

Bilgisayarla Görü Yöntemleri İle Sivri Biberlerin Eğriliğe Göre Sınıflandırılması

Can Çoksöyler

YÜKSEK LİSANS TEZİ

Elektrik Elektronik Mühendisliği Anabilim Dalı

Ekim 2018

Classification Of Green Peppers Using Computer Vision Methods

Can oksöyler

MASTER OF SCIENCE THESIS

Electrical Electronics Engineering Department

Oct. 2018

Bilgisayarla Görü Yöntemleri İle Sivri Biberlerin Eğrilğe Göre Sınıflandırılması

Can Çoksoyler

Eskişehir Osmangazi Üniversitesi
Fen Bilimleri Enstitüsü
Lisansüstü Yönetmeliği Uyarınca
Elektrik Elektronik Mühendisliği Anabilim Dalı
Telekomünikasyon-Sinyal İşleme Bilim Dalında
YÜKSEK LİSANS TEZİ
Olarak Hazırlanmıştır

Danışman: Dr. Öğr. Üyesi Helin Dutağacı

Ekim 2018

ONAY

Elektrik Elektronik Mühendisliđi Anabilim Dalı YÜKSEK LİSANS öğrencisi Can Çoksöyler'in YÜKSEK LİSANS tezi olarak hazırladığı “**Bilgisayarla Görü Yöntemleri İle Sivri Biberlerin Eğrilğe Göre Sınıflandırılması**” başlıklı bu çalışma, jürimizce lisansüstü yönetmeliđin ilgili maddeleri uyarınca deđerlendirilerek oybirliđiyle kabul edilmiřtir.

Danışman : Dr. Öğr. Üyesi Helin Dutađacı

İkinci Danışman : -

Yüksek Lisans Tez Savunma Jürisi:

Üye : Dr. Öğr. Üyesi Helin Dutađacı

Üye : Dr. Öğr. Üyesi Hasan Serhan Yavuz

Üye : Dr. Öğr. Üyesi Muammer Akçay

Fen Bilimleri Enstitüsü Yönetim Kurulu'nun tarih ve
..... sayılı kararıyla onaylanmıştır.

Prof.Dr. Hürriyet Erřahan
Enstitü Müdürü

ETİK BEYAN

Eskişehir Osmangazi Üniversitesi Fen Bilimleri Enstitüsü tez yazım kılavuzuna göre, Dr. Öğr. Üyesi Helin Dutağacı danışmanlığında hazırlamış olduğum “**Bilgisayarla Görü Yöntemleri İle Sivri Biberlerin Eğrilğe Göre Sınıflandırılması**” başlıklı tezimin özgün bir çalışma olduğunu; tez çalışmamın tüm aşamalarında bilimsel etik ilke ve kurallara uygun davrandığımı; tezimde verdiğim bilgileri, verileri akademik ve bilimsel etik ilke ve kurallara uygun olarak elde ettiğimi; tez çalışmamda yararlandığım eserlerin tümüne atıf yaptığımı ve kaynak gösterdiğimi ve bilgi, belge ve sonuçları bilimsel etik ilke ve kurallara göre sunduğumu beyan ederim. 08/10/2018

Can Çoksöyler

ÖZET

Bu tez çalışması kapsamında sivri biberleri eğrilik miktarına göre otomatik olarak sınıflandıran bir uygulama geliştirilmiştir. Kalite sınıflandırması geleneksel olarak el ile doku, boyut ve şekil özelliklerine göre yapılan sivri biberlerin, eğrilik miktarı uluslararası piyasada bir kalite kriteridir ve eğriliğin artması bir bozukluk olarak kabul edilmektedir. Çalışma sırasında biberin sapının eğrilikle ilgili yanıtıcı bir etkisi olduğu gözlenmiştir. Biber imgelerinde sap kısmı ve gövdeyi birbirinden ayıran özgün bir yaklaşım geliştirilmiştir. Sivri biberlerin medyal eksenleri çıkartılmış ve eksen çizgisi kullanılarak biberin eğrilik miktarının hesaplanması aşamasında da özgün bir yöntem geliştirilmiştir. Sivri biberlerin eğrilik düzeylerine göre sınıflandırılması için geometrik öznitelikler çıkartılmıştır. Ayrıca tüm biber konturlarının oluşturduğu uzayı temsil eden ana bileşenler, Ana Bileşen Analizi (ABA) yöntemi ile çıkartılmıştır. Her biber için bu özvektörler üzerindeki izdüşümlerinden oluşan bir öznitelik vektörü tanımlanmıştır. Geometrik ve ABA'ya dayalı öznitelikleri birlikte ve ayrı ayrı içeren vektörler oluşturulmuştur. Sivri biber imgeleri bu vektörler kullanılarak k-En Yakın Komşu (k-EYK) yöntemi, çoklu sınıf Destek Vektör Makinası (DVM) ve AdaBoost algoritmaları ile sınıflandırılmıştır. AdaBoost ile hem ikili hem de çoklu sınıf için sınıflandırma yapılmıştır.

Anahtar Kelimeler: sivri biber, kalite sınıflandırma, sap ayırma, k-en yakın komşu, destek vektör makinası, ana bileşen analizi, AdaBoost, aktif şekil modeli, sınıflandırma.

SUMMARY

The aim of this thesis is to develop a method that classifies green peppers based on their flexure. Quality sorting of green peppers is traditionally being done by hand with respect to their texture, size, and shape properties. Flexure is also a quality criterion; high flexure in green pepper is considered as a defect in international markets. The stem of the pepper has a misleading effect on computing the flexure from pepper images. In this thesis, a novel approach is developed to segment the stem of the green pepper. Then the medial axis of the flesh region is extracted, and a novel method is used to determine the flexure. In order to classify green peppers based on flexure, geometric features are extracted from pepper images. Also, Principal Component Analysis (PCA) is used to extract principal components representing the space of pepper contours. A feature vector is constructed by projecting the contour onto the eigenvectors obtained by PCA. K-Nearest Neighbor (k-NN), Support Vector Machine (SVM) and AdaBoost methods are used to classify geometric and PCA-based feature vectors. Both binary and multi-class classifications are performed with AdaBoost.

Keywords: Green pepper, quality sorting, stem extraction, k-nearest neighbor, support vector machines, principle component analysis, AdaBoost, active shape modeling, classification.

TEŞEKKÜR

Tez çalışması sürecinin her adımında yanımda olan, bana yol gösteren, bu süreçte hem akademik hem de manevi katkıyı sağlayan, lisans eğitimimden itibaren araştırma merakıma yön veren, çok değerli danışmanım Dr. Öğr. Üyesi Helin Dutağacı'na teşekkürü bir borç bilirim.

Lisans eğitimim dahil beni her aşamada destekleyen, güçlendiren, yoldaş ve dost olan sevgili eşim Aslıhan Çoksöyler'e sonsuz teşekkürlerimi sunarım.

Hayatım boyunca maddi, manevi ve akademik her türlü desteği sağlayan, yoluma ışık olan çok sevgili aileme teşekkür ve minnetlerimi sunarım.

Yüksek lisans eğitimim boyunca ders aldığım tüm değerli hocalarıma ufkumu genişlettikleri ve verdikleri çok değerli bilgiler için sonsuz teşekkür ederim.

İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	vi
SUMMARY	vii
TEŞEKKÜR	viii
İÇİNDEKİLER	x
ŞEKİLLER DİZİNİ	xi
ÇİZELGELER DİZİNİ	xii
1. GİRİŞ VE AMAÇ	1
2. LİTERATÜR ARAŞTIRMASI	6
3. YÖNTEM	8
3.1. Önışleme	8
3.1.1. Yeniden Boyutlama	9
3.1.2. Bölütleme	10
3.1.3. Morfolojik İmge İşleme	11
3.2. Öznitelikler	13
3.2.1. Medyal eksenin çıkarılması	13
3.2.2. Geometrik Öznitelikler	14
3.2.3. Ana Bileşen Analizi'ne Dayalı Öznitelikler	18
3.3. Sınıflandırma	21
3.3.1. K- En Yakın Komşu	23
3.3.2. Destek Vektör Makinası	25
3.3.3. AdaBoost	27
4. BULGULAR VE TARTIŞMA	30
4.1. Donanım	30
4.2. Veri Özellikleri	31
4.3. Sınıflandırma Sonuçları	38
5. SONUÇ VE ÖNERİLER	41
5.1. Sonuçların Değerlendirmesi	41

İÇİNDEKİLER (devam)

5.2. Gelecek Çalışmalar	42
KAYNAKLAR DİZİNİ	44

ŞEKİLLER DİZİNİ

<u>Şekil</u>	<u>Sayfa</u>
1.1 Sivri biber kalite sınıflarına örnekler	3
3.1 İşlem Akışı	8
3.2 Önişleme Akışı	9
3.3 Üç temel aradeğerleme yöntemi ile yeniden boyutlama	10
3.4 Arka plan çıkarma ile bölütleme	11
3.5 Doğrusallıktan sapma gösterimi	16
3.6 Sivri biberin sınır çizgileri ve medyal eksenini	17
3.7 Kalınlık profili (kırmızı eğri) ve türevi (mavi eğri)	18
3.8 Sap ayırma işlemi	19
3.9 Normalize edilmiş sınır verileri	20
3.10 1. Mod $a=1$ için	22
3.11 1. Mod $a=3$ için	22
3.12 2. Mod $a=1$ için	23
3.13 2. Mod $a=3$ için	23
3.14 4. Mod $a=1$ için	24
3.15 4. Mod $a=3$ için	24
3.16 Doğrusal olarak ayıran hiper-düzlem (Borges 1998)	27
4.1 Donanım tasarımı	31
4.2 Veri kümesindeki biber imgeleri	32
4.3 Veri kümesindeki biber imgeleri (Şekil 4.2'nin devamı)	33
5.1 2B uzayda sınıflara göre öznitelik dağılımı	41
5.2 Ortak olarak hatalı sınıflandırılan iki örnek	42
5.3 Karışık halde bulunan biberlerin ayrıştırılması	42

ÇİZELGELER DİZİNİ

<u>Çizelge</u>	<u>Sayfa</u>
4.1 Elle Sınıflandırma Verileri	34
4.2 Saplı Biberlerin k-EYK İle Sınıflandırma Verileri	39
4.3 Sapsız Biberlerin k-EYK İle Sınıflandırma Verileri	39
4.4 Saplı Biberlerin DVM İle Sınıflandırma Verileri	39
4.5 Sapsız Biberlerin DVM İle Sınıflandırma Verileri	40
4.6 ABA'ya Dayalı Özniteliklerin AdaBoost İle Sınıflandırılması	40
4.7 Geometrik ve ABA'ya Dayalı Özniteliklerin AdaBoost İle Sınıflandırılması	40
4.8 Geometrik ve ABA'ya Dayalı Özniteliklerin AdaBoost İle İkili Olarak Sınıflandırılması	40

1. GİRİŞ VE AMAÇ

Doğduğumuz andan itibaren nesnelere öğrenmeye ve sınıflandırmaya başlarız. Örneğin ilgili ebeveynleri olan bir bebek 1-1.5 yaşlarında elmayla armudu birbirinden ayırt etmeye başlayabilir. Sebzeler daha geç öğrenildiğinden marulla lahanayı bir süre karıştırması beklenecektir. Domates türlerini bir bakışta ayırmak ise bir yetişkin için bile zordur. Bir öğrenme ve deneyimleme süreci kesinlikle gerekecektir.

Konu uluslararası standartlara göre iyi kalite sayılan bir sivri biberi o kadar iyi olmayandan bir bakışta ayırmaya geldiğinde ne yaptığını gerçekten biliyor olmak gerekiyor. İşte bu noktada yine insan eliyle karar alınmasını istersek uzmanlık, çok sayıda tekrar ve bilgiye ihtiyacımız vardır ki yine de azımsanmayacak bir oranda hatayı göze almak gereklidir.

Zirai alanda mahsullerin kalite derecelendirmesi hasat sonrası teknolojileri alanında yüksek bir önceliğe sahiptir. Üreticiler mahsullerinin pazarda yer almasını istiyorlarsa temel ayırtmalarını, sınıflandırmalarını ve kalite derecelendirmesini yapmak durumundalardır.

Pazar alternatiflerinin artması, üretim teknolojilerinin gelişmesi ve tüketici beklentilerinin genişlemesi ürünlerin kalite sınıflarına göre birbirinden ayrılması ihtiyacını da körüklemiştir. Tarımsal teknolojiler geliştikçe üretim arttığı gibi birim alana düşen ürün miktarı da yükselmiştir. Artan ürün miktarı beraberinde daha hızlı ve düşük fireli bir hasat gereksinimini doğurur. Bu da çok daha hızlı bir ayıklama ve sınıflandırma ihtiyacını yaratacaktır. Hasat öncesi, sırası ve sonrası aşamaları birbirinin hem tamamlayıcısı hem de engeli konumundadır. Sonuçtaki kazanç en yavaş olan işleme göre belirlenmektedir.

Diğer taraftan ürün çeşitliliği üç aşama için farklı teknolojiler geliştirme zorunluluğunu doğurmuştur. Buğday tarlasında hasat toplamak için bir biçerdöver yeterli iken onunla serada ürün toplamak imkansızdır. Pirinç taneleri arasındaki sorunluları ayıklamak ile birinci kalite bir elmayı sınıflandırmak için de farklı işlemler gerekecektir. O nedenle hasat öncesi, sırası ve sonrası işlemler her ürün grubu için ayrı ayrı tasarlanmalıdır. Üç aşamadan birinde ileriye doğru atılan bir adım diğer aşamalar için çitayı yukarı çekme potansiyeline sahiptir.

