



T.C.

SELÇUK ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

YAPAY ZEKA TEKNİKLERİ KULLANILARAK PİRİNÇ ÇEŞİTLERİNİN SINIFLANDIRILMASI

İlkay ÇINAR

YÜKSEK LİSANS TEZİ

Bilgisayar Mühendisliği Anabilim Dalı

Aralık-2019
KONYA
Her Hakkı Saklıdır

ÖZET

YÜKSEK LİSANS

YAPAY ZEKA TEKNİKLERİ KULLANILARAK PİRİNÇ ÇEŞİTLERİNİN SINIFLANDIRILMASI

İlkay ÇINAR

Selçuk Üniversitesi Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Murat KÖKLÜ

2019, 123 Sayfa

Jüri
Dr. Öğr. Üyesi Murat KÖKLÜ
Dr. Öğr. Üyesi İlker Ali ÖZKAN
Dr. Öğr. Üyesi Muhammed Fahri ÜNLERŞEN

Dünya genelinde üretim ve tüketim değerleri en fazla olan tahıl ürünleri grubundan pirinç, ülkemizde de ekonomik ve besleyici olması açısından ana besin maddeleri arasında yerini almaktadır. Pirinç, tarladan sofralara gelinceye kadar bazı üretim aşamalarından geçmektedir. Bu aşamalardan temizleme, pirincin istenmeyen maddelerden ayrıştırılmasıdır. Sınıflandırma aşamasında sağlam olanlar ile kırık olanlar ayrıştırılır ve boylama işlemleri gerçekleştirilir. Son olarak renklere göre ayıklama aşamasında ise pirinç tanesi yüzeyinde bulunan beyazlık dışındaki çizgili ve lekeli olanların ayrıştırılması işlemi gerçekleştirilir.

Bu tez çalışmasında, morfolojik, şekil ve renk özellikleri kullanılarak sınıflandırma işlemlerinin gerçekleştirilmesi için aynı markaya ait beş farklı pirinç çeşidi seçilmiştir. Her pirinç çeşidine ait 15 bin adet olmak üzere toplam 75 bin adet pirinç tanesi görüntüsü elde edilmiştir. Görüntüler, MATLAB yazılımı kullanılarak ön işlemlerden geçirilmiş ve özellik çıkarımına hazırlanmıştır. Görüntülerden, 12 adet morfolojik özellik, morfolojik özellikler kullanılarak elde edilen 4 adet şekil özelliği de eklenerek toplam 16 özellik, beş farklı renk uzayından elde edilen 90 adet renk özellikleri ile son olarak morfolojik, şekil ve renk özellikleri bir arada kullanılarak 106 adet özellik çıkarımı yapılmıştır. Sınıflandırma için, yapay zeka tekniklerinden k-en yakın komşu, karar ağacı, lojistik regresyon, çok katmanlı algılayıcı, rastgele orman ve destek vektör makineleri algoritmaları ile modeller oluşturularak 12, 16, 90 ve 106 adet olan özellik kümeleri için performans ölçüm değerleri elde edilmiştir. Modeller içerisinde ortalama sınıflandırma doğruluğu en yüksek olan algoritmaların başarıları, morfolojik özellikler için rastgele orman algoritması ile %97.99, morfolojik ve şekil özelliklerinin bir arada kullanıldığı özellikler için rastgele orman algoritması ile %98.04, renk özellikleri için lojistik regresyon algoritması ile %99.25, son olarak morfolojik, şekil ve renk özelliklerinin birlikte kullanıldığı özellikler için çok katmanlı algılayıcı algoritması ile %99.91 olarak elde edilmiştir.

Sonuçlar incelendiğinde eklenen her yeni özellik ile sınıflandırma başarılarının arttığı görülmektedir. Elde edilen performans ölçüm değerlerine bakıldığında çalışmanın pirinç çeşitlerini sınıflandırmada başarıya ulaştığını söylemek mümkündür.

Anahtar Kelimeler: Görüntü işleme, yapay zeka teknikleri, morfolojik özellikler, pirinç sınıflandırma, renk özellikleri, şekil özellikleri

ABSTRACT

MS THESIS

CLASSIFICATION OF RICE VARIETIES USING ARTIFICIAL INTELLIGENCE TECHNIQUES

İlkay ÇINAR

THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCE OF SELÇUK UNIVERSITY
THE DEGREE OF MASTER OF SCIENCE
IN COMPUTER ENGINEERING

Advisor: Asst. Prof. Dr. Murat KÖKLÜ

2019, 123 Pages

Jury
Asst. Prof. Dr. Murat KÖKLÜ
Asst. Prof. Dr. İlker Ali ÖZKAN
Asst. Prof. Dr. Muhammed Fahri ÜNLERŞEN

Rice, which has the highest production and consumption values in the worldwide, is among the main nutrients in terms of being economical and nutritious in our country as well. Rice goes through some stages of production from the field to the dinner tables. The cleaning phase is the separation of rice from unwanted substances. During the classification phase, solid ones and broken ones are separated and calibration operations are performed. Finally, in the process of extraction according to the colors, the striped and stained ones other than the whiteness on the surface of the rice grain are separated.

In this thesis, five different varieties of rice belonging to the same trademark were selected to carry out classification operations using morphological, shape and color features. A total of 75 thousand rice grain images, including 15 thousand for each varieties, were obtained. The images were pre-processed using MATLAB software and prepared for feature extraction. 12 morphological features, using a combination of 12 morphological and 4 shape features a total of 16 features, 90 color features obtained from five different color spaces and finally using a combination of morphological, shape and color features 106 features were inferred from the images. For classification, from machine learning techniques k-nearest neighbor, decision tree, logistic regression, multilayer perceptron, random forest and support vector machines with algorithms, models were created. With these models, performance measurement values were obtained for feature sets of 12, 16, 90 and 106. Among the models, the success of the algorithms with the highest average classification accuracy was achieved 97.99% with random forest for morphological features. 98.04% were obtained with random forest for morphological and shape features. It was achieved with logistic regression as 99.25% for color features. Finally, 99.91% was obtained with multilayer perceptron for morphological, shape and color features.

When the results are examined, it is observed that with each new feature added, the success of classification increases. Based on the performance measurement values obtained, it is possible to say that the study achieved success in classifying rice varieties.

Keywords: Color features, image processing, machine learning techniques, morphological features, rice classification, shape features

ÖNSÖZ

Öncelikle hayatım boyunca maddi manevi her anlamda beni destekleyen ailem başta olmak üzere sabrını ve desteğini eksik etmeyen sevgili eşime teşekkür ederim. Ayrıca her daim desteğini, bilgisini ve tecrübesini esirgemeyen danışmanım Dr. Öğr. Üyesi Murat KÖKLÜ hocama teşekkürü borç bilirim.

İlkay ÇINAR
KONYA-2019

İÇİNDEKİLER

ÖZET ..... **iv**

ABSTRACT ..... **v**

ÖNSÖZ ..... **vi**

İÇİNDEKİLER ..... **vii**

SİMGELER VE KISALTMALAR ..... **x**

1. GİRİŞ **1**

2. KAYNAK ARAŞTIRMASI **3**

3. TAHIL ÜRÜNLERİ **10**

3.1. Tahılın Tanımı ve Önemi 10
3.2. Tahıl Türleri ve Sınıflandırması 10
3.2.1. Buğday 11
3.2.2. Arpa 11
3.2.3. Çeltik-Pirinç 12
3.2.4. Mısır 13
3.2.5. Yulaf 14
3.2.6. Çavdar 15
3.3 Tahıl Ürünlerinin Dünya'daki ve Türkiye'deki Üretim Miktarları 15
3.4. Tahıl Tane Yapısı ve Fiziksel Özellikleri 16
3.5. Tahıl Ürünlerini Ayrıştırma Yöntemleri 18
3.5.1. Kuru temizleme 18
3.5.2. El ile ayrıştırma 20
3.5.3. Renklerine göre ayrıştırma 21
3.5.4. Kalibrasyon (Boylama) 22
3.6. Bölüm Değerlendirmesi 23

4. GÖRÜNTÜ İŞLEME **24**

4.1. Görüntü İşleme Nedir? 24
4.2. Görüntünün Elde Edilmesi İşlemleri 24
4.3. Dijital Görüntü ve Türleri 25
4.4. Renk Uzayları 27
4.4.1. RGB renk uzayı 27
4.4.2. HSV renk uzayı 28
4.4.3. L*a*b* renk uzayı 29
4.4.4. YCbCr renk uzayı 30
4.4.5. XYZ renk uzayı 30
4.5. Görüntü İşleme Teknikleri 31
4.6. Bölüm Değerlendirmesi 32

5. YAPAY ZEKA 33

5.1. Yapay Zekanın Tanımı 33
5.2. Yapay Zeka ile İlişkili Disiplinler 33
5.3. Yapay Zeka Yöntemleri 35
5.3.1. k-En yakın komşu 35
5.3.2. Karar ağacı 36
5.3.3. Lojistik regresyon 37
5.3.4. Çok katmanlı algılayıcılar 38
5.3.5. Rastgele orman 39
5.3.6. Destek vektör makinesi 39
5.4. Bölüm Değerlendirmesi 40

6. MATERYAL VE YÖNTEM 41

6.1. Görüntünün Elde Edilmesi 41
6.2. Görüntü İşleme 42
6.3. Özellik Çıkarımı 43
6.4. Performans Ölçümleri 49
6.5. Çapraz Doğrulama 51
6.6. Kappa Testi 52
6.7. Pirinç Veriseti 53
6.8. Bölüm Değerlendirmesi 69

7. ARAŞTIRMA SONUÇLARI VE TARTIŞMA 70

7.1. K-En Yakın Komşu Algoritması Sonuçları 70
7.1.1. Morfolojik özelliklerden elde edilen sonuçlar 70
7.1.2. Morfolojik ve şekil özelliklerinden elde edilen sonuçlar 71
7.1.3. Renk özelliklerinden elde edilen sonuçlar 72
7.1.4. Morfolojik, şekil ve renk özelliklerinden elde edilen sonuçlar 73
7.2. Karar Ağacı Algoritması Sonuçları 74
7.2.1. Morfolojik özelliklerden elde edilen sonuçlar 74
7.2.2. Morfolojik ve şekil özelliklerinden elde edilen sonuçlar 75
7.2.3. Renk özelliklerinden elde edilen sonuçlar 76
7.2.4. Morfolojik, şekil ve renk özelliklerinden elde edilen sonuçlar 77
7.3. Lojistik Regresyon Algoritması Sonuçları 78
7.3.1. Morfolojik özelliklerden elde edilen sonuçlar 78
7.3.2. Morfolojik ve şekil özelliklerinden elde edilen sonuçlar 79
7.3.3. Renk özelliklerinden elde edilen sonuçlar 79
7.3.4. Morfolojik, şekil ve renk özelliklerinden elde edilen sonuçlar 80
7.4. Çok Katmanlı Algılayıcı Algoritması Sonuçları 81
7.4.1. Morfolojik özelliklerden elde edilen sonuçlar 81
7.4.2. Morfolojik ve şekil özelliklerinden elde edilen sonuçlar 82
7.4.3. Renk özelliklerinden elde edilen sonuçlar 83
7.4.4. Morfolojik, şekil ve renk özelliklerinden elde edilen sonuçlar 84
7.5. Rastgele Orman Algoritması Sonuçları 85
7.5.1. Morfolojik özelliklerden elde edilen sonuçlar 85
7.5.2. Morfolojik ve şekil özelliklerinden elde edilen sonuçlar 86
7.5.3. Renk özelliklerinden elde edilen sonuçlar 87
7.5.4. Morfolojik, şekil ve renk özelliklerinden elde edilen sonuçlar 88

7.6. Destek Vektör Makinesi Algoritması Sonuçları 89
7.6.1. Morfolojik özelliklerden elde edilen sonuçlar 89
7.6.2. Morfolojik ve şekil özelliklerinden elde edilen sonuçlar 90
7.6.3. Renk özelliklerinden elde edilen sonuçlar 90
7.6.4. Morfolojik, şekil ve renk özelliklerinden elde edilen sonuçlar 91
7.7. Tüm Algoritmalara Ait Performans Ölçüm Sonuçları 92
7.7.1. Morfolojik özelliklerden elde edilen sonuçlar 92
7.7.2. Morfolojik ve şekil özelliklerinden elde edilen sonuçlar 94
7.7.3. Renk özelliklerinden elde edilen sonuçlar 95
7.7.4. Morfolojik, şekil ve renk özelliklerinden elde edilen sonuçlar 96
7.8. Grafik Arayüzü Tasarımı 98
7.9. Bölüm Değerlendirmesi 100

8. SONUÇLAR VE ÖNERİLER 101

8.1 Sonuçlar 101
8.2 Öneriler 103

KAYNAKLAR 104

ÖZGEÇMİŞ 112

SİMGELER VE KISALTMALAR

Simgeler

%	: Yüzde
=	: Eşittir
+	: Artı
-	: Eksi
<	: Küçüktür
>	: Büyüktür
∑	: Toplam
π	: pi
√	: Karekök
log	: Logaritma

