik değer hesaplamışlar ve görüntülerin değerlerini bu eşik değer ile karşılaştırarak bölütleme işlemini gerçekleştirmişlerdir. PCA tabanlı sınıflandırma algoritmasını toplam 128 elmadan oluşan görüntüler ile test etmişlerdir. Bu sınıflandırma algoritması ile 62 çürük olmayan elma yaklaşık %93,55 oranında sağlam olarak kabul edildiğini ve morluklar bulunan 66 elmaların ise yaklaşık %86 doğru sınıflandırıldığını tespit etmişlerdir. PLSDA tabanlı sınıflandırma algoritmasını toplam 115 elmadan oluşan görüntüler (kalibrasyon için kullanılan elma hariç) ile test etmişlerdir. Bu algoritma ile tüm sağlam ve çürük elmaları yaklaşık % 82,3 doğru olarak sınıflandırmışlardır.

Swain ve ark. (2010), makine görmesi kullanılarak yaban mersini meyvesinin verim haritalaması üzerine çalışmışlardır. Yaban mersini tarlalarında yapılan deneylerin sonuçlarında resimlerdeki mavi piksellerin yüzdesi ve gerçek meyve verimi arasında belirgin bir korelasyon olduğunu tespit etmişlerdir. Kullandıkları yöntemde BPI (Blue Pixel Index)'yi, her bir pikselin mavi piksel indeksi olarak tanımlamışlardır. Buna göre S'nin BPI'nın 75'ten (75 burada önceden belirlenmiş bir eşik değerdir) büyük ya da eşit

olduğu piksel kümesi, N'nin ise bir görüntünün piksel sayısı olduğunu ifade etmişlerdir. Görüntüdeki BPI yüzdesini Eşitlik 2.1'deki gibi ifade etmişlerdir.

$$\%BPI = \frac{|S|}{N} \quad (2.1)$$

Eşitlik 2.1'deki |S|'in, S'nin satır sayısı olduğunu ifade etmişlerdir.

Xiao-boa ve ark. (2010), elma kusurlarını hat üzerinde algılama için yaptıkları çalışmada üç adet renkli kameradan oluşan görüntüleme sistemi kullanmışlardır. Elma sap uçları ve çanaklardaki kusurların belirlenmesi amacıyla üç adet renkli fotoğraf makinesini ve bir bilgisayar kontrollü sistemi hat üzerinde yerleştirmişlerdir. Bu hat üzerinde hareket eden silindirlere yerleştirilen elmalar dönerken her bir kamera tarafından her elma için üç görüntü yakalamışlardır Böylece her elma için yüzey taramasını sağlayan toplam dokuz görüntü elde etmişlerdir. Daha sonra elma görüntülerini çoklu eşik yöntemleriyle siyah renkli arka plandan bölütlemişlerdir. Eğer dokuz resimden iki veya daha fazlasında ilgilenilen alan tespit edilirse elmayı kusurlu olarak kabul etmişlerdir. Bu yöntemde hiçbir karmaşık görüntüleme süreci veya örüntü tanıma algoritmasını kullanmamışlardır. Çalışmada 318 elma üzerinde yapılan deneyler sonucunda sağlam ve arızalı elmalar arasında iyi bir ayırım yapılabilmışlerdir. Üç kamera sistemi kullanılarak sağlam veya kusurlu olarak ortalama hatalı sınıflandırma oranının %11 olarak saptamışlardır. Bu yöntemin dezavantajının farklı kusur tiplerini ayırt edememesi olduğunu, bu nedenle morarma, uyuz, mantar üremesi ve hastalık gibi kusurların aynı olarak kabul edildiğini ifade etmişlerdir.

Omid ve ark. (2010), limon, ıhlamur, portakal ve mandalina gibi narenciyelerin hacim ve kütlelerini ölçmek için görüntü işleme tabanlı bir teknik geliştirmişlerdir. Meyve ağırlığının gerçek zamanlı olarak ölçülmesi için alternatif bir yöntem olarak hacim tabanlı bir sıralama sistemi önermişlerdir. Meyve yoğunluğunun sabit olduğu kabul edilerek paketleme hattı üzerinde bir tartı cihazı kullanmadan meyvenin hacmi üzerinden ağırlığını tahmin etmişlerdir. Meyvenin gerçek hacminin meyve ve sebzeler gibi büyük nesnelere hacim ölçümünde kullanılan "Su Hacmi Yöntemi" (WDM)'ni kullanmışlar ve önerilen görüntü işleme yöntemi ile narenciyelerin hacim tahmininde

%96 doğruluk oranı elde etmişlerdir. Ayrıca yaptıkları analizler neticesinde, HSI renk uzayındaki renk değerlerinin narenciyelerin meyve renk ton değerinin hesaplanması için diğer sistemlere nispeten daha kararlı olduğunu ve çalışmaların bu yönde sürdürülebilir olduğunu belirtmişlerdir.

Qazi ve ark. (2011), uydu görüntülerinde renk ve doku bölütlemesi üzerine bir çalışma yapmışlardır. CIE (Uluslararası Aydınlatma Komisyonu) Lab renk uzayının, renkli doku karakterizasyonu elde etmek için RGB ve IHLS (Improved Hue, Luminance, Saturation) renk modellerinden daha iyi bir performans sergilediğini belirtmişlerdir. Bununla birlikte bu görüntüler için yapılan analiz sonuçlarında CIE Lab renk uzayının hem hata oranları açısından hem de bölütleme sonuçlarının kararlılığı açısından önemli ölçüde daha iyi bir performans gösterdiği saptamışlardır.

Linker ve ark. (2012), meyve bahçelerinden alınmış RGB görüntüler ile yeşil elma sayısının belirlenmesi üzerine bir çalışma yapmışlardır. Doğal aydınlatma altında meyve bahçelerinden edinilen renkli görüntüler ile elma sayısını tahmin etmek için bir algoritma geliştirmişler ve bunun sonuçlarını doğrulamışlardır. Algoritmanın performansını iki veri seti kullanarak incelemişlerdir. İlk veri setini kameranın tam otomatik poz ayarında ve farklı ışık koşulları altında kaydedilen görüntülerden, ikinci veri setini ise elle poz ayarında ve çoğunlukla difüzyif (günbatımına yakın) ışık altında kaydedilmiş görüntülerden elde etmişlerdir. Hazırladıkları algoritmanın, ilk veri seti ile görünür elma sayısını %85 oranında doğru algıladığını, ikinci veri seti ile %95 seviyesinde doğru algıladığını saptamışlardır.

Payne ve ark. (2013), bölütleme yöntemiyle mango meyvesinin görüntülerini analiz ederek verim tahmini üzerine bir çalışma yapmışlardır. Hasat edilmeden önce gündüz saatlerinde mango ağaçlarından alınan görüntülerden meyve sayısı hesaplamışlardır. Çalışmada kullandıkları 15 adet ağacı dört yönden görüntülemişler ve görüntülerdeki meyveleri göz ile saymışlardır. Meyvelerin göz ile yapılan sayımı ile hesaplanan elma sayıları arasında güçlü bir R2 korelasyon katsayısı olduğu belirlemişlerdir (iki yön için R2 = 0,91 ve dört yön için R2 = 0,93). Bir diğer deneyde 555 adet ağacı ise sadece bir yönden görüntülemişler ve bu görüntüler üzerinde RGB ve YCbCr renk uzayları

üzerinde renkli bölütleme kullanarak meyve ve arka plan piksellerini bölütlemişlerdir. Görüntüleri, RGB renk uzayının R ve G kanalları kullanılarak YCbCr renk uzayına taşımışlardır. Bu renk uzayının da Cr kanalı (kırmızı renk bileşeninin farklılığı) üzerinde analizler yapılmışlardır. Sonuç olarak, geliştirdikleri algoritma ile her bir görüntüdeki baloncukları mango meyve sayısını elde etmek için sayılmışlardır. 555 resimlik mango ağacı grubunda doğrusal regresyon ile yaptıkları deneyde korelasyon katsayısını $R^2 = 0,74$ bulmuşlar ve yapılan tahminlerin ortalama karesel hatasını ise 7,7 olarak tespit etmişlerdir. Farklı aydınlatma koşulları altında alınan görüntüler kullanılarak yaptıkları analizlerde, hesaplanan elma sayılarının değiştiği tespit etmişlerdir.

3. MATERYAL VE YÖNTEM

Bu çalışmada elma meyvelerinin rekolte tahmininin yapılması amacıyla görüntü işleme tabanlı bir yazılım geliştirilmiştir. Yazılım için gereken görüntü örnekleri bir kamera vasıtası ile Kazova Ovası'nın Taşlıçiftlik mevkiinde yetiştirilen bir meyve bahçesinden elde edilmiştir. Bu görüntüler çeşitli görüntü işleme teknikleri ile işlenerek özellik çıkartımı yapılmıştır. Bu özellikler kullanılarak tahminleme yapılmıştır. Bu bölümde ilk olarak çalışmada kullanılan veri tanımlanacak daha sonra özellik çıkartımı ve tahminleme aşamalarında kullanılan tekniklerden bahsedilecektir.


3.1. Kullanılan Veri

Çalışmada kullanılan ham görüntü verisini toplama işlemi için 7,2 MP renkli görüntü alabilen bir fotoğraf makinesi kullanılmıştır. Bu cihazla maksimum çözünürlükte çekilen fotoğrafların sayısal ortamdaki boyutları yatayda 3072 ve dikeyde 2304 piksel olmaktadır. Görüntüler toplanmadan önce bahçe içerisinde veri olarak kullanılacak 15 elma ağacı seçilmiştir. Seçilen bu ağaçlar Şekil 3.1'deki bahçe planında gösterilmektedir.



Şekil 3.1. Bahçeden seçilen ağaçların krokisi (Anonim, 2013a)

Şekil 3.1 incelendiğinde, bahçenin çeşitli sıralarından ağaç seçimi yapıldığı görülebilir. Bunun sebebi, bahçede çeşitli türlerde elma ve armut ağaçlarının bulunmasıdır. Bahçeden seçilen Red Chief elma ağaçları etiketli plastik bağlar kullanılarak numaralandırılmıştır. Bu bağlar Şekil 3.2’de gösterilmektedir.



Şekil 3.2. Numaralandırmada kullanılan etiketli plastik bağlar

Şekil 3.2’de gösterilen etiketli plastik bağlar ile yapılan numaralandırma işlemi, görüntülerin alınması ve elmaların toplanması aşamalarında karışıklık oluşmaması ve fotoğraf-ağırlık ilişkilendirmesinde kolaylık olması açısından yapılmıştır.

Toplanan görüntüler hasat zamanının iki ay öncesinden başlanarak iki haftalık periyotlarla farklı hava koşullarında (açık, bulutlu) ve ağacın dört ana yönünden (doğu, kuzey, batı ve güney) alınmıştır. Görüntülerin standart olması açısından fotoğraflar ağaçların tacına 3 metre mesafeden çekilmiştir. Elmanın hem türü hem de olgunluğu dikkate alınarak hasat için en uygun zaman belirlenmiş ve 1 Ekim 2012 tarihinde elmalar hasat edilmiştir. Ağaçlardaki elmalar numara sırasıyla hasat edilmiş, böylece

her ağacın elmalarının diğer ağaçlarıkiyle karışması engellenmiştir. Her ağaçtan toplanan elmalar ayrı kasalara yerleştirilmiştir. Bu kasalar da toplandığı ağacın numarasıyla etiketlenmiştir. Kasaların etiketli plastik bağlarla numarlandırılması Şekil 3.3'te gösterilmektedir.



Şekil 3.3. Kasaların numarlandırılması

Şekil 3.3'te de gösterilen kasaların numarlandırılması işlemi tamamlandıktan sonra toplanan elmaların tartılması işlemine geçilmiştir. Elmaların tartım işlemi için 200 gr hassasiyetli elektronik kantar kullanılmıştır. Kasaların darası 1,8 kg olarak ölçülmüştür. Dara ağırlığı her bir ağacın toplam elma ağırlığından çıkarılmış, böylece ağaçlardan hasat edilen net elma ağırlıkları tespit edilmiştir. Ağaçlara ait tartı verisi Çizelge 3.1'de ayrıntılı olarak verilmektedir.

Çizelge 3.1. Ağaçların tartı verisi

Ağaç No	Kasa Sayısı	Brüt(kg)	Dara(kg)	Net(kg)
1	4	83	7,2	75,8
2	4	76,2	7,2	69
3	3	63,8	5,4	58,4
4	3	60,4	5,4	55
5	3	69,6	5,4	64,2
6	2	49,8	3,6	46,2
7	3	60	5,4	54,6
8	3	58,4	5,4	53
9	4	87,2	7,2	80
10	3	51	5,4	45,6
11	4	76	7,2	68,8
12	3	58,8	5,4	53,4
13	3	58	5,4	52,6
14	3	61,6	5,4	56,2
15	3	48,2	5,4	42,8
			Ortalama	58,37

Çizelge 3.1’de görülmekte olduğu gibi her ağacın net elma rekoltesi verilmektedir. Ortalama elma rekoltesinin 58,37 kg olduğu görülmektedir.

Ağaçlardan toplanan görüntü verisi özellik çıkartma aşamasında, Çizelge 3.1’de verilen tartı verisi ise tahminleme aşamasında kullanılmıştır.

3.2. Sayısal Görüntü İşleme

3.2.1. Sayısal Görüntü

Kamera ve tarayıcı gibi aygıtlar ile sayısal ortama taşınmış ya da doğrudan bilgisayar ortamında hazırlanan görüntüler sayısal görüntüler olarak ifade edilmektedir. Sayısal ortamda görüntüler 0 ve 1 lerden ibarettir. Her biri bir renk bilgisini gösteren piksellerin birleşmesi ile veya vektörel olarak belirlenen değerlerle görüntü verisi oluşturulmaktadır (Erbaş, 2011).

Raster Görüntüler


Dijital kameralar veya tarayıcılar yardımıyla alınan sayısal görüntüler ya da harita gibi çizimlerin sayısallaştırılmasıyla elde edilen görüntülerdir. Bu görüntüler piksellerin renk bilgisini bir monitör üzerinde boyanmasıyla görüntülenmektedir. Piksel tabanlı olduklarından döndürme, büyütme gibi işlemlerde çözünürlük kaybına uğrayabilmektedirler (Açıkgöz ve ark., 1999). Bu çalışmada toplanan ve sayısal ortama taşınan elma ağacı görüntüleri de raster görüntülerdir.