Hasat sonrası işlemlerde teknoloji kullanımı olmazsa olmazdır. Ancak zirai mahsullerin türlerine, cinslerine veya kalitelerine göre sınıflandırılmasında hakim

yöntem insan eliyle ayırıştırma şeklindedir. Konusunun uzmanı kişiler bilgi ve deneyimlerine bağlı olarak ürün sınıflandırmaları yapmaktadır. Kalite derecelendirme, sınıflama, ayıklama gibi aşamalar için görüntü işleme temelli çalışmalar geliştirilmişse de birçok ürün çeşidinde egemen olan yöntem hala insan kontrolünde ayırıştırma şeklindedir.

Ülkemizde sebze üretimini ele aldığımızda son 10 yıllık ortalamaya göre biber üretimi ve ihracatı domatesin ardından ikinci sırada gelmektedir. TÜİK, 2018 raporuna göre geçtiğimiz yıl toplam sağlam biber üretimin yaklaşık %8.2'si ihraç edilirken bu ürünlerin %66.5'i Avrupa Birliği ülkelerine gitmiştir. Hem yurtiçi hem de yurtdışı pazarda arzı yüksek olan ürünün TÜİK, 2017'e göre yine son 10 yıla bakıldığında en büyük payının sivri bibere ait olduğu görülmektedir.

Geçtiğimiz yıl üretimi 2,457,822 tonu bulan biberin 43,500 tonu hasat aşaması, 221,770 tonu ise hasat sonrası kaybı olarak TÜİK, 2018 raporunda gösterilmiştir. %10'u aşan kayıp oranının düşürülmesi üretim teknolojilerinin gelişmesi ve uygulanması ile mümkündür. Bu miktardaki üretimin insan eliyle sınıflandırılması mümkün görülmemektedir. Ortalama 150 gr olan sivri biberin 1 adedine 5 saniye ayrıldığı düşünülürse yaklaşık 23 milyon kişi/saat'lik bir çalışma gerektirmesi bu alanda otomatik bir sistemin geliştirilmesinin önemini göstermektedir.

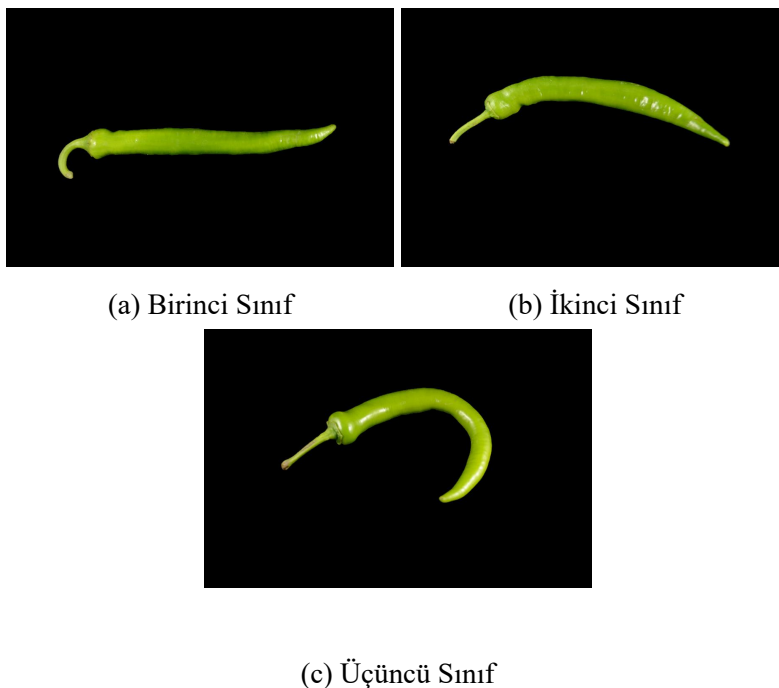
Sivri biberler temelde doku ve şekil özelliklerine bakılarak sınıflara ayrılmaktadır. Ülkemizde Resmi Gazete'de yayımlanan Dış Ticaret Müsteşarlığı, 2007 tebliği ile bir standartlaşmaya gidilmek hedeflenmiştir. Buna göre sivri biberler iki sınıfa ayrılmaktadır. Boy ve çap ölçüleri sınıfın şekilsel özelliklerini nitelerken, lekeler ve dirilik dokusal özellikleri tanımlamaktadır. Tebliğde lekeler türlerine ve buldukları yere göre sınıfın belirlenmesinde rol oynamaktadır. Belirlenen sınırın üzerinde lekesi olan biberler ikinci sınıfa alınmaktadır. Biber türlerine göre belirtilen çap ve boy değerlerini belirli bir tolerans içerisinde tutturamayan ürünler de ikinci sınıfa ayrılmaktadır.

Ancak özellikle dış ticaret söz konusu olduğunda daha ayrıntılı standartlar öne çıkmaktadır. Ulusal bağlamda daha güncel ve ayrıntılı bir standart bulunmasa da kalite sınıflandırması bugün uluslararası kriterlere göre yapılmaktadır. Şekilsel özelliklerde United States Department of Agriculture, 2016'a göre boy ve çap parametresinin haricinde, eğrilik ve boğumluluk adında iki özellik göze çarpmaktadır. Sivri biber ihracatçıları da sınıflandırmayı uluslararası standartlara göre yapmakta ve kalite sınıflarını belirlerken eğrilik miktarını bir bozukluk olarak kabul etmektedirler. Sınıflandırma ustalar tarafından elle yapılmakta ve birinci sınıf, ikinci sınıf ve fire şeklinde 3 grup oluşturulmaktadır. Fire kayıp olarak ele alınırken ikinci sınıf yurtiçi, birinci sınıf ürünler ise yurtdışı pazarına

sürülmektedir. Gönderilen ülkelerde ise United States Department of Agriculture, 2016'a göre örnekleme metoduyla kontrol edilmektedir.

Meyve ve sebzelerin kalite sınıflandırmasının otomatik olarak bilgisayarla görü kullanılarak yapılması yeni bir konu değildir (Njoroge vd., 2002). Sivri biberlerin ülkemizde ve dünyada üretiminin yaygın olmasına karşın otomatik kalite kontrolü hedefleyen çok az çalışma bulunmaktadır. Yapılan araştırmalar elma, domates, portakal, dolmalık biber, patates gibi meyve ve sebzelere yöneliktir. Hatta bu ürünler için endüstriyel sistemler de bulmak mümkündür.

Bu tez çalışması otomatik olarak kalite sınıflandırması yapılması gerekliliği kaçınılmaz olan sivri biber türünü eğriliğe göre sınıflandıran bilgisayarla görüye dayalı bir sistem geliştirmek üzerinedir. Tasarlanan kontrollü ortamda fotoğrafları çekilen sivri biberler şekil 1.1'de görüldüğü gibi eğriliğe göre üç kalite sınıfına ayrılmıştır.



Şekil 1.1: Sivri biber kalite sınıflarına örnekler

Tez çalışmasının hedefi geleneksel olarak elle yapılan sivri biberlerin kalite sınıflandırması sürecinin otomatik hale gelmesi aşamalarından biri olan biberin eğriliğine göre kalite sınıflandırmasını bilgisayarla görü ve makine öğrenimi yapıları kullanarak geliştirmektir. Amaçlanan sistemi kullanarak biber imgeleri dönmeden bağımsız olarak eğrilik düzeylerine göre bir sınıfa atanmaktadır. Programın, en düz olan biber grubunu

birinci sınıf, görece eğri olanları ikinci sınıf ve çok eğri olanları üçüncü sınıf şeklinde etiketlemesi hedeflenmiştir.

Bu tez çalışması kapsamında geliştirilen uygulama, biber imgelerinden, biberin belli nirengi noktalarını otomatik olarak bulmakta, biberi sap ve gövde kısımlarına ayırmakta ve gövde kısmından çıkardığı özelliklere göre biberi uygun bir sınıfa atamaktadır. Biber gövdesi düz olsa dahi sapının eğri olduğu durumlarda yanıltıcı sonuçların ortaya çıktığı gözlemlenmiştir. Bu yanıltıcı etkiyi engellemek için uygulama sivri biberin kritik noktalarını otomatik olarak bulacak ve sap bölümünü ayrıştıracak şekilde geliştirilmiştir. Böylelikle sınıflandırma başarımının artırılması amaçlanmıştır.

Biber imgelerinden geometrik ve Ana Bileşen Analizi'ne (ABA) bağlı öznitelikler çıkartılmıştır. Geometrik olarak sivri biberin eğrilik düzeyini belirlemede kullanılabilir öznitelikler üzerine durulmuştur. Diğer taraftan (ABA) ile özniteliklerin çıkartılması için biberin Nokta Dağılım Modeli (NDM) çıkartılmış ve modelin ana bileşenlerine göre değişimi incelenmiştir.

Sivri biberlerin boyutları, eğrilik şekil ve miktarları tamamen değişken olduğundan tek bir şekil modeli ile tanımlamak mümkün değildir. O nedenle esnek bir model tanımlamak gerekmektedir. Biberlerin tüm sınır verisi yerine seçilen karakteristik noktaları üzerinden değişimlerini incelemek mümkündür. Çalışmada bu değişimlerin hangi özelliklere göre gerçekleştiği incelenmiş ve değişim düzeyleri kullanılarak eğriliğe göre kalite sınıflandırması yapılmıştır.

Cootes vd., 1995 çalışmasında boyut ve şekil olarak belirli aralıklarda kendi içerisinde çeşitlenebilen nesnelere için NDM çıkartmıştır. Modellerin ana bileşenlerine göre deforme ederek esnek modeller oluşturmuş ve bu yaklaşımı Aktif Şekil Modeli (AŞM) olarak adlandırmıştır. AŞM ile bir bölgede test verilerinin aranabileceğini, bölümlenebileceğini göstermiştir. Yörük vd., 2005 ise, insan eli biyometrik şemalarını oluşturdukları algoritmalarında ABA ile çıkartılan öznitelikleri de kullanmıştır. Çalışmada el modellerinin ana bileşenlerine göre değişimi de incelemiştir.

Sınıflandırma aşamasında hem geometrik hem de ABA'ya bağlı öznitelikler birlikte ve ayrı ayrı kullanılmıştır. Bu aşamada üç farklı sınıflandırıcı ile çalışılmıştır. İlk olarak geometrik öznitelik vektörlerinin eğitim verilerine mesafelerine göre sınıflandıran k-En Yakın Komşu (k-EYK) sınıflandırıcısı kullanılmıştır. Bu sınıflandırıcının aykırı değerlerden diğerlerine göre fazla etkilendiği tespit edilmiştir.

Sonraki aşamada yine geometrik verileri kullanarak Destek Vektör Makinası (DVM) çoklu sınıf yapısına uyarlanarak kullanılmıştır. Cortes ve Vapnik, 1995 çalışmasında gösterdiğine göre DVM, iki sınıf arasını en geniş aralıkla ayıran bir hiper-düzlem tanımlamaktadır. Bu işlemde aykırı değerler hiper-düzlemin yapısında k-EYK kadar belirleyici olmamaktadır. DVM ile sınıflandırma başarımı, tezin 5. bölümünde gösterildiği gibi önemli ölçüde gelişmiştir.

Freund ve Schapire, 1995, çalışmasında ilk olarak tanıtılan AdaBoost algoritması da tezde, biberlerin sınıflandırılması için kullanılmıştır. Algoritma zayıf bir sınıflandırıcıyı tekrara dayalı olarak kullanmaktadır. Her tekrarda zayıf sınıflandırıcının sınıflandırma hatası hesaplanmakta ve sınıflandırıcı bir ağırlık vektöründeki değiştirilen değerlerle birlikte "kuvvetlendirilmektedir". Her döngüde "güçlendirilen" zayıf sınıflandırıcıları kullanan AdaBoost algoritması ABA ile çıkartılan öznitelik vektörlerinin de katılımıyla sınıflandırmada aşamasına kullanılmıştır.

Bu tez çalışmasının bundan sonraki bölümleri şu şekilde organize edilmiştir:

İkinci bölümde konuyla ilgili geçmiş çalışmalara yer verilmiştir.

Üçüncü bölümde veri toplama sürecinden bahsedilmiştir. Verilerin özellikleri, veri toplamada izlenen yöntem ve kontrollü ortamın tasarım özellikleri de bu bölümde açıklanmıştır.

Dördüncü bölümde yöntem açıklanmış ve sivri biber imgeleri ile yapılan kalite sınıflandırması tüm aşamalarıyla ele alınmıştır. Sırasıyla önışleme, öznitelik çıkarımı ve sınıflandırma aşamaları ayrı başlıklarda incelenmiştir. Biber imgesinde, sapı gövdeden otomatik olarak ayıran özgün yaklaşım yine bu bölümde anlatılmıştır.

Beşinci bölümde sonuçlar değerlendirilmiş ve sınıflandırıcılardan elde edilen başarımlar birbirleriyle karşılaştırılmıştır. Altıncı bölümde bu sonuçlara da bakarak gelecek çalışmalardan bahsedilmiştir.

2. LİTERATÜR ARAŞTIRMASI

Zirai ürünlerin bilgisayarla görü kullanarak kalite sınıflandırmasının yapılması yeni bir konu değildir. Ancak gelişen hasat öncesi ve sonrası teknolojiler, yükselen kalite standartları, artan arz düzeyleri hasat sonrası teknolojilerin de gelişmesini daima zorunlu kılmıştır. Diğer taraftan meyve ve sebzelerin birçok türü için endüstriyel bir uygulama bulunmamaktadır.

George, 2015 çalışmasında dolmalık biberlerin olgunluk düzeyini belirlemek için yıkıcı-olmayan sensörler ve yıkıcı yöntemlerle elde edilen referans parametrelerinin bir füzyonunu kullanılmıştır. Kimyasal içerik düzeyleri alınan örnek parçaları üzerinden ölçülmüş ve buradan alınan referans değerlerini kullanarak, kısa-dalga yakın infrared (SWIR) ve görünür-yakın infrared (VIS-NIR) spektrofotometreleri, renk sensörü, ultrasonik sinyal jeneratörü ve bir baskı ölçüm probundan toplanan özneliklerle bir model oluşturulmuştur. Bu modelle dolmalık biberlerin olgunluk düzeyleri tahmin edilmek istenmiştir. Model oluşumunda kullanılan çeşitli sınıflandırıcılar da bu çalışmada karşılaştırılmıştır.