Kısaltmalar

A	: Alan (Area)
B	: Basıklık (Kurtosis)
ANN	: Yapay Sinir Ağı (Artificial Neural Network)
BP-ANN	: Geri Yayılım Algoritması (Back Propagation Artificial Neural Network)
BPSO	: İkili Parçacık Sürüsü Optimizasyonu (Binary Particle Swarm Optimization)
CCD	: Charge-Coupled Device
Ç	: Çevre (Perimeter)
Çr	: Çarpıklık (Skewness)
DA	: Diskriminant Analizi (Discriminant Analysis)
DBA	: Dışbükey Alan (Convex Area)
DC	: Doğru akım (Direct Current)
DN	: Doğru Negatif (True Negative)
DP	: Doğru Pozitif (True Positive)
DT	: Karar Ağaçları (Decicion Tree)
E	: Entropi (Entropy)
EBO	: En Boy Oranı (Aspect Ratio)
EÇ	: Eşdeğer Çap (Equivalent Diameter)
Eks	: Eksantriklik (Eccentricity)
GA	: Genetik Algoritma (Genetic Algorithm)
GLCM	: Gri Seviye Eş Oluşum Matrisi (Gray Level Co-occurrence Matrix)
GLRM	: Gri Seviye Çalışma Uzunluğu Matrisi (Gray Level Run-length Matrix)
HSV	: Renk Tonu, Doygunluk, Değer (Hue, Saturation, Value)
ICA	: Bağımsız Bileşen Analizi (Independent Component Analysis)
K	: Kapsam (Extent)
K-NN	: K-En Yakın Komşu (K-Nearest Neighbors)
Ko	: Kompaktlık (Compactness)
l	: Küçük Eksen Uzunluğu (Minor Axis Lenght)
L	: Ana Eksen Uzunluğu (Major Axis Lenght)
L*a*b*	: Açıklık, Kırmızı/Yeşil, Sarı/Mavi (Lightness, Red/Green, Yellow/Blue)
LBP	: Yerel İkili Modeli (Local Binary Pattern)
LDA	: Doğrusal Diskriminant Analizi (Linear Discriminant Analysis)
LR	: Lojistik Regresyon (Logistic Regression)

LSN	: Yerel Benzerlik Numaraları (Local Similarity Numbers)
LSP	: Yerel Benzerlik Modelleri (Local Similarity Pattern)
M-SVM	: Çok Sınıflı Destek Vektör Makinaları (Multi-class Support Vector Machine)
MLP	: Çok Katmanlı Algılayıcılar (Multilayer Perceptrons)
NDA	: Doğrusal Olmayan Diskriminant Analizi (Non-linear Discriminant Analysis)
Ort	: Ortalama (Mean)
PAL	: Faz Değiştirme Hattı (Phase Alternation Line)
PCA	: Temel Bileşen Analizi (Principal Component Analysis)
PCB	: Baskı Devre Kartı (Printed Circuit Board)
RF	: Rastgele Orman (Random Forest)
RGB	: Kırmızı Yeşil Mavi (Red Green Blue)
SPSS	: Sosyal Bilimler İçin İstatistik Programı (Statistical Package for the Social Sciences)
S	: Sertlik (Solidty)
SF1	: Şekil Faktörü 1 (Shape Factor 1)
SF2	: Şekil Faktörü 2 (Shape Factor 2)
SF3	: Şekil Faktörü 3 (Shape Factor 3)
SF4	: Şekil Faktörü 4 (Shape Factor 4)
SS	: Standart Sapma (Standard Deviation)
SVM	: Destek Vektör Makinesi (Support Vector Machine)
TMO	: Toprak Mahsulleri Ofisi
V	: Varyans (Variance)
XYZ	: Kırmızı Bileşen, Parlaklık, Mavi Bileşen (Red Component, Luminance, Blue Component)
Y	: Yuvarlaklık (Roundness)
YCbCr	: Parlaklık, Mavi Fark Kroma, Kırmızı Fark Kroma (Luminance, Blue Difference Chroma, Red Difference Chroma)
YN	: Yanlış Negatif (False Negative)
YP	: Yanlış Pozitif (False Pozitive)

1. GİRİŞ

Dünya genelinde tahıl ürünlerinin üretim değerlerine bakıldığında, buğday ve mısırın ardından en önemli ürün pirinçtir. Pirinç, karbonhidrat ve nişasta bakımından oldukça zengin bir tahıl ürünüdür. Ayrıca besleyici ve ekonomik olması açısından dünya genelinde olduğu gibi ülkemizde de insan beslenmesinde büyük öneme sahip olup, aynı zamanda da sanayi alanında yaygın olarak kullanılmaktadır (Şapaloğlu, 2015).

Ülkemizde üretimi yapılan pirinç çeşitleri için farklı kalite kriterleri mevcuttur. Bunlar; fiziksel görünüm, pişme özellikleri, tat ve aroma özelliklerinin yanında randıman gibi hususlardır. Nihai tüketici açısından bakıldığı zaman, market raflarında paket içerisinde satılan pirinç çeşitlerinde öne çıkan kriterlerden fiziksel görünüm akla ilk gelendir (Mutafçılar, 2019).

Bu çalışmada, 5 farklı pirinç çeşidi için görüntü işleme teknikleri kullanılarak özellik çıkarımı ve sınıflandırma işlemleri gerçekleştirilmiştir. Çalışmada, Arborio, Basmati, İpsala, Jasmine ve Karacadağ çeşitleri kullanılmıştır.

Öncelikle her çeşit için 15 bin adet olmak üzere toplamda 75 bin adet pirinç tane görüntüsü elde edilmiştir. Elde edilen görüntüler, özellik çıkarma ve sınıflandırma işlemlerinin en doğru biçimde gerçekleştirilebilmesi açısından MATLAB yazılımı kullanılarak çeşitli ön işlemlerden geçirilerek özellik çıkarımı aşamasına hazırlanmıştır. Ön işlemlerden geçirilen görüntüler için 12 adet morfolojik, 16 adet morfolojik ve şekil, 90 adet renk ve son olarak morfolojik, şekil ve renk özelliklerinin birlikte değerlendirildiği toplam 106 adet özellik çıkarımı gerçekleştirilmiştir. Sınıflandırma işlemleri için en bilinen yapay zeka tekniklerinden olan k-en yakın komşu (k-NN), karar ağacı (DT), lojistik regresyon (LR), çok katmanlı algılayıcı (MLP), rastgele orman (RF) ve destek vektör makineleri (SVM) kullanılmıştır. Sınıflandırma işlemleri sonrası her özellik kümesine ait çok sınıflı sınıflandırma performans ölçümleri için karmaşıklık matris değerleri hesaplanmıştır.

Bu tez çalışmasının ana hatları aşağıda verilmiştir;

Birinci bölüm olan giriş bölümünde, çalışmanın temel çerçevesi açıklanmıştır.

İkinci bölümde, çeşitli tahıl ürünleri üzerine görüntü işleme teknikleri kullanılarak özellik çıkarımı ve sınıflandırma işlemleri gerçekleştirilen mevcut çalışmalara değinilmiştir.

Üçüncü bölümde, tahıl ürünleri hakkında genel bilgiler verilmiş, dünyada ve ülkemizdeki üretim miktarlarına değinilmiş ve tahıl ürünlerinin ayrıştırılma yöntemlerinden bahsedilmiştir.

Dördüncü bölümde, görüntü işleme hakkında genel bilgiler verilmiş ve dijital görüntüler ile renk uzayları anlatılmıştır.

Beşinci bölümde, yapay zeka konusuna değinilmiş ve çalışmada kullanılan yapay zeka yöntemleri açıklanmıştır.

Altıncı bölümde, çalışmada kullanılan pirinç çeşitlerine ait görüntülerin elde edilmesi işlemleri, görüntülerin işlenmesi ve özellik çıkarımları hakkında bilgilere yer verilerek sınıflandırma ve performans ölçümleri sonucunda elde edilen veriler paylaşılmıştır.

Yedinci bölümde, morfolojik özellikler, morfolojik ve şekil özellikleri, renk özellikleri ve morfolojik, şekil ve renk özelliklerinin birlikte değerlendirildiği özellik kümeleri kullanılarak, algoritmalardan elde edilen sonuçlar verilmiş ve yorumlanmıştır. Ayrıca MATLAB GUI ortamında geliştirilen arayüz ile ilgili bilgilere yer verilmiştir.

Sekizinci bölüm olan sonuçlar ve öneriler bölümünde elde edilen sonuçlar hakkında genel bir değerlendirme yapılarak öneriler belirtilmiştir.

2. KAYNAK ARAŞTIRMASI

Tahıl ürünleri üzerinde makine görme sistemleri ve görüntü işleme teknikleri kullanılarak son yıllarda yapılan çalışmalara bakıldığında ürünlerin renk, doku, kalite ve boyut gibi pek çok fiziksel özellik bakımından incelendiği görülmektedir.

Gunasekaran ve ark. (1987) tarafından, mısır taneleri üzerindeki stres çatlaklarını tespit etmek için bir görüntü işleme algoritması geliştirmişlerdir. Tane görüntüleri, geliştirilen algoritma yardımıyla işlendiğinde, stres çatlaklarına karşılık gelen beyaz çizgiler ürettiğini görmüşlerdir. Tane üzerinde çoklu stres çatlaklarını tespit etmenin tekli çatlak olanlara göre daha kolay olduğunu belirtmişlerdir. Tek ve çoklu çatlakların verimli şekilde algılanması için aydınlatmanın önemine değinmişlerdir (Gunasekaran ve ark., 1987).

Han ve ark. (1996) tarafından yapılan çalışmada, mısır taneleri üzerinde stres çatlaklarını incelemek için iki boyutlu Fourier Dönüşümü kullanarak sınıflandırma işlemi gerçekleştirmişlerdir. Tane üzerinde çatlağı tanımlayabilmek için iyileştirme tekniklerinden kontrast geliştirme ve kenar belirleme gibi çeşitli tekniklerini uygulamışlardır. Stres çatlakları sınıflandırma kriterlerini geliştirmek için çok değişkenli diskriminant analizi ve çoklu regresyon analizinden faydalanmışlardır (Han ve ark., 1996).

Luo ve ark. (1999) yaptıkları çalışmada, sağlam ve farklı hasarlara sahip buğday tanelerinin tanımlanması için renkli makine görme sistemi kullanmışlardır. Renk ve morfolojik özellikler kullanılarak parametrik ve parametrik olmayan istatistiksel sınıflandırma yöntemlerini kullanmışlardır. En iyi sonuca parametrik olmayan bir sınıflandırıcı ile ulaşmışlardır (Luo ve ark., 1999).

Yadav ve Jindal (2001) çalışmalarında, öğütülmüş pirinçlerin, beyazlık kontrolünü yapmak ve kırılmış çekirdek yüzdesini belirlemek için dijital görüntü analizi yaparak pirinç tanesinin uzunluk, çevre ve şekil özelliklerini çıkartarak niceliklerini hesaplamıştır (Yadav ve Jindal, 2001).

Visen ve ark. (2003) tarafından yapılan çalışmada, görüntü işleme teknikleri ve yapay sinir ağı kullanılarak arpa, yulaf, çavdar, buğday ve makarnalık buğday olmak üzere beş çeşit tahıl türünün renkli görüntülerini elde ederek analiz etmek için algoritmalar geliştirmişlerdir. Elde edilen görüntüleri 150'den fazla renk ve dokusal özellik üzerinden, bilinmeyen taneleri tanımlamak için yapay sinir ağı temelli bir

sınıflandırıcı geliştirmişlerdir. Bilinmeyen tanelerin tanımlanmasında tüm tahıl türleri için %90'ın üzerinde başarı oranı yakalamışlardır (Visen ve ark., 2003).

Baykan ve ark. (2005) yaptıkları çalışmada, buğday taneleri kullanılarak elde edilen görüntülerin her biri için 9 adet morfolojik özellik ile tanenin gri seviye ortalamasını elde etmişlerdir. Sınıflandırma için yapay sinir ağları tekniklerinden çok katmanlı algılayıcılardan faydalanmışlardır. 5 farklı buğday türü için sınıflandırmada %72.62 başarı elde etmişlerdir. Tanımlaması zor bir türü sınıflandırmadan çıkardıklarında ise başarının %82.65'e ulaştığı görülmüştür (Baykan ve ark., 2005).

Dubey ve ark. (2006) tarafından yapılan çalışmada, üç farklı ekmeklik buğday çeşidini sınıflandırmışlardır. Yapay sinir ağı sınıflandırması için 45 adet morfolojik özellik kullanmışlardır. Sınıflandırmada özellik sayısının artmasının, başarı oranını da artırdığı görülmüştür. Sınıflandırma doğruluğu olarak tüm ürünler için yaklaşık %88 başarı elde etmişlerdir (Dubey ve ark., 2006).