Vektörel Görüntüler

Matematiksel olarak vektörlerle ifade edilen ve bilgisayar ortamında çizim araçları ile oluşturulan görüntülerdir. Bilindiği gibi vektör, sayısal değerinin yanında yönü de olan bir niceliktir. Yani bu durumda vektörel görüntüler birden fazla vektörün birleşmesi ile oluşan şekillerdir. Vektörün koordinat sisteminde başlangıç, bitiş noktası ve yönü belirli olduğu için vektörel görüntüler görüntünün küçülmesi ya da büyütülmesi esnasında çözünürlük kaybına uğramamaktadırlar (Mehmed, 2009).

3.2.2. Sayısal Görüntü İşlemenin Temel Basamakları

Geleneksel bir görüntü işleme sisteminin çalışmasındaki temel işlem basamakları Şekil 3.4'te grafiksel olarak gösterilmektedir (Gonzalez ve Woods, 2002).



Şekil 3.4. Görüntü işlemenin temel basamakları

Şekil 3.4'den de anlaşılacağı gibi görüntü işlemenin her safhasında bir bilgi elde edilebilmektedir. Burada ilk adım, gerçek dünyadaki görüntüyü bir kamera aygıtı yardımıyla alıp sayısal ortama aktarmaktır. Bu cihazlarda bir resim algılayıcısı ve algılanan resmi sayısal hale getiren dönüştürücü bir birim bulunmaktadır. İçerdikleri mikroişlemciler sayesinde birçok ayarı otomatik yapabilen bu cihazlar ile görüntüler sayısal ortamlara kolayca kaydedilebilmektedir.

Görüntü verisi elde edildikten sonra görüntü işlemenin ikinci işlem basamağı ön işleme aşamasıdır. Ön işleme aşaması, daha başarılı sonuçlar elde edebilmek için sayısal görüntülerin bazı ön işlemlerden geçirilmesini sağlar. Ön işleme için kontrastın ayarlanması, gürültülerin azaltılması ve resimdeki bölgelerin birbirinden ayrılması örnek olarak verilebilmektedir.

Ön işlemlerden sonra bölütleme aşaması, bir resimdeki nesne ve arka planın veya resim içerisindeki ilgilenilen değişik özelliklere sahip bölgelerin birbirinden ayrıştırılması işlemidir. Bölütleme görüntüyü, birbirine benzeyen ve yararlı bilgiler içeren parçalara

ayırma amaçlanmaktadır. Bu parçalardan elde edilen bilgiler de gösterme ve tanılama aşamalarında kullanılmaktadır.

3.2.3. Sayısal Görüntü İşlemede Kullanılan Bazı Teknikler

Bölütleme

Görüntü işlemede bölütleme, bir görüntüyü, özellikleri bakımından farklı ve anlamlı bilgiler içeren parçalara ayırma olarak tanımlanabilmektedir. Bu parçalar aynı kontrast veya aynı parlaklık değerlerine sahip piksellerden oluşabilmekte ve bu pikseller de görüntü içerisinde farklı nesnelere tanımlayabilmektedir. Burada önemli olan pikselden nesneye doğru uygun yapıyı kurmaktır. Bunun için görüntüye ait ölçek, renk, biçim, yumuşaklık ve bütünlük değişkenlerini kullanmak gerekebilmektedir. Bu değişkenlerin dâhil olduğu bir fonksiyon yardımıyla pikselden parçalara ve buradan da daha büyük parçalara doğru bir zincir yapısı kurulabilmektedir (Rego, 2003).

Bölütleme, bir resimdeki nesnenin sınırları, şekli veya o nesnenin alanı gibi ham bilgiler üretmektedir. Görüntü bölütleme ile ilgili şimdiye kadar birçok yöntem önerilmiştir. Bunlardan en fazla kullanılanları; sıkıştırma-tabanlı yöntemler, kümeleme yöntemleri, bölge-tabanlı yöntemler, böl ve birleştir yöntemi ve histogram-tabanlı yöntemlerdir. Bölütleme, görüntü işlemenin en zor aşamasıdır ve bu nedenle bölütleme yöntemlerinin sonuçlarında belli bir hata oranı da olabilmektedir. Aynı zamanda herhangi bir görüntü üzerinde bölütleme yapabilecek belirli bir yöntem olduğu da söylenememektedir. Bir ya da daha fazla yöntem birlikte kullanılarak bölütleme yapılabilmektedir.

Gri tonlamalı görüntülerden siyah-beyaz görüntülerin elde edilmesi için yapılan bölütleme işlemlerinde görüntünün piksel değerleri üzerinde bazı temel özellikler kullanılmaktadır. Bunlar gri tonlamalı değerlerin benzerliği ve süreksizliğidir. Süreksizlik bilgisi kullanılarak görüntülerin kenar tespiti yapılabilmektedir. Bunun için gri tonlama değerlerindeki ani değişimler dikkate alınmaktadır. Benzerlik bilgisine dayanarak görüntüyü bölgelere ayırma işlemleri yapılabilmektedir (Wu, 2011).

Eşikleme

Görüntü bölütlemeye en sık kullanılan teknik, histogram tabanlı bölütleme yöntemi olan eşiklemedir. Eşikleme tekniği, bölütleme işleminde birbirine benzeyen görüntü kümelerini oluşturmayı sağlamaktadır. Bu işlem sonucunda elde edilen görüntüde belirlenen eşik değerine bağlı olarak bir bilgi kaybı söz konusu olmaktadır (Kızılkaya, 2008).

Eşikleme işlemi genellikle gri tonlamalı görüntüler üzerinde yapılır. Fakat gerçek hayatta görüntüler RGB gibi üç boyutlu renk uzaylarında ifade edilmektedir. RGB renk uzayındaki bir görüntüyü gri tonlamalı görüntüye çevirmek için Eşitlik 3.1'de görüldüğü gibi RGB renk kanallarının ağırlıklı ortalaması kullanılmaktadır.

$$X = K_R * R + K_G * G + K_B * B \quad (3.1)$$

Eşitlik 3.1'de K_R , K_G ve K_B değerleri R, G ve B renk kanallarına ait aydınlatma katsayılarıdır. Bu katsayılar 0 ile 1 arasında olup insan gözünün renklere olan duyarlılığına göre belirlenmektedir. İnsan gözünün yeşil renge daha duyarlı olmasından dolayı yeşilin aydınlatma katsayısı her zaman daha fazla alınmaktadır. Bu formül kullanılarak elde edilen ağırlıklı ortalama RGB'nin gri tonlamalı karşılığını vermektedir.

Gri tonlamalı görüntüler siyah, beyaz ve aradaki grinin bütün tonlarına dağıtılmış durumdadır. Bu seviyede her rengin değeri 0 ile 255 arasındadır. Eşikleme işlemi için 0 ile 255 arasından bir eşik değeri seçilmektedir. Şekil 3.5'de bir gri tonlamalı görüntü üzerinde eşikleme işleminin nasıl yapıldığı gösterilmektedir.



a)



b)



c)

Şekil 3.5. Gri tonlamalı görüntü üzerinde eşikleme işlemi

Şekil 3.5.a'da verilen orijinal RGB görüntü gri tonlamalı görüntüye dönüştürülmüştür. Şekil 3.5.b'de verilen görüntü üzerinde eşik değeri 100 seçilmiş ve Eşitlik 3.2'den yararlanarak eşikleme yapılmıştır. Şekil 3.5.c'de verilen eşiklenmiş sonuç görüntüsü elde edilmiştir.


$$P = \begin{cases} 1, & P > E \\ 0, & \text{Değilse} \end{cases} \quad (3.2)$$

Eşitlik 3.2'de E eşik değerini ve P piksel renk ton değerini göstermektedir. Eğer pikselin renk ton değeri bu eşik değerinden büyükse piksel renk ton değeri ikilik sayı sisteminde 1, değilse sıfır yapılmaktadır.

Orijinal RGB görüntü üzerinde eşikleme yapmak için RGB görüntünün kanallarını kullanmak gerekmektedir. Şekil 3.6'da RGB görüntünün R ve G kanalı üzerinden yapılan eşikleme işlemi gösterilmektedir.



a)



b)

Şekil 3.6. RGB görüntü üzerinde eşikleme işlemi

Şekilde 3.6.a'da orijinal RGB görüntü ve Şekil 3.6.b'de R ve G kanalları üzerinden eşikleme işlemine tabi tutulmuş siyah beyaz görüntü gösterilmiştir. Eşikleme işlemi için şart olarak R kanalı değerlerinin G kanalı değerlerinden daha büyük olması sağlanmıştır. Böylece, Şekil 3.6'da verildiği gibi renk kanalları üzerinde yapılan eşikleme işlemi sonucunda elma nesnelere ve arka planın daha doğru bölütlenmesi sağlanmıştır.

Eşikleme için kullanılan eşik değeri elle belirlenebileceği gibi bazı algoritmalar yardımıyla otomatik olarak ta belirlenebilmektedir. Otomatik belirlenen eşik değerine dinamik eşik değeri denmektedir (Kızılkaya, 2008). Eşik değeri görüntünün tamamına uygulamak için seçilen bir değer olabileceği gibi bölgesel olarak uygulanabilecek eşik değerleri de seçilebilmektedir (Wu, 2011).

Şekilsel İşlemler

Matematiksel şekilbilim, geometrik özelliklere sahip şekiller üzerinde yapılan konvolüsyon ve korelasyon gibi işlemler ve tekniklerdir. Bu işlemlerin temelinde küme teorisi ve topolojisi yatmaktadır. Bu nedenle kümeler üzerindeki bazı temel kavramları kullanmak gerekmektedir. Bunlar kesişim, birleşim, alt küme ve tümleyen gibi kavramlardır. P ve R görüntüleri temsil eden iki küme olmak üzere bu kümelerin elemanları koordinatları gösteren ikililerden oluşmaktadır. Örneğin P kümesinin bir elemanı $p(px,py)$ şeklinde gösterilmektedir (Vernon, 1991).

P kümesinin bir başka $c(cx,cy)$ elemanı ile koordinat düzleminde ötelenmesi işlemi Eşitlik 3.2'deki gibi tanımlanmaktadır (Emiroğlu, 2011).

$$(P)_k = \{k \mid k = p + c, \forall p \in P\} \quad (3.2)$$

Görüntü işlemede şekilsel işleme uğrayacak pikseller bir küme olarak düşünülmektedir. Bunun için yapılandırma elemanı olarak bilinen bir filtre bu küme üzerinde gezdirilmektedir. Kare, dikdörtgen gibi simetrik şekillerde ve farklı büyüklüklerde olabilen bu filtrenin bir merkez noktası bulunmakta ve filtrenin her hareketinde bu

merkez noktası kümenin bir elemanı üzerine gelmektedir. Daha sonra kümenin bu elemanı üzerinde gerekli şekilsel işlemler yapılmaktadır. Görüntüler üzerinde en sık uygulanan şekilsel işlemler aşındırma, genişletme, açma, kapama ve doldurma işlemleridir. Bu işlemler amaca göre sırasıyla uygulanabilmektedir (Kazan, 2011).

Şekilsel işlemler sırasında yapılandırma elemanı (R) ile yapılandırma elemanının o anda üzerinde bulunduğu görüntü kümesinin elemanları (P) üzerinde kesişim (mantıksal VE) veya birleşim (mantıksal VEYA) işlemleri yapılmaktadır. Böylece o anki durumun fit veya hit olup olmadığı anlaşılmaktadır. Eğer R ile P 'nin bütün elemanları örtüşüyorsa buna fit, en az bir elemanı örtüşüyorsa buna da hit olma durumu var denmektedir. Aşındırma işlemi için pikselin fit, genişletme işlemi içinse hit olarak tespit edilmesi gerekmektedir. Şekil 3.7 ve Şekil 3.8'de piksellerin fit ve hit olma durumları gösterilmektedir.

0	1	0
1	1	1
0	1	0

a) Görüntü kümesi (P)

Şekil 3.7. Fit olma durumu

0	1	0
1	1	1
0	1	0

b) Disk biçimli yapılandırma elemanı (R)

0	0	0
0	0	1
0	0	1

a) Görüntü kümesi (P)

Şekil 3.8. Hit olma durumu

0	1	0
1	1	1
0	1	0

b) Disk biçimli yapılandırma elemanı (R)

Şekil 3.7'de gösterilen fit olma durumunun tespit edilebilmesi için R ile P kümesinin elemanları arasında Eşitlik 3.4 ve Eşitlik 3.5'de verilen bağıntılar kullanılmaktadır.

$$\begin{aligned}
G = & P(x-1,y-1) \cap R(x-1,y-1) + P(x,y-1) \cap R(x,y-1) + \\
& P(x+1,y-1) \cap R(x+1,y-1) + P(x-1,y) \cap R(x-1,y) + \\
& P(x,y) \cap R(x,y) + P(x+1,y) \cap R(x+1,y) + \\
& P(x-1,y+1) \cap R(x-1,y+1) + P(x,y+1) \cap R(x,y+1) + \\
& P(x+1,y+1) \cap R(x+1,y+1)
\end{aligned} \tag{3.4}$$

$$P(x,y) = \begin{cases} 0, & G \geq 1 \\ 1, & \text{Değilse} \end{cases} \tag{3.5}$$

Eşitlik 3.4'te verilen kesişim işlemlerinin toplamından elde edilen değer G geçici değişkenine atanmaktadır. Eşitlik 3.5'de G 'nin değerine göre fit olma durumunda görüntü kümesindeki $P(x,y)$ elemanı aşındırmaya uğrayabilmektedir. Şekil 3.8'de gösterilen hit olma durumunun tespit edilebilmesi için R ile P kümesinin elemanları arasında Eşitlik 3.6 ve Eşitlik 3.7'de verilen bağıntılar kullanılmaktadır.

$$\begin{aligned}
G = & P(x-1,y-1) \cup R(x-1,y-1) + P(x,y-1) \cup R(x,y-1) + \\
& P(x+1,y-1) \cup R(x+1,y-1) + P(x-1,y) \cup R(x-1,y) + \\
& P(x,y) \cup R(x,y) + P(x+1,y) \cup R(x+1,y) + \\
& P(x-1,y+1) \cup R(x-1,y+1) + P(x,y+1) \cup R(x,y+1) + \\
& P(x+1,y+1) \cup R(x+1,y+1)
\end{aligned} \tag{3.6}$$


$$P(x,y) = \begin{cases} 1, & G \geq 1 \\ 0, & \text{Değilse} \end{cases} \tag{3.7}$$

Eşitlik 3.6'da birleşim işlemlerinin toplamından elde edilen değer G geçici değişkenine atanmaktadır. Eşitlik 3.7'de G 'nin değerine göre hit olma durumunda görüntü kümesindeki $P(x,y)$ elemanı genişletme işlemine uğrayabilmektedir (Abacı, 2012).