Saito vd., 2003 patlıcanlar için görüntü işleme ve yapay sinir ağları temelli bir otomatik derecelendirme sistemi önermektedir. Kontrollü bir ortamda çekilen patlıcan imgelerinin en uzak iki noktasının gövdenin başı ve sonu olduğu varsayımından hareketle şekilsel özellikleri hesaplanmaktadır. Sebzenin saplarının elle ayrılmış olduğu ve tüm işlemlerin bu koşullarda yapıldığı görülmektedir. Çalışmada iki uç noktaya göre döndürülen patlıcan imgesi üzerinden gövde genişliği, uzunluk değeri hesaplanmakta, eğrilik düzeyi ise girinti miktarına göre ölçülmektedir. İmgenin RGB renk uzayı kullanılarak bölütlenmesi ile lekeler ayrıştırılmış ve bu lekeler yapay sinir ağları kullanılarak sınıflandırılmıştır. Çalışmada bir kalite derecelendirmesine göre performans analizi yapılmamıştır.

Cho ve Lee, 2007 sivri biberlerin kalite derecelendirmesini hedefleyen çok az sayıda çalışmadan biridir. Çalışma ürün besleme, görüntü analizi ve ayırma sistemi şeklinde üç bölümden oluşan komple bir sınıflandırıcı üretim hattı önermektedir. Görüntü işleme aşamasında biberler boy ve eğiklik özelliklerine göre küçük, orta, büyük ve yüksek eğimli şeklinde 4 gruba ayrılmaktadır. Hat çıkışındaki mekanik ayrıştırıcının da gelen biberleri bu gruplara göre tahliye etmesi beklenmektedir. Uzunluk bilgisinin hassas bir ölçümü için biberin taç bölgesinin otomatik olarak ayrıştırıldığından bahsedilmektedir. Biberin kalınlığının ani değişiminden sap bölümünün tespit edildiği çalışmada biberlerin kameranın

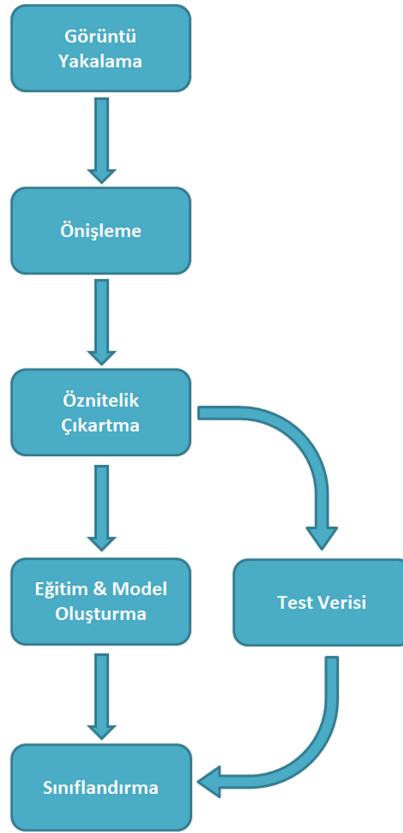
görüş alanına belirli bir doğrultuda gelmesi gerekmektedir. Şekil özelliklerinin bulunması için nirengi noktaları kullanılmıştır ancak çalışmada bu noktaların nasıl bulunduğundan bahsedilmemektedir ve eğrilik bilgisi ancak "C" şekilli biberler için ölçülebilir durumdayken "S" şeklindeki biberler için eğrilik hesaplanmamaktadır.

Rong vd., 2017'deki çalışmada üzerlerinde çeşitli leke türleri barındıran 1191 adet portakal görseline bölütleme uygulanmıştır. Haşerat hasarı, güneş yanığı, don lekesi gibi farklı özellik gösteren lekeleri yerel bölütleme, kayan pencere karşılaştırması gibi bölütleme aşamalarını ve morfolojik filtreleri ardışık olarak uygulayarak portakal imgesinden ayrılması hedeflenmiştir. Önerilen yöntemle %97'lik bir başarımla elde edildiği belirtilmektedir. Çalışmada leke türleri için bir sınıflandırma uygulanmamıştır. Ayrıca portakalın üzerinde bulunan sap dibinin lekenin bölütlenmesinde yanıltıcı bir etkisi olduğundan bahsedilmektedir. Lekelerin sap dibi ile çakıştığı bölgelerde bölütlenme başarımlarının daha düşük olduğu tespit edilmiştir.

Bilgisayarla görü kalite sınıflandırmasının yanı sıra biber türlerinin sınıflandırılmasında da kullanılmıştır. Sekiz farklı biber türüne ait tohumların sınıflandırması için Kurtulmuş vd., 2016 çalışmasında çok katmanlı algılayıcı (MLP) kullanılmıştır. Ofis tipi bir tarayıcıdan alınan tohum imgelerine ait renk, şekil ve doku ile ilgili öznitelikler çıkartılmıştır. Görüntü alınırken tohumların birbirlerine değmemelerine dikkat edilmiştir. İmge üzerinde bölütleme çalışması için öncelikle elle tohum merkezleri işaretlenerek ilgi bölgesi (ROI) belirlenmiştir. Bölütlenmiş tohum imgelerinin ikili maskesi gerçek referans (Ground Truth) olarak eğitim aşamasında kullanılmıştır. Ardışık öznitelik seçici (Sequential Feature Selection) algoritması ile 257 olan öznitelik sayısı 10'a düşürülmüştür. Farklı sayılarda gizli katmanla yapılan testlerin sonucunda 30 katmanlı yapıda %84.94'lük bir sınıflandırma başarımla elde edilmiştir.

3. YÖNTEM


Bu çalışmada önerilen yöntemin genel akışı şekil 3.1’de gösterilmiştir. Görüntü yakalama adımı bölüm 3.1’de incelenmiştir. İmgesi elde edilen sivri biberlerin özelliklerine göre kalite sınıflandırması süreci önışleme, öznelik çıkartma ve sınıflandırma adımlarından oluşmaktadır. Model eğitimi ve test süreçleri bölüm 3.3’te açıklanmıştır.



Şekil 3.1: İşlem Akışı

3.1 Önışleme

Önışleme aşamasını ham verinin en iyi verimle işlenebilecek hale getirilmesi olarak genellemek mümkündür. Çalışmada önışleme üç aşamadan oluşmaktadır. (Şekil 3.2). Önce ham verilerin boyutları düşürülmüştür. Daha sonra bölütleme aşamasına geçilmiştir. Son olarak da bölütlemenin ardından lokal olarak temizlenemeyen kalıntılar temizlenmiş ve aynı aşamada ana unsur üzerinde bozulan ya da kaybolan veriler geriye getirilmiştir.



Şekil 3.2: Önişleme Akışı

3.1.1 Yeniden Boyutlama

Uygulamanın gereksinimlerine göre eldeki imgenin büyütülmesi, küçültülmesi ya da sündürülmesi gerektiğinde yeniden boyutlama işlemi yapılır. Özellikle imge büyütülmek istendiğinde elde olmayan verileri en iyi şekilde tahmin etmek gerekmektedir. Bu konuda çok çeşitli yaklaşımlar bulunsa da en yakın komşu aradeğerleme, çift doğrusal aradeğerleme ve çift kübik aradeğerleme en bilinenleridir. Temelde hepsi bilinmeyen bir piksel değerinin türetilmesine dayanmaktadır. Ancak kullanım yerine ve yaklaşımın daha fazla bilineni ağırlıklı olarak kullanmasına göre gerçeğe yakın bir sonuç yakalama oranı artmaktadır.

En yakın komşu aradeğerleme türetilmek istenen verinin en yakınındaki değeri bilinen pikselin değerini alması şeklinde özetlenebilir. Bu yaklaşım kullanıldığında özellikle kenar, köşe gibi ani renk değişimlerinin olduğu bölgelerde merdiven şeklinde bozulmalar göze çarpmaktadır.

Çift doğrusal aradeğerlemede ise bilinmeyen piksel değeri en yakınındaki piksellerin mesafelerine göre ağırlıklandırılmış ortalaması ile tahmin edilir. Renk değişimlerinin doğrusal olduğu varsayımı üzerinden işlem yapılmaktadır. O nedenle ani değişimin olduğu kenar, köşe gibi bölgelerde bulanıklaşma fazla olmaktadır. Diğer taraftan bu yöntemle en yakın komşu aradeğerlemede oluşan merdiven tipi bozukluk büyük oranda giderilmektedir.

Eğer işlem süresiyle ilgili bir kısıtlama yoksa çift kübik aradeğerleme ile yeniden boyutlandırma yapmak pek çok uygulama için en başarılı sonuçları vermektedir. Yöntemde

bilinmeyen piksel değeri en yakındaki piksel değerlerinin yanı sıra birinci derece komşuların gradyanlarının da hesaba katılmasıyla tahmin edilir. Ani geçişlerde gerçeğe daha yakın bir görüntü elde edilir.




Şekil 3.3: Üç temel aradeğerleme yöntemi ile yeniden boyutlama

3.1.2 Bölütleme

Rafael C. Gonzalez ve Richard E. Woods, 2007 kitabında bölütleme imgeyi kendisini oluşturan bölge ya da objelere ayırmak olarak tanımlanmaktadır. Bölütleme, çoğu bilgisayarla görü uygulamasının ilk adımlardan biridir ve incelenmek istenen nesneye ya da nesnelere ulaşabilmek için kullanılmaktadır. Oldukça geniş bir konudur ve çok sayıda yaklaşım ve araştırma bulunmaktadır. Bu çalışmada, biber imgeleri, arka plan çıkarma ve eşikleme yöntemleri kullanılarak bölütlenmiştir.

Piccardi, 2004'te arka plan çıkarma işleminin çoğunlukla hareketli objelerin sabit bir kameradan çekilen video görüntüsünden bölütlenmesinde kullanıldığından bahsetmektedir. Çalışmada arka plan çıkarma işlemi referans karesinin hareketli kareden çıkartılması ile özetlenmiştir. Diğer taraftan her video karesinde ışık, yansımalar, hareket eden nesnelere bağlı olarak kamera ayarları da değişebildiğinden arka plan modellemesi için farklı zamanlarda çekilmiş imgeler kullanılmaktadır. Uygulama şekline göre çeşitlenen yaklaşımlar çoğunlukla arka planın farklı yaklaşımlarla modellenmesine dayanmaktadır.

Bu çalışmada kontrollü bir arka plan kullanıldığından değişiminin sınırlı bir aralıkta kalacağı varsayılmıştır. Arka plan çıkarma işleminin ardından RGB değerleri deneysel olarak belirlenen bir aralıkta olmayan pikseller bibere ait, bu aralıkta kalan pikseller ise arka plana ait olarak sınıflandırılmıştır. 3.1 denkleminde f pikselin değerini, t ise eşik değerini göstermektedir. θ değeri 3.1 denkleminde görüldüğü gibi $f \geq t$ koşulu sağlandığında "1" değerini almakta aksi durumda "0" kalmaktadır. 3.1 denklemi ile yapılan eşikleme sonucunda ikili bir maske elde edilmiştir.



Şekil 3.4: Arka plan çıkarma ile bölütleme

$$\theta(f, t) = \begin{cases} 1 & f \geq t \\ 0 & f < t \end{cases} \quad (3.1)$$

3.1.3 Morfolojik İmge İşleme

Morfolojik işlemler, Szeliski, 2011 bölümünde ikili imgelerdeki objelerin şekillerini değiştirmeye yönelik yapılan işlemler olarak özetlenmektedir. Kitapta işlemin bir yapısal öge ile objenin evrişimi sonucu ortaya çıktığı belirtilmektedir. Bu noktada imgeye uygulanan operasyon, operasyon sayısı, operasyon tekrarı, yapısal ögenin şekli ve boyutları çıktı imgeyi belirlemektedir ve bu değişkenler uygulamaya özel olarak belirlenmektedir.

Morfolojik operasyonlar özellikle imgeye uygulanan eşikleme sonucunda ortaya çıkan kalıntıların temizlenmesi, bölütlenmek istenen objenin sınır verisindeki parazitlerin giderilmesinde ya da objede oluşan deliklerin kapanmasında kullanılan araçlardır. Megha Goyal, 2011 çalışmasına göre de genişleme süzgeci, kemirme işleci, açma ve kapatma operasyonları morfolojik operasyonlar arasında en bilinenleri ve en yaygın kullanılanlarıdır.