Demirbaş ve Dursun (2007) tarafından yapılan çalışmada, ekmeklik ve makarnalık türünden 13 farklı buğday çeşidinin görüntü işleme tekniği ile morfolojik özelliklerinin belirlenmesini amaçlamışlardır. Görüntü işleme programı olarak UTHSCSA Image Tool Version 3.0 programını kullanarak görüntüler değerlendirilmiştir. Sonuç olarak el ile ve görüntü işleme ile elde ölçüm sonuçlarının yakın olması, buğday tanelerine ait fiziksel özelliklerinin bazılarının belirlenmesinde görüntü işleme tekniğinin kullanılabileceği kanısına varmışlardır (Demirbaş ve Dursun, 2007).

Zhixing ve ark. (2008) tarafından yapılan çalışmada, genetik algoritma (GA) ve İstatistiksel Program (SPSS) ile birlikte destek vektör makinesi (SVM) kullanılarak sarı mısır tanelerinin beyaz kısmındaki (embriyo) ile sarı kısmındaki tohumun (taç) oranını tespit etmeyi amaçlamışlardır. Renkleri ve şekilleri farklı olan mısır tohumlarının görüntülerini ve verilerini analiz ederek, beyaz kısmın sarı kısma göre daha değerli olduğunu ve sarı kısmın renk özelliklerinin, mısır çeşitlerini tanımlamak için daha belirleyici olduğunu belirtmişlerdir (Zhixing ve ark., 2008).

Zapotoczny ve ark. (2008) tarafından yapılan çalışmada, arpanın varietal sınıflandırması için görüntü analizi tekniği kullanmışlardır. Beş farklı arpa çeşidinin sınıflandırılmasında morfolojik özelliklerin faydasına değinmişlerdir. Çalışmada her bir arpa çeşidinin 74 adet morfolojik özelliğini çıkarmışlardır. Sınıflandırma yöntemi olarak temel bileşen analizi (PCA), doğrusal diskriminant analizi (LDA) ve doğrusal olmayan

diskriminant analizlerini (NDA) kullanmışlardır. Sonuç olarak morfolojik özellikleri kullandıkları yöntemin, arpa varietal tanımlaması için başarılı olarak kullanılabileceği sonucuna varmışlardır. Ayrıca sınıflandırma yöntemleri içerisinde LDA'nın en iyi yöntem olduğunu belirtmişlerdir (Zapotoczny ve ark., 2008).

Choudhary ve ark. (2008) tarafından yapılan çalışmada, bir alan tarama kamerası yardımıyla CWRS ve CWAD buğdayı, arpa, yulaf ve çavdar çekirdeklerinden aldıkları görüntüler üzerine lineer ve istatistiksel sınıflandırıcılar ile sınıflandırma çalışması gerçekleştirmişlerdir. Her bir çekirdekten toplam 51 morfolojik özellik, 93 renk özelliği, 56 dokusal özellik ve 135 dalgacık özelliği çıkarılmıştır. Sınıflandırma sonucunda CWRS buğdayı için %99.4, CWAD buğdayı için %89.4, çavdar için %99.3, arpa için %98.6 ve yulaf için %98.5 doğruluk oranı elde etmişlerdir (Choudhary ve ark., 2008).

Chen ve ark. (2010) çalışmalarında, 5 adet mısır çeşidi üzerinden elde edilen görüntülerden 17 geometrik, 13 şekil ve 28 renk özelliği çıkarılmıştır. Yapay sinir ağı modeli ile mısır çeşitleri arasındaki sınıflandırma başarısının ortalama %90 seviyesinde olduğunu tespit etmişlerdir (Chen ve ark., 2010).

Babalık ve ark. (2010) tarafından yapılan çalışmada, çok sınıflı destek vektör makineleri (M-SVM) ve ikili parçacık sürüsü optimizasyonu (BPSO) algoritması ile 5 adet buğday türüne ait dijital görüntülerden 9 geometrik ve 3 renk özelliği çıkarılarak sınıflandırılması yapılmıştır. M-SVM algoritması ile %91.5, BPSO algoritması ile %92.02 ortalama sınıflandırma doğruluğu elde etmişlerdir (Babalık ve ark., 2010).

Xia ve ark. (2010) tarafından yapılan çalışmada, buğday görüntülerinden 7 morfolojik parametre ve 6 renk parametresine göre sınıflandırma yapmışlardır. Sonuç olarak doğrusal olmayan dönüşüm algoritmalarına dayalı renk parametrelerinin, morfolojik parametrelerin aksine, çimlendirilmiş buğday ve küflü buğdayları tanımlamak için daha uygun olduğunu belirtmişlerdir (Xia ve ark., 2010).

Aggarwal ve Mohan (2010) tarafından yapılan çalışmada, pirinçlerin tane kalitesi için görüntü işleme tekniği kullanılarak en ve boy oranı analizini gerçekleştirmişlerdir. Analizin yapılmasında amaç, marketlerde satılan ve büyüklüklerine göre fiyatlandırılan üç farklı sınıftan (tam, yarı ve kırılmış) numune alınarak karışımlarını incelemek ve piyasadaki referans en boy oranını belirlemektir (Aggarwal ve Mohan, 2010).

Ouyang ve ark. (2010) yaptıkları çalışmada, farklı pirinç tohumlarını ayırt etmek için görüntü işleme tekniği kullanılarak otomatik görüntü alan bant sistemi tasarlanmıştır.

5 farklı pirinç tohumu bant sistemi üzerinden geçerken CCD kamera kullanılarak görüntüleri toplanmıştır. Görüntü analizi Visual C++ 6.0 ile yapılmıştır. Geri yayılım sınıflandırması (BP-ANN) kullanılarak 5 farklı pirinç çeşidi olan Xiannong (No 5), Jinyougui, Xiannong, Medium you 463 türleri için ortalama başarı oranı %86.65 olarak elde edilmiştir (OuYang ve ark., 2010).

Kiratiratanapruk ve Sinthupinyo (2011) tarafından yapılan çalışmada, mısır tohumlarının renk ve doku özelliklerini çıkararak destek vektör makinesi (SVM) tipi sınıflandırıcıyı kullanarak 10 binden fazla örnek üzerinde sınıflandırma yapmışlardır. Sınıflandırma sonunda normal tohumlar için %95.6, kusurlu tohumlar için %80.6 başarı oranına ulaşmışlardır (Kiratiratanapruk ve Sinthupinyo, 2011).

Guevara-Hernandez ve Gil (2011) tarafından yapılan çalışmada, buğday ve arpa tanelerinde nesne sınıflandırılması, diskriminant analizi (DA) ve K-en yakın komşular (K-NN) algoritmalarıyla gerçekleştirilmiştir. Yapılan sınıflandırma sonucunda, yüksek bir sınıflandırma sonucuna ulaşıldığı belirtilmiştir. Morfolojik özellikler, renk ve doku özelliklerinin bir arada kullanılmasının sonuçta daha iyi doğruluk sunacağını belirtmişlerdir. Ayrıca maksimum yarıçapın ve ortalamaların gri seviye eş oluşum matrisi (GLCM) kullanılarak çıkarılmasının en yüksek sınıflandırma doğruluğunu sağladığını belirtmişlerdir (Guevara-Hernandez ve Gil, 2011).

Pourreza ve ark. (2012) tarafından yapılan çalışmada, İran'da yetişen dokuz farklı buğday tohumu çeşidinin çeşitliliğini görüntülerinden tespit etmeye çalışmıştır. Her çeşitten 120 adet görüntü elde edilmiştir. Toplam 131 dokusal özelliği, gri seviye, gri seviye eş oluşum matris (GLCM), gri seviye çalışma uzunluğu matrisi (GLRM), yerel ikili modeller (LBP), yerel benzerlik modelleri (LSP) ve yerel benzerlik numaraları (LSN) matrislerinden elde etmişlerdir. Sınıflandırma için doğrusal ayırt edici analiz (LDA) sınıflandırıcı kullanmışlar ve seçilen tüm özelliklerin ilk 50'si kullanıldığında, %98.15'lik ortalama sınıflandırma doğruluğu elde etmişlerdir (Pourreza ve ark., 2012).

Szczypiński ve Zapotoczny (2012) gerçekleştirdikleri çalışmada, arpa çekirdeğinin tespiti ve yüzey yapısının değerlendirilmesi için bir algoritma geliştirilmiştir. Algoritma ile, görüntüleri alınan çekirdeklerin pürüzlü ve pürüzsüz bölgeleri belirlenerek ortalama %99'luk bir başarı oranına ulaşmışlardır. Bu sayede çekirdeklerin kalite değerlendirilmesinin yapılabileceğini belirtmişlerdir (Szczypiński ve Zapotoczny, 2012).

Farahani (2012) tarafından yapılan çalışmada, Showa, Altar 84, Altar 84-3, Dipper ve Bushen isimli 5 adet makarnalık buğday çeşidinin morfolojik özelliklerini görüntü işleme tekniğiyle çıkarmayı amaçlamıştır. Doğrusal ayrımcılık analizleri için beş özellik kümesi kullanılmıştır. 11 adet morfolojik özellik kullanılarak yapılan ayrımcılık analizinde en iyi sonuç olan %67.66 sınıflandırma doğruluğu elde etmişlerdir (Farahani, 2012).

Silva ve Sonnadara (2013) tarafından yapılan çalışmada, pirinç çeşitlerini sınıflandırmak için yapay sinir ağı kullanmışlardır. Çalışmada 9 farklı pirinç çeşidinden görüntüler kullanarak 13 morfolojik özellik, 6 renk özelliği ve 15 doku özelliği çıkartmak için algoritma geliştirmişlerdir. Bu özellikler için ayrı ayrı ve birlikte olmak üzere faklı sınıflandırmalar yapmışlardır. Sınıflandırma sonucu ayrı ayrı yapılan sınıflandırmalarda, morfolojik ve renk özelliklerinden çok doku özelliklerinin daha yüksek oranda başarı sağladığı görülmüştür. Tüm özellikler bir arada olan sınıflandırma sonucunda başarı oranı %92 olarak elde edilmiştir (Silva ve Sonnadara, 2013).

Kaur ve Singh (2013) tarafından yapılan çalışmada, çok sınıflı destek vektör makineleri kullanarak pirinç sınıflandırması için bir makine algoritması üzerinde çalışmışlardır. Görüntülerdeki pirinç tanelerini arka plandan ayırmak için maksimum varyans yöntemini uygulamışlardır. Pirinçleri, geometrik özellikler kullanarak baş pirinç, kırık pirinç ve öğütülmüş pirinç olarak her biri için yüzdelerini ve özelliklerini belirlemişlerdir. Pirinç tanelerini, şekil özellikleri, yüzdeleri ve opak olma durumlarını kullanılarak sınıflandırma işlemini gerçekleştirmiş ve %86'dan yüksek başarı oranı yakalamışlardır (Kaur ve Singh, 2013).

Abirami ve ark. (2014) tarafından yapılan çalışmada, basmati pirinç tanelerini sınıflandırmak için görüntü işleme ve sinir ağı örüntü tanıma tekniklerinden faydalanmışlardır. Kamera yardımıyla alınan görüntüler ön işleme tekniklerinden, filtreleme, eşikleme, kenar bulma gibi işlemlerden geçirilerek çeşitli morfolojik özellikleri çıkartılmış ve sinir ağı örüntü tanıma ile sınıflandırılmıştır. Sınıflandırma sonucunda %98.7 başarı oranına ulaşmışlardır (Abirami ve ark., 2014).

Ebrahimi ve ark. (2014) tarafından yapılan çalışmada, buğday saflığı belirleme ve derecelendirme için otomatik bir makine sistemi önerisinde bulunmuşlardır. Dört adet yerel buğday tohumu ile en yaygın sekiz adet yabani ot tohumu örnek görüntülerinden elde edilen toplam 52 adet morfolojik, renk ve doku özelliklerini en iyi karakteristik

parametreleri bulmak ve sağlam sınıflandırma modelleri oluşturmak için bağımsız bileşen analizi (ICA) ve yapay sinir ağlarını (YSA) beraber kullanarak sınıflandırmış ve sonuç olarak sırasıyla %96.25, %87.50 ve %77.22 olarak elde edilmiştir (Ebrahimi ve ark., 2014).

Szczypiński ve ark. (2015) yaptıkları çalışmada, arpa çeşitlerini tanımlamada çekirdeğin görüntüden elde edilen şekil, renk ve doku özelliklerine dayanarak belirlenmesinin etkinliğini değerlendirmişlerdir. Çalışmada, doğrusal ayırt edici analiz ve yapay sinir ağları sınıflandırmalarında %67 ile %86 arasında değişen başarı oranları elde etmişlerdir. Çekirdek görüntülerinin, ön ve arka oryantasyonları açısından standartlaştırılması ve çekirdek üzerindeki buruşuk bölgelere uygulanabilecek ek analizler ile sınıflandırma sonuçlarının iyileştirilebileceğini belirtmişlerdir (Szczypiński ve ark., 2015).