Aşındırma ve genişletme işlemleri görüntü işlemede kullanılan önemli şekilsel işlemlerdir. Bu işlemin yapıldığı pikseller birer küme olarak düşünülür. P üzerinde işlem yapılan görüntünün parçası ve R yapılandırma elemanı diye iki küme olmak üzere aşındırma işleminin gösterimi Eşitlik 3.8'de verilmektedir.

$$P \ominus \check{R} = \{k \mid R_k \subset P\} \quad (3.8)$$

Buna göre P kümesinin R yapılandırma kümesinin yansıması ile aşındırmaya uğraması, k elemanı ile ötelenen R yapılandırma kümesinin P kümesinin öz alt kümesi olan, yani R kümesinin bütün elemanlarının P kümesinin içinde yer aldığı öteleme elemanları kümesi olarak ifade edilebilmektedir. Şekil 3.9'da aşındırmaya uğramış bir görüntü örneği verilmektedir.



a)

b)


Şekil 3.9. Görüntü üzerinde aşındırma işlemi

Şekil 3.9.b'de de görüldüğü gibi Şekil 3.9.a'da verilen görüntü üzerinde yapılan aşındırma işlemi ile görüntü daralmakta, çıkıntılar ve girintiler kısılmaktadır (Emiroğlu, 2011).

Genişletme işleminin gösterimi Eşitlik 3.9'da verilmektedir.

$$P \oplus \check{R} = \{P^c \ominus \check{R}\} \quad (3.9)$$

Buna göre P kümesinin R yapılandırma kümesinin yansıması ile genişletilmesi için P 'nin tümleyeni ile R 'nin yansımasının aşındırma işlemine tabi tutulması gerekmektedir. Şekil 3.10'da genişletmeye uğramış bir görüntü örneği verilmektedir.



a)

b)


Şekil 3.10. Görüntü üzerinde genişletme işlemi

Şekil 3.10.b'de de görüldüğü gibi Şekil 3.10.a üzerinde yapılan genişletme işlemi ile görüntü yayvanlaşmakta, çıkıntılar ve girintiler daha fazla ortaya çıkmaktadır.

Açma işlemi, görüntü üzerinde sırasıyla aşındırma ve genişletme işlemlerinin yapılması olarak tarif edilebilmektedir. Yani P kümesinin, R kümesinin yansıması ile önce aşındırma işlemine tabi tutulması, sonra elde edilen kümenin R kümesi ile genişletmeye tabi tutulması ile elde edilen sonuç kümesi olarak tarif edilmektedir. Bu işlem Eşitlik 3.10'da verilmektedir.

$$P_R = (P \ominus \check{R}) \oplus R \quad (3.10)$$

Eşitlik 3.10'da verilen denklemde \check{R} ifadesi R kümesinin yansımasını ifade etmektedir. Şekil 3.11'de açma işlemine tabi tutulmuş bir görüntü örneği verilmektedir.



a)

b)


Şekil 3.11. Görüntü üzerinde açma işlemi

Şekil 3.11.b’de de görüldüğü gibi Şekil 11.a’da verilen görüntüde açma işlemine uğrayan nesnelere üzerindeki küçük çıkıntılar kaybedilebilmektedir. Nesneyi bir arada tutan küçük bağlar koparak nesne birden çok parçaya ayrılabilir ve bu işlemde yapılandırma elemanı küçük nesnelere de yok edilebilmektedir.

Kapama işlemi, görüntü üzerinde sırasıyla genişletme ve aşındırma işlemlerinin yapılması olarak tarif edilebilmektedir. Yani P görüntü kümesinin R yapılandırma elemanının yansıması ile önce genişletmeye tabi tutulması, sonra elde edilen kümenin R yapılandırma kümesi ile aşındırmaya tabi tutulması ile elde edilen sonuç kümesi olarak tanımlanabilmektedir. Bu işlem Eşitlik 3.11’deki gibi ifade edilmektedir.

$$P^R = (P \oplus \check{R}) \ominus R \quad (3.11)$$

Şekil 3.12’de kapama işlemine tabi tutulmuş bir görüntü örneği verilmektedir.



a)

b)


Şekil 3.12. Görüntü üzerinde kapama işlemi

Şekil 3.12.b'de de görüldüğü üzere Şekil 3.12.a' da verilen görüntü üzerinde yapılan kapama işlemi ile nesnelerin dış kısımlarında kalan detaylar kaybolabilmekte ve birbirine yakın nesneler birleşebilmektedir (Emiroğlu, 2011).

Boşluk doldurma işlemi için şekilsel olarak yeniden yapılandırmaya dayalı bir algoritma kullanılmaktadır. Doldurma işlemi Eşitlik 3.12'deki gibi ifade edilmektedir.

$$P_k = (P_{k-1} \oplus R) \cap A^c \quad k = 1, 2, 3, \dots \quad (3.12)$$

Burada A , görüntüyü, A^c , A 'nın tümleyenini ve R , yapılandırma elemanını ifade etmektedir. P , A ile aynı boyutta, ilgilenilen alandaki tüm doldurulmuş delikleri ve sınırları içeren bir matristir. Algoritmanın her adımında yapılan genişletme işlemini sonlandırmak için $P = P_k$ şartına bakılmaktadır. Doldurma işlemi, koşullu bir genişletme işlemine benzetilebilmektedir. Şekil 3.13'te doldurma işlemine uğramış görüntü örneği verilmektedir.



Şekil 3.13. Görüntü üzerinde doldurma işlemi

Şekil 3.13.b'de görüldüğü gibi Şekil 3.13.a'da verilen görüntü üzerinde yapılan doldurma işleminden sonra görüntüdeki boşluklar kapanmıştır (Gonzalez ve Woods, 2002).

3.2.4. Renkli Görüntü İşleme

Renk

Renk, ışık demetlerinin cisimlere çarpıp yansyarak farklı dalga boylarında gözümüze ulaşması ve ardından beyindeki görme merkezi tarafından yorumlanması ile meydana gelen algılama olarak tarif edilebilmektedir. Gözümüzde rengi algılayan fotoreseptörler (koni hücreleri) bulunmaktadır. Sinirler aracılığıyla gözden beyne ulaşan renkler kırmızı, yeşil veya mavidir. Diğer renkler ise bu üç ana rengin farklı oranlarda beyinde yorumlanmasıyla elde edilmektedir. Gözümüz ancak 380nm ile 740nm dalga boyları arasındaki ışığı görebilmektedir. Göremediğimiz dalga boylarına sahip renkler ise mor ötesi ışınlar ya da kızılötesi ışınlar olarak adlandırılmaktadır. Bunlar ise elektronik aygıtlar yardımıyla gözümüzle algılanabilir hale getirilebilmektedir. Şekil 3.14'te insan gözünün görebildiği renkler ve bunların dalga boyları verilmiştir.


RENK	DALGABOYU
Mor	380-440 nm
Mavi	440-485 nm
Cam Göbeği	485-500 nm
Yeşil	500-565 nm
Sarı	565-590 nm
Turuncu	590-625 nm
Kırmızı	625-740 nm

Şekil 3.14. Görülebilen renklerin dalga boyları

Şekil 3.14'te de görüldüğü gibi algılayabildiğimiz her rengin dalga boyları farklı aralıklarda bulunmaktadır.

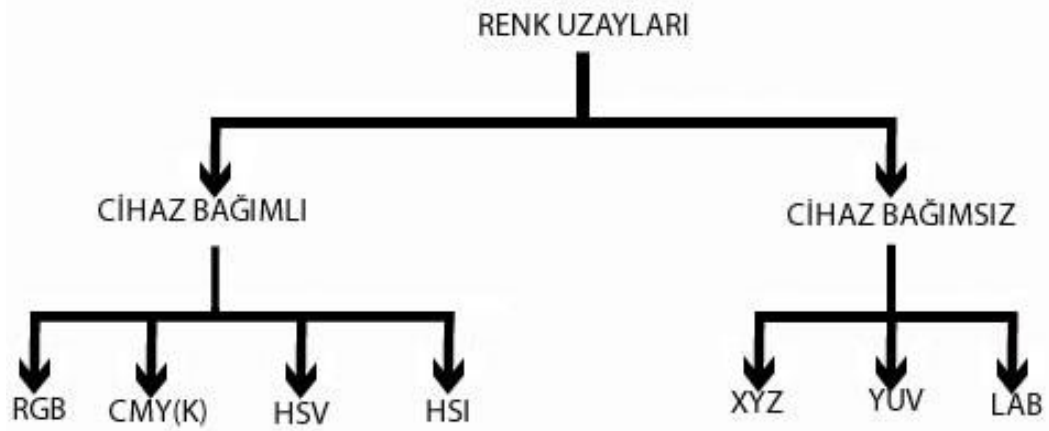
Renk Uzayları

Renklerin makinelerce tanımlanabilmesi amacıyla üç veya dört boyutlu olarak oluşturulan soyut matematiksel modellerdir. Şekil 3.15'te insan gözünün görebildiği renk alanını gösteren ve gamut olarak bilinen yapı gösterilmektedir.




Şekil 3.15. Görülebilen renk alanları (Bastı, 2005)

Şekil 3.15'te A insan gözünün renk alanı, B renkli filmin renk alanı, C monitörün renk alanı ve D baskı renk alanını göstermektedir. Renk uzaylarını kullanan makineler genellikle baskılama ya da görüntüleme aygıtlarıdır. Eğer bir renk uzayı bir aygıtın tasarımına dayanarak oluşturulmuş ise buna cihaz bağımlı renk uzayı denmektedir. CIE tarafından elde edilen cihaz bağımsız renk uzaylarında ise standart gözlemci (2° , 10°) ve standart aydınlatıcı (A, B, C, D50, D65, E, F) olmak üzere iki sabit değer belirlenmektedir. Şekil 3.16'da renk uzaylarından bazıları gösterilmektedir.



Şekil 3.16. Renk uzayları

RGB renk uzayı adını kırmızı, yeşil ve mavi renklerin İngilizce baş harflerinden alan koordinat eksenleri bu üç rengin temsil ettiği bir uzaydır. Bir rengi ifade etmek için kullanılan bu koordinatların her biri 0 ile 255 arasında değişen değerler almaktadır. Bilgisayar monitörü gibi görüntüleme aygıtlarında ve tarayıcı cihazlarda kullanılmaktadır (Yılmaz, 2007). RGB renk uzayında oluşturulmuş bir görüntü sayısal ortamda $M \times N \times 3$ boyutlarında bir matris şeklinde indekslenmektedir. Burada M ve N görüntünün piksel cinsinden boyutlarını, üçüncü boyut ise kırmızı, yeşil ve mavi rengin oranlarını ifade etmektedir (Gonzalez ve Woods, 2004). Şekil 3.17'de RGB renk uzayının renk kanalları görülmektedir.



Şekil 3.17. RGB renk uzayı


CIE XYZ renk uzayı RGB renk uzayın özelliklerine bağlı olarak oluşturulmaktadır. Burada Y , bir rengin parlaklık ölçütü olarak düşünülmektedir. Bir rengin kromatikliği ise, x , y ve bu iki değerden türetilmiş z değeriyle ifade edilmektedir. Buna göre x , y ve z değerleri Eşitlik 3.13'te verilen bağıntılarla hesaplanmaktadır.

$$x = \frac{X}{X+Y+Z}$$

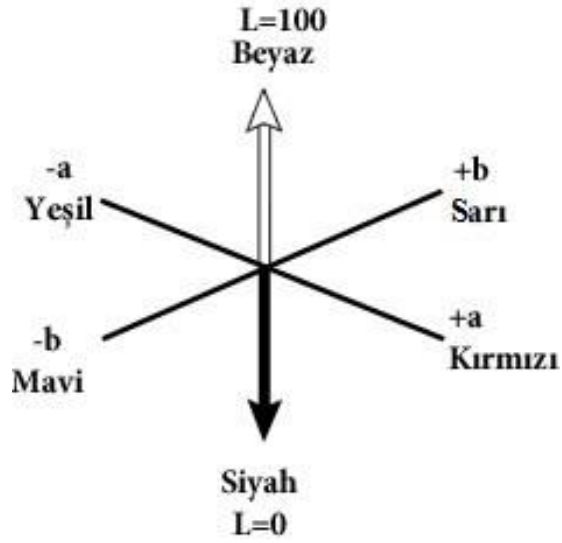
$$y = \frac{Y}{X+Y+Z} \quad (3.13)$$

$$z = 1 - x - y$$

CIE tarafından tanımlanan CIE Lab renk uzayında L (Lightness) aydınlık düzeyini, a (tonlama) kırmızıdan yeşile ve b (doygunluk) sarıdan maviye doğru azalan değerlerle ifade edilen düzlemi göstermektedir. Şekil 3.19'da görüldüğü gibi L eksenini 0 ile 100 arasında değişen değerler almaktadır. CIE Lab cihaz bağımsız bir renk uzayıdır. Birçok alanda standart renk uzayı olarak kullanılmaktadır. Şekil 3.18'de CIE XYZ renk uzayının renk alanı ve Şekil 3.19'da CIE Lab renk uzayının renk alanı gösterilmektedir.




Şekil 3.18. CIE XYZ renk uzayı (Anonim, 2013b)



Şekil 3.19. CIE Lab renk uzayı

Şekil 3.19’da verilen L , a ve b kanallarının değerleri Şekil 3.18’de verilen CIE XYZ renk uzayının değerleri ile hesaplanmaktadır. Ayrıca hangi standart aydınlatıcı ve standart gözlemcinin kullanılacağı belirlenmelidir (Yılmaz, 2007).


CIE Luv renk uzayı CIE YUV (1960) renk uzayını temel alarak oluşturulmuştur. Burada L aydınlık düzeyini, u yeşilden kırmızıya değişimleri ve v ise maviden mora doğru olan değişimleri temsil etmektedir. Bu çalışmada da üzerinde analizler yapılan renk uzayı olan CIE Luv'nin kırmızı rengin belirlenmesinde etkili olduğu tespit edilmiştir. Şekil 3.20'de CIE Luv renk uzayının renk kanalları gösterilmektedir.



Şekil 3.20. CIE Luv renk uzayı

Şekil 3.20'de görüldüğü gibi CIE Luv renk uzayının u kanalı kırmızı yeşil arasında değişen bir yörüngeyi ifade etmektedir. Bu kanal kullanılarak yapılan bir eşikleme ile kırmızı ve yeşil renkli nesnelere kolayca bölümlenebilmektedir.

HSV (Hue, Saturation, Value) renk uzayının eksenleri, renk (H), doygunluk (S) ve aydınlık (V) değerleridir. Burada doygunluk, rengin canlılığını temsil etmektedir. Doymunluk değeri düşük olduğunda renkler daha soluk gözükmektedir. Aydınlık değeri ise rengin karanlık ya da parlak olmasına neden olmaktadır. Bu üç eksen 0 ile 255 arasında değerler almaktadır. Geliştirilme amacı insanın algılamasına daha yakın bir renk uzayı oluşturmaktır. HSV renk uzayı, cihaz bağımlı renk uzayları sınıfındadır. Bu nedenle renkler cihaza göre değişik şekillerde üretilmektedirler. HSV renk uzayının renk kanalları Şekil 3.21'de gösterilmektedir.