Genleşme süzgeci 3.2 denklemindeki gibi tanımlanabilmektedir. 3.2 denkleminde A ikili imgeyi, S ise yapısal ögeyi temsil etmektedir. S merkezi s olacak şekilde A imgesi içerisinde dolaştırıldığında 3.2 denklemindeki ilişkiyi sağlayan pikseller A_s imgesini oluşturulur. Özetle A imgesi ile S yapısal ögesinin bileşkesi A_s yeni imgesine atanır. Bileşim alındığından ortaya çıkan imgede ilk imgeye göre objelerin kapladığı alanlar genişlemiş ve delikler kapanmış olarak görülecektir.

$$A \oplus S = \bigcup_{s \in S} A_s \quad (3.2)$$

Kemirme işlecinde 3.3 denkleminde A imgesi ile S yapısal ögesinin tam olarak örtüştüğü bölgeler dışında kalan pikseller A_s 'de erozyona uğramaktadır. Kemirme işleci bölütlemenin ardından istenmeyen bir şekilde birleşen objeleri birbirinden ayırmakta, inceltmede ve objenin iskeletleştirilmesinde kullanılabilir.

$$A \ominus S = \bigcap_{s \in S} A_s \quad (3.3)$$

Açma işleci 3.4 denkleminde ” \circ ” ile gösterilmiştir. İmgenin bir yapısal öge ile sırasıyla aynı S yapısal ögesi ile işlemlerine tabi tutulması şeklinde özetlenebilmektedir. Megha Goyal, 2011'e göre sınır çizgilerini yumuşatmakta, ince bağları koparmakta ve ince parazitleri ortadan kaldırmakta öncelikli olarak kullanılmaktadır. Açma işlemi özellikle doğru yapılaşma elemanı seçimiyle objeleri daha küçük parazitlerden ayrıştırmak, bu esnada da objelerin ölçülerini mümkün olduğunca korumakta kullanılabilir.

$$A \circ S = (A \ominus S) \oplus S \quad (3.4)$$

Kapatma işleci 3.5 denkleminde \bullet ile gösterilmiştir. Tek bir yapısal ögenin ilgili imgeyle önce genleşme sonra da kemirme ilişkisine girmesi olarak tanımlanmaktadır. Temelmorfolojik operasyonlardan biridir ve dar kırılmaları, sınır çizgisindeki kesintileri gidermekte, delikleri ortadan kaldırmakta kullanılmaktadır.

$$A \bullet S = (A \oplus S) \ominus S \quad (3.5)$$

Çalışmada arka plan çıkarma ve eşikleme uygulamasının ardından oluşan parazitleri gidermek için şekil 3.2’de görüldüğü üzere morfolojik operasyonları uygulanmıştır. 3 piksel çapında dairesel bir yapısal öge kullanarak ikili görüntüye önce açma sonra da kapatma operatörü uygulanmıştır. Açma operasyonu ile eşikleme sonrası kalan parazitler giderilmiştir. Hemen ardından yapılan kapatma operasyonu ile de biber objesinde olası kopmalar ya da oluşan delikler giderilmiştir.

Morfolojik operatörler parazit giderme ve veri kurtarma dışında, ikili objelerin deforme edilmesinde, objelerden öznitelik elde edilmesinde ya da objelerin iskeletleştirilmesi amacıyla kullanılmaktadır. İskeletleştirme ile medyal eksenin çıkartılması, medyal eksenin kullanımı bölüm 3.2’de ayrıntılı olarak verilmiştir.

3.2 Öznitelikler

Kumar ve Bhatia, 2014’e göre öznitelik çıkartma özel bir çeşit boyut düşürme olarak düşünülebilir. Burada önemli olan büyük bir verinin içerisinden veriyi en etkin olarak tanımlayabilecek özellikleri bir araya getirmektir. Böylece orijinal veri düşük boyutlu bir uzayda temsil edilebilir. Sınıflandırma, örüntü tanıma, dağılım kestirme gibi uygulamalarda en yaygın ve geçerli yol Guyon ve Elisseeff, 2006’ya göre öznitelik vektörü oluşturmaktır. Modern uygulamalarda veri saklama ve hızlı işleme teknolojileri geliştiğinden öznitelik vektörleri de artık daha büyük boyutlu olabilmektedir.

Bu çalışmada önışlemeden geçirilen sivri biber imgelerinden iki türde öznitelik çıkarılmıştır. İlk olarak bir dizi farklı geometrik öznitelik çıkarılmış ve bunlar daha sonra sınıflandırma kapasitelerine, biberlerdeki eğrilik düzeylerini doğru şekilde temsil etme kapasitelerine göre elenmiş, eğitim ve test aşamalarında kullanılacak nihai öznitelik vektörü oluşturulmuştur. Bu öznitelikler arasında yaygın olarak kullanılan ölçümlerin yanı sıra doğrusallıktan sapma adı verdiğimiz özgün bir öznitelik de sivri biberlerin eğriliğini temsil etmekte kullanılmıştır. Bu çalışmada kullandığımız ikinci tür öznitelikler Ana Bileşenler Analizine dayanmaktadır ve ayrıntıları 3.2.3 bölümünde verilmiştir.

3.2.1 Medyal eksenin çıkarılması

İkili sivri biber imgelerinin medyal eksenlerini bulmak için iskeletleştirme işlemi yapılmıştır. İkili bir objenin tek genel şekil özelliklerinin bir tek çizgi düzeyine indirgenmesine iskeletleştirme denilmektedir (Loncaric, 1998). Bölge tabanlı bir öznitelik çıkarma süreci olarak ele alınmaktadır. Saeed vd., 2010 çalışmasına göre iskeletleştirme teknikleri ve kullanım yerlerine göre binin üzerinde çalışma yayınlanmıştır. Örüntü tanıma, optik karakter tanıma, sınıflandırma, veri sıkıştırma ve saklama gibi alanlarda

kullanılabilmektedir. Blum, 1967 çalışmasında medyal eksen kavramı ve bulunma yöntemi tanıtılmış ve şeklin simetrikliğinin bir ölçümü olarak ifade edilmiştir.

Saeed vd., 2010 çalışmasında iskeletleştirme yöntemlerini döngülü ve döngüsüz olarak ikiye ayrılmakta ve onlar da alt dallarına bölünmektedir. Kemirme işleciyle ikili imgeye ait piksellerin tek piksel kalınlığında bir çizgi kalana kadar döngüsel olarak silinmesi döngüsel yöntemlere bir örnektir. Döngüsel olmayan yöntemlerde ise sınır noktaları kullanılarak merkez çizgisi oluşturulmakta ve bu çizgi objenin medyal eksenini olarak tanımlanmaktadır.

Yöntem tek piksel kalınlığında bir veya birbirine bağlı birden fazla çizgi tarafından objenin tüm sınır özellikleriyle ne ölçüde ifade edilebileceğiyle ilgilidir. Tez çalışmasında biber imgesinin bölümlerinin tanımlanabilmesi, eğrilik miktarının hesaplanması ve oryantasyonunun belirlenmesi aşamalarında medyal eksenden faydalanılmıştır. Medyal eksenin bulunması için denklem 3.3'te gösterilen kemirme algoritması tabanlı bir yaklaşım kullanılmıştır. Sivri biber imgesi kemirme uygulanarak tek bir çizgiye indirgenmiştir. Şekil 3.6'da bir sivri biberin medyal eksenini ve sınır verisini birlikte gösterilmiştir.

3.2.2 Geometrik Öznitelikler

Önişlemeden sonra ikili hale getirilen sivri biber imgelerinin geometrik öznitelikleri çıkartılmıştır. Sivri biberler herhangi bir doğrultuda gelebileceğinden çıkartılan özniteliklerin dönmeden bağımsız olması gerekmektedir. Dongping Tian, 2013 çalışmasında şekilleri betimleyen öznitelikler kontur ve bölge tabanlı olarak ikiye ayrılmaktadır. Çalışmaya göre sadece sınır verisini kullananlar kontur tabanlı, tüm bölge verisini kullanarak çıkarılan öznitelikler de bölge tabanlı olarak gruplandırılabilir.

Bu çalışmada sivri biberleri eğrilige göre sınıflandırabilmek için bir dizi şekil betimleyicisi kullanılmıştır. Bunlar basıklık, katılık ve kaplama ek olarak özgün bir öznitelik olan doğrusallıktan sapma miktarıdır.

Birinci sınıf bir sivri bibere ait piksellerin düz bir medyal eksen etrafında simetrik olarak uzunlamasına dağılacığı düşünülmektedir. Sivri biberin sınır çizgisine dışarıdan tam oturacak bir elipsin büyük eksenine a , küçük eksenine b dersek, basıklık değeri 3.6 denklemi ile bulunabilir. Denklemin sonucundaki değerin büyüklüğü biberin düzlüğünü ifade etmektedir.

$$\text{Basıklık} = \sqrt{1 - \frac{b^2}{a^2}} \quad (3.6)$$

Çalışmada kullanılan bir diğer öznitelik katılık değeridir. Bölge tabanlı bir öznitelik olarak sınıflandırılabilir. Mingqiang vd., 2008 çalışmasında açıklandığı üzere katılık, incelenen bölgenin konvekslik değerinin hesaplanmasında kullanılmaktadır. P_b bölgenin alanını gösterirken, H ise dışbükey zarfın alanını göstermektedir. Bu iki değer birbirine oranı ise 3.7 denkleminde görüldüğü gibi hesaplanmaktadır.


$$\text{Katılık} = \frac{P_b}{H} \quad (3.7)$$

Kaplam özelliği ise katılık özelliğine benzer şekilde bölge tabanlı bir yaklaşımdır. 3.8 denkleminde P_b bölgenin alanını B ise objeye dıştan oturan en küçük dikdörtgenin alanını ifade etmektedir. İkisinin arasındaki oran kaplam değerini vermektedir. Kaplam özelliğinin basıklık özelliği ile benzer bir eğilim göstermesi beklenmektedir.

$$\text{Kaplama} = \frac{P_b}{B} \quad (3.8)$$

Çalışmada sivri biberlerin eğrilik miktarlarına göre sınıflandırmak için basıklık, katılık ve kaplama özniteliklerinin yanı sıra doğrusallıktan sapma adını verdiğimiz özgün bir öznitelik önerilmiştir. Yöntem şekil 3.6'de görülen medyal eksene oturtulan iki farklı mertebeden polinomun kiriş uzunluklarının birbirlerine oranı şeklinde özetlenebilir. Burada kiriş uzunluğu, veriye oturtulan eğrinin, medyal eksenin başlangıç ve bitiş noktasına karşılık gelen noktalar arasındaki uzunluğunu belirtmektedir. Bunun için ilk olarak birinci dereceden bir doğru küçük kareler yöntemi ile medyal eksene oturtulmuştur ve kiriş uzunluğu denklem 3.9'da gösterildiği gibi piksel konumlarındaki değişimin Öklid normlarının toplamı şeklinde hesaplanmıştır. Piksel konumlarındaki değişim ise denklem 3.10'daki gibi hesaplanmıştır. İkinci olarak medyal eksene dördüncü dereceden bir doğru oturtulmuş ve 3.9 denkleminde i_b eğrinin başlangıç, i_e ise bitiş noktalarının konumlarını ifade etmektedir. İki nokta arasında tanımlı 3.9 denkleminde ile kiriş uzunluğu hesaplanmıştır. Birinci dereceden polinomun kiriş uzunluğunu L_1 , dördüncü dereceden polinomun kiriş uzunluğunu ise L_2 olarak gösterirsek, bu iki değer birbirine oranı da bize doğrusallıktan sapmayı vermektedir.

Şekil 3.5'te birinci sınıf ve üçüncü sınıf iki adet sivri biberin doğrusallıktan sapmaları gösterilmiştir. Birinci dereceden doğrular mavi renkle, dördüncü dereceden eğriler ise kırmızı renkli göstermektedir. Şekil 3.5a için doğrusallıktan sapma değeri 1'e yakinken, 3.5b'de bu



(a) 1. sınıf sivri biber

(b) 3. sınıf sivri biber

Şekil 3.5: Doğrusallıktan sapma gösterimi

değer görece daha düşüktür. 3.11 eşitliğindeki değer yüksekliği biberin düzlüğü hakkında bilgi vermektedir.

$$L = \sum_{i_b}^{i_e} \|\Delta x_i\| \quad (3.9)$$

$$\Delta x_i = x_{i+1} - x_i \quad (3.10)$$


$$\text{Doğrusallıktan Sapma} = \frac{L_1}{L_2} \quad (3.11)$$

Kalite sınıflandırması aşamasında sivri biberde eğrilik problemi sadece biberin gövdesi için geçerlidir. Biberin sap kısmının eğri ya da düz olması bir kalite kriteri olarak tanımlanmamıştır. United States Department of Agriculture, 2016 ve Dış Ticaret Müsteşarlığı, 2007 tebliğlerine göre sapın bir bütün olarak yerinde bulunması sivri biber için yeterli bir kalite kriteridir. Diğer taraftan sivri biberin saplarındaki eğrilik, sınıflandırma aşamasında yanıltıcı bir etki yapmaktadır. Tez çalışmasında, sınıflandırma başarısını arttırmak için biberlerin sap kısımları otomatik olarak belirlenmiş ve ayrıştırılmıştır. Bu etkinin yarattığı sonuçlar bölüm 5'te gösterilmektedir.

Sivri biber imgeleri incelendiğinde sap kısımlarının renk ve doku özelliklerinin değişkenlik gösterdiği görülmektedir. Bu özellikler kullanılarak eşikleme yöntemi ile ayrıştırma işleminin yapılması mümkün olmamaktadır. Bunun yerine biber sapının başlangıç noktası biberin kalınlık profilindeki ani değişimden tespit edilmiştir. Şekil 3.7'de kırmızı çizgi sivri biberin tek tarafına ait sınır noktalarının medyal eksene olan dik

uzaklıklarının haritasını, mavi çizgi uzaklıkların deęişim miktarını ve yeşil nokta da deęişimin en yüksek olduęu sınır deęerini göstermektedir.

Biber imgesinde sap bölgesi, taç yaprak, omuz noktaları, uç ve son noktaları gibi kritik verileri elde etmek için medyal eksen ve sınır verileri kullanılmıştır. 3.6 şeklinde biberin sınır noktaları kırmızı, medyal eksenini ise siyah renkle gösterilmektedir. Kalınlık profilinin çıkartılabilmesi için öncelikle biberin 3.6 şeklinde siyah ile gösterilen medyal eksen boyunca iki bölüme ayrılması gerekmiştir. Bunu için medyal eksenin iki uç noktası biberin baş ve son noktalarını tanımlamak için kullanılmıştır.