Ozan ve ark. (2015) görüntü işleme ve yapay zeka tekniklerini kullanarak Baldo, Osmancık ve Yasemin pirinç çeşitleri ile bu çeşitler arasında bulunan kırık pirinçleri de bir çeşit olarak düşünerek toplamda 4 çeşit üzerinde sınıflandırma gerçekleştirmişlerdir. Toplam 6 adet şekil özelliği kullanılarak yapılan sınıflandırma sonucunda %90.5 sınıflandırma doğruluğu elde etmişlerdir (Ozan ve ark., 2015).

Kaya (2017) tarafından yapılan çalışmada, görüntü işleme teknikleri ile yapay sinir ağları (YSA) tekniklerinden faydalanılmıştır. Durum buğdayı tanelerinin görüntüleri alınarak 10 farklı morfolojik özellik kullanılarak yabancı maddelerin tespiti yapılmış ve 15 farklı renk özelliği kullanılarak da camsılık özelliklerine bakılmıştır. Sınıflandırma işlemi YSA ile gerçekleştirilmiş ve başarı oranı %91.73 elde edilmiştir (Kaya, 2017).

Tin ve ark. (2018) yaptıkları çalışmada Myanmar'a özgü 5 farklı pirinç çeşidi üzerinde görüntü işleme teknikleri kullanarak her bir çeşit için 5 adet morfolojik özellik çıkarmışlardır. Çalışmalarını pirinç çeşitlerinin otomatik sınıflandırılabilmesi için bilgisayar tabanlı sistemlerin geliştirilebilmesi adına gerçekleştirdiklerini belirtmişlerdir. Ayrıca Myanmar tarımcıları ve araştırmacıları için tarım alanında büyümenin gerçekleşmesi adına büyük ölçüde yardımcı olabileceğini belirtmişlerdir (Tin ve ark., 2018).

Sethy ve Chatterjee (2018) tarafından yapılan çalışmada Odisha bölgesine ait Asan Chudi, Bada Kadalia, Babulal, Chit Pagalia, Radha Jugala ve Sahabhagi isimli toplamda 6 adet pirinç çeşidinin geometrik ve doku özelliklerini çok sınıflı destek vektör

makinesi (M-SVM) algoritmasını kullanarak sınıflandırmışlardır. Sınıflandırma sonucunda %92 doğruluk elde etmişlerdir (Sethy ve Chatterjee, 2018).

Chen ve ark. (2019) çalışmalarında kırmızı indica pirincinin görüntüleri üzerinde morfolojik özellikler kullanılarak kırık, kireçli, lekeli ve kusurlu pirinç tanelerini incelemek için bir makine görme sistemi geliştirmişlerdir. Sınıflandırma için destek vektör makinesi (SVM) kullanmışlar ve kırık, kireçli, lekeli ve kusurlu pirinç tanelerini tanıma doğruluğu olarak sırasıyla %99.3, %96.3 ve %93.6 sonuçlarına ulaşmışlardır. Ayrıca sistemin ortalama 0.15 sn. gibi bir sürede sonuca ulaştığını ve önerilen yöntemin pirinç kalitesini tespit etmek için hızlı ve doğru sonuçlar verdiğini belirtmişlerdir (Chen ve ark., 2019).

Literatürede yapılan çalışmalar incelendiğinde, farklı tahıl ürünlerinden elde edilen görüntülerde çeşitli görüntü işleme teknikleri kullanılarak morfolojik özelliklerin yanı sıra şekil ve renk özellikleri kullanılarak ürün özellikleri elde edilmeye çalışılmıştır. Bu özellikler kullanılarak farklı yöntemlerle sınıflandırılmıştır.

3. TAHIL ÜRÜNLERİ

3.1. Tahılın Tanımı ve Önemi

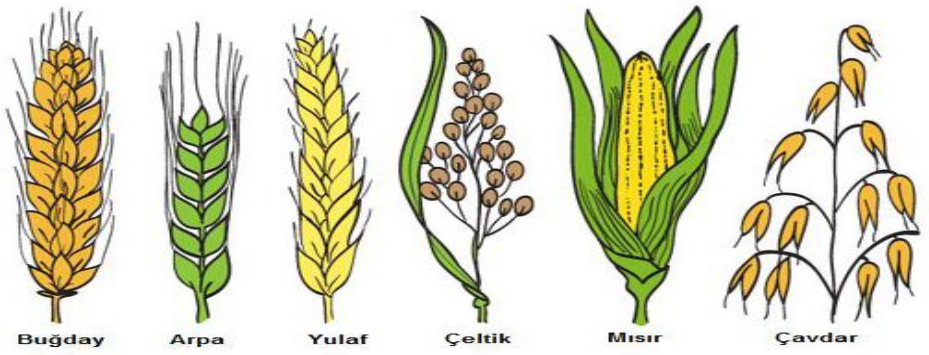
Tanelerinde büyük oranda nişasta içeren, öğütülmeleri ile un ve kepek elde edilen ürün grubuna tahıl (hububat) denir. Tahıllar içerisinde yağ, protein ve mineral maddelerini barındırırlar. Ayrıca, yetiştirilme şartları için belirli sıcaklık değerlerine ihtiyaç duyarlar (Megep, 2011).

Günümüzde tahıllar, içerdiği yüksek oranda karbonhidrata bağlı olarak sağladıkları enerji ile dikkat çekmektedir. Buna ek olarak tahıl ürünlerinin doyum sağlayıcı özellikleri de oldukça önemlidir. Tat ve aroma bakımından nötr (etkisiz) oldukları için yüzyıllardır bıkmadan, usanmadan tüketilen temel gıda maddesi olma özelliklerini muhafaza etmişlerdir. Sadece insanlar için besin kaynağı değil, hayvanların ihtiyacı olan yemler de tahıllar sayesinde karşılanmaktadır. Tahılların, sosyal ve ekonomik yaşantıda diğer tarım ürünlerine göre önemi büyüktür (Megep, 2011).

Ucuz olması, temininin kolay olması, doyurucu özelliği, kısmen de olsa yüksek protein içermesi ve enerji kaynağı olması sebebiyle de tahıllar çokca tüketilmektedir. Ayrıca, tahıllar dünya çapında ekonomik değere sahip olmasından dolayı ihracat açısından da önem taşımaktadır (Megep, 2011).

3.2. Tahıl Türleri ve Sınıflandırması

Beslenme açısından en önemli tahıl türleri arasında buğday, arpa, pirinç, mısır, yulaf ve çavdar yer almaktadır. Şekil 3.1'de tahıl türleri gösterilmiştir.



Şekil 3.1. Tahıl türleri (Megep, 2016)

3.2.1. Buğday

Dünyada ve ülkemizde buğday tarımı, insanların besin ihtiyacını karşılayan temel besinlerin ham maddesi olması yönünden diğer tarımsal ürünlerin yanında ayrı bir önem ifade etmektedir (TMO, 2017). Buğday, ekmek ve diğer unlu mamullerin üretilmesinde kullanıldığı gibi hayvanların yem ihtiyacını karşılamak için de kullanılmaktadır.

Buğdaylar botanik yapılarına göre üç sınıfta incelenebilir (Megep, 2011).

- Ekmeklik buğday (Triticum aestivum)
- Makarnalık buğday (Triticum durum)
- Bisküvilik buğday (Triticum compactum)

Ayrıca buğdaylar sertlik, tane rengi ve ekilme durumlarına göre de sınıflandırılmaktadır. Örneğin,

- Tane sertliğine göre sert, yarı sert ve yumuşak
- Tane rengine göre beyaz, kırmızı
- Ekim durumuna göre yazlık, kışlık

olarak sınıflandırılabilir (Megep, 2011). Şekil 3.2'de buğday gösterilmiştir.



Şekil 3.2. Buğday (Megep, 2011)

3.2.2. Arpa

Kökeni çok eski çağlara dayanan arpanın gen merkezi Asya'dır. Buğdaygiller familyasından gelmektedir. Dünya tahıl ekonomisinde buğday, çeltik ve mısırdan sonra dördüncü sırada yer almaktadır. Ülkemizde ise buğdaydan sonra ekim alanı en fazla olan üründür (Megep, 2011).

Arpanın, insanların besin ihtiyaçları arasında doğrudan kullanımı çok azdır. Daha çok hayvansal yem olarak ve de malt sanayisinde ham madde olarak kullanılır (Megep, 2011).

Arpa başak eksenindeki boğumların dane bağlamasına göre,

- İki sıralı arpalar (Hordeum distichum)
- Altı sıralı arpalar (Hordeum hexastichum)

olarak sınıflandırılmaktadır (Megep, 2011; TMO, 2017). Şekil 3.3'de arpa gösterilmiştir.



Şekil 3.3. Arpa (Megep, 2011)

3.2.3. Çeltik-Pirinç

Çeltik sıcak bölgelerde yetişen ve yetiştiği bu bölgelerde medeniyeti simgeleyen bir kültür bitkisidir. Bu bitki buğdaygiller familyasından olup botanik dilindeki ismi Oryza sativa ve Oryza glaberrimasleuddur. Ana vatanı, Güneydoğu Asya olarak bilinir. Özellikle Hindistan ve Çin çeltik cinsinin gen merkezi olarak belirtilmektedir. Ülkemize ise yaklaşık 500 yıl kadar önce güneyden girdiği tahmin edilmektedir (Megep, 2011).

Çeltik, su içinde çimlenebilmesi ve kökleri aracılığıyla suda erimiş oksijenden faydalanabilen tek tahıl cinsidir (Megep, 2011).

Pirinç çeltikten elde edilmektedir. Pirinçteki nişasta oranı buğdaya göre daha yüksektir. Pirincin besin maddesi olmasının yanında sanayi alanında da yaygın kullanım alanları mevcuttur (Megep, 2011). Şekil 3.4'de pirinç görüntüsü verilmiştir.




Şekil 3.4. Pirinç (Megep, 2011)

Bir çeltik tanesi, karyopsis ile birlikte karyopsisi çevreleyen iç kavuz ve kapçıktan oluşur. Bu kavuzlar, çeltiğin harmanlanması sonucunda da karyopsisten ayrılmaz. Kavuzlu ürüne çeltik adı verilir. Kavuzları soyulmuş ancak herhangi bir parlatma ve ön pişirme işleminden geçmemiş taneye kahverengi pirinç veya kargo adı verilir. Kabukları soyululan ve çeşitli işlemlerinden geçirilmiş ürüne ise pirinç adı verilir (Megep, 2011; TMO, 2017).

Çeltik,

- İndica grubu
- Japonica grubu
- Javonica grubu

olmak üzere üç grup olarak sınıflandırılmaktadır (IUBÜ, 2012).

3.2.4. Mısır

Mısır, yüzlerce hatta binlerce yıldan bu yana tarımı yapılan bir bitkidir. Amerika'nın keşfinden sonra tanınmaya başlanmış olan mısır, İspanyollar tarafından Avrupa'ya getirildiği ve buradan dünyanın her yerine dağıldığı bilinmektedir. Ülkemize ise 1630'lu yıllarda Suriye ve Kuzey Afrika bölgelerinden geldiği düşünülmektedir (Megep, 2011).

Ülkemizde daha önceden Karadeniz, Akdeniz, Ege ve Marmara bölgelerinde birincil tarım ürünü olarak ekimi yapılmış olsa da günümüzde özellikle Çukurova, Amik ovası, Ege ve Güneydoğu bölgelerinde yan ürün olarak tarımı yapılıp, birincil tarımı yapılan ürüne üretim miktarı olarak yakındır. Ülkemiz genelinde, tahıl ürünleri arasında buğday ve arpadan sonra üçüncü sırada yer almaktadır (Megep, 2011).

Mısır, zengin besin öğelerini içinde barındırması sebebiyle insanlar ve hayvanlar için besin maddesi olmasının yanında yağ, nişasta, glikoz ve yem sanayisinde ham madde olarak önemli bir yere sahiptir (Megep, 2011). Şekil 3.5'de mısır gösterilmiştir.



Şekil 3.5. Mısır (Megep, 2011)

3.2.5. Yulaf

Yulaf, buğday ve arpaya ile karşılaştırıldığında daha yeni tanınan bir kültür bitkisidir. Yulaf, daha önceleri sadece hayvan beslenmesinde kullanılan bir ürün iken günümüzde insan beslenmesinde de aranan bir ürün olma yolunda ilerlemektedir. İnsan beslenmesinde yulaf, bebek maması, bisküvi, ezme, un, gevrek ve çorba yapımında kullanılmaktadır (Megep, 2011). Şekil 3.6'da yulaf tanesi ve bitkisi gösterilmiştir.



Şekil 3.6. Yulaf (Megep, 2011)

3.2.6. Çavdar

Çavdar (Secale cereale), buğdaya göre daha geç kültüre alınmış ve geç tanınmış bir bitkidir. Ana vatanı olarak Orta Asya ve Anadolu kabul edilmektedir.