Şekil 3.21. HSV renk uzayı

Şekil 3.21’de de görüldüğü gibi sıfır aydınlık düzeyinde dahi H ve S değerleri ile bir renk tanımlanabilmektedir. Burada H kanalı renkleri gösteren açısal değerlere sahiptir ve bu ekseninde kırmızı ve yeşil değerleri zıt bölgelerdedir (Tonguç, 2007; Anonim, 2013c).

Renk Uzayları Arası Dönüşümler

CIE XYZ ve RGB renk uzayları arasında yapılacak dönüşümlerde Y , standart beyaz değeri için 100 olarak alınmaktadır. Dönüşüm işlemi Eşitlik 3.14 ve Eşitlik 3.15 kullanılarak yapılmaktadır (Yılmaz ve ark., 2003).

$$\begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = \begin{bmatrix} X_R & X_G & X_B \\ Y_R & Y_G & Y_B \\ Z_R & Z_G & Z_B \end{bmatrix} \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (3.14)$$

$$\begin{bmatrix} R \\ G \\ B \end{bmatrix} = \begin{bmatrix} X_R & X_G & X_B \\ Y_R & Y_G & Y_B \\ Z_R & Z_G & Z_B \end{bmatrix}^{-1} \begin{bmatrix} X \\ Y \\ Z \end{bmatrix} \quad (3.15)$$

Eşitlik 3.14 ve Eşitlik 3.15’te verilen bağıntılarda kullanılan standart değerler Çizelge 3.2 ve Çizelge 3.3’te verilmektedir.

Çizelge 3.2. RGB’den CIE XYZ renk uzayına dönüşüm değerleri:

Renk	X	Y	Z
Kırmızı (R)	0.4124564	0.3575761	0.1804375
Yeşil (G)	0.2126729	0.7151522	0.0721750
Mavi (B)	0.0193339	0.1191920	0.9503041

Çizelge 3.3. CIE XYZ’den RGB renk uzayına dönüşüm değerleri:

Renk	X	Y	Z
Kırmızı (R)	3.2404542	-1.5371385	-0.4985314
Yeşil (G)	-0.9692660	1.8760108	0.0415560
Mavi (B)	0.0556434	-0.2040259	1.0572252

Çizelge 3.2 ve Çizelge 3.3’te verilen değerler standart gözlemci = 2° ve standart aydınlatıcı = D65 alındığı zaman kullanılan sRGB standart renk değerleridir. Bu değerler genellikle renklerin üreticileri tarafından verilmektedir.

CIE XYZ renk uzayından CIE Lab renk uzayına dönüşüm işleminde önce standart beyazın (X_w , Y_w ve Z_w) ne olacağına karar verilmektedir. Daha sonra CIE Lab renk uzayının CIE XYZ renk uzayına dönüşüm işlemi için Eşitlik 3.16’da verilen bağıntılar kullanılmaktadır (Yılmaz, 2007).

$$L = 116 \frac{Y}{Y_w} - 16$$

$$a = 500 \left[f\left(\frac{X}{X_w}\right) - f\left(\frac{Y}{Y_w}\right) \right] \quad (3.16)$$

$$b = 200 \left[f\left(\frac{Y}{Y_w}\right) - f\left(\frac{Z}{Z_w}\right) \right]$$

Eşitlik 3.16’da ifade edilen f fonksiyonu Eşitlik 3.17’de verilmektedir.

$$f(t) = \begin{cases} t^{1/3}, & t > \delta^3 \\ \alpha + \frac{16}{116}, & \text{Değilse} \end{cases} \quad (3.17)$$

Eşitlik 3.17’de ifade edilen standart değerler,

$$\delta = \frac{6}{29}$$

$$\alpha = \frac{1}{3}\delta^{-2} = 7,787037$$

$$t_0 = \delta^3 = 0,008856$$

olarak alınmaktadır (Schanda, 2007).

RGB renk uzayından HSV renk uzayına dönüşüm için doğrusal olmayan bir yöntem kullanılır. Dönüşümün algoritması aşağıdaki gibi tanımlanmaktadır (Yılmaz ve ark., 2003).

- Adım1. $X = \max(R, G, B)$
 Adım2. $N = \min(R, G, B)$
 Adım3. $\delta = X - N$
 Adım4. $V = X$
 Adım5. *Eğer* $X \neq 0$ *ise* $S = \frac{\delta}{X}$
 Adım6. *Eğer* $X = 0$ *ise* $S = \infty, H = -1$
 SON
 Adım7. *Eğer* $X = R$ *ise* $H = \frac{G-B}{\delta}$
 Adım8. *Eğer* $X = G$ *ise* $H = 2 + \frac{B-R}{\delta}$
 Adım9. *Eğer* $X = B$ *ise* $H = 4 + \frac{R-G}{\delta}$
 Adım10. $H = H * 60$
 Adım11. *Eğer* $H < 0$ *ise* $H = H + 360$

RGB renk uzayındaki bir görüntünün CIE Luv renk uzayına taşınması için önce CIE XYZ renk uzayına taşınması gerekmektedir. Burada hesaplanan X, Y ve Z değerleri

kullanılarak CIE Luv renk uzayına dönüşüm işlemi Eşitlik 3.18'de bağıntılar ile yapılmaktadır.

$$\begin{aligned}
 varU &= \frac{4X}{15Y+X+3Z} \\
 varV &= \frac{9Y}{15Y+X+3Z} \\
 varY &= \frac{Y}{100} \\
 varY &= f(varY) = \begin{cases} varY^{1/3}, & varY > \delta^3 \\ \alpha * varY + \frac{16}{116}, & Değilse \end{cases}
 \end{aligned} \tag{3.18}$$

Eşitlik 3.18'deki f fonksiyonunda bulunan standart değerler,

$$\begin{aligned}
 \delta &= \frac{6}{29} \\
 \alpha &= \frac{1}{3}\delta^{-2} = 7,787037 \\
 t_0 &= \delta^3 = 0,008856
 \end{aligned}$$

olarak alınmaktadır. Standart Gözlemci = 2° ve Standart Aydınlatıcı = D65 seçilirse standart referans değerleri,

$$ref_X = 95,047 \qquad ref_Y = 100 \qquad ref_Z = 108,883$$

olarak alınmaktadır. $refU$ ve $refV$ değerleri ise Eşitlik 3.19 ve Eşitlik 3.20 kullanılarak hesaplanmaktadır.

$$refU = \frac{4 * ref_X}{15 * ref_Y + ref_X + 3 * ref_Z} \tag{3.19}$$

$$refV = \frac{9 * ref_Y}{15 * ref_Y + ref_X + 3 * ref_Z} \tag{3.20}$$

Son adımda ise L , U ve V değerleri Eşitlik 3.21'de verilen bağıntılar ile hesaplanmaktadır (Anonim, 2013d).

$$L = (116 * varY) - 16$$

$$U = (varU - refU) * L * 13 \quad (3.21)$$

$$V = (varV - refV) * L * 13$$

3.3. Kullanılan Tahminleme Yöntemleri

3.3.1. Doğrusal Regresyon

Regresyon, eldeki veri seti üzerinde sınıflandırma ve tahmin yapmak için kullanılan en basit yöntemdir. Regresyon için doğrusal ve doğrusal olmayan diye iki yaklaşım vardır. Doğrusal regresyon yaklaşımı, giriş değişkenlerinin ağırlıklı toplamı ile çıkış değişkeni arasında belirli bir hata (E) olduğunu varsaymaktadır. Bu durumda giriş değişkenleri ile çıkış arasında doğrusal bir bağlantı vardır. Birden çok özelliğe sahip giriş verisi için kullanılan çoklu doğrusal bir regresyon denklemi Eşitlik 3.22'deki gibi gösterilmektedir.

$$Y = W_0 + \sum_{j=1}^N W_j X_j + E \quad (3.22)$$

Eşitlik 3.22'de yer alan W_j ağırlık değerlerini, X_j verinin özellik vektörlerini, N verideki toplam özellik sayısını, E hatayı ve Y ise hedef değişkeni temsil etmektedir. Burada önemli olan W_j değerlerini bulmaktır. Bunun için en çok kullanılan yöntem en küçük kareler yöntemidir (Chapra ve Canale, 2003). En küçük kareler yöntemi, karesel hataların toplamını minimum yapan denklem katsayılarını bulmak üzerine kurulmuştur. Bu yöntemin ana prensibi aşağıda Eşitlik 3.23'te ifade edilen Ortalama Karesel Hata (OKH)'nin en küçük yapılmasına dayanmaktadır.


$$OKH = \frac{1}{N} \sum_{i=1}^N (d_i - \bar{d}_i)^2 \quad (3.23)$$

$$OKHK = \sqrt{OKH} \quad (3.24)$$

Eşitlik 3.23'te ifade edilen $d_i - \bar{d}_i$ her bir hedef değişken ile hesaplanan doğru denklemleri arasındaki hatayı (uzaklığı) göstermektedir. Eşitlik 3.24'te ifade edilen Ortalama Karesel Hata Karekökü (OKHK), ölçülen değerler ile tahminler arasındaki hata oranını tespit etmek amacıyla kullanılmaktadır. OKHK değerinin sıfıra yaklaşması sistemin tahmin kabiliyetinin artması anlamına gelmektedir (Singh ve ark., 2009).

3.3.2. Çok Katmanlı Algılayıcı Sinir Ağı

Nöronların biyolojik modeline dayanan yapay nöronun McCulloch ve Pitts (1943) tarafından önerilen gösterimi benimsenmiştir. Şekil 3.22'de nöronun McCulloch-Pitts modeli gösterilmektedir.



Şekil 3.22. Yapay nöronun yapısı (McCulloch ve Pitts, 1943)

Bu nöron yapısından elde edilecek y_k çıkış değişkenini hesaplamak için Eşitlik 3.25'te verilmektedir.

$$v_k = \sum_{i=1}^n w_i x_i \quad (3.25)$$


$$y_k = \varphi(v_k)$$

Eşitlikleri kullanılmaktadır. Eşitlik 3.25'te φ aktivasyon fonksiyonunu, x giriş değerlerini ve w ise uygun ağırlık katsayılarını ifade etmektedir (Anonim, 2013e). Eşitlik 3.25'te elde edilen v_k değerleri aktivasyon fonksiyonuna girecek olan ağırlıklandırılmış toplam değerlerdir. Kullanılan aktivasyon fonksiyonuna bağlı olarak elde edilen y_k çıkışları da değişmektedir. Tek kutuplu basamak fonksiyonuna göre y_k çıkışlarının nasıl elde edilebileceği Eşitlik 3.26'da gösterilmektedir.

$$y = \begin{cases} 1, & v \geq T \\ 0, & v < T \end{cases} \quad (3.26)$$

Eşitlik 3.26'ya göre çıkışın iki sonuçtan biri olması gerektiği durumlarda y değeri belli bir eşikten büyükse 1, küçükse 0 sonucunu üretmesi sağlanmaktadır. Eşik değer T olarak gösterilmiştir. Bu eşik değeri daha önce verilen çıkışlara göre değerlendirilerek değiştirilebilmekte ya da sabit kalabilmektedir. Eşikleme için kullanılan tek kutuplu basamak fonksiyonu dışında en sık kullanılan aktivasyon fonksiyonları, çift kutuplu basamak fonksiyonu, doğrusal fonksiyon, sigmoid fonksiyonu ve hiperbolik tanjant fonksiyonlarıdır (Soytürk, 2005).

Bu çalışmada tahminleyici olarak kullanılan çok katmanlı algılayıcı (ÇKA) ağı, geliştirilmiş bir yapay sinir ağı modelidir. İstatistiksel sınıflandırıcılara göre daha az eğitim verisi ile daha başarılı tahminleme yapılabilmektedir. Bu model genellikle doğrusal olmayan problemlerin çözümünde kullanılmaktadır. Ağın eğitimi için geriye yayılım algoritması kullanılmaktadır. Böylece ağırlık değerleri her iterasyonda çıkış hataları ile geriye doğru güncellenmekte ve ağ daha etkin biçimde eğitilebilmektedir. Şekil 3.23'te sigmoid aktivasyon fonksiyonu kullanan bir ÇKA'nın genel yapısı gösterilmektedir.



Şekil 3.23. ÇKA sinir ağının genel yapısı

Şekilde görüldüğü gibi ağda üç katman bulunmaktadır. Bunlar giriş katmanı, gizli katman ve çıkış katmanlarıdır. İki farklı ağırlık matrisi bulunmaktadır. W_1 giriş katmanından gizli katmana ve W_2 gizli katmandan çıkış katmanına olan ağırlık matrisleridir. Eğitimin amacı OKH'yı olabildiğince en küçük değere getirmektir (Lancashire ve ark., 2008).

3.3.3. RBF Sinir Ağı


Merkezi tabanlı fonksiyon olan RBF (Radial Basis Function), doğrusal olarak ayrılamayan sınıfları, bir haritalama işlemi yardımıyla doğrusal olarak ayrılabilen farklı bir uzaya taşımayı amaçlayan basit bir sinir ağı modelidir. Haritalama işlemi x veri kümesi üzerinde $\phi(x)$ ile gösterilen bir fonksiyonla yapılmaktadır.

$$\phi(x) = \exp\left(-\frac{\|c_j - x_i\|^2}{2r^2}\right) \quad (3.27)$$

$$y(x) = \sum_{i=1}^N (W_i \phi(x))$$

Eşitlik 3.27'deki haritalama fonksiyonu ile merkezi noktalarla (c_j) giriş veri noktaları (x_i) arasındaki farklar genellikle öklid uzaklığı kullanılarak hesaplanmaktadır. Burada r değeri prototipin çapını (yayıma katsayısı) ifade etmektedir ve bu değer giriş verisinin

dağılımına göre seçilmektedir. N değeri gizli katmandaki nöron sayısını ve W_i gizli katman ile çıkış katmanı arasındaki ağırlıkları göstermek üzere, x giriş verisine göre çıkıştan elde edilecek y değerleri hesaplanmaktadır. RBF ağıının genel yapısı Şekil 3.24'te gösterilmektedir.