Şekil 3.6: Sivri biberin sınır çizgileri ve medyal eksenini


Medyal ekseninin uç noktalarının Öklid mesafesi (3.12) olarak en yakın oldukları sınır noktalarının her zaman baş ve son noktalarını temsil etmedikleri gözlenmiştir. O nedenle medyal eksenin uç noktalarının son ikişer noktasından geçen doğrular çizilmiş ve bu doğrulara en kısa dik uzaklığa sahip sınır noktası 3.13 denklemi ile bulunmuştur. Burada p_i, p_{i+1} medyal eksene ait verinin uç iki noktasını, q_i ise buna karşılık gelen sınır noktasını ifade etmektedir. 3.13 denklemini minimize eden deęerler sınır verisinin uç noktaları olarak tanımlanmıştır.

$$d_{i,j} = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2} \quad (3.12)$$

$$d_i = \frac{\|(p_i - p_{i+1}) \times (p_i - q_i)\|}{\|p_i - p_{i+1}\|} \quad (3.13)$$

Sivri biber imgelerinde tanımlanan başlangıç ve bitiş noktaları arasında sınır verileri ile medyal eksen arasındaki dik uzaklık hesaplanarak biberin kalınlık profili çıkartılmıştır (3.7). Ardarda gelen iki noktanın medyal eksene olan uzaklıkları arasındaki fark karınlık

profilinin ayrık türevi olarak hesaplanmıştır. Ayrık türevi en yüksek olan nokta biber sapının başlangıç noktası olarak belirlenmiştir. Tüm aşamalar biberin diğer tarafında da uygulanmış ve burada da biber sapının başlangıç noktası hesaplanmıştır.




Şekil 3.7: Kalınlık profili (kırmızı eğri) ve türevi (mavi eğri)

Biber sapının başlangıç noktaları bu şekilde belirlendikten sonra sapın otomatik olarak ayrıştırılması mümkündür. Bu iki noktadan çizilen doğru ile biber sapı imgenin geri kalanından şekil 3.8'deki gibi ayrıştırılmıştır. Bu işlem dizisi tüm biberlere uygulanmış ve 145 biber için de biber sapının doğru noktalardan ayrıldığı gözlemlenmiştir. Bu sonuç önerilen yaklaşımın biber sapının otomatik olarak ayrıştırılmasında başarılı sonuç verdiğini göstermektedir.

3.2.3 Ana Bileşen Analizi'ne Dayalı Öznitelikler

Çalışmanın bu bölümünde sivri biber imgelerinin Nokta Dağılım Modeli (NDM) çıkartılmıştır. Eğitim kümesindeki sivri biber konturlarından ABA ile bir model oluşturulmuştur. Kalite sınıflandırması, bir biber konturunun ortalama konturdan ana bileşenler yönündeki değişim eğilimlerinin bir öznitelik vektöründe özetlenmesiyle



(a) Orjinal sivri biber

(b) Sapı ayrılmış sivri biber

Şekil 3.8: Sap ayırma işlemi

yapılmıştır. Bu öznitelik vektörünün sınıflandırılmasında kullanılan algoritmalar ise Bölüm 3.3'te incelenmiştir.

Sivri biberlerin boyutları, eğrilik şekil ve miktarları tamamen değişkendir. Biberlerin tüm sınır verisi yerine çıkartılan karakteristik noktaları arasında örneklenen sınır verisini kullanarak değişimlerini incelemek mümkündür. Çalışmada bu değişimlerin hangi özelliklere göre gerçekleştiği incelenmiş ve değişim düzeyleri kullanılarak eğriliğe göre kalite sınıflandırması yapılmıştır.


Cootes vd., 1995 çalışmasında boyut ve şekil olarak belirli aralıklarda kendi içerisinde çeşitlenebilen nesnelere için NDM çıkartmıştır. nesnelere değişimleri ana bileşenleri ile temsil edilerek esnek modeller oluşturulmuş ve bu yaklaşım Aktif Şekil Modeli (AŞM) olarak adlandırılmıştır. AŞM ile bir bölgede şekil modeli bilinen bir nesnenin aranabileceğini ve bölümlenebileceğini göstermiştir. Yörük vd., 2005 ise, insan eli biyometrik şemalarını varyasyonlarını belirlemek için el konturlarından ABA ile çıkarılan öznitelikleri kullanmıştır.

ABA'ya dayalı özniteliklerin çıkartılması aşamasında, öncelikle bölütleme evresinde çıkartılan sınır verisinin tamamını tutmak yerine yeniden örneklenecek hali kullanılmıştır. Bunun için öncelikle sınır verisi üzerinden karakteristik noktalar belirlenmiştir. Bunlar tasarlanan arayüz aracılığıyla el ile seçilerek işaretlenmiştir. Biberin sapının uç noktası, sap dibi, omuz noktaları ve biberin gövdesinin ucu el ile bu noktaların araları belli sayılarda nokta ile örneklenip, bütün biber konturları 270 noktadan oluşacak şekilde yeniden örneklenecektir.

Yeniden örneklenen sınır verilerinden ortak bir biber modeli çıkartabilmek için veriler iki uç noktaları aynı hizada ve $x = 0$ ekseninde olacak şekilde döndürülmüştür.

Biberlerin sınır verilerinin oluşturduğu özuzaydaki değişkenliğin eğrilik değişimlerini ön plana çıkaracak şekilde enlemesine olmasını sağlamak için döndürülüp kaydırılmış sınır verilerinin yeniden boyutlanması yapılmıştır. Tüm sınır verileri, başlangıç noktaları gibi bitiş noktaları da aynı noktada olacak şekilde dönüştürülmüştür.

Son olarak, biberlerin eğriliğinin standart bir yönü bulunmadığından tüm sınır verilerinin x eksenine göre simetrisi alınmış, veri sayısı iki katına çıkartılmıştır. Şekil 3.9’da sınır verileri üst üste bindirilmiş biberler kırmızı ile, ortalama biber ise mavi ile gösterilmektedir.



Şekil 3.9: Normalize edilmiş sınır verileri

Biberlere ait sınır verilerinin ABA ile elde edilen özvektörlerden oluşan özuzaya projeksiyonunu sağlamak için $x_i = \{(x_{i0}, y_{i0}), (x_{i1}, y_{i1}), \dots, (x_{in-1}, y_{in-1})\}^T$ biçiminde bulunan sınır verisi tek bir $x_i = \{x_{i0}, y_{i0}, x_{i1}, y_{i1}, \dots, x_{in-1}, y_{in-1}\}^T$ vektörüne dönüştürülmüştür. Böylece her sivri biber sınır verisi için $2n$ boyutlu bir vektör elde edilmiştir.

$$\bar{x} = \frac{1}{N} \sum_{i=1}^N x_i \quad (3.14)$$

$$\tilde{x}_i = x_i - \bar{x} \quad (3.15)$$

$$\xi = \frac{1}{N} \sum_{i=1}^N \tilde{x}_i \tilde{x}_i^T \quad (3.16)$$

$$x = \bar{x} + eb \quad (3.17)$$

$e = [e_1, e_2, \dots, e_N]$, 3.16 denklemindeki matrise ait özvektörlerin oluşturduğu matris ve $b = (b_1, b_2, \dots, b_N)^T$ ise x vektörünün bu özvektörler üzerindeki izdüşüm katsayılarının vektörüdür. 3.17 denklemi ile sivri biber sınır verilerinin farklı modlarına ulaşmak mümkündür. 3.18 eşitsizliğinde özdeğer λ_k sınır verileri vektörünün özdeğerini simgelemektedir. Farklı modlarda a katsayının değişimiyle modelin özelliklerindeki etki şekil, 3.10, 3.11, 3.12, 3.13, 3.14 ve 3.15'den görülmektedir.

$$-a\sqrt{\lambda_k} \leq b_k \leq a\sqrt{\lambda_k} \quad (3.18)$$





Nihai öznitelik vektörünü oluşturmak için 145 bibere ait \tilde{x}_i vektörlerinin 3.19 denklemi ile ABA özvektörlerinden oluşan özuzaya izdüşümleri hesaplanmıştır. Büyük değişimleri taşıyan özvektörler öncelikli birkaç vektör olduğundan, sınıflandırma aşamasında kullanılan vektör sayısı deneysel olarak belirlenmiştir. Bölüm 3.3'te sınıflandırma süreci incelenmiştir.

$$b_{i,j} = e_j^T \tilde{x}_i \quad (3.19)$$

3.3 Sınıflandırma

Çalışmanın sınıflandırma aşamasında geometrik ve ABA ile çıkartılan öznitelikleri kullanarak sivri biberlerin hangi sınıfa ait oldukları belirlenmiştir. Bu işlem için k-En Yakın Komşu, Destek Vektör Makinası ve AdaBoost sınıflandırıcıları kullanılmıştır.





Carbonell vd., 1983 makine öğrenimi yaklaşımlarını bilginin doğrudan yerleştirilmesi ile, bir yönergenin izlenmesi ile, genelleme ile, örneklerin kullanımı ile ve keşif ile öğrenme şeklinde 5 gruba ayırmıştır. Bugün, öğrenme yaklaşımlarının, öğreticili,

(a) $a=1$ için(b) $a=-1$ içinŞekil 3.10: 1. Mod $a=1$ için(a) $a=3$ için(b) $a=-3$ içinŞekil 3.11: 1. Mod $a=3$ için

öğreticisiz ve yarı kontrollü öğrenme şeklinde üç kategoriye ayrılması daha yaygındır (Theodoridis ve Koutroumbas, 2009).

Öğreticili öğrenme, tamamı etiketlenmiş eğitim verilerinin makine öğreniminde kullanılması şeklinde özetlenebilir. Sınıflandırma yapılacak sınıflar önceden belirlenmiştir ve hangi sınıfa ait olduğu belli olan veriler ile makine öğrenimi gerçekleştirilir.





Öğreticisiz öğrenme ise tamamı etiketsiz olan verilerin yine ön tanımlı olmayan kümelere ayrılmasına dayalı makine öğrenimi yaklaşımıdır. Veriden çıkartılan öznelik vektörlerinin birbirlerine olan uzaklıklarına, bir kümeleme oluşturup oluşturmadıklarına bakılarak sınıflandırma işlemi gerçekleştirilmektedir.

(a) $a = 1$ için(b) $a = -1$ içinŞekil 3.12: 2. Mod $a = 1$ için(a) $a = 1$ için(b) $a = -1$ içinŞekil 3.13: 2. Mod $a = 3$ için

Yarı kontrollü öğrenme, öğreticili öğrenme ile benzer bir hedefe sahiptir. Ancak makine öğrenimi sürecinde etiketsiz veriler de kullanılabilir. Theodoridis ve Koutroumbas, 2009 çalışmasına göre elde sınırlı sayıda etiketli veri olduğunda tercih edilmektedir. Diğer taraftan eğitim sürecinin yeni eklenen verilerle devam etmesi istendiğinde de bu yaklaşımdan faydalanılmaktadır.

3.3.1 K- En Yakın Komşu

k-En Yakın Komşu öğreticili bir sınıflandırıcıdır. Cover ve Hart, 1967 çalışmasına göre k-EYK test verisini daha önceden sınıflandırılmış eğitim verileri arasında en yakınında olanlara ait sınıfa atamaktadır.

(a) $a = 1$ için(b) $a = -1$ içinŞekil 3.14: 4. Mod $a = 1$ için(a) $a = 1$ için(b) $a = -1$ içinŞekil 3.15: 4. Mod $a = 3$ için

k-EYK parametrik olmayan bir sınıflandırıcı türüdür. Parametrik metotlarla sınıflandırma yaparken bir model varsayılmakta ve test verisinin bu modele uyup uymadığına göre sınıflandırma gerçekleştirilmektedir (Alpaydın, 2010). Eğitim işleminin sonucunda eğitim verileri sabit boyutlu bir parametre grubuna indirgenmektedir. Eğitim için kullanılan veriler çoğaldıkça parametreler değişse de boyut sabit kalır. Böylece test aşamasındaki hassasiyet artarken işlem süresi değişmeden kalmaktadır.

Diğer taraftan k-EYK gibi parametrik olmayan sınıflandırıcılarda eğitim verileri bir bütün halinde korunmakta ve her testte tüm eğitim verisi tümüyle ele alınmaktadır. Sınıflandırıcının eğitiminde kullanılan öznitelik vektörleri eğitime katılan her veri ile daha da genişlemektedir. Test verisine ait aynı boyutlu vektörün uygun bir mesafe ölçütü kullanılarak eğitim kümesinde bulunan vektörlerin tümüne olan mesafesi hesaplanmaktadır.

Sınıflandırmak istenen veri kendisine en 'yakın' aynı sınıftan k adet eğitim verisinin dahil olduğu sınıfa atanmaktadır. M genişliğinde $\{\theta_1, \theta_2, \dots, \theta_M\}$ etiketlerine sahip bir sınıflandırma uygulamasında $\{x_i^N, \theta_j\}$ çifti N boyutlu öznitelik vektörü ve ($j \leq M$) iken sınıf etiketi çiftini ifade etmektedir. $\{x^N, \theta\}$ herhangi bir etiketsiz verisi için $\min d(x^N, x_i^N)$, (3.20)'de verilen test verisi kümesinin her elemanı için hesaplanmaktadır. Öklid normu (3.12) veya başka bir mesafe denklemiyle ölçülen değerler $d_1(x) \leq d_2(x) \leq \dots \leq d_n(x)$ biçiminde artan bir düzende sıralandığında $d_1(x)$ 'ten itibaren aynı θ_j etiketine sahip k adet veri $\{x^N, \theta\}$ çiftinin sınıfını belirlemektedir.

$$T = \{x_1^N, x_2^N, \dots, x_n^N\} \quad (3.20)$$

K-EYK sınıflandırıcısının test sürecinde parametrik sınıflandırıcılara göre daha fazla işlem yoğunluğu gerçekleşmektedir. Her yeni örnekte tüm eğitim verileri tekrar işleme sokulduğundan, eğitim verisi arttıkça işlem yoğunluğu da artmaktadır. Diğer taraftan uygulaması oldukça kolay ve hızlı kavranabilir bir yöntemdir. Öznitelik vektörleri birbirlerinden belirgin şekilde ayrışmamış sınırlı sayıdaki verilerle çalışıldığında aykırı değerler sınıflandırma başarısını düşürebilmektedir. Ancak Cover ve Hart, 1967 çalışmasındaki önermeye göre $k = 1$ için örnek sayısı sonsuza yaklaşırken, hata oranı da sınıflandırmada ulaşılabilir en düşük hata oranı kabul edilen Bayes hata oranının iki katından daha düşük bir değere ulaşmaktadır.