Ülkemizde çavdar genel olarak yem sanayisinde kullanılmaktadır. Ancak son yıllarda sağlıklı beslenme bilincinin artmasıyla çavdar insan beslenmesinde de kullanılmaya başlanmıştır (Megep, 2011). Şekil 3.7'de çavdar gösterilmiştir.



Şekil 3.7. Çavdar (Megep, 2011)

3.3 Tahıl Ürünlerinin Dünya'daki ve Türkiye'deki Üretim Miktarları

Ülkemizde üretimi yapılan tahıl ürünlerinin, son 10 yıl baz alınarak üretim miktarları (ton bazında) Çizelge 3.1'de verilmiştir.

Çizelge 3.1 Türkiye'de üretilen tahıl ürünlerinin üretim miktarları (TÜİK, 2019).

	Ürünler					
Yıllar	**Buğday**	**Arpa**	**Mısır**	**Çeltik**	**Çavdar**	**Yulaf**
2009/2010	20,600,000	7,300,000	4,250,000	750,000	343,330	218,286
2010/2011	19,674,000	7,250,000	4,310,000	860,000	365,560	203,870
2011/2012	21,800,000	7,600,000	4,200,000	900,000	365,750	218,040
2012/2013	20,100,000	7,100,000	4,600,000	880,000	370,000	210,000
2013/2014	22,050,000	7,900,000	5,900,000	900,000	365,000	235,000
2014/2015	19,000,000	6,300,000	5,950,000	830,000	300,000	210,000
2015/2016	22,600,000	8,000,000	6,400,000	920,000	330,000	250,000
2016/2017	20,600,000	6,700,000	6,400,000	920,000	300,000	225,000
2017/2018	21,500,000	7,100,000	5,900,000	900,000	320,000	250,000
2018/2019	20,000,000	7,000,000	5,700,000	940,000	320,000	260,000

Ülkemizde, tahıl ürünlerini üretim miktarlarını en yüksekten en düşüğe doğru sıraladığımızda buğday, arpa, mısır, çeltik, çavdar ve yulaf olarak sıralandığı görülmektedir.

Dünya genelinde üretimi yapılan tahıl ürünlerine bakıldığında son 10 yıldaki üretim miktarları (milyon ton bazında) Çizelge 3.2'de verilmiştir.

Çizelge 3.2 Dünya genelinde üretilen tahıl ürünlerinin üretim miktarları (TMO, 2019; IGC, 2019)

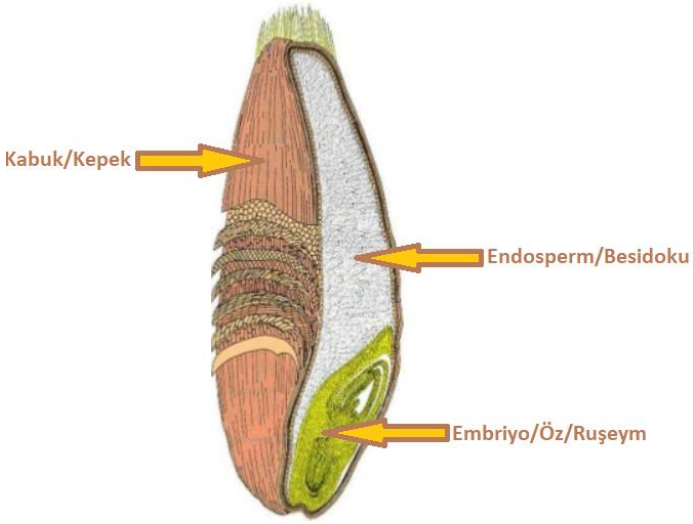
	Ürünler					
Yıllar	**Mısır**	**Buğday**	**Çeltik**	**Arpa**	**Yulaf**	**Çavdar**
2009/2010	833	683	440	150.8	23.4	18.24
2010/2011	849	655	451	124.2	19.6	12.40
2011/2012	907	701	470	133.7	22.9	13.14
2012/2013	901	659	477	131.6	21.2	14.43
2013/2014	1,032	718	481	144.9	23.9	16.80
2014/2015	1,061	732	483	144.2	22.9	15.14
2015/2016	1,024	740	478	149.8	22.3	12.67
2016/2017	1,132	757	491	148.5	24.4	12.81
2017/2018	1,090	763	494	145.0	23.8	12.81
2018/2019	1,118	735	500	141.2	22.2	10.91

Dünya genelinde, tahıl ürünlerini üretim miktarlarını en yüksekten en düşüğe doğru sıraladığımızda mısır, buğday, çeltik, arpa, yulaf ve çavdar olarak sıralandığı görülmektedir.

3.4. Tahıl Tane Yapısı ve Fiziksel Özellikleri

Tahıl tanesinde meyve ve tohum kabuğunun birbirlerine yapışık pozisyonda bulunmasına karyopsis denir. Tahıllarda tane, karyopsis durumundadır. Tahıl tanesinin kısımları Şekil 3.8'de verilmiştir.

- Kabuk (Kepek)
- Endosperm (Besidoku)
- Embriyo (Öz/Ruşeym)



Şekil 3.8. Tahıl tanesinin kısımları (Ekinci, 2016)

Kabuk, taneyi dış etkenlerden ve su kaybından koruyan zırhtır. Endosperm, embriyonun enerji kaynağıdır. Döllenme sonucu oluşan bitkinin fotosentez yapana kadar gelişimine yardımcı olan yedek besin maddesidir. Embriyo ise yeni bitkinin meydana gelmesini sağlayacak kısımdır. Tahıl tane ağırlıklarının %12-13'ü kabuk, %85'i endosperm ve %2-3'ü embriyodur (Megep, 2016).

Tahıl bitkilerinin hepsi aynı familyaya üye olduklarından tanelerinin anatomik yapısı da birbirlerine benzemektedir. Ancak detaylara bakıldığında farklılıklar anlaşılabilmektedir. Tane dış görünüşü ele alındığında tahıl ürünleri arasında şeklen ayırıcı özellikler bulunmaktadır. Çizelge 3.3'de tahıl ürünlerine ait tanelerinin yaklaşık boyutları ile bin adedinde ortalama ağırlık değerleri verilmiştir (Megep, 2011).

Çizelge 3.3. Tahıl tanelerinin yaklaşık boyutları ve bin adedinin ortalama ağırlıkları

Tahıl Ürünü	Uzunluk (mm)	Genişlik (mm)	1000 Adet Ağırlığı (gr)
Buğday	5-8	2.5-4.5	37
Arpa	8-14	1-4.5	37
Çeltik	5-10	1.5-5	27
Mısır	8-17	5-15	285
Yulaf	6-13	1-4.5	32
Çavdar	4.5-10	1.5-3.5	21

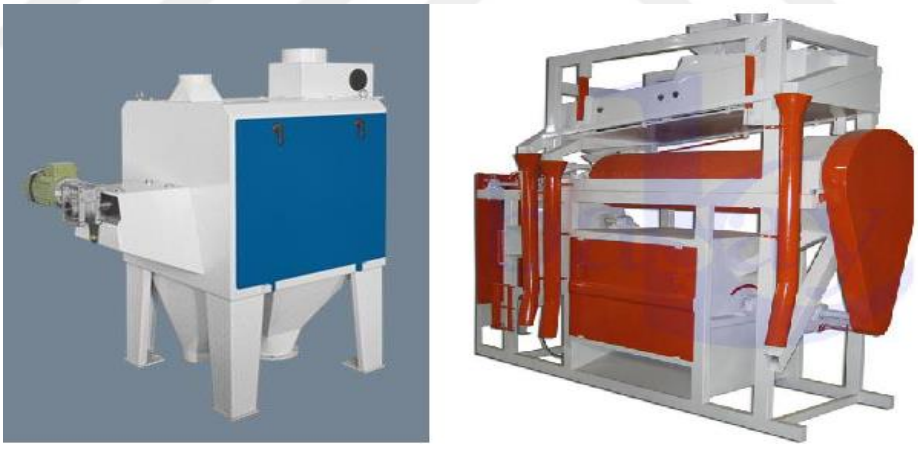
3.5. Tahıl Ürünlerini Ayrıştırma Yöntemleri

3.5.1. Kuru temizleme

Kuru temizleme, tahıl ürünlerinin içindeki yabancı maddeleri ayırmak ve ürünün fiziki durumunu iyileştirmek için yapılmaktadır. Kuru temizlemenin, kaba ayırma, ince ayırma, manyetik ayırma, kabuk soyma ve taş ayırma olarak farklı işlem çeşitleri bulunmaktadır.

Kaba ayırma işlevine sahip ekipmanlar, ayrımı genellikle özgül ağırlığı baz alarak yapmaktadır. Tahıl tanesinden hafif olan toz, kavuz ve yabancı diğer maddeler hava akımı sayesinde uzaklaştırılır. Bu tür ayırma işleminde kullanılan araçlar özellik olarak farklı olsa da genelde işlev olarak aynıdır. Sistemde, elek, aspiratör ve fan gibi standart ekipmanlar kullanılır.

Kaba ayırmada kullanılan ekipmanlardan bazıları, skalperatör (ön temizleyici) ve türevleri, kaba elek (çöp sasörü), aspiratörler ve türevleri, silindirik elekler ve selektörlerdir. Şekil 3.9'da kaba ayırmada kullanılan ekipmanlardan tamburlu skalperatör ve selektör gösterilmiştir (Megep, 2011).



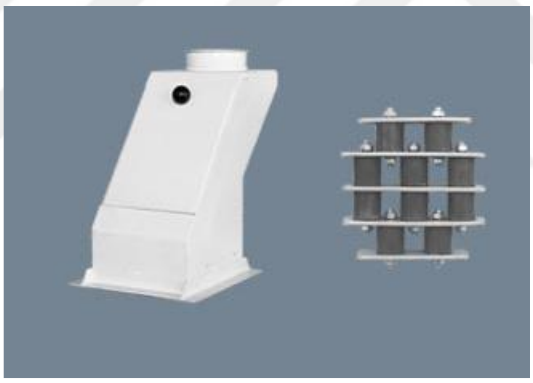
Şekil 3.9. Tamburlu skalperatör ve selektör (Megep, 2011)

İnce ayırmada, kaba ayırmadan geçmiş ürünler yeniden temizlemeye alınır. İnce ayırmada kullanılan ekipmanlar yabancı maddeleri irilik farklılıklarına göre ayırmaktadır. İnce ayırmada kullanılan ekipmanlardan bazıları, silo sasörü, değirmen sasörü ve triyörlerdir. Şekil 3.10'da ince ayırmada kullanılan triyör gösterilmektedir (Megep, 2011).



Şekil 3.10. Triyör (Megep, 2011)

Manyetik ayırmada, tahıl içinde bulunabilecek metal parçalar ekipman üzerinde bulunan mıknatıslar tarafından yakalanarak ayırma işlemi gerçekleştirilir. Şekil 3.11'de manyetik ayırmada kullanılan ekipman gösterilmektedir (Megep, 2011).



Şekil 3.11. Manyetik temizleme ekipmanı (Megep, 2011)

Kabuk soymada, ovalama ve sürtünme işlemi sonrasında ürünlerin dış kabuğunun soyulması sağlanır. Şekil 3.12'de kabuk soyma işleminde kullanılan ekipman gösterilmektedir (Megep, 2011).



Şekil 3.12. Kabuk soyma ekipmanı (Megep, 2011)

Taş ayırmada, ürünün özgül ağırlığına göre ayrım yapılmaktadır. Taş ayırma ekipmanları, mantık olarak üründen daha ağır olan yabancı maddelerin ayrılmasında kullanılır. Şekil 3.13'de taş ayırmada kullanılan ekipman gösterilmiştir (Megep, 2011).



Şekil 3.13. Taş ayırma ekipmanı (Megep, 2011)

3.5.2. El ile ayrıştırma

El ile ayrıştırma işlemi insan gücüyle yapılmaktadır. Bant sistemi çevresinde seçmeciler bulunur ve bant üzerinden geçen ürünlerden, yabancı maddeler ile bozuk ürünleri seçerler. El ile ayrıştırma işleminde insan faktörü olduğu için personelin tecrübesiz olması ya da eksik olması ayrıştırma işlemini olumsuz etkiler. Ayrıca hijyen şartlarını sağlayabilmek de çok önemlidir. Şekil 3.14'de el ile ayrıştırma işlemi gösterilmiştir (Megep, 2010).