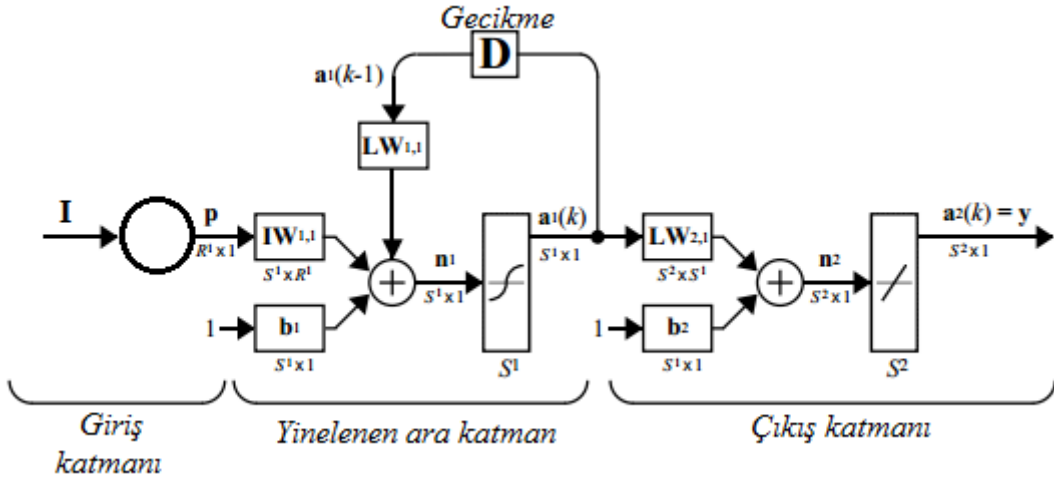


Şekil 3.24. RBF sinir ağıının genel yapısı

Şekil 3.24'te görüldüğü gibi RBF sinir ağlarında genellikle bir giriş katmanı, her biri RBF fonksiyonu içeren bir gizli katman ve bir çıkış katmanı bulunmaktadır (Hardy, 1971; Press ve ark., 2007).

3.3.4. Elman Sinir Ağı

Elman ağları, gizli katmanın çıkışından giriş katmanına bir geri besleme bağlantısının ilave edilmesi ile oluşturulan genellikle iki katmanlı ve geri yayımlı ağlardır. Bu geri besleme sayesinde Elman ağları hem zamansal hem de uzaysal modelleri öğrenebilmektedir. Şekil 3.25'te bir Elman ağıının genel yapısı gösterilmektedir.



Şekil 3.25. Elman sinir ağının genel yapısı (Demuth ve Beale, 2002)

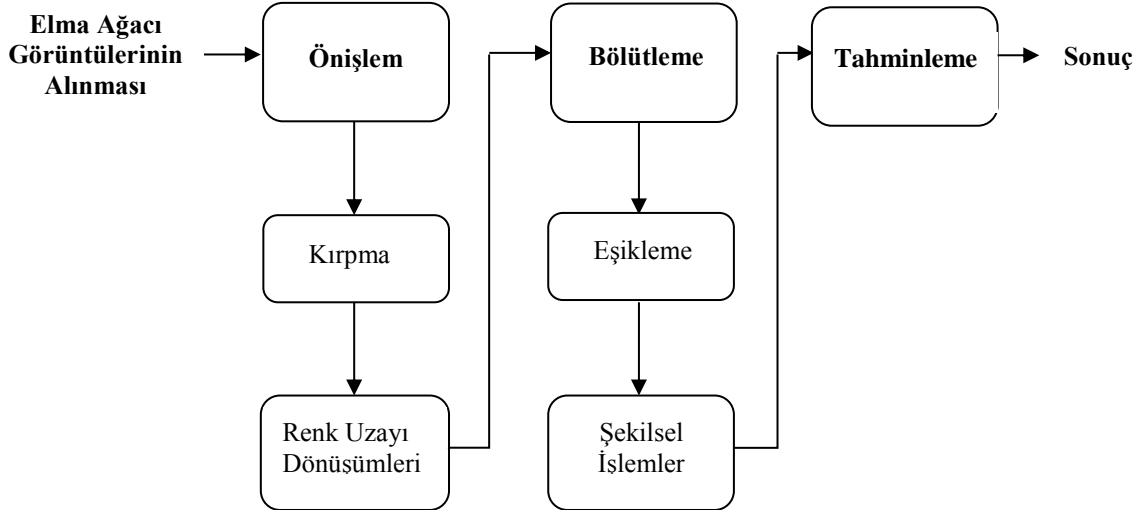
Şekil 3.25'te görüldüğü gibi gizli katmanda bir aktivasyon fonksiyonu, geri yayılım işlemi için bir geri yayılım algoritması kullanılmaktadır. Ağın performansının ölçülmesi için ise genellikle OKH kullanılmaktadır. Elman ağı ilk oluşturulduğunda her katmanın ağırlık ve bias değerleri belirlenmektedir. Daha sonra her eğitim aşamasında aşağıdaki adımlar gerçekleştirilmektedir.

- 1- Ağa giren tüm giriş veri seti için çıkışta bir hata değeri hesaplanır,
- 2- Her adımda bulunan hata değeri, tüm ağırlık ve bias değerleriyle birlikte geri yayılım algoritması kullanılarak eğitim hesaplanır,
- 3- Bulunan eğitim değeri geri yayımlı eğitim algoritması ile ağırlıkları günceller.

Elman ağının sıradan iki katmanlı ağlardan farkı, gizli katmandan giriş katmanına olan geri beslemedir. Bu şekilde, bir zaman gecikmesi ile bir önceki adımın değerleri bir sonraki adımda kullanılabilir. Aynı ağırlık ve bias değerlerinde bile aynı girişlere karşılık farklı zaman adımlarında farklı sonuçlar elde edilebilmektedir. Bu sayede giriş verisinin sıralı olduğu durumlarda başarılı sonuçlar elde edilebilmektedir. Elman ağlarında gizli katmandaki nöron sayısının doğru belirlenmesi önemlidir (Elman, 1990; Demuth ve Beale, 2002).

4. BULGULAR VE TARTIŞMA

Bu bölümde önerilen görüntü işleme yazılımının çalışması ayrıntılı bir şekilde incelenmiştir. Bunun için, daha önceki bölümde anlatılan ve toplanan sayısal görüntülerden oluşan iki ayrı veri kümesi kullanılmıştır. Birincisi kapalı havada elde edilen sayısal görüntüler ve ikincisi ise açık havada elde edilen sayısal görüntülerdir. Bu veri kümelerindeki görüntülerin işlenmesi amacıyla Matlab yazılım platformu üzerinde önceki bölümde bahsedilen geleneksel görüntü işleme teknikleri kullanılarak bir yazılım geliştirilmiştir. En verimli sonucu elde etmek amacıyla hem bulutlu havada hem de açık havada toplanan görüntüler üzerinde deneyler yapılmıştır. Bununla birlikte RGB renk uzayında elde edilen sayısal görüntüler dönüştürme teknikleri kullanılarak CIE Lab, CIE Luv ve HSV renk uzaylarına taşınmış ve bunlar üzerinden özellikler çıkartılmıştır. Rekolte tahmin sisteminin eğitim aşamasında doğrusal regresyon, ÇKA, RBF ve Elman sinir ağı modelleri kullanılmıştır. Tahmin sonuçları grafikler ve çizelgeler halinde sunulmuş ve yorumlanmıştır. Geliştirilen bu görüntü işleme yazılımının çalışma adımları Şekil 4.1’de gösterilmektedir.



Şekil 4.1. Rekolte tahmin yazılımının çalışma adımları

Şekil 4.1’de gösterilen adımların ilki, toplanan sayısal görüntüler üzerinde standart bir kırpma işleminin uygulanmasıdır. Böylece görüntülerdeki elmaların yoğun olarak

bulunduđu bölgelerin seçilmesi sağlanmıştır. Şekil 4.2’de bu işlemin nasıl yapıldığı gösterilmektedir.



a)

b)

Şekil 4.2. Resimlerin kırılması


Şekil 4.2.b’de görüldüğü gibi Şekil 4.2.a’daki orijinal resim alt kısmından belli bir miktar kırılmış böylece bölütleme aşamasında oluşan hatalar en aza indirgenmeye çalışılmıştır.

Çalışmanın ikinci aşamasında görüntünün renk bilgisinden yola çıkarak bir bölütleme algoritması geliştirilmiştir. Bu algoritmanın oluşturulması sırasında RGB, CIE Lab, CIE Luv ve HSV renk uzaylarının renk kanalları üzerinde analizler yapılmıştır. Buradaki amaç görüntülerdeki elma nesnelere en iyi şekilde arka plandan (toprak, gökyüzü, yapraklar vb.) ayırmaktır. Görüntüdeki elma nesnelere toplam alanları (piksel sayısı cinsinden) öznitelik olarak belirlenmiştir. Bu şekilde doğru olarak elde edilecek elma alanları bir sonraki aşamada tahmin sisteminin eğitiminde giriş özelliği olarak kullanılacaktır. Bu nedenle elma alanlarının en doğru şekilde tespit edilmesi tahmin sisteminin başarısını yükseltecektir. Geliştirilen bölütleme algoritmasının elma alanlarını ne kadar doğru tespit edebildiğini anlamak için veri kümesindeki görüntülerden bazılarının elma alanları bir resim işleme programında el ile işaretlenmiştir. Bu şekilde elde edilen alan bilgileri algoritma tarafından hesaplanan alan bilgileriyle karşılaştırılmıştır. El ile bulunan ve CIE Luv renk uzayında hesaplanan alan bilgileri Çizelge 4.1’de verilmektedir.


Çizelge 4.1. Doğu yönünden alınan görüntülerin elma alanı karşılaştırması

Ağaç	Alan (CIE Luv)	Alan (Elle)
1	197.261	202.810
2	136.395	119.744
3	41.997	75.068
4	144.810	211.735
5	117.008	124.762
6	100.492	114.437
7	145.404	140.238
8	143.217	139.150
9	213.357	194194
10	110.432	158.910
11	169.051	173.850
12	147.482	150.023
13	136.102	129.746
14	74.920	84.886
15	125.574	147.897
ORT	133.567	144.497

Çizelge 4.1’de verilen bilgilere göre elle bulunan elma alanlarının ortalama olarak 144.497 piksel olduğu görülmektedir. Elle bulunan ve hesaplanan elma alanları arasındaki ilişkiyi görmek amacıyla OKHK değeri hesaplanmış ve 25.250 piksel olarak bulunmuştur. Bu değer ile elle bulunan ortalama elma alanı değeri karşılaştırıldığında %17’lik bir hata ile elma alanlarının hesaplanabildiği anlaşılmıştır. Bundan dolayı çalışmada özellik çıkartma yöntemi aşamasında görüntülerin renk bilgisi kullanılmıştır. Şekil 4.3’te bir elma ağacı görüntüsü üzerinde elle bulunan ve hesaplanan elma alanları verilmektedir.



a) El ile bulunan elma alanları



b) Algoritma ile bulunan elma alanları

Şekil 4.3. Elma alanlarını gösteren ikili görüntü


Şekil 4.3.a ve Şekil4.3.b’de görüldüğü üzere elle bulunan ve hesaplanan alan bilgileri oldukça benzemektedir.

Geliştirilen ilk algoritma RGB renk kanalları üzerinden bölütleme işlemi yapmaktadır. Çalışmada kullanılan elma türü kırmızı renkli olduğundan R kanalının diğer kanallar

olan G ve B kanallarına oranla daha yüksek deęerde olduęu piksellerin seilmesi saęlanmıřtır. Yapılan bu eřikleme Őekil 4.4'te gsterilmektedir.



a) Orijinal RGB grnt




b) Eřiklenmiř siyah-beyaz grnt

Őekil 4.4. RGB renk uzayında eřikleme iřlemi

RGB renk uzayında yapılan bölütleme işlemi aşağıdaki adımlardan oluşmaktadır.

- Adım1. Şekil 4.4.a'da verilen RGB renk uzayındaki görüntüde $R > G$ ve $R > B$ olan pikseller seçilmiştir.
- Adım2. Seçilen piksellerin değeri «1», diğerleri «0» yapılarak aynı boyuttaki siyah-beyaz resim elde edilmiştir.
- Adım3. Açma işlemi uygulanmış, bu sayede görüntüdeki gürültüler temizlenmiştir.
- Adım4. Kapama işlemi uygulanmıştır.
- Adım5. Doldurma işlemi uygulanmıştır.
- Adım6. Elde edilen Şekil 4.4.b'deki siyah-beyaz resim üzerinde elma alanları hesaplanmıştır.

Geliştirilen ikinci bölütleme algoritması, RGB renk uzayından XYZ ve oradan da Lab renk uzayına taşınan görüntülerin a kanalı üzerinde bölütleme işlemi yapmaktadır. Böylece a renk kanalı yardımıyla ağaç resimlerindeki yeşil-kırmızı zıtlığı kullanılmış ve yeşil yaprak ile kırmızı elmanın ayrıştırılması sağlanmıştır. Yapılan işlemler Şekil 4.5'te gösterilmektedir.



Şekil 4.5.a. CIE Lab uzayındaki görüntünün a kanalına ait görüntü




Şekil 4.5.b. CIE Lab renk uzayında eşikleme işlemi


CIE Lab renk uzayında yapılan bölütleme işlemi aşağıdaki adımlardan oluşmaktadır.

- Adım1. Şekil 4.4.a'da verilen RGB renk uzayındaki görüntü CIE XYZ renk uzayına, oradan da CIE Lab renk uzayına taşınmıştır.
- Adım2. Şekil 4.5.a'da verilen a kanalı üzerinde $a > 138$ olan pikseller seçilmiştir.
- Adım3. Seçilen piksellerin değeri «1», diğerleri «0» yapılarak aynı boyuttaki siyah-beyaz resim elde edilmiştir.
- Adım4. Açma işlemi uygulanmıştır.
- Adım5. Kapama işlemi uygulanmıştır.
- Adım6. Doldurma işlemi uygulanmıştır.
- Adım7. Elde edilen Şekil 4.5.b'deki siyah-beyaz resim üzerinde elma alanları hesaplanmıştır.

Üçüncü bölütleme algoritması ile HSV renk uzayına taşınan görüntülerin H renk kanalı üzerinde bölütleme yapılmıştır. Şekil 4.6'da yapılan işlemler gösterilmektedir.



a) HSV renk uzayındaki görüntünün H kanalına ait görüntü



b) Eşiklenmiş siyah-beyaz görüntü

Şekil 4.6. HSV renk uzayında eşikleme işlemi

HSV renk uzayında yapılan bölütleme işlemi aşağıdaki adımlardan oluşmaktadır.

Adım1. Şekil 4.4.a'da verilen RGB renk uzayındaki görüntü HSV renk uzayına taşınmıştır.