Tez çalışmasında k -EYK ile sınıflandırmada mesafe ölçütü olarak Öklid mesafe ölçütü (3.12) kullanılmıştır. Sınıflandırıcının keskinliğini belirlemede kullanılan "k" parametresi deneysel olarak bulunmuş ve $k = 3$ olarak belirlenmiştir.

3.3.2 Destek Vektör Makinası

Destek Vektör Makinası parametrik ve öğreticili bir sınıflandırıcı türüdür. Cortes ve Vapnik, 1995'te DVM ikili bir sınıflandırıcı olarak tanıtılmıştır. Yöntem iki sınıftan oluşan eğitim verisini ayıran optimal hiper-düzlemi kestimeyi hedefler.

$\theta_i = \{-1, 1\}$ şeklinde iki sınıftan gelen olan n adet gözlemin yapıldığı bir sınıflandırma uygulamasını ele alalım. $x_i \in R^N$ eğitim vektörlerinden karşı sınıf vektörlerine en yakın olanlardan 3.21 denklemini sağlayanlara yani hiper-düzlemin üzerinde bulunan noktalara destek vektörleri denmektedir. Her iki sınıf için de tanımlanan bu hiper-düzlemler H_1 ve H_2 paralel olarak belirlenmektedir. Burges, 1998'de açıklandığı üzere 3.21 denkleminde ω bu hiper-düzlemlerin normal vektörünü temsil etmektedir. $|b|/\|\omega\|$ de paralel iki düzleme eşit uzaklıkta olan orijin noktasına olan uzaklığı

vermektedir. Orijinden geçen ve H_1 ve H_2 'ye paralel olan hiper-düzlem ise optimal hiper-düzlem olarak anılmaktadır ve bu düzlemin iki tarafı ayrı sınıfları temsil etmektedir.

$$\omega \cdot x + b = 0 \quad (3.21)$$

Şekil 3.16'de çemberlere alınan noktalara destek vektörleri denmektedir. Burges, 1998'e göre H_1 ve H_2 hiper-düzlemleri üzerinde olan ve kaldırıldığında sonucu değiştiren vektörlerdir. 3.22 ve 3.23 eşitsizlikleri veri vektörünün hangi sınıfa atılacağını göstermektedir.

$$x_i \cdot \omega + b \geq +1 ; \theta_i = +1 \quad (3.22)$$

$$x_i \cdot \omega - b \leq -1 ; \theta_i = -1 \quad (3.23)$$

Doğrusal olarak ayrılmayan eğitim verileri ise Cortes ve Vapnik, 1995'teki çalışmaya göre bir çekirdek fonksiyonu yardımıyla yüksek boyutlu bir vektör uzayına haritalandırılmakta ve veri bu noktada doğrusal olarak ayrıştırılabilir hale gelmektedir. Aynı zamanda algoritmanın kuvvetli bir genelleme kapasitesi olduğundan dolayı aykırı verileri göz ardı edebilmektedir. Tez çalışmasında Gauss radyal bazlı fonksiyonu (RBF) çekirdek denklemi kullanılmıştır.


DVM ikili bir sınıflandırıcı olarak tasarlanmıştır. Ancak çoğu gerçek hayat problemleri çoklu sınıf yapısını gerektirmektedir. Wang ve Xue, 2014'e göre temelde iki çoklu sınıf yaklaşımı bulunmaktadır. Bunlar biri-hepsine-karşı ve biri-birine-karşı olarak isimlendirilmektedir. İki yaklaşımda da çoklu sınıf yapısı çok sayıda ikili sınıf yapısı olarak ele alınmaktadır.

Biri-hepsine-karşı algoritması sınıf sayısı $k \geq 2$ için k adet ayrı ikili sınıflandırıcı problemi çözmektedir. Her seferinde bir sınıf +, diğer tüm sınıflar - etiketiyle işleme tabi tutulmaktadır. Test aşamasında ise karar en yüksek skoru veren sınıflandırıcıya göre verilmektedir.

Biri-birine-karşı yapısında ise olası tüm ikili kombinasyonlar için ayrı bir ikili sınıflandırıcı eğitilmektedir. Daha karmaşık bir eğitim sürecine sahip bu yaklaşımda

$k(k - 1)/2$ adet hiper-düzlem oluşturulmaktadır. Test aşamasında veri her sınıflandırıcıdan bir oy alır. Nihai sınıf bu oyların sonucuna göre belirlenmektedir.

Bu tez çalışmasında biri-hepsine-karşı yaklaşımı kullanılmıştır. Sınıf sayısı $k = 3$ olduğundan 3 ayrı sınıflandırıcı eğitilmiştir. Her bir test verisi bu 3 hiper-düzleme pozitif yönden uzaklıklarını maksimize eden sınıfın etiketini almıştır.



Şekil 3.16: Doğrusal olarak ayıran hiper-düzlem (Burges 1998)

3.3.3 AdaBoost

AdaBoost bir takviyeli sınıflandırıcıdır. Freund ve Schapire, 1995, çalışmasında AdaBoost algoritmasını için rastgele seçimden biraz daha başarılı olan zayıf sınıflandırıcıları takviye ederek yüksek başarımlı bir sınıflandırıcı haline getirebileceğinden bahsetmektedir. Algoritma eğitim aşamasında her döngüde bir zayıf sınıflandırıcı kullanarak oluşan hatayı hesaplar ve bir ağırlık vektöründeki ağırlıkları bu hata oranına göre günceller. Böylelikle uygun sayıda zayıf sınıflandırıcı eğitim sırasında öğrenilen ağırlık vektörleri ile takviye edilmiş olmaktadır. Freund ve Schapire, 1995, AdaBoost algoritmasını açıklarken her döngüde hata oranını kullanarak bir sonraki döngüye takviye vektörünün uyumlandırıldığından bahsetmektedir.

Schapire, 1999'da AdaBoost.M1 olarak nitelenen algoritma temelde ikili bir ayırıcı olarak oluşturulmuştur. Bir $\{(x_1, \theta_1), (x_2, \theta_2), \dots, (x_N, \theta_N)\}$ eğitim setinde x eğitim verisini, θ ise sınıf etiketini göstermektedir. AdaBoost zayıf sınıflandırıcılardan oluşan geniş bir kümeden, her döngüde en az hata oranını verecek sınıflandırıcıyı $t = 1, 2, \dots, T$ kere seçmektedir. $D_t(i)$ ise i girdisinin t döngüsündeki ağırlık dağılımını göstermektedir. Schapire, 1999'a göre başlangıçta tüm ağırlıklar pozitif ve eşit olarak kurulmakta ancak her

döngüde hatalı sınıflandırılan verilerin ağırlıkları arttırılmaktadır. Böylece zayıf sınıflandırıcıların zor olan verilere odaklanması sağlanmaktadır.

$$\alpha_t = \frac{1}{2} \ln\left(\frac{1 - \epsilon_t}{\epsilon_t}\right) \quad (3.24)$$

Her döngüde yani $t = 1, 2, \dots, T$ için ϵ_t hata oranı, $x_i \in X$ için ayrı ayrı hesaplanmaktadır. Hata miktarına bağlı 3.24 denklemi ile α_t önem katsayısı yine eğitim verisinin her elemanı için bulunmaktadır. $D_t(i)$ ağırlık dağılımı Z_t ile normalize edilerek her döngüde 3.25 denklemi ile $D_{t+1}(i)$ için hesaplanmaktadır. Parçalı denklemden de anlaşılacağı gibi $D_{t+1}(i)$ 'nin büyüme ya da küçülme eğilimi $h_t(x_i)$ hipotezinin, yani zayıf sınıflandırıcı çıktısının, doğruluğuna göre değişmektedir. 3.26 denklemindeki $H(x)$ değeri zayıf sınıflandırıcıların destekleme işlemi sonucunda oluşturdukları son kuvvetli sınıflandırıcıyı ifade etmektedir.

$$D_{t+1}(i) = \frac{D_t(i)}{Z_t} \begin{cases} e^{-\alpha_t} & \text{if } h_t(x_i) = \theta_i \\ e^{\alpha_t} & \text{if } h_t(x_i) \neq \theta_i \end{cases} \quad (3.25)$$

$$H(x) = \text{sign}\left(\sum_{t=1}^T \alpha_t h_t(x)\right) \quad (3.26)$$

Bu tez çalışmasında Adaboost.M1 algoritması iki aşamada kullanılmıştır. Ana Bileşen Analizi (ABA)'ya bağlı öznitelik vektörlerini kullanarak sınıflandırma süreci ikili hale indirgenmiştir. Biberler birinci sınıf ve ikinci sınıf olarak bölünmüştür. Birinci sınıf aynı kalırken önceki bölümde üçüncü sınıfta yer alan kategori de ikinci sınıfa dahil edilerek sınıflandırma gerçekleştirilmiştir.

Ayrıca Adaboost.M2 algoritması da çoklu sınıf uygulamasında kullanılabilir. Schapire, 1999'da algoritmanın ikili sınıflandırma yapısına uygun olduğunu belirtmiş ve AdaBoost'u çoklu sınıf uygulamaları için genişletmenin birçok yolu olduğundan bahsetmiştir. Hastie vd., 2009'a göre çoklu sınıflandırma uygulamalarında, çok sayıda ikili sınıf problemine indirgmeden çözmek mümkündür. Geliştirdikleri algorithmada kayıp fonksiyonunu çoklu sınıfa uygun hale getirmişlerdir. Diğer taraftan tez çalışmasında AdaBoost.M2 algoritmasında biri-hepsine-karşı yaklaşımı kullanılmıştır. (Mukherjee ve Schapire, 2011).

İkinci adımda ise geometrik öznitelikler ile ABA'ya bağılı öznitelikler birlikte kullanılmıştır. Döngü sayısı her iki uygulama için de deneysel olarak belirlenmiş ve en yüksek başarımın elde edildiğı sayıda bırakılmıştır. Bu adımda da hem ikili sınıf hem de çoklu sınıf uygulaması yapılmıştır.

4. BULGULAR VE TARTIŞMA


Bu çalışma için oluşturduğumuz veri kümesinde 145 adet sivri bibere ait imgeler bulunmaktadır. Biber imgeleri ayrıntıları 4.1’de verilen kontrollü bir düzenek ile elde edilmiştir. Biber imgelerinin özelliklerinden 4.2’de bahsedilmektedir.

4.1 Donanım

Biber fotoğrafı çekilirken arada ışığı dağıtıcı bir malzeme kullanılmadığı takdirde biber pürüzsüz yüzeyi sayesinde ışığı direk yansıtmakta ve bu da lokal parlamalara yol açmaktadır. Bu parlamalar hem bölütleme aşamasında sorun oluşturmakta hem de doku özelliklerinde bilgi kaybına yol açmaktadır. O nedenle parlama özelliği olan ürün çekimlerinde ışığı dağıtma/saçma özelliği olan malzemeler ya da boyalar kullanılmaktadır. Led difüzör olarak adlandırılan polistren malzemeler led ışıklandırmalarda, bina içi aydınlatmada yaygın olarak kullanılmaktadır. Benzer şekilde ürün çekimlerinde kullanılan ışık çadırları da ya polistren malzemedен ya da difüzyon özellikli kumaşlardan yapılmaktadır.

Çalışmada düzgün yayılmış bir aydınlatma sağlamak ve parlamanın önüne geçebilmek için şekil 4.1’de görüldüğü gibi polistren kaplı bir kabin tasarlanmıştır. Aydınlatma yan yüzeylerden ve kabinin dışından olacak şekilde dizayn edilmiştir. Böylece ürün üzerinde düzgün dağılmış bir aydınlanma sağlanmak istenmiştir. Işık polistren malzemedен geçerken saçıldığından ortamda eşit bir ayınlama elde edilmesi hedeflenmiştir. Ayrıca ortam ışığının değişiminden de minimum etkilenmektedir. Kamera yansıtıcı özellikli çıkabilir üst sacın ortasında açılan boşluğa yerleştirilmiş ve çekim bu noktadan yapılmıştır. Çekim penceresi merkezli olarak tasarlanmış böylece her zaman aynı noktadan çekim yapılması sağlanmıştır.

Çekimler Nikon 750D model kamera ile yapılmıştır. Biberler siyah bir fon üzerine yerleştirilerek arka planın sabit renkte ve homojen olması sağlanmıştır. İmgeler 4608 x 3072 çözünürlükte ve JPG formatında kaydedilmiştir. Ayrıca üst sac sabitlenmediğinden ürünler yukarıdan koyulup çıkartılmıştır. Komple bir sistem tasarımında kabinin siyah bantlı bir konveyör üzerine yerleştirilmesi gerektiği düşünülmektedir. Aydınlatma aynı şekilde dışarıdan olabileceği gibi, kabin içinden de yapılabilir.