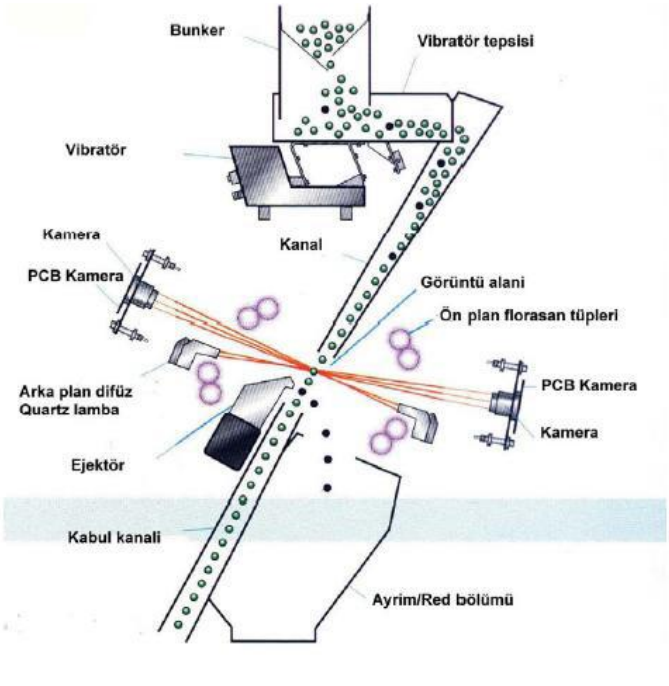


Şekil 3.14. El ile ayrıştırma işlemi (Megep, 2010)

3.5.3. Renklerine göre ayrıştırma

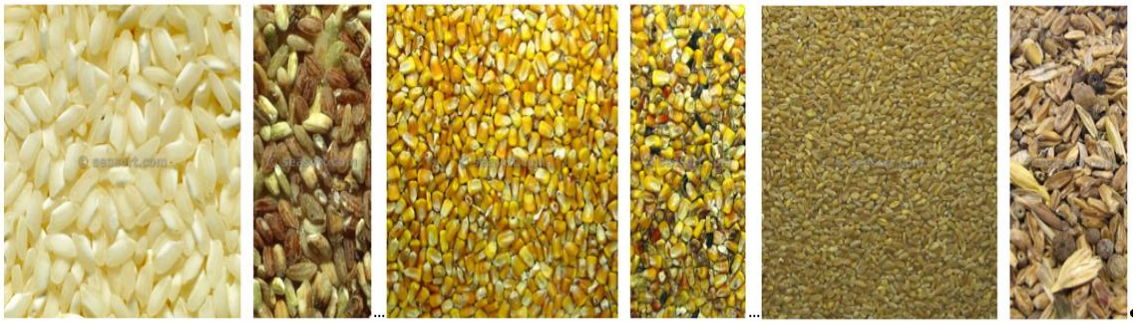
Renklerine göre ayrıştırma, teknolojinin gelişmesiyle beraber, ürünlerin standart tipte üretimini gerçekleştirmek için gıda sektöründe de kullanılmaktadır. Makineye verilen ürünlerin renkleri baz alınarak ayrışması sağlanmaktadır.

Renklerine göre ayrıştırma işleminde kullanılan sistemlerin temelinde mikroprosesör kontrol elemanları yardımıyla yüksek hızda geçen maddeler renklerine göre ayrıştırılmaktadır. Şekil 3.15'de renklere göre ayrıştırma sisteminin çalışma prensibi gösterilmektedir (Megep, 2010).



Şekil 3.15. Renklere göre ayrıştırma sistemi çalışma prensibi (Megep, 2010)

Sistemde depoya (bunker) alınan ürün vibratör sayesinde kanala yönlendirilir. Kanaldan geçen ürünler görüntü alanından geçerken baskı devre kartlı (PCB) kameralar tarafından izlenir ve tespit edilen yabancı maddeler enjektörden verilen sıkıştırılmış hava sayesinde red/ayrım bölümüne atılır. Red bölümüne alınanlar arasında, farklı renkteki ürünler ve yabancı maddeler bulunmaktadır. Şekil 3.16'da renklerine göre ayrıştırılmış ürünlerden örnekler gösterilmektedir.



Şekil 3.16. Pirinç, mısır ve buğdayın renk ayrıştırma işlemi sonrası görüntüleri (Seasort, 2018)

3.5.4. Kalibrasyon (Boylama)

Boylama işleminde kullanılan ekipmanlarda, tekne sayısı ve delik aralık numaraları değişebilen elekli makineler kullanılmaktadır. Elekler vasıtasıyla ürünler boylarına, kalibrelerine göre elek deliklerinden geçerek sınıflama yapılmaktadır. Şekil 3.17'de üç tekneli boylama makinesi gösterilmektedir.



Şekil 3.17. Üç tekneli boylama makinesi (Akyürek, 2018)

3.6. Bölüm Değerlendirmesi

Bu bölümde tahıl ürünleri üzerinde durulmuştur. Tahıl ürünleri hakkında genel bilgiler verilmiş, Dünya ve Türkiye'deki üretim miktarları hakkında bilgiler paylaşılmıştır. Tahıl tanesinin yapısı incelenerek fiziksel özelliklerinden bahsedilmiştir. Son olarak tahıl ürünlerinin mevcut ayrıştırma yöntemleri hakkında bilgiler verilmiştir.

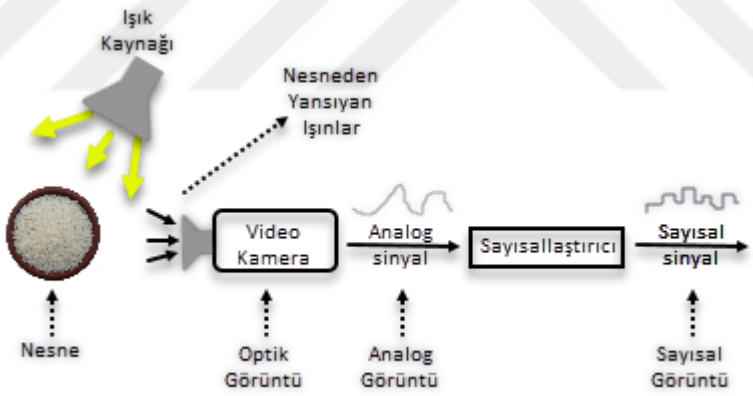
4. GÖRÜNTÜ İŞLEME

4.1. Görüntü İşleme Nedir?

Görüntü işleme kısaca, dijital bilgilerin analizi olarak tanımlanabilir. Daha açık ifade ile tanımlamak gerekirse, sayısal olarak elde edilmiş görüntülerin bilgisayar ortamına aktarılarak üzerinde işlem yapılması (analiz edilmesi) ve sonrasında çıkış birimine yani monitöre iletilme sürecidir (Çetinkaya ve Çetinkaya Saray, 2019).

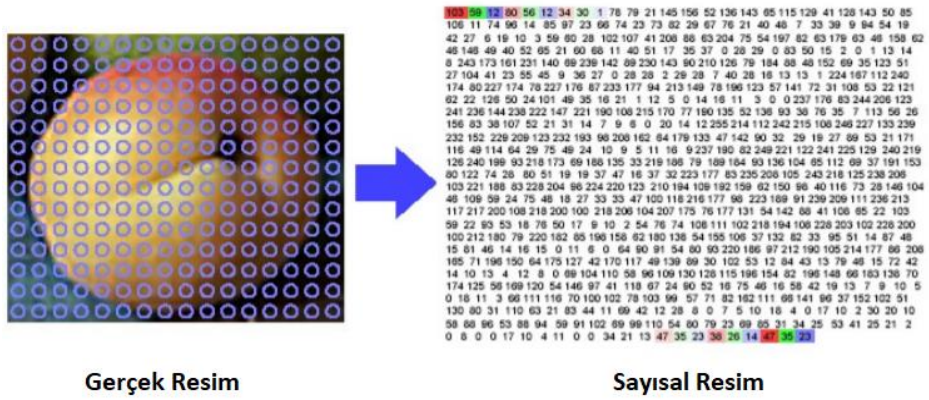
4.2. Görüntünün Elde Edilmesi İşlemleri

Görüntü işlemede ilk olarak görüntünün elde edilmesi gerekmektedir. Bu aşamada sensörler veya kameralar yardımıyla görüntü yakalanıp sayısallaştırma işlemi gerçekleştirilir. Şekil 4.1'de görüntünün yakalanması ve sayısallaştırılması işlemleri gösterilmektedir.



Şekil 4.1. Görüntünün yakalanması ve sayısallaştırılması işlemleri (Aktan, 2004; Beyaz, 2014)

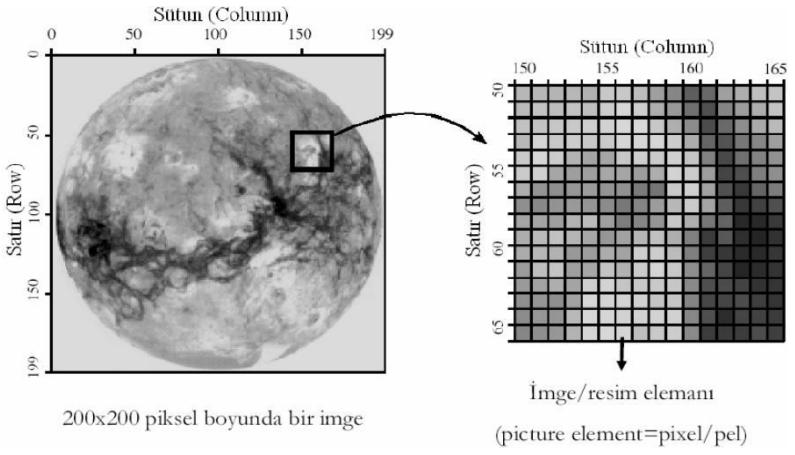
Şekil 4.1'deki işlemleri açıklamak gerekirse, ışık kaynağı tarafından aydınlatılan nesneden yansıyan ışınlar kameraya aktarılmaktadır. Kamera yardımıyla nesne görüntüsü analog forma dönüştürülmektedir. Sayısallaştırıcı, analog sinyalleri dijital sinyale çevirerek görüntünün artık bilgisayar ortamında işlenmesi ve analiz edilmesine olanak sağlamaktadır (Beyaz, 2014). Şekil 4.2'de kamera yardımıyla görüntüsü alınan bir resmin sayısallaştırma işlemi sonrası durumu gösterilmiştir.



Şekil 4.2. Gerçek ve sayısal resim (Akbulut, 2016)

4.3. Dijital Görüntü ve Türleri

Dijital görüntü, görüntü içerisinde satır ve sütun indislerinin herhangi bir noktayı tanımlayan elemanlardan oluşmuş bir matris olarak düşünülebilir. Bu matrisin elamanlarının her birinin içerdiği sayısal (dijital) değerler, o noktaya ait renk bilgisini içerir. Bu sayısal matrisin elemanlarının her birine görüntünün birim elemanı veya piksel adı verilir. Şekil 4.3'de dijital bir görüntü ve görüntü üzerinde seçilmiş bir kısma ait piksellerin büyütülmüş hali verilmiştir (Gonzalez ve Woods, 2002; Perihanoğlu, 2015).



Şekil 4.3. Dijital bir görüntü üzerinde seçilmiş bir kısma ait piksellerin büyütülmüş hali

Dijital görüntü türleri, renkli görüntü, gri tonlamalı görüntü ve ikili görüntü olmak üzere üç başlık altında toplanmıştır.

Renkli (RGB) Görüntü: Kırmızı (Red), yeşil (Green) ve mavi (Blue) olarak üç katmandan oluşur. 24 bitlik veri olarak bilgisayar ekranlarında görüntülenir. Renkli görüntü örneği Şekil 4.4'de verilmiştir.



Şekil 4.4. Renkli görüntü

Gri (Gray) Tonlamalı Görüntü: Tek renkli görüntü olup Şekil 4.5'de gösterildiği gibi grinin tonlarından oluşurlar ve renk bilgisi içermezler.



Şekil 4.5. Gri tonlamalı görüntü

İkili (Binary) Görüntü: Şekil 4.6'daki gibi sadece siyah ve beyaz olarak 0 ve 1 değerini alırlar.



Şekil 4.6. İkili (Binary) görüntü

4.4. Renk Uzayları

Renk uzayları, rengi tanımlamada kullanılan matematiksel bir temsildir. Bazı renk alanları insanların renkleri seçmesine olanak sağlamak için formüle edilirken bazıları ise makinelerde verilerin işlenmesini kolaylaştırma amaçlı formüle edilmiştir.

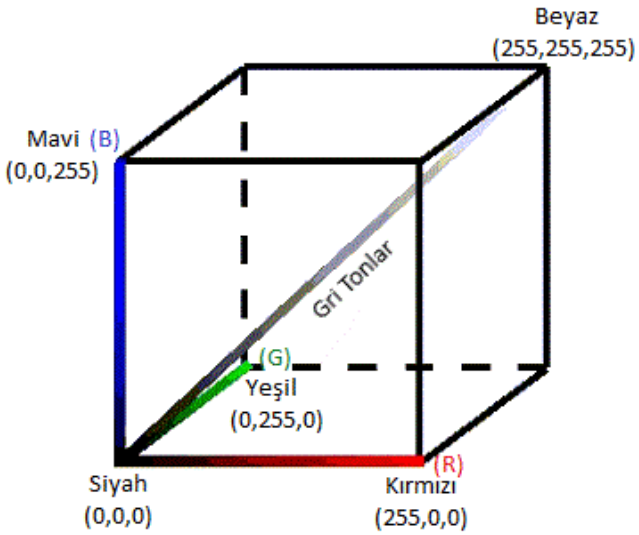
Üç tür renk uzayı vardır. Bunlar donanım odaklı, insan odaklı ve enstrümantal renk uzaylarıdır. Donanım odaklı olanlar çok az miktarda renk değişimini bile hissedebildikleri için ürünlerin işlenmesi sırasındaki renk değişimlerini değerlendirmede oldukça popüler bir yere sahiptirler. İnsan odaklı olanlar insanların görsel algı kavramına dayalı olduğundan daha çok ton, parlaklık, doygunluk ve hafiflik gibi etkenler ön plandadır. Bu sebeple insan görüşünde olduğu gibi küçük renk değişimine duyarlı olmadığı için işleme sırasında ürünün renk değişikliğini değerlendirmede uygun değildir. Enstrümantal olanlar ise renk ölçümleri için kullanılmaktadır (Wu ve Sun, 2013).