- Adım2. Elde edilen görüntünün Şekil 4.6.a'da verilen H kanalı üzerinde $H > 0,9$ olan pikseller seçilmiştir.
- Adım3. Seçilen piksellerin değeri «1», diğerleri «0» yapılarak aynı boyuttaki siyah-beyaz resim elde edilmiştir.
- Adım4. Açma işlemi uygulanmıştır.
- Adım5. Kapama işlemi uygulanmıştır.
- Adım6. Doldurma işlemi uygulanmıştır.
- Adım7. Elde edilen Şekil 4.6.b'deki siyah-beyaz görüntü üzerinde elma alanları hesaplanmıştır.

Dördüncü bölütleme algoritması CIE Luv renk uzayına taşınan elma ağacı görüntülerinin u kanalı üzerinde bölütleme işlemi yapmaktadır. Şekil 4.7'de bu işlemin nasıl yapıldığı gösterilmektedir.



Şekil 4.7.a. CIE Luv renk uzayındaki görüntünün u kanalına ait görüntü



Şekil 4.7.b. CIE Luv renk uzayında eşikleme işlemi

CIE Luv renk uzayında yapılan bölütleme işlemi aşağıdaki adımlardan oluşmaktadır.

- Adım1. Şekil 4.4.a'da verilen RGB renk uzayındaki görüntü CIE XYZ renk uzayına, oradan da CIE Luv renk uzayına taşınmıştır.
- Adım2. Elde edilen görüntünün Şekil 4.7.a'da verilen u kanalı üzerinde $u > 0,25$ olan pikseller seçilmiştir.
- Adım3. Seçilen piksellerin değeri «1», diğerleri «0» yapılarak aynı boyuttaki siyah-beyaz resim elde edilmiştir.
- Adım4. Açma işlemi uygulanmıştır.
- Adım5. Kapama işlemi uygulanmıştır.
- Adım6. Doldurma işlemi uygulanmıştır.
- Adım7. Elde edilen Şekil 4.7.b'deki siyah-beyaz görüntü üzerinde elma alanları hesaplanmıştır.

Çalışmada kullanılan 15 ağacın görüntülerinden elde edilen bu alan bilgileri tahminleme yöntemlerinin eğitim ve test aşamalarında kullanılmıştır. İlk aşamada doğrusal regresyon kullanılmasının amacı problemin basitçe modellenebilmesidir. Doğrusal

regresyon modelinin tahminleme başarısını genelleylebilmek için sekiz parçalı çapraz geçerlilik uygulanmıştır. Böylece her seferinde veri kümesinin %13'ü test ve kalanı eğitim için kullanılmıştır. Çizelge 4.2'de sekiz parçalı çapraz geçerlilik yönteminin veri kümesi üzerinde nasıl uygulandığı görülmektedir.

Çizelge 4.2. Çapraz geçerlilik yönteminin uygulanması

Test Grubu	Ağaç Numaraları														
1	<u>1</u>	<u>2</u>	3	4	5	6	7	8	9	10	11	12	13	14	15
2	1	2	<u>3</u>	<u>4</u>	5	6	7	8	9	10	11	12	13	14	15
3	1	2	3	4	<u>5</u>	<u>6</u>	7	8	9	10	11	12	13	14	15
4	1	2	3	4	5	6	<u>7</u>	<u>8</u>	9	10	11	12	13	14	15
5	1	2	3	4	5	6	7	8	<u>9</u>	<u>10</u>	11	12	13	14	15
6	1	2	3	4	5	6	7	8	9	10	<u>11</u>	<u>12</u>	13	14	15
7	1	2	3	4	5	6	7	8	9	10	11	12	<u>13</u>	<u>14</u>	15
8	<u>1</u>	2	3	4	5	6	7	8	9	10	11	12	13	14	<u>15</u>

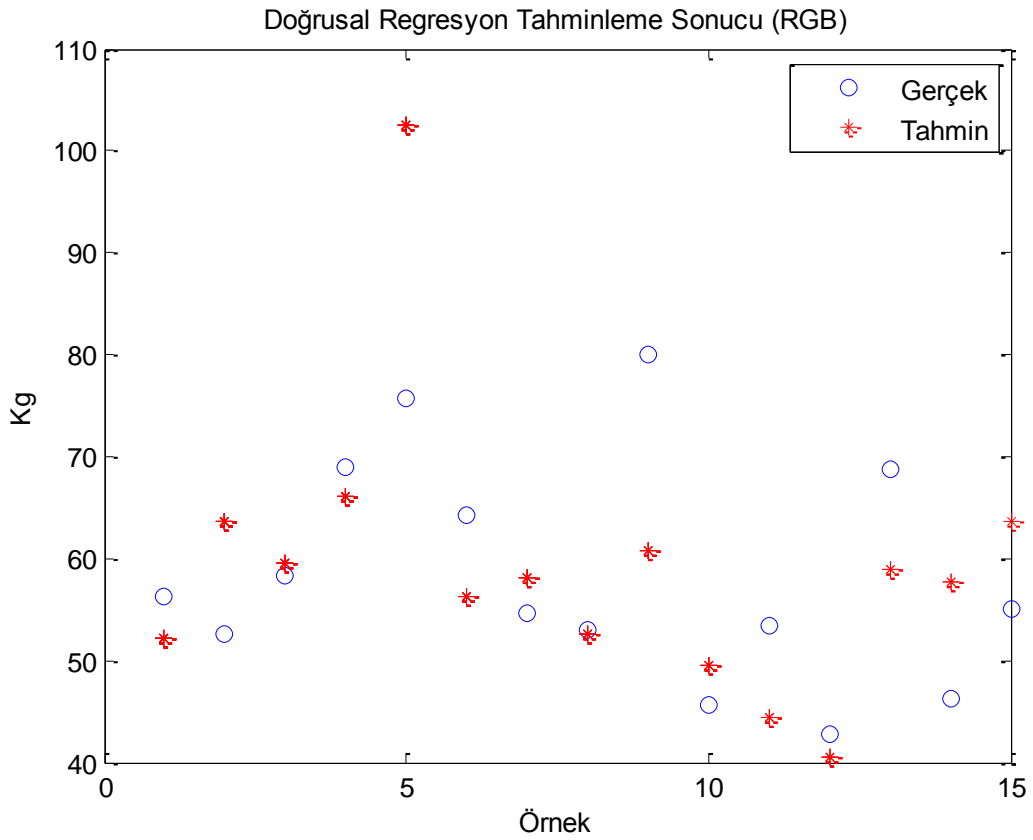
Çizelge 4.2'de verilen bilgilere bakıldığında 8 farklı test grubunda her seferinde farklı ağaç ikililerinin test (altı çizili olanlar) ve diğerlerinin eğitim için kullanıldığı görülmektedir. Bu şekilde elde edilecek başarı ölçütü daha güvenilir olmaktadır. Kullanılan doğrusal regresyon modelinin tahmin başarısı, hesaplanan OKHK değeri ile elde edilmektedir.

İkinci veri kümesindeki görüntülerde güneş ışınlarının sebep olduğu yerel parlamalar bulunmaktadır. Bu da özellik çıkartma aşamasında elma alanlarının doğru tespit edilmesini engellemektedir. Nitekim ikinci veri kümesi kullanılarak elde edilen tahminleme birinci veri kümesine oranla kötü sonuçlar vermiştir. Bu nedenle çalışmanın bu aşamasından sonra ikinci veri kümesi değerlendirme dışında bırakılmıştır.

Yukarıda analizleri yapılan RGB, CIE Lab, HSV ve CIE Luv renk uzaylarına dayalı olarak geliştirilen bölütleme algoritmalarından elde edilen özellikler ile tahminlemeler

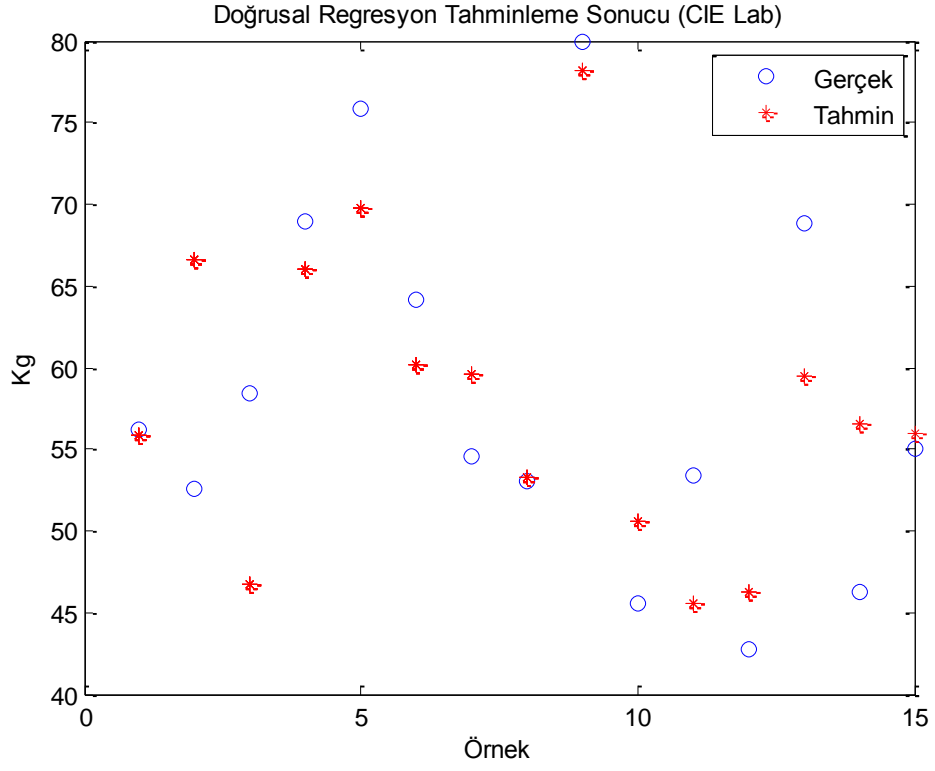
yapılmıştır. Kullanılan tahminleme yöntemleri doğrusal regresyon, ÇKA, Elman ve RBF sinir ağı modelleridir.

Hesaplama karmaşıklığının az olması nedeniyle ilk olarak doğrusal regresyon ile tahminleme yapılmıştır (Cömert ve ark., 2013). Yapılan tahminleme neticesinde hesaplanan OKHK değerleri Şekil 4.8, Şekil 4.9, Şekil 4.10 ve Şekil 4.11’de verilmiştir.




Şekil 4.8. Doğrusal regresyon ile elde edilen tahminleme sonuçları (RGB)


Şekil 4.8’de görülen grafiğin yatay eksenini örnekler, dikey eksenini reeltekeri vermektedir. Burada yuvarlaklar gerçek reeltekeri, yıldızlar ise tahmin edilen reeltekeri göstermektedir. Şekil 4.8’de en yüksek tahmin hatasının 14’üncü örnekte olduğu ve en düşük tahmin hatasının 12’nci örnekte olduğu görülmektedir.



Şekil 4.9. Doğrusal regresyon ile elde edilen tahminleme sonuçları (CIE Lab)



Şekil 4.10. Doğrusal regresyon ile elde edilen tahminleme sonuçları (HSV)




Şekil 4.11. Doğrusal regresyon ile elde edilen tahminleme sonuçları (CIE Luv)

Şekil 4.9’da en yüksek tahmin hatasının 2’nci örnekte olduğu ve en düşük tahmin hatasının 8’inci örnekte olduğu görülmektedir. Şekil 4.10’da en yüksek tahmin hatasının 9’uncu örnekte olduğu ve en düşük tahmin hatasının 15’inci örnekte olduğu görülmektedir. Şekil 4.11’de en yüksek tahmin hatasının 2’nci örnekte olduğu ve en düşük tahmin hatasının 1’inci örnekte olduğu görülmektedir.


Çalışmada tahminleyici olarak kullanılan ÇKA sinir ağı modelinde gizli katmanda 20, çıkış katmanında 1 adet nöron kullanılmıştır. Ağın eğitimi için geri yayılım algoritması kullanılmıştır. Modelin tahminleme başarısını ölçmek için ise rastgele parçalı çapraz geçerlilik yöntemi uygulanmıştır. Giriş verisinin %60’ı eğitim, %20’si geçerlilik ve %20 ise test için kullanılmıştır. RGB, CIE Lab, HSV ve CIE Luv renk uzaylarına dayalı olarak elde edilen özelliklerden yapılan tahminleme işleminde hatalar OKH cinsinden hesaplanmış ve buna göre modelin başarısı aşağıda grafikler ve şekiller halinde verilmiştir. Elde edilen hata değerleri yapay sinir ağı modelinin 50 iterasyon eğitilmesi sonucunda elde edilen OKHK değerlerinin ortalaması olarak alınmıştır.

Yapılan tahminleme neticesinde hesaplanan OKHK değerleri Şekil 4.12, Şekil 4.13, Şekil 4.14 ve Şekil 4.15'te verilmiştir.




Şekil 4.12. ÇKA sinir ağı ile elde edilen tahminleme sonuçları (RGB)


Şekil 4.12'de en yüksek tahmin hatasının 8'inci örnekte olduğu ve en düşük tahmin hatasının birçok örnekte sıfır olduğu görülmektedir. Grafiğin yatay eksenini örnekleri, dikey eksenini rekolteleri vermektedir. Burada yuvarlaklar gerçek rekolteleri, yıldızlar ise tahmin edilen rekolteleri göstermektedir.