Şekil 4.1: Donanım tasarımı


4.2 Veri Özellikleri

Çalışmada kullanılmak üzere farklı zamanlarda ve farklı satıcılardan toplam 145 adet sivri biber farklı eğriliklerde olmasına dikkat edilerek seçilmiştir. Biber çekimleri ise yine farklı zamanlarda aynı düzenek kullanılarak kontrollü bir ortamda yapılmıştır. Biber imgelerinin yanı sıra 1 adet de boş arka plan görüntüsü bölütleme aşamasında kullanılmak üzere çekilmiştir. Çekilen 145 biber imgesinin tamamı birinci sınıf, ikinci sınıf ve üçüncü sınıf olarak elle derecelendirilmiştir. Bu derecelendirme biri konunun uzmanı olan 5 farklı kişiden United States Department of Agriculture, 2016 standardında belirtildiği gibi düz veya hafif eğri olanlar birinci sınıfa, hafif eğriden fazla, ciddi eğriden az eğrilikte olanlar ikinci sınıfa, ciddi eğri olanlar da üçüncü sınıfa atama yapması istenmiştir. Sonuç olarak beş kişiden 1, 2 ve 3 şeklinde alınan derecelendirmelerin aritmetik ortalaması alınmış ve

referans olarak kabul edilmiştir. 4.1 çizelgesinde referans sütunundaki değerler biberlerin eğitim ve test aşamalarındaki sınıf etiketleri olarak kullanılmıştır.



Şekil 4.2: Veri kümesindeki biber imgeleri



Şekil 4.3: Veri kümesindeki biber ingeleri (Şekil 4.2'nin devamı)

Elde edilen biber ingelerinin tamamı şekil 4.2 ve 4.3'te verilmiştir. Çekilen sivri biberlerin sınıflandırması ve referans kabul edilen değerleri ise 4.1 çizelgesinde gösterilmiştir. Biber numaralarının sırası şekil 4.2'de sol üst köşe ilk biber olmak üzere sağa

ve aşağıya doğru artarak sıralanmaktadır. Veri kümesindeki her bir imgeye ait, beş ayrı kişi tarafından yapılan sınıflandırma ve bu sınıflandırmaların aritmetik ortalaması alınarak elde edilen referans değerleri, çizelge 4.1’de verilmiştir.

Çizelge 4.1: Elle Sınıflandırma Verileri

İmge Adı	A	B	C	D	E	Referans
Biber_0001	2	1	2	2	1	2
Biber_0002	2	2	2	2	2	2
Biber_0003	1	1	1	1	1	1
Biber_0004	1	1	1	1	1	1
Biber_0005	1	1	1	1	1	1
Biber_0006	2	2	2	2	2	2
Biber_0007	2	2	2	3	2	2
Biber_0008	1	1	2	2	2	2
Biber_0009	2	1	2	2	2	2
Biber_0010	2	1	2	2	2	2
Biber_0011	1	1	1	2	1	1
Biber_0012	1	1	1	1	1	1
Biber_0013	1	1	1	1	1	1
Biber_0014	1	1	1	2	1	1
Biber_0015	3	2	3	3	2	3
Biber_0016	1	1	1	1	1	1
Biber_0017	1	1	1	1	1	1
Biber_0018	3	2	3	3	2	3
Biber_0019	1	1	2	1	2	1
Biber_0020	2	2	2	2	2	2
Biber_0021	1	1	1	1	1	1
Biber_0022	3	2	3	3	2	3
Biber_0023	1	1	1	1	1	1
Biber_0024	2	2	3	2	2	2
Biber_0025	3	2	3	2	3	3
Biber_0026	3	2	3	3	2	3
Biber_0027	2	2	3	2	2	2
Biber_0028	3	2	3	3	3	3
Biber_0029	3	2	3	3	3	3
Biber_0030	2	2	2	3	2	2
Biber_0031	2	2	2	3	2	2

Çizelge 4.1 – Elle Sınıflandırma Verileri (devam)

İmge Adı	A	B	C	D	E	Referans
Biber_0032	1	1	1	1	1	1
Biber_0033	2	2	2	2	2	2
Biber_0034	3	2	3	2	3	3
Biber_0035	3	2	3	3	3	3
Biber_0036	2	1	2	2	2	2
Biber_0037	1	1	1	1	1	1
Biber_0038	3	2	3	3	2	3
Biber_0039	3	3	3	3	3	3
Biber_0040	3	2	3	2	3	3
Biber_0041	3	2	3	2	3	3
Biber_0042	2	1	2	1	2	2
Biber_0043	3	3	3	2	3	3
Biber_0044	3	3	3	3	3	3
Biber_0045	2	1	2	1	2	2
Biber_0046	3	2	3	2	3	3
Biber_0047	2	2	2	2	2	2
Biber_0048	3	2	3	1	3	3
Biber_0049	1	1	1	1	1	1
Biber_0050	3	3	3	2	2	3
Biber_0051	3	2	2	1	2	2
Biber_0052	3	2	2	1	2	2
Biber_0053	2	2	2	1	2	2
Biber_0054	2	2	2	2	2	2
Biber_0055	2	1	2	1	1	1
Biber_0056	2	1	1	1	1	1
Biber_0057	3	3	2	2	3	3
Biber_0058	3	3	3	2	2	3
Biber_0059	3	2	2	1	2	2
Biber_0060	3	2	3	2	3	3
Biber_0061	3	2	2	1	2	2
Biber_0062	2	1	2	1	2	2
Biber_0063	1	1	2	1	2	1
Biber_0064	2	2	2	2	2	2
Biber_0065	3	3	3	2	2	3
Biber_0066	2	1	2	1	2	2
Biber_0067	3	3	3	2	3	3

Çizelge 4.1 – Elle Sınıflandırma Verileri (devam)

İmge Adı	A	B	C	D	E	Referans
Biber_0068	1	1	2	1	2	1
Biber_0069	3	3	3	2	3	3
Biber_0070	2	2	2	1	2	2
Biber_0071	1	1	1	1	1	1
Biber_0072	2	2	2	2	2	2
Biber_0073	2	2	2	2	2	2
Biber_0074	2	1	2	1	2	2
Biber_0075	2	2	2	2	2	2
Biber_0076	2	2	2	3	2	2
Biber_0077	3	3	3	2	2	3
Biber_0078	3	2	3	2	3	3
Biber_0079	2	1	1	2	2	2
Biber_0080	3	2	2	2	1	2
Biber_0081	3	3	2	2	3	3
Biber_0082	3	2	3	2	3	3
Biber_0083	2	2	2	3	2	2
Biber_0084	1	1	1	1	1	1
Biber_0085	1	1	1	1	1	1
Biber_0086	1	1	1	1	1	1
Biber_0087	2	2	2	2	2	2
Biber_0088	2	2	2	2	2	2
Biber_0089	3	3	3	3	3	3
Biber_0090	2	1	2	1	2	2
Biber_0091	1	1	1	1	1	1
Biber_0092	3	2	3	3	3	3
Biber_0093	3	3	3	3	3	3
Biber_0094	1	1	1	1	1	1
Biber_0095	2	2	1	1	2	2
Biber_0096	2	2	2	2	1	2
Biber_0097	2	2	2	2	2	2
Biber_0098	2	2	2	3	2	2
Biber_0099	1	2	1	1	1	1
Biber_0100	3	2	2	3	3	3
Biber_0101	2	2	2	2	2	2
Biber_0102	3	2	2	3	3	3
Biber_0103	1	1	2	1	1	1

Çizelge 4.1 – *Elle Sınıflandırma Verileri (devam)*

İmge Adı	A	B	C	D	E	Referans
Biber_0104	2	2	2	1	2	2
Biber_0105	3	2	3	3	3	3
Biber_0106	2	1	2	1	2	2
Biber_0107	2	1	2	2	2	2
Biber_0108	3	2	2	3	3	3
Biber_0109	3	2	3	2	3	3
Biber_0110	2	2	2	2	2	2
Biber_0111	3	2	2	1	2	2
Biber_0112	3	3	3	3	3	3
Biber_0113	3	1	3	2	3	3
Biber_0114	1	1	1	1	1	1
Biber_0115	3	2	3	3	2	3
Biber_0116	3	3	2	3	2	3
Biber_0117	2	1	2	2	2	2
Biber_0118	2	2	2	1	2	2
Biber_0119	2	2	2	1	2	2
Biber_0120	3	2	2	3	3	3
Biber_0121	3	2	2	3	3	3
Biber_0122	3	3	2	3	2	3
Biber_0123	2	1	1	1	1	1
Biber_0124	2	1	2	2	2	2
Biber_0125	3	2	3	3	3	3
Biber_0126	3	2	3	3	3	3
Biber_0127	3	3	3	3	3	3
Biber_0128	1	1	1	1	1	1
Biber_0129	1	1	1	1	1	1
Biber_0130	1	1	1	1	1	1
Biber_0131	2	2	2	2	2	2
Biber_0132	3	3	3	3	3	3
Biber_0133	2	2	2	3	2	2
Biber_0134	3	3	2	2	3	3
Biber_0135	2	1	2	2	2	2
Biber_0136	2	1	2	2	1	2
Biber_0137	3	2	2	3	3	3
Biber_0138	2	2	1	1	2	2
Biber_0139	3	2	3	3	3	3

Çizelge 4.1 – Elle Sınıflandırma Verileri (devam)

İmge Adı	A	B	C	D	E	Referans
Biber_0140	3	2	3	2	3	3
Biber_0141	3	3	3	3	3	3
Biber_0142	2	1	2	1	2	2
Biber_0143	3	3	3	3	3	3
Biber_0144	2	2	2	1	1	2
Biber_0145	3	2	3	2	3	3

4.3 Sınıflandırma Sonuçları

Çıkarılan öznitelikleri kullanarak k-EYK, DVM ve AdaBoost ile sınıflandırma yapılmıştır. Sınıflandırıcılardan k-EYK ve DVM ile sadece geometrik öznitelikleri kullanarak sınıflandırma işlemi yapılmıştır.

Çizelge 4.2’de k-EYK algoritması ile biberlerin sapsarı ayrıştırılmadan yapılan sınıflandırmanın sonucu gösterilmektedir. Çizelge 4.3’de ise k-EYK algoritması sapsarı ayrıştırılmış biberlerde uygulanmıştır. İki çizelgenin karşılaştırmasında sapsarın ayrıştırıldıktan sonraki gelişme görülebilmektedir. İlk durumda ayrıştırma başarısı %68.8 iken ikinci durumda %82.2’ye çıkmıştır.

Çizelge 4.4’te sapsarı ayrıştırılmamış biberlerin DVM ile yapılan sınıflandırılmaları görülmektedir. Benzer şekilde çizelge 4.5’te ise sapsarı otomatik olarak ayrılmış biberlerin DVM ile sınıflandırılması görülmektedir. Sınıflandırıcının kendisi her iki durumda da k-EYK’dan daha iyi sonuçlara ulaşmıştır. Tez çalışmasının 3.3.2 bölümünde de incelendiği üzere DVM algoritması sınıflandırılmayan verilerden daha az etkilenmektedir. Hiper-düzlem sınıflandırılabilen veriler üzerine oturmaktadır. Ancak k-EYK sınıflandırıcısı yerel olarak sınıflandırma işlemi yapmaktadır. Aykırı veriler sonucu belirgin şekilde değiştirebilmektedir.

Çizelge 4.6 ve çizelge 4.7 AdaBoost algoritması ile yapılan sınıflandırma işlemlerini göstermektedir. Algoritma çoklu sınıfla çalışmaya uygun olacak şekilde kullanılmıştır. Sadece ABA’ya dayalı öznitelikleri kullanarak yapılan sınıflandırma çizelge 4.6’de gösterilmektedir. Geometrik olanlara göre ayrıştırma kabiliyeti oldukça düşük kalmıştır. Diğer taraftan çizelge 4.7’de geometrik özniteliklerin de sınıflandırma aşamasına katıldığı

hali gösterilmektedir. Buradaki sonuçların önemli ölçüde geliştiği görülmektedir. Hataların çoğunlukla ikinci sınıf ve üçüncü sınıf arasında olduğu görülmektedir.

Son olarak AdaBoost.M1 algoritması ile ikili sınıflandırma uygulaması yapılmıştır. Burada sınıf sayısı ikiye indirilmiştir. İkinci ve üçüncü sınıf birleştirilmiş ve negatif sınıf etiketi verilmiştir. Birinci sınıf aynı kalacak şekilde yapılan sınıflandırmada %86.6 başarımla elde edilmiştir.

Çizelge 4.2: Saplı Biberlerin k-EYK İle Sınıflandırma Verileri

		Sınıflandırma		
		Sınıf 1	Sınıf 2	Sınıf 3
Gerçek	Sınıf 1	4	2	0
	Sınıf 2	2	11	4
	Sınıf 3	1	5	16

Çizelge 4.3: Sapsiz Biberlerin k-EYK İle Sınıflandırma Verileri

		Sınıflandırma		
		Sınıf 1	Sınıf 2	Sınıf 3
Gerçek	Sınıf 1	5	1	0
	Sınıf 2	2	14	1
	Sınıf 3	0	4	18

Çizelge 4.4: Saplı Biberlerin DVM İle Sınıflandırma Verileri

		Sınıflandırma		
		Sınıf 1	Sınıf 2	Sınıf 3
Gerçek	Sınıf 1	5	1	0
	Sınıf 2	3	12	2
	Sınıf 3	1	5	16

Çizelge 4.5: Sapsız Biberlerin DVM İle Sınıflandırma Verileri

		Sınıflandırma		
		Sınıf 1	Sınıf 2	Sınıf 3
Gerçek	Sınıf 1	6	0	0
	Sınıf 2	3	14	0
	Sınıf 3	0	2	20

Çizelge 4.6: ABA'ya Dayalı Özniteliklerin AdaBoost İle Sınıflandırılması

		Sınıflandırma		
		Sınıf 1	Sınıf 2	Sınıf 3
Gerçek	Sınıf 1	4	2	0
	Sınıf 2	4	11	2
	Sınıf 3	0	8	14

Çizelge 4.7: Geometrik ve ABA'ya Dayalı Özniteliklerin AdaBoost İle Sınıflandırılması

		Sınıflandırma		
		Sınıf 1	Sınıf 2	Sınıf 3
Gerçek	Sınıf 1	6	0	0
	Sınıf 2	2	15	0
	Sınıf 3	0	6	16


Çizelge 4.8: Geometrik ve ABA'ya Dayalı Özniteliklerin AdaBoost İle İkili Olarak Sınıflandırılması

		Sınıflandırma	
		Sınıf 1	Sınıf 2
Gerçek	Sınıf 1	5	1
	Sınıf 2	5	34

5. SONUÇ VE ÖNERİLER


5.1 Sonuçların Değerlendirmesi

Sonuç olarak, bu tez çalışmasında sivri biberleri eğriliklerine göre sınıflandıran bir yapı üzerine çalışılmıştır. Eğrilik değerlerin ölçülmesinde geometrik ve Ana Bileşen Analizi (ABA)'ya dayalı öznitelikler kullanılmıştır. Çalışmada doğruluktan sapma adını verdiğimiz bir öznitelik üretilmiştir. Ayrıca sivri biberlerin eğriliklerine göre kalite derecelendirmesi aşamasında biber sapının yanıtıcı etkisi sınıflandırma aşamasında gösterilmiştir. Biber sapının otomatik olarak ayırıştırın bir algoritma da tez çalışması aşamasında geliştirilmiştir.