Renk uzaylarının tasarımları üç boyutlu olarak tasarlanmaktadır. Renkli bir görüntü üzerinde bulunan her piksel 3 renk kanalından oluşmaktadır (Toptaş, 2017). Bu çalışmada RGB, HSV, L*a*b*, YCbCr ve XYZ renk uzayları kullanılmıştır.

4.4.1. RGB renk uzayı

RGB renk uzayı, günlük yaşantımızda en çok bilgisayar teknolojilerinde ve televizyonlarda karşımıza çıkmaktadır. RGB, ana renkler olan kırmızı (R), yeşil (G) ve maviyi (B) temsil etmektedir. Diğer tüm renkler bu üç ana rengin doğrusal bir bileşimi ile temsil edilmektedir (Koschan ve Abidi, 2008).

RGB renk değerleri, 0 ile 255 değer aralığında ifade edilir. Siyah renk değerleri (0,0,0) ile, beyaz renk değerleri (255,255,255) ile temsil edilir ve ana köşegen üzerinde bulunan değerler ise gri renk değerlerini temsil etmektedir. RBG, görüntü uygulamaları için temel renk modeli kabul edildiğinden herhangi bir dönüşüm gerektirmeden görüntüyü ekranda görmek mümkündür (Ibraheem ve ark., 2012). Şekil 4.7'de kübik RGB renk uzayı gösterilmiştir.

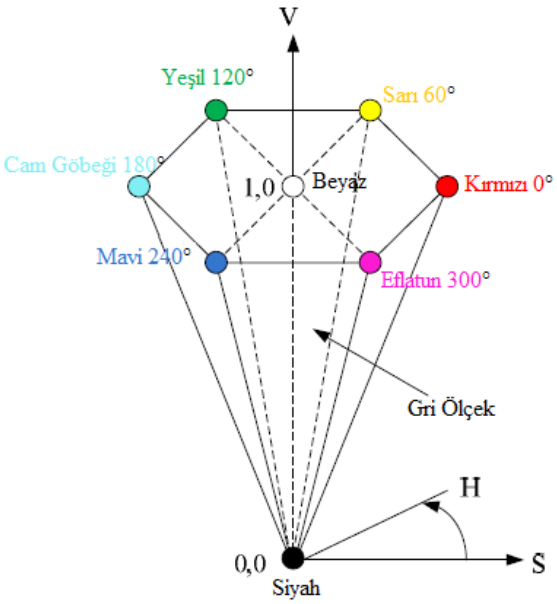


Şekil 4.7. RGB renk uzayı kübik gösterimi

4.4.2. HSV renk uzayı

HSV renk uzayı günümüzde, yüksek kaliteli grafik özelliklerine sahip bilgisayar sistemlerinde ve görüntü analizi uygulamalarında kullanılmaktadır. HSV renk uzayı, renk özü-tonu (H), doygunluk (S) ve değer (V) olmak üzere üç parametreden oluşur. Renk tonu, rengin baskın olan dalga uzunluğu ifade eder ve 0-360 derece arasında bir değer alır. Doygunluk, rengin canlılığını ifade etmektedir. Yüksek doygunluk değeri renklerin canlı olmasına, düşük doygunluk değeri ise rengin gri tonlarına yaklaşmasına neden olur. Değer ise, rengin parlaklığını yani içerisindeki beyaz oranını ifade etmektedir. Parlaklık değeri sıfıra yaklaştıkça renk siyah tonlarına, aksi yönde ise beyaz tonlarına yaklaşır (García-Mateos ve ark., 2015; Çevik, 2019).

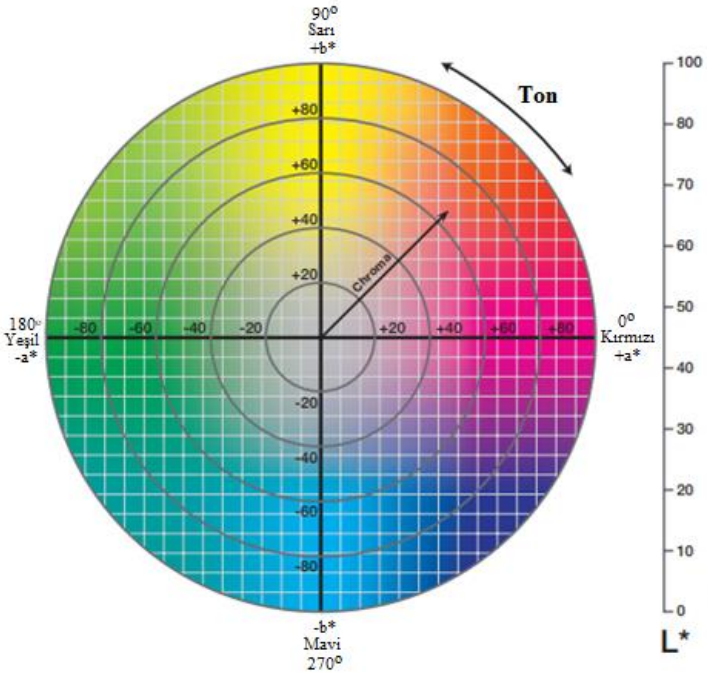
HSV renk uzayı genellikle ters piramit ile gösterilmektedir. Şekil 4.8'de HSV renk uzayı gösterilmiştir (Erbay, 2011).



Şekil 4.8. HSV renk uzayı

4.4.3. L*a*b* renk uzayı

L*a*b* renk uzayı CIE (Uluslararası Aydınlatma Komisyonu) tarafından tanımlanan bir renk uzayıdır ve CIELAB olarak da bilinmektedir. Cisimler üzerinde renk kontrolü için sıklıkla kullanılmaktadır. Bu renk uzayında renkler üç değer olarak ifade edilmektedir. L* değeri açıklığı ifade eder ve 0 siyahı, 100 ise beyazı gösterir. a* değeri kırmızı ile yeşili ifade eder ve (+) a* kırmızıyı, (-) a* ise yeşili belirtmektedir. b* değeri ise sarı ile maviyi ifade eder ve (+) b* sarıyı, (-) b* ise maviyi belirtmektedir. L*a*b* uzayındaki bu değerler tasarlanırken insan gözünün algılayabileceği özellikte tasarlanmıştır (Odakblog, 2018). Şekil 4.9'da L*a*b* renk uzayı gösterilmiştir.



Şekil 4.9. L*a*b* renk uzayı

4.4.4. YCbCr renk uzayı

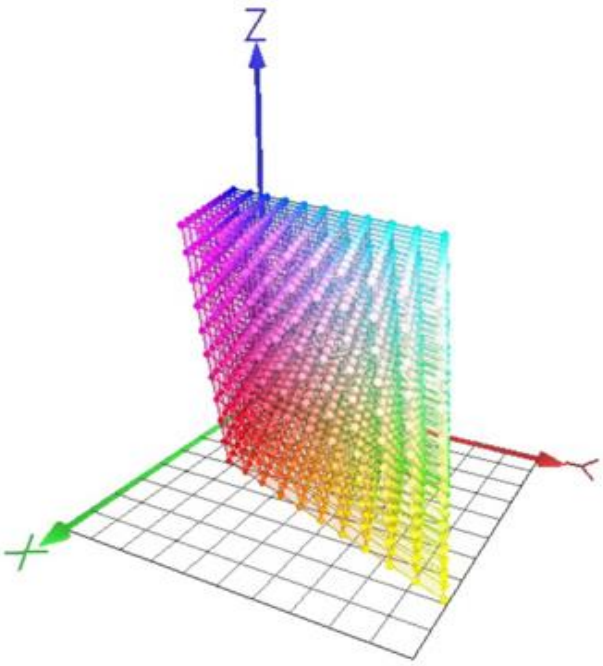
YCbCr renk uzayı renkli televizyon iletim sistemlerinde video bilgilerini işlemek için tasarlanmıştır (Wang, 2017). YCbCr bileşenleri, parlaklık (Y), mavi fark (Cb) ve kırmızı fark (Cr) bileşenleridir (Ibraheem ve ark., 2012).

YCbCr renk uzayı renk ve parlaklık bilgilerini birbirinden ayırmaktadır. Parlaklık aslında görüntü üzerinde bulunan ışık miktarını, renklilik ise görüntü üzerindeki renk özü-tonu oran miktarları ile ilgili bilgileri vermektedir (Toptaş, 2017).

4.4.5. XYZ renk uzayı

XYZ renk uzayı CIE tarafından tanımlanan ilk renk uzayıdır. Renk eşleşmesi elde edebilmek için gerekli olan tristimulus değerlerinin bazı durumlarda negatif olmasından dolayı bu değerleri pozitife dönüştürmek için yapay bir koordinat sistemi geliştirilmiştir. Böylece tristimulus değeri ile Y renk parlaklık değeri eşdeğer olacak şekilde seçilmiştir. XYZ üç bileşenden oluşmaktadır. X kırmızıyı, Z maviyi ve Y bileşeni de parlaklığı belirtmektedir (Pratt, 2001; Ibraheem ve ark., 2012).

XYZ renk uzayı, insanlar tarafından görülebilen tüm renk değerlerini kapsamaktadır (Mendoza ve ark., 2006). Şekil 4.10'da XYZ renk uzayı gösterilmiştir.



Şekil 4.10. XYZ renk uzayı

4.5. Görüntü İşleme Teknikleri

Görüntü işleme tekniklerinden önemli olanları alt başlıklar halinde açıklanmıştır.

Görüntü İyileştirme (Image Enhancement): Görüntü kalitesine bağlı olarak, görüntüyü açık veya koyu hale getirme, kontrastını artırıp azaltma veya çeşitli filtreleme işlemleri yapılarak görüntünün netleştirilmesi işlemidir (Mathworks, 2019a).

Görüntü Onarma (Image Restoration): Hareket bulanıklığı ve gürültü gibi bozulma faktörlerine maruz kalan görüntünün, orijinal ve temiz halini tahmin ederek elde edilmesi işlemidir (Mathworks, 2019a).

Morfolojik İşlemler (Morphological Operations): Görüntü üzerinde genişletme, sınır belirleme, aşındırma (erozyon), delik doldurma gibi temelinde küme teorisi olan işlemlerdir. Morfolojik bir işlemde görüntüdeki her piksel, çevresindeki diğer piksellerin değerine göre ayarlanır (Mathworks, 2019a).

Kenar Belirleme (Edge Detection): Görüntülerdeki nesnelerin sınırlarını bulmak için kullanılan bir görüntü işleme tekniğidir. Parlaklıktaki süreksizlikleri tespit ederek çalışır (Mathworks, 2019a).

Bölütleme (Segmentation): Görüntü bölümlendirme ya da bölütleme, görüntüyü birden fazla parçaya bölme işlemidir. Genellikle dijital görüntülerde nesneleri arka plandan veya diğer nesnelerden ayırır (Mathworks, 2019a).

Nesne Tanıma (Recognition): Nesne tanıma, sabit veya hareketli görüntülerdeki nesneleri tanımlamak için kullanılan bir bilgisayar görme tekniğidir (Mathworks, 2019a).

Nesne Takibi (Object Tracking): Nesne takibi, görüntüdeki nesne ve arka plan renklerini temel alarak hareketli nesneleri belirleme ve takip etme tekniğidir (Mathworks, 2019a).

Şablon Eşleme (Template Matching): Şablon eşleme, kaynak görüntü şablonu üzerinde hedef görüntüyü tespit etmek için kullanılan bir yöntemdir (Mathworks, 2019a).

Resim Sıkıştırma (Image Compression): Resmin boyutunu azaltmak için kullanılan bir işlemdir. Sıkıştırma, kayıplı veya kayıpsız olabilir. Resmin saklanması için gerekli olan bellek miktarını ve iletilmesi için gereken bant genişliğini minimize etmeyi amaçlar (Mathworks, 2019a).

4.6. Bölüm Değerlendirmesi

Bu bölümde görüntü işlemenin tanımı yapılmış ve görüntülerin elde edilmesi işlemleri anlatılmıştır. Ayrıca dijital görüntü ve türleri anlatılarak çalışmada kullanılan renk uzayları hakkında bilgiler verilmiştir. Son olarak en bilindik görüntü işleme tekniklerine kısaca değinilmiştir.