Şekil 4.13. ÇKA sinir ağı ile elde edilen tahminleme sonuçları (CIE Lab)




Şekil 4.14. ÇKA sinir ağı ile elde edilen tahminleme sonuçları (HSV)



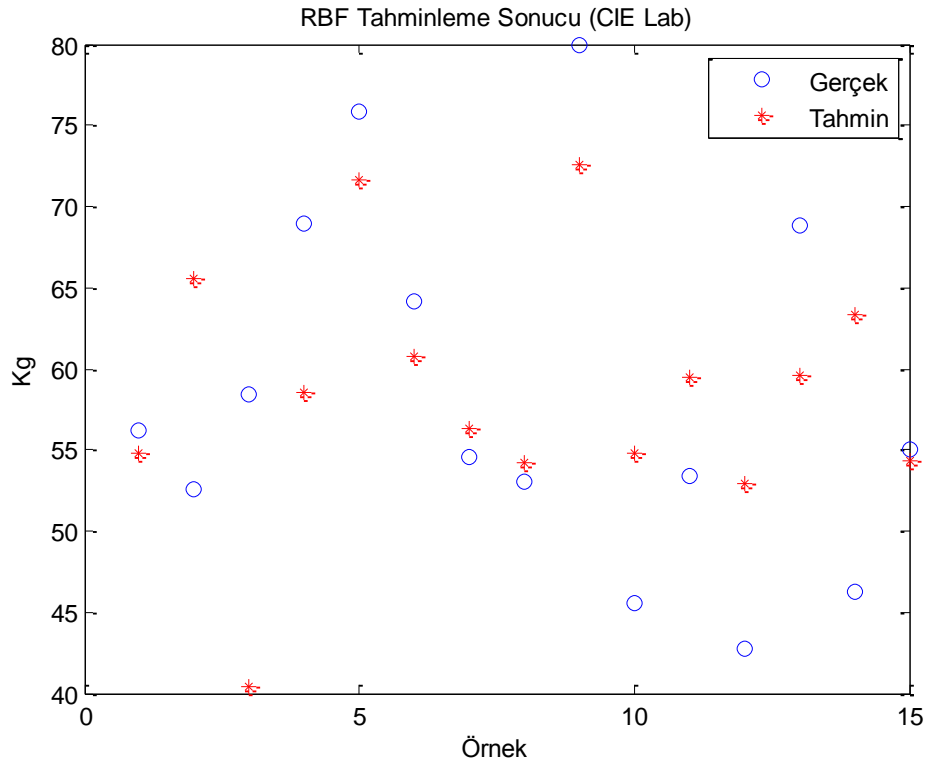
Şekil 4.15. ÇKA sinir ağı ile elde edilen tahminleme sonuçları (CIE Luv)

Şekil 4.13'te en yüksek tahmin hatasının 13'üncü örnekte olduğu ve en düşük tahmin hatasının 9'uncu örnekte olduğu görülmektedir. Şekil 4.14'te en yüksek tahmin hatasının 1'inci örnekte olduğu ve en düşük tahmin hatasının 15'inci örnekte olduğu görülmektedir. Şekil 4.15'te en yüksek tahmin hatasının 13'üncü örnekte olduğu ve en düşük tahmin hatasının birçok örnekte sifıra yaklaştığı görülmektedir.


Tahminleyici olarak kullanılan RBF sinir ağının yayılma katsayısı 10 olarak alınmış ve gizli katmanda 15 adet nöron ve çıkış katmanında 1 adet nöron kullanılmıştır. Bu özelliklere sahip olan RBF sinir ağı modeli kullanılarak yapılan tahminleme neticesinde hesaplanan OKHK değerleri Şekil 4.16, Şekil 4.17, Şekil 4.18 ve Şekil 4.19'da verilmiştir.



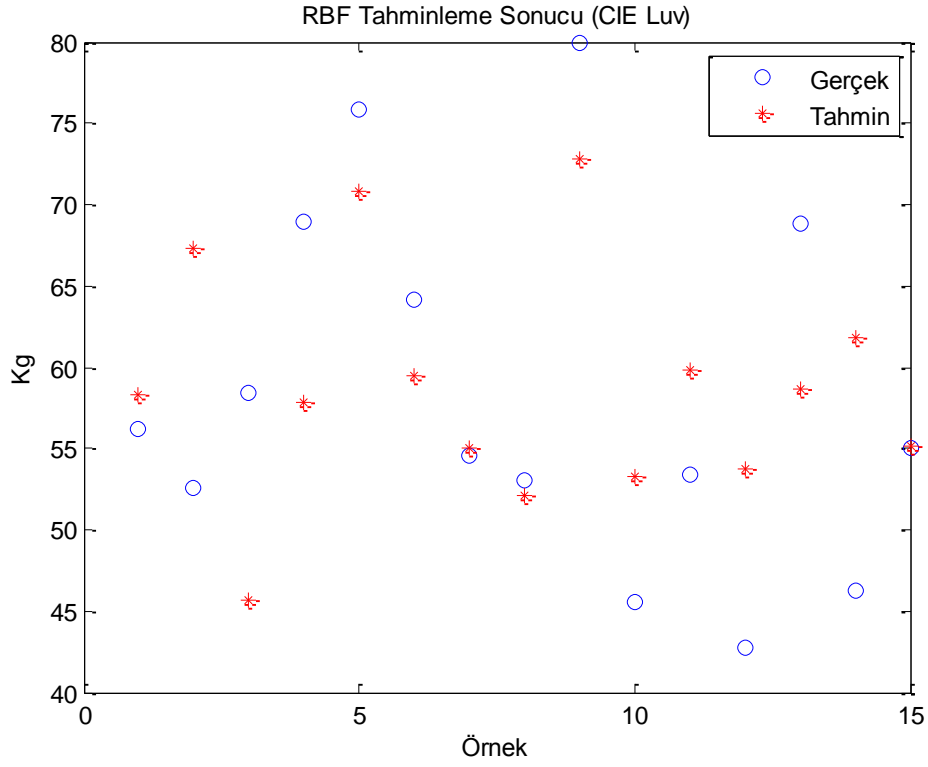
Şekil 4.16. RBF sinir ağı ile elde edilen tahminleme sonuçları (RGB)



Şekil 4.17. RBF sinir ağı ile elde edilen tahminleme sonuçları (CIE Lab)



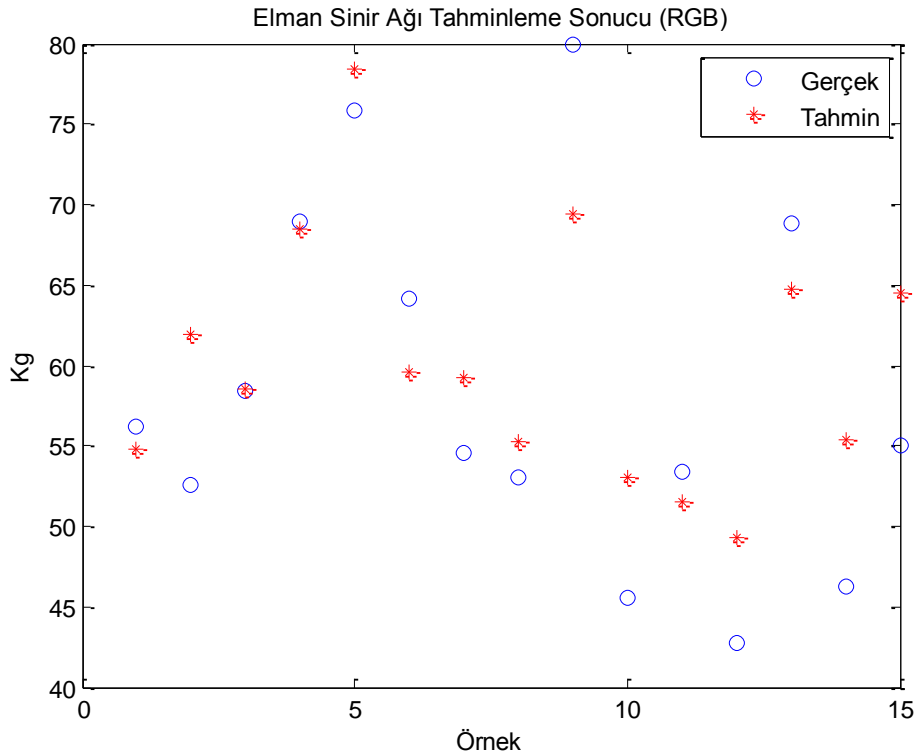
Şekil 4.18. RBF sinir ağı ile elde edilen tahminleme sonuçları (HSV)




Şekil 4.19. RBF sinir ağı ile elde edilen tahminleme sonuçları (CIE Luv)

Şekil 4.16’da en yüksek tahmin hatasının 5’inci örnekte olduğu ve en düşük tahmin hatasının 1’inci örnekte olduğu görülmektedir. Şekil 4.17’de en yüksek tahmin hatasının 3’üncü örnekte olduğu ve en düşük tahmin hatasının 15’inci örnekte olduğu görülmektedir. Şekil 4.18’de en yüksek tahmin hatasının 9’uncu örnekte olduğu ve en düşük tahmin hatasının 5’inci örnekte olduğu görülmektedir. Şekil 4.19’da en yüksek tahmin hatasının 14’üncü örnekte olduğu ve en düşük tahmin hatasının 15’inci örnekte olduğu görülmektedir.


Çalışmada tahminleyici olarak kullanılan Elman sinir ağı modelinde gizli katman ve çıkış katmanı olmak üzere iki katman bulunmaktadır. Gizli katmanda 10, çıkış katmanında 1 nöron kullanılmıştır. Ağın eğitimi için sıkça kullanılan yöntemlerden biri olan statik geri yayılım algoritması kullanılmıştır. Modelin tahminleme başarısını ölçmek için ise rastgele parçalı çapraz geçerlilik yöntemi uygulanmıştır. Giriş verisinin %60’ı eğitim, %20’si geçerlilik ve %20 ise test için kullanılmıştır. Ağın test hataları ise OKH cinsinden hesaplanmıştır. Elman sinir ağı modeli kullanılarak yapılan tahminleme neticesinde hesaplanan OKHK değerleri Şekil 4.20, Şekil 4.21, Şekil 4.22 ve Şekil 4.23’te verilmiştir.



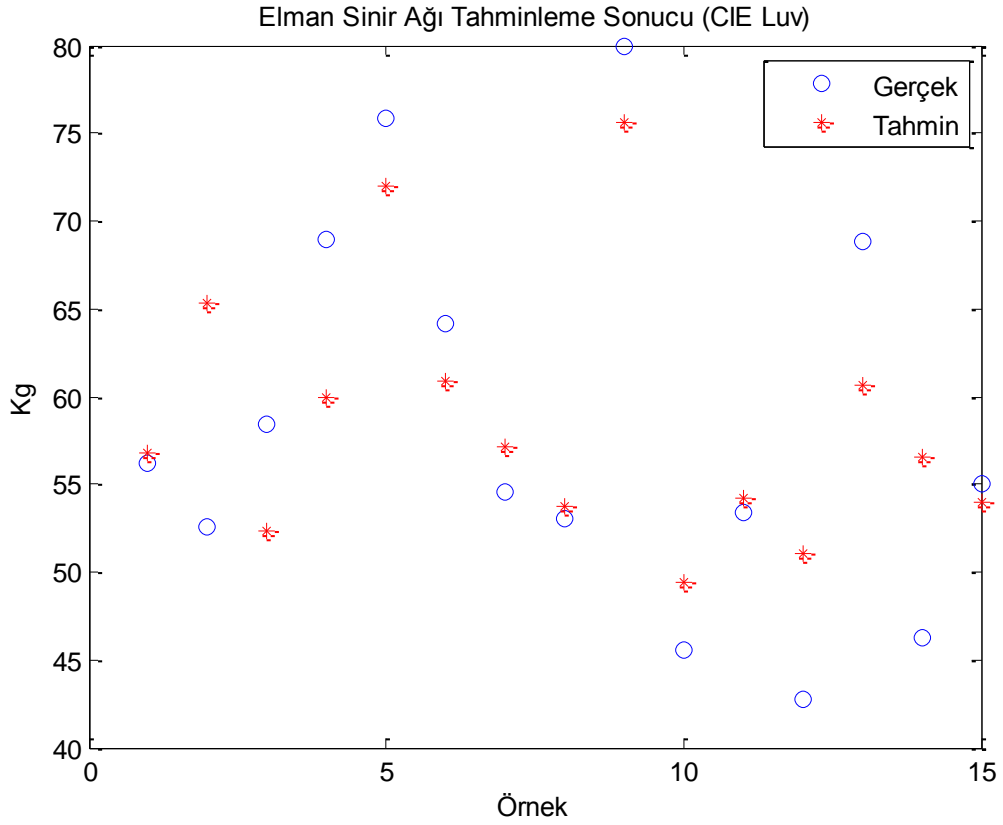
Şekil 4.20. Elman sinir ağı ile elde edilen tahminleme sonuçları (RGB)



Şekil 4.21. Elman sinir ağı ile elde edilen tahminleme sonuçları (CIE Lab)



Şekil 4.22. Elman sinir ağı ile elde edilen tahminleme sonuçları (HSV)



Şekil 4.23. Elman sinir ağı ile elde edilen tahminleme sonuçları (CIE Luv)

Şekil 4.20’de en yüksek tahmin hatasının 9’uncu örnekte olduğu ve en düşük tahmin hatasının 3’üncü örnekte olduğu görülmektedir. Şekil 4.21’de en yüksek tahmin hatasının 13’üncü örnekte olduğu ve en düşük tahmin hatasının 1’inci örnekte olduğu görülmektedir. Şekil 4.22’de en yüksek tahmin hatasının 5’inci örnekte olduğu ve en düşük tahmin hatasının 4’üncü örnekte olduğu görülmektedir. Şekil 4.23’te en yüksek tahmin hatasının 2’inci örnekte olduğu ve en düşük tahmin hatasının 1’inci örnekte olduğu görülmektedir.

Tahmin modelinin başarısını ölçen OKHK değerleri bir elma ağacının hesaplanan ile gerçek rekoltesi arasındaki hatayı göstermektedir. Çalışmada yapılan tahminleme deneylerinin sonuçlarının karşılaştırması Çizelge 4.3’te verilmektedir.

Çizelge 4.3. Tahminleme ve özellik çıkartım yöntemlerinin karşılaştırması

		Tahminleyici Modeli (OKHK)				Ortalama (OKHK)
		Doğrusal Regresyon	ÇKA	RBF	Elman	
Özellik	RGB	10,69	7,26	9,58	6,05	8,40
Çıkartım	CIE Lab	6,92	5,62	9,31	6,08	6,98
Yöntemi	HSV	7,74	6,91	7,22	6,41	7,07
(OKHK)	CIE Luv	6,50	4,36*	8,56	6,28	6,43
Ortalama (OKHK)		7,96	6,04	8,67	6,21	

Çizelge 4.3'te verilen sonuçlara göre, tahminleme yöntemi olarak ÇKA ve Elman sinir ağı modellerinin ve özellik çıkartım yöntemi olarak ise CIE Luv ve CIE Lab yöntemlerinin diğer yöntemlere göre daha başarılı olduğu görülmektedir. Bu sonuçlara göre özellikle RGB ile yapılan özellik çıkartım yönteminin bu problemin çözümünde yetersiz olduğu görülmektedir. Aynı şekilde Doğrusal Regresyon ve RBF sinir ağı modelleriyle, elde edilen özellik verisi üzerinde yeterince başarılı tahminleme yapamadığı kanısına varılmıştır.