Şekil 5.1: 2B uzayda sınıflara göre öznitelik dağılımı

Şekil 5.1'de test imgelerinin doğrusallıktan sapma ve basıklık özniteliklerine göre dağılımları gösterilmektedir. Birinci sınıf biberler kırmızı, ikinci sınıf yeşil, üçüncü sınıf ise mavi ile ifade edilmektedir. Şekil 5.1'den sınıfların iç içe geçtikleri bölgeler



(a) 3. sınıftan 2. sınıfa yanlış sınıflandırılmış (b) 2. sınıftan 1. sınıfa yanlış sınıflandırılmış

Şekil 5.2: Ortak olarak hatalı sınıflandırılan iki örnek

görülebilmektedir. DVM algoritması çekirdek fonksiyonu kullanarak daha iyi bir ayrıştırma sağlarken, k-EYK algoritması iç içe geçen bölümlerde hatalı sonuç verebilmektedir.

Uygulamada sınıflandırıcıların ayrıştırma başarıları incelendiğinde her durumda sapların yanıtıcı etkisinin ortadan kaldırılmasının başarıyı önemli oranda yükselttiği görülmektedir. Ayrıca Şekil 5.2’de sınıflandırıcılar tarafından hatalı olarak tanımlanan biber imgelerine yer verilmiştir. Biber eğriliklerinin sınıflar arası geçiş bölgelerine yakın olan bu gibi örnekleri göz ile dahi doğru olarak sınıflandırmak zordur.

5.2 Gelecek Çalışmalar



(a) Temas eden biberler

(b) Karışık halde biberler

Şekil 5.3: Karışık halde bulunan biberlerin ayrıştırılması

Bu tez çalışmasının devamı olarak Aktif Şekil Modeli (AŞM) oluşturularak, Şekil 5.3’te görülen toplu halde bulunan biberlerin ayrıştırılması ve kalite derecelendirmesinin yapılması hedeflenmektedir. Görüntü yakalama aşamasında ise derinlik verisinin de kullanılabilmesi için her sahnenin birden fazla açıdan çekiminin yapılması planlanmaktadır.

Ek olarak veri sayısı çoğaltıp, doku ve renk özelliklerini de katarak kalite kontrol parametrelerinin geliştirilmesi, sistemin leke türlerine göre de sınıflandırma yapması hedeflenmektedir.

Ayrıca bu tez çalışmasının bir bölümü 26. Uluslararası Sinyal İşleme ve Uygulamaları Konferansı'nda (Coksoyler ve Dutagaci, 2018) bildiri olarak sunulmuş ve IEEE Xplore dijital kütüphanesinde yayımlanmıştır.

KAYNAKLAR DİZİNİ

Alpaydin, E. (2010), *Introduction to Machine Learning*. 2nd. The MIT Press. ISBN: 026201243X, 9780262012430.

Blum, H. (1967), *A transformation for extracting new descriptors of shape*. URL: papers2://publication/uuid/33A7D570-B63C-4E43-996A-4DE15D8EE75F.

Burges, C. J. C. (1998), A Tutorial on Support Vector Machines for Pattern Recognition, *Data Min. Knowl. Discov.* 2.2, 121–167. ISSN: 13845810. DOI: 10 . 1023 / A : 1009715923555. arXiv: 1111 . 6189v1. URL: <http://link.springer.com/10.1023/A:1009715923555>{\%}5Cnpapers3://publication/doi/10.1023/A:1009715923555.

Carbonell, J. G., Michalski, R. S. ve Mitchell, T. M. (1983), An Overview of Machine Learning, *Mach. Learn. An Artif. Intell. Approach*. Ed. R. S. Michalski, J. G. Carbonell ve T. M. Mitchell. Berlin, Heidelberg: Springer Berlin Heidelberg, 3–23. ISBN: 978-3-662-12405-5. DOI: 10 . 1007 / 978 - 3 - 662 - 12405 - 5 _ 1. URL: <https://doi.org/10.1007/978-3-662-12405-5>{_}1.

Cho, N.-h. ve Lee, S.-h. (2007), Development of Automatic Sorting System for Green Pepper Using Machine Vision, 0300.07. DOI: 10.1096/fj.09.

Coksoyler, C. ve Dutagaci, H. (2018), Quality Sorting of Green Peppers based on Flexure, *2018 26th Signal Process. Commun. Appl. Conf.* 1–4.

Cootes, T., Taylor, C., Cooper, D. ve Graham, J. (1995), Active Shape Models-Their Training and Application, *Comput. Vis. Image Underst.* ISSN: 10773142. DOI: 10 . 1006 / cviu . 1995 . 1004.

KAYNAKLAR DİZİNİ (devam)

Cortes, C. ve Vapnik, V. (1995), Support-Vector Networks, *Mach. Learn.* 20.3, 273–297. ISSN: 15730565. DOI: 10.1023/A:1022627411411. arXiv: arXiv:1011.1669v3.

Cover, T. ve Hart, P. (1967), Nearest neighbor pattern classification, *IEEE Trans. Inf. Theory* 13.1, 21–27. ISSN: 0018-9448. DOI: 10.1109/TIT.1967.1053964. URL: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=1053964>.

Dış Ticaret Müsteşarlığı (2007), Resmî Gazete, 26542.TEBLİĞ NO: 2007/40, 1–21. URL: <http://www.resmigazete.gov.tr/eskiler/2007/06/20070604-3.htm>.

Dongping Tian (2013), A Review on Image Feature Extraction and Representation Techniques, 8.4, 385–396. ISSN: 19750080.

Freund, Y. ve Schapire, R. E. (1995), A decision-theoretic generalization of on-line learning and an application to boosting, 23–37. ISSN: 00220000. DOI: 10.1007/3-540-59119-2_166. arXiv: /statistics.berkeley.edu/sites/default/files/tech-reports/367.pdf [http:]. URL: http://link.springer.com/10.1007/3-540-59119-2_{_}166.

George, M. (2015), Multiple Fruit and Vegetable Sorting System Using Machine Vision, *Int. J. Adv. Technol.* 06.01, 1–4. ISSN: 09764860. DOI: 10.4172/0976-4860.1000142. URL: <https://www.omicsonline.org/open-access/multiple-fruit-and-vegetable-sorting-system-using-machine-vision-0976-4860-1000142.php?aid=57692>.

Guyon, I. ve Elisseeff, A. (2006), An Introduction to Feature Extraction, *Featur. Extr. Found. Appl.* Ed. I. Guyon, M. Nikravesh, S. Gunn ve L. A. Zadeh. Berlin, Heidelberg: Springer

KAYNAKLAR DİZİNİ (devam)

Berlin Heidelberg, 1–25. ISBN: 978-3-540-35488-8. DOI: 10.1007/978-3-540-35488-8_1. URL: https://doi.org/10.1007/978-3-540-35488-8_1.

Hastie, T., Rosset, S., Zhu, J. ve Zou, H. (2009), Multi-class AdaBoost, *Stat. Interface* 2.3, 349–360. ISSN: 19387989. DOI: 10.4310/SII.2009.v2.n3.a8. arXiv: arXiv:1011.1669v3. URL: <http://www.intlpress.com/site/pub/pages/journals/items/sii/content/vols/0002/0003/a008/>.

Kumar, G. ve Bhatia, P. K. (2014), A detailed review of feature extraction in image processing systems, *Int. Conf. Adv. Comput. Commun. Technol. ACCT* February, 5–12. ISSN: 23270659. DOI: 10.1109/ACCT.2014.74.

Kurtulmuş, F., Alibaş, İ. ve Kavdir, İ. (2016), Classification of pepper seeds using machine vision based on neural network, *Int J Agric Biol Eng* 9.91, 51–62. ISSN: 1934-6344. DOI: 10.3965/j.ijabe.20160901.1790.

Loncaric, S. (1998), A survey of shape analysis techniques, *Pattern Recognit.* 31.8, 983–1001. ISSN: 00313203. DOI: 10.1016/S0031-2023(97)00122-2.

Megha Goyal (2011), Morphological Image Processing, *Pract. Image Video Process. Using ...* 8491.4, 161–165. ISSN: 0024094X. DOI: 10.1117/1.2744044. URL: <http://onlinelibrary.wiley.com/doi/10.1002/9781118093467.ch13/summary>.

Mingqiang, Y., Kidiyo, K. ve Joseph, R. (2008), A Survey of Shape Feature Extraction Techniques, *Pattern Recognit. Tech. Technol. Appl.* DOI: 10.5772/6237. URL: http://www.intechopen.com/books/pattern_recognition_techniques_technology_and_applications/a_survey_of_shape_feature_extraction_techniques.

KAYNAKLAR DİZİNİ (devam)

Mukherjee, I. ve Schapire, R. E. (2011), A theory of multiclass boosting, 14, 437–497. ISSN: 1532-4435. DOI: citeulike-article-id:8467733. arXiv: 1108.2989. URL: <http://arxiv.org/abs/1108.2989>.

Njoroge, J., Ninomiya, K., Kondo, N. ve Toita, H. (2002), Automated fruit grading system using image processing, *Proc. 41st SICE Annu. Conf. SICE 2002*. 2, 0–5. DOI: 10.1109/SICE.2002.1195388.

Piccardi, M. (2004), Background subtraction techniques: a review, *2004 IEEE Int. Conf. Syst. Man Cybern. (IEEE Cat. No.04CH37583)* 4, 3099–3104. ISSN: 1062-922X. DOI: 10.1109/ICSMC.2004.1400815. URL: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=1400815>.

Rafael C. Gonzalez ve Richard E. Woods (2007), Digital Image Processing, *Digit. Image Process.* ISSN: 1098-6596. DOI: 10.1017/CB09781107415324.004. arXiv: arXiv:1011.1669v3.

Rong, D., Rao, X. ve Ying, Y. (2017), Computer vision detection of surface defect on oranges by means of a sliding comparison window local segmentation algorithm, *Comput. Electron. Agric.* 137, 59–68. ISSN: 01681699. DOI: 10.1016/j.compag.2017.02.027. URL: <http://dx.doi.org/10.1016/j.compag.2017.02.027>.

Saeed, K., Tabędzki, M., Rybniak, M. ve Adamski, M. (2010), K3M: A universal algorithm for image skeletonization and a review of thinning techniques, *Int. J. Appl. Math. Comput. Sci.* 20.2, 317–335. ISSN: 1641876X. DOI: 10.2478/v10006-010-0024-4.

KAYNAKLAR DİZİNİ (devam)

Saito, Y., Hatanakat, T., Shigetot, K., Factory, S., Electric, M., Sciences, P. ve Zosen, H. (2003), Eggplant Classification Using Artificial Neural Network, *Ieee* 2, 1013–1018.

Schapiro, R. E. (1999), A Short Introduction to Boosting, *Society* 14.5, 771–780. ISSN: 10450823. DOI: 10.1.1.112.5912. arXiv: arXiv:1508.01136v1.

Szeliski, R. (2011), Image processing, *Comput. Vis. Algorithms Appl.* London: Springer London, 87–180. ISBN: 978-1-84882-935-0. DOI: 10.1007/978-1-84882-935-0_3. URL: [https://doi.org/10.1007/978-1-84882-935-0{_}3](https://doi.org/10.1007/978-1-84882-935-0_{_}3).

TÜİK (2017), *Meyvesi için yetiştirilen sebzeler, 1988-2017*. techreport. Türkiye İstatistik Kurumu, 1. URL: <http://www.tuik.gov.tr>.

— (2018), *Bitkisel ürün denge tabloları; "Sebzeler" 2000/'01-2016/'17*. techreport. Türkiye İstatistik Kurumu, 1. URL: <http://www.tuik.gov.tr>.

Theodoridis, S. ve Koutroumbas, K. (2009), Chapter 1 - Introduction, *Pattern Recognit. (Fourth Ed.* Ed. S. Theodoridis ve K. Koutroumbas. Fourth Edi. Boston: Academic Press, 1–12. ISBN: 978-1-59749-272-0. DOI: <https://doi.org/10.1016/B978-1-59749-272-0.50003-7>. URL: <http://www.sciencedirect.com/science/article/pii/B9781597492720500037>.

United States Department of Agriculture (2016), Peppers Shipping Point and Market Inspection, March.

KAYNAKLAR DİZİNİ (devam)

Wang, Z. ve Xue, X. (2014), Support Vector Machines Applications, 23–49. ISSN: 0883-4237.
DOI: 10.1007/978-3-319-02300-7. URL: <http://link.springer.com/10.1007/978-3-319-02300-7>.

Yörük, E., Duta, H. ve Sankur, B. (2005), Hand Based Biometry, 5685.90, 1106–1115. ISSN:
0277786X. DOI: 10.1117/12.587815.