5. SONUÇ

Red Chief elma ağaçları üzerinde yapılan bu çalışmada elma rekoltesinin tahmininde yaşanan olumsuzlukların aşılması amaçlanmıştır. Bunun için bilgisayar görmesi kullanılarak rekolte tahminin yapılması sağlanmıştır. Öncelikle hasat öncesi elma ağaçlarından sayısal görüntüler toplanmıştır. Toplanan bu görüntüler geleneksel görüntü işleme yöntemleri kullanılarak işlenmiştir. Bu yöntemler eşikleme, aşındırma, genişletme, açma ve kapama işlemleridir. İşlenen görüntülerden çıkarılan bilgiler ile tahminleme yapılmıştır. Tahminleme için en sık kullanılan yöntemler olan doğrusal regresyon, ÇKA sinir ağı, RBF sinir ağı ve Elman sinir ağı kullanılmıştır. Tahminleme yöntemlerinden elde edilen sonuçlar gerçek elma rekoltesiyle karşılaştırılarak yazılımın başarısı test edilmiştir. Test sonuçları incelendiğinde özellik çıkartım yöntemi olarak CIE Luv renk uzayında yapılan bölütlemenin ve ÇKA sinir ağı ile yapılan tahminlemenin diğer yöntemlere göre daha başarılı olduğu tespit edilmiştir.

Elde edilen en düşük OKHK değeri 4,36 olarak elde edilmiştir (Çizelge 4.3). Buna göre, gerçekte 56,37 kg rekolteye sahip bir Red Chief elma ağacından alınan görüntünün çalışmada önerilen yaklaşıma verilmesiyle elma rekoltesinin 4,36 kg hata ile tahmin edilebileceği gösterilmiştir.

Sonuçta önerilen yazılımın oldukça küçük sapma değerleriyle rekolte tahmini yapabildiğini, dolayısıyla bu konuda da bilgisayarların insanlara yardımcı olabileceği gösterilmiştir. Aynı zamanda elma bahçelerinde yapılan kabala satışlarda tahmin hatalarının düşürülmesi açısından yapılan bu çalışmanın önemli yararlar sağlayacağı ve bu konuda yapılacak olan çalışmalara yön vereceği düşünülmektedir.

KAYNAKLAR

- Abacı, B., 2012. Morfolojik Görüntü İşleme. Bahri Abacı Kişisel Web Sitesi, <http://www.cescript.com/2012/08/morfolojik-goruntu-isleme.html>-(30.05.2013).
- Açıkgöz, R., Doğan, S. ve Baneer, G., 1999. Raster Görüntülerin Yapısı, Görüntüleme Tekniklerinin Temelleri ve Bitmap Formatı, Harita ve Kadastro Mühendisliği Dergisi, TMMOB, Sayı:86, sayfa: 62-80.
- Alchanatis, V., Peleg, K. ve Ziv, M., 1993. Classification of tissue culture segments by colour machine vision, 70, sayfa: 299–311.
- Anonim, 2013a. Google Haritalar. <https://maps.google.com/>-(21.06.2013)
- Anonim, 2013b. Color Models. http://software.intel.com/sites/products/documentation/hpc/ipp/ippi/ippi_ch6/ch6_color_models.html-(07.04.2013).
- Anonim, 2013c. HSV renk uzayı. Wikipedia, http://tr.wikipedia.org/wiki/HSV_renk_uzayı-(05.04.2013).
- Anonim, 2013d. <http://www.easyrgb.com/index.php?X=MATH&H=16#text16>-(25.04.2013).
- Anonim, 2013e. Artificial neuron. Wikipedia, http://en.wikipedia.org/wiki/Artificial_neuron-(07.04.2013).
- Ballard, D.H., ve Brown, C.M., 1982. Computer Vision. Prentice Hall. New York.
- Baoping, J., 1999. Nondestructive Technology for Fruits Grading Proceedings of 99 International Conference on Agricultural Engineering. Beijing, China, December.
- Bastı, M., 2005. Renk Kavramı ve Renk Modelleri. Mehmet Bastı Web Sayfası, <http://www.fatih.edu.tr/~mbasti/Ders/RENK.ppt>-(05.04.2013).
- Bennedsen, B.S., Peterson, D.L. ve Tabb, A., 2005. Identifying defects in images of rotating apples Computers and Electronics in Agriculture, 48, sayfa: 92–102.
- Brosnan, T., ve Sun, D., 2004. Improving quality inspection of food products by computer vision Journal of Food Engineering, 61, sayfa: 3-16.

- Chapra, S. C. ve Canale, R. P., 2003. (Çevirenler: Hasan Heperkan ve Uğur Kesgin).
Yazılım Ve Programlama Uygulamalarıyla Mühendisler İçin Sayısal Yöntemler.
Literatür Yayıncılık, ISBN: 975-8431-83-8.
- Cömert, O., Orhan U. ve Hekim M., 2013. Sayısal Görüntüleme Destekli Meyve
Rekolte Tahmini, 4. Ulusal Mekatronik Mühendisliği Öğrenci Kongresi
(MeMÖK2013), Atılım Üniversitesi, Ankara, sayfa: 74-80.
- Demuth, H. ve Beale, M., 2002. Neural Network Toolbox For Use with MATLAB,
http://www.image.ece.ntua.gr/courses_static/nn/matlab/nnet.pdf-(24.05.2013).
- Elman, J. L., 1990. Finding structure in time, *Cognitive Science*, vol.14, sayfa: 179-211.
- Emiroğlu, İ., 2011. Matematik Mühendisliği Bölümü Görüntü İşleme Ders Notları.
İbrahim Emiroğlu Web sayfası, [http://www.yarbis.yildiz.edu.tr/web/
userAnnouncementsFiles/dosya9838fbd1cd0c297d3bce14b5c08ddf11.pdf](http://www.yarbis.yildiz.edu.tr/web/userAnnouncementsFiles/dosya9838fbd1cd0c297d3bce14b5c08ddf11.pdf)-
(01.04.2013).
- Erbaş S.K., 2011. Sayısal görüntü ve sayısal görüntü işlemenin tasarım eğitimine etkisi,
2nd International Conference on New Trends in Education and Their
Implications, sayfa: 231-237.
- Winter, F., 1986. Modelling the biological and economic development of an apple
orchard *Acta Horticulturae*, 160, sayfa: 353–360.
- Ford A. ve Roberts A., 1998. *Colour Space Conversions*, 9.
- Gonzalez R.C. ve Woods R.E., 2002. *Digital Image Processing Second Edition*,
Prentice Hall.
- Gonzalez R.C. ve Woods R.E., 2004. *Digital Image Processing Using Matlab*, Prentice
Hall.
- Welte, H.F., 1990. Forecasting harvest fruit size during the growing season *Acta
Horticulturae*, 276, sayfa: 275–282.
- Hardy, R.L., 1971. Multiquadric equations of topography and other irregular surfaces,
Journal of Geophysical Research, 76(8), sayfa: 1905–1915.
- Karabörk H., Gündüz M., Bildirici İ.Ö. ve Yıldız F., 2005. “Raster görüntüleri
vektörizasyonu ve jeodezi-fotogrametri mühendisliğindeki önemi”, TMMOB
Harita ve Kadastro Mühendisleri Odası 10. Türkiye Harita Bilimsel ve Teknik
Kurultayı, Ankara.

- Kazan, S., 2011. Bilgisayar Görmesi Ders Notu-7. Serap Kazan Web Sayfası, [https://dosya.sakarya.edu.tr-\(31.03.2013\)](https://dosya.sakarya.edu.tr-(31.03.2013)).
- Kızılkaya, A., 2008. Görüntü Bölütleme. Aydın Kızılkaya Web Sayfası, [http://akizilkaya.pamukkale.edu.tr/Bölüm4_goruntu_isleme.pdf-\(01.04.2013\)](http://akizilkaya.pamukkale.edu.tr/Bölüm4_goruntu_isleme.pdf-(01.04.2013)).
- Lancashire L. J., Rees R. C. ve Ball G. R., 2008. Identification of gene transcript signatures predictive for estrogen receptor and lymph node status using a stepwise forward selection artificial neural network modelling approach, *Artificial Intelligence in Medicine*, Volume 43, Issue 2, sayfa: 99–111.
- Leemans V., Magein H. ve Destain M.-F., 1998. Defects segmentation on ‘Golden Delicious’ apples by using colour machine vision, *Computers and Electronics in Agriculture* 20, sayfa: 117–130
- Linker, R., Cohen, O. ve Naor, A., 2012. Determination of the number of green apples in RGB images recorded in orchards *Computers and Electronics in Agriculture* 81, sayfa: 45–57.
- McCulloch, W. ve Pitts, W., 1943. A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, vol:5, sayfa: 115-133.
- Mehmed, N., 2009. Vektörel Resim Nedir?. Nurten Mehmed’in web sayfası, [http://nurten.wordpress.com/2009/05/26/vektorel-resim-nedir/-\(29.05.2013\)](http://nurten.wordpress.com/2009/05/26/vektorel-resim-nedir/-(29.05.2013)).
- Miller, B.K. ve Delwiche, M.J., 1991. Peach defect detection with machine vision, *Trans. ASAE*, 34 (6), sayfa: 2588–2597.
- Miranda, C., Girard, T. ve Lauri, P.E., 2007. Random sample estimates of tree mean for fruit size and colour in apple *Scientia Horticulturae* 112, sayfa: 33–41.
- Morrisey, M. M., 1988. HSI Color Processing on Personal Computers. *Applications of Digital Image Processing*, SPIE 974, sayfa: 173–176.
- Omid, M., Khojastehnazhand, M. ve Tabatabaeefar, A., 2010. Estimating volume and mass of citrus fruits by image processing technique *Journal of Food Engineering* 100, sayfa: 315–321.
- Payne A.B., Walsh K.B., Subedi P.P. ve Jarvis D., 2013. Estimation of mango crop yield using image analysis – Segmentation method, *Computers and Electronics in Agriculture* 91, sayfa: 57–64

- Press, W.H., Teukolsky, S.A., Vetterling, W.T. ve Flannery, B.P., 2007. Numerical Recipes-The Art of Scientific Computing (3rd Edition), Cambridge University Press, New York. sayfa: 139-142.
- Qazi, I.U.H., Alata, O., Burie, J.C., Abadi, M., Moussa, A. ve Fernandez-Maloigne, C., 2011. Parametric models of linear prediction error distribution for color texture and satellite image segmentation, Computer Vision and Image Understanding 115, sayfa: 1245–1262.
- Rego, FL., 2003. Automatic Land-Cover Classification Devired from High-resulation Ikonos Satellite image in the Urban Atlantic Forest in Rio de Janerio, Brasil by means of object oriented approach. PhD dissertation, Department of Remote Sensing and Landspace Information System, University of Freiburg, Germany, sayfa: 222.
- Rehkugler, G. E. ve Throop J. A., 1986. Apple Sorting With Machine Vision. Transaction of ASAE, 29, (5), sayfa: 1388–1397.
- Schanda J., 2007. Colorimetry Understanding the CIE System, sayfa :61
- Singh, K.P., Basant, A., Malik, A. ve Jain, G., 2009. Artificial neural network modeling of the river water quality-A case study, Ecological Modelling, 220(6), sayfa: 888-895.
- Soytürk M.A., 2005. Sayısal kenar çıkarma ve yapay sinir ağları yardımıyla araç tanıma, Erciyes Üniversitesi Fen Bilimleri Enstitüsü Yüksek Lisans Tezi.
- Stajanko D., Lakota M. ve Hocevar 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, sayfa: 31–42.
- Swain, K.C., Zaman, Q.U., Schumann, A.W., Percival, D.C. ve Boshtis, D.D., 2010. Computer vision system for wild blueberry fruit yield mapping biosystems engineering 106, sayfa: 389-394.
- Thomas, W. V. ve Connoly, C., 1986. Applications of Color Processing in Optical Inspection. Applications of Digital Image Processing, SPIE 654, sayfa: 116–122.
- Tonguç G., 2007. Görüntü işleme teknikleri kullanılarak meyve tasnifi, Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Yüksek Lisans Tezi.

- Toprak A. ve GÜLER İ., 2009. Bulanık uyarlamalı ortalama filtresi kullanarak mr görüntülerindeki darbe gürültüsünün bastırılması, 5. Uluslararası İleri Teknolojiler Sempozyumu (IATS'09).
- Vernon, D., 1991. Machine Vision,UK.
- Wu, X., 2011. http://www.ece.mcmaster.ca/~xwu/lecture7_segmentation.pdf (11.04.2013).
- Xiao-bao Z., Jie-wena Z., Yanxiaoa L. ve Holmes M., 2010. In-line detection of apple defects using three color cameras system, Computers and Electronics in Agriculture 70, sayfa: 129–134.
- Xing J., Saeys W. ve Baerdemaeker J. D., 2007. Combination of chemometric tools and image processing for bruise detection on apples, Computers and Electronics in Agriculture 56, sayfa: 1–13.
- Yılmaz İ., 2007. Renk sistemleri, renk uzayları ve dönüşümler, Selçuk Üniversitesi Jeodezi ve Fotogrametri Mühendisliği Öğretiminde 30. Yıl Sempozyumu, Sunulmuş Bildiri.
- Yılmaz İ., Güllü M., Baybura T. ve Erdoğan A.O., 2003. Renk uzayları ve renk dönüşüm programı(RDP), Afyon Kocatepe Üniversitesi Fen Bilimleri Dergisi 2(2), sayfa: 19-35.

ÖZGEÇMİŞ

Kişisel Bilgiler

Adı Soyadı : Onur CÖMERT
Doğum Tarihi : 20.06.1982
Doğum Yeri : Tokat
Uyruğu : T.C.
Medeni Hali : Evli
E-Posta : onur.comert@gop.edu.tr

Eğitim

2010 - ... Gaziosmanpaşa Üniversitesi Mekatronik Mühendisliği – Yüksek Lisans (TOKAT)
2005 - 2010 Fırat Üniversitesi Bilgisayar Mühendisliği – Lisans (ELAZIĞ)
2003 - 2005 Gaziosmanpaşa Üniversitesi Bilgisayar Teknolojisi ve Programlama Bölümü – Önlisans (TOKAT)
1996 - 1999 Tokat Endüstri Meslek Lisesi Bilgisayar Bölümü – Lise (TOKAT)

Yabancı Dil

İngilizce

Deneyimler

2012 - ... Gaziosmanpaşa Üniversitesi Tokat Teknik Bilimler Meslek Yüksekokulu – Öğretim Görevlisi (TOKAT)
2008 Forte Bilgi ve İletişim Teknolojileri San. ve Tic. A.Ş – Staj (ANKARA)
2007 - 2012 Gaziosmanpaşa Üniversitesi Bilgi İşlem Daire Başkanlığı – Ağ Yöneticisi (TOKAT)

Yayımlar

Orhan, U., Adem, K. ve Cömert, O., 2012. Least Squares Approach to Locally Weighted Naive Bayes Method, Journal of New Results in Science, cilt 1, sayfa: 71-78.

Cömert, O., Orhan U. ve Hekim M., 2013. Sayısal Görüntüleme Destekli Meyve Rekolte Tahmini, 4. Ulusal Mekatronik Mühendisliği Öğrenci Kongresi (MeMÖK2013), Atılım Üniversitesi, Ankara, sayfa: 74-80.