5. YAPAY ZEKA

5.1. Yapay Zekanın Tanımı

Yapay zekâ; bir bilgisayarın, bilgisayar altyapısına sahip veya bilgisayar denetiminde olan bir makinenin, insana özgü davranışlardan akıl yürütme, anlam çıkartma, genelleme ve geçmiş tecrübelerinden öğrenme gibi yüksek zihinsel işlevlere ilişkin görevlerin yerine getirilmesi yeteneği olarak tanımlanmaktadır (Nabiyev, 2005; Ünal, 2009).

Yapay zeka kavramı için farklı tanımlamalar mevcuttur. Bu tanımlamalardan bazıları aşağıda verilmiştir.

Yapay zekâ akıllı davranışın incelenmesidir. Amacı, akıllı varlıkların davranışını açıklaması ve akıllı davranış yeteneğine sahip yapay varlıkların ortaya çıkarılmasıdır (Genesereth ve Nilsson, 1987).

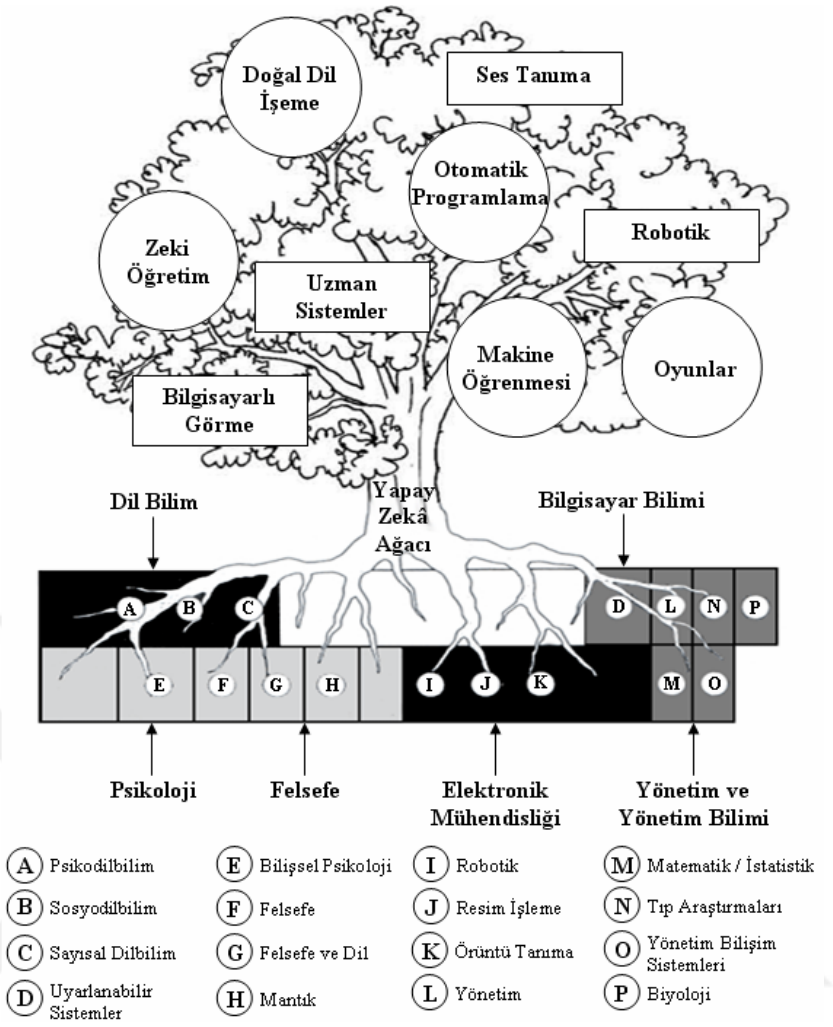
Yapay zeka; temelinde sezgisel programlama yer alan bir yaklaşımdır (Abinov, 1989).

Yapay zeka; insanların yaptıklarını bilgisayarlara da yaptırabilme çalışmasıdır (Nenov, 1999).

Yapay zeka, bir bilgisayarın veya bilgisayar kontrollü bir robotun, akıllı varlıklarla ilişkilendirilen görevleri gerçekleştirme yeteneğidir (Copeland, 2018).

5.2. Yapay Zeka ile İlişkili Disiplinler

Yapay zeka disiplinler arası bir yapıya sahiptir. Yapay zekanın ilişkili olduğu disiplinler ve alanlar Şekil 5.1'de gösterilmiştir.



Şekil 5.1. Yapay zekanın ilişkili olduğu disiplinler (Cercone ve McCalla, 1984; Erkoç, 2008)

Şekil 5.1'de; psikoloji, felsefe, dilbilim, elektronik mühendisliği, bilgisayar bilimi ve yönetim biliminden gelen katkılar da dahil olmak üzere yapay zekanın türetildiği kökler, disiplinler gösterilmektedir (Cercone ve McCalla, 1984).

Bilişsel psikoloji ve psiko-dilbilim alt alanları, psikoloji ve yapay zeka merkezleri arasındaki kesişimi oluşturur. Dil felsefesi, felsefe ve mantık alt alanları, felsefe ve yapay zeka merkezleri arasındaki kesişimi oluşturur.

Dilbilim ile yapay zeka merkezleri arasındaki kesişimi, psiko-dilbilimi, sosyo-dilbilimi ve sayısal dilbilimi alt alanları oluşturur. Elektronik mühendisliği ve yapay zeka merkezleri arasındaki kesişimi, görüntü işleme, örüntü tanıma ve robotik alt alanları oluşturur.

Bilgisayar bilimi ve yapay zeka merkezleri arasındaki kesişimi, uyarlanabilir (adaptif) sistemler oluşturur. Son olarak, yönetim bilimi ve yapay zeka merkezleri arasındaki kesişimde ise geriye kalan alt alanlar örtüşmektedir.

5.3. Yapay Zeka Yöntemleri

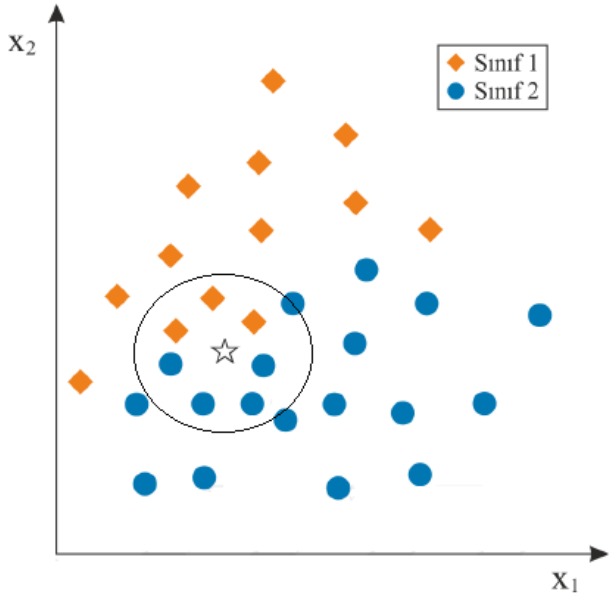
Sınıflandırma yöntemleri çeşitli alanlarda kullanılan yüksek öneme sahip yöntemlerdir. Sınıf belirlemede, verilerin hangi sınıfa ait olduğunu belirlemek için sınıflandırma yöntemleri kullanılır. Sınıflandırma yöntemi, öngörüler yaparak çalışmaktadır. Sınıflandırmanın amacı, söz konusu verileri ayrıştırmak için verilerin ortak özelliklerinden yararlanmaktır (Özkan, 2008).

Bu tez çalışmasında yapay zeka tekniklerinden sıklıkla kullanılan, k-En Yakın Komşu (k-NN), Destek Vektör Makinesi (SVM), Çok Katmanlı Algılayıcılar (MLP), Karar Ağacı (DT), Lojistik Regresyon (LR) ve Rastgele Orman (RF) sınıflandırma algoritmaları kullanılmıştır.

5.3.1. k-En yakın komşu

k-En Yakın Komşu (k-NN) yöntemi parametrik olmayan bir öğrenme algoritmasıdır. k-NN, veriler arasındaki uzaklığı hesaplamak için Öklid mesafesini, k'nin komşu sayısını temsil ettiği veri kümesini sınıflandırma adına bir parametre olarak kullanmaktadır (Kumar ve ark., 2019).

k-NN ile sınıfı bilinmeyen örnek verinin sınıflandırılması amaçlanır. Bu sebeple eğitim kümesindeki önceden sınıflandırılmış veri seti ile örnek veriye olan uzaklık mesafesi hesaplanır (Toptaş, 2018). Test edilecek belli bir miktar veri olduğu düşünülürse, test verisi mevcut verilerin tümüyle tek tek işleme alınır. Test verisi ölçülen bütün özellikler açısından kendisine yakın olan pek çok komşuya sahip olacaktır. Bu sebeple test verisine en yakın k adet veri seçilir. Bunun sonucunda da seçilen verilerden hangi sınıfa ait daha fazla veri varsa test edilen verinin o sınıfa ait olduğu söylenir (Richman, 2011; Nadkarni, 2016). Şekil 5.2’de k değeri yedi (7) seçilerek k-NN algoritması için bir örnek gösterilmiştir.



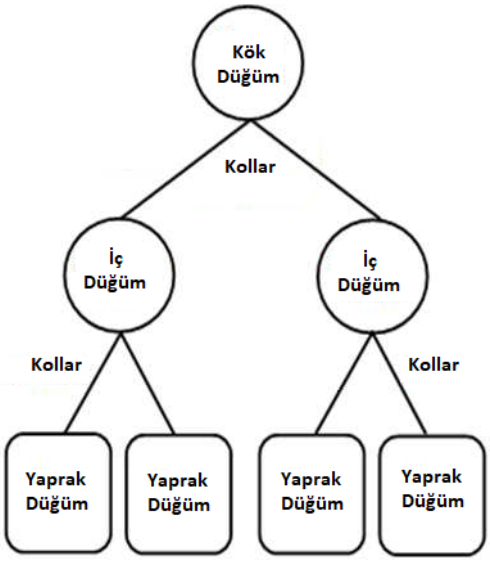
Şekil 5.2. k-NN algoritması örneği

Şekil 5.2'de verilen örnekte sınıf 1 için (♦) işareti, sınıf 2 için (●) işareti ve test verisi için de (☆) işareti kullanılmıştır. Test verisi, veri seti içerisindeki tüm veriler ile kıyaslandıktan sonra kendisine komşu olan k=7 adet veri seçilerek oluşan küme içinde sayıca fazla olan sınıf 2'ye dahil edilir (Toptaş, 2018).

k-NN algoritmasının bazı avantaj ve dezavantajları mevcuttur. En önemli avantajı verimli ve esnek olmasıdır. İşlevsellik açısından oldukça basit bir algoritma olması hız ve ölçeklenebilirlik açısından verimli olmasını sağlamaktadır. Algoritmanın esnek olması ise, ilişkilerin karmaşıklığı ile doğrusal veya doğrusal olmayan ilişkiler tarafından açıklanamayan veri kümelerini yönetebilmesini kolaylaştırmaktadır. Ancak diğer veri madenciliği algoritmalarının aksine yeni yapılacak tahminlerde, değişkenlerden hangisinin önemli olduğu konusunda fikir vermemesi, eğitim seti verilerinin tümünü depolaması açısından yüksek hafızaya ihtiyaç duyması ve maliyetinin yüksek olması algoritmanın en önemli dezavantajlarıdır (Miner ve ark., 2014; Kalaycı, 2018).

5.3.2. Karar ağacı

Karar ağaçları (DT), veri madenciliğinde sinir ağları ile birlikte akla ilk gelen sınıflandırma yöntemlerden biridir. DT genel olarak bir ağaç diyagramı şeklinde düşünülürse, dallarının ve düğümlerinin her birinde bir sınıflandırma sorgusuna sahip olacak şekilde dallanır (Soylu, 2019). Şekil 5.3'de DT genel yapısı gösterilmiştir.



Şekil 5.3. DT genel yapısı

DT'de kök düğüm özniteliği temsil eder. İç düğüm, bir özelliğin testini veya değerlendirilmesini gösterir. Kol, niteliği temsil eder ve iç düğümdeki değerlendirmenin sonucunu gösterir. Sonuç düğümü veya yaprak düğümü ise sınıfları temsil eder ve son kararı gösterir (Sá ve ark., 2011).

DT'lerin karmaşık problemlerle başa çıkmadaki özellikleri ile mantıksal sınıflandırma kurallarındaki çıkarımları avantaj olarak görülmektedir (Amor ve ark., 2006). Ayrıca DT'nin kurulumunun pahalı olmaması, veri tabanlarına entegrasyonunun kolay olması ve güvenirliliklerinin yüksek olması sebebiyle diğer sınıflama modelleri arasında öne çıkmasını sağlamaktadır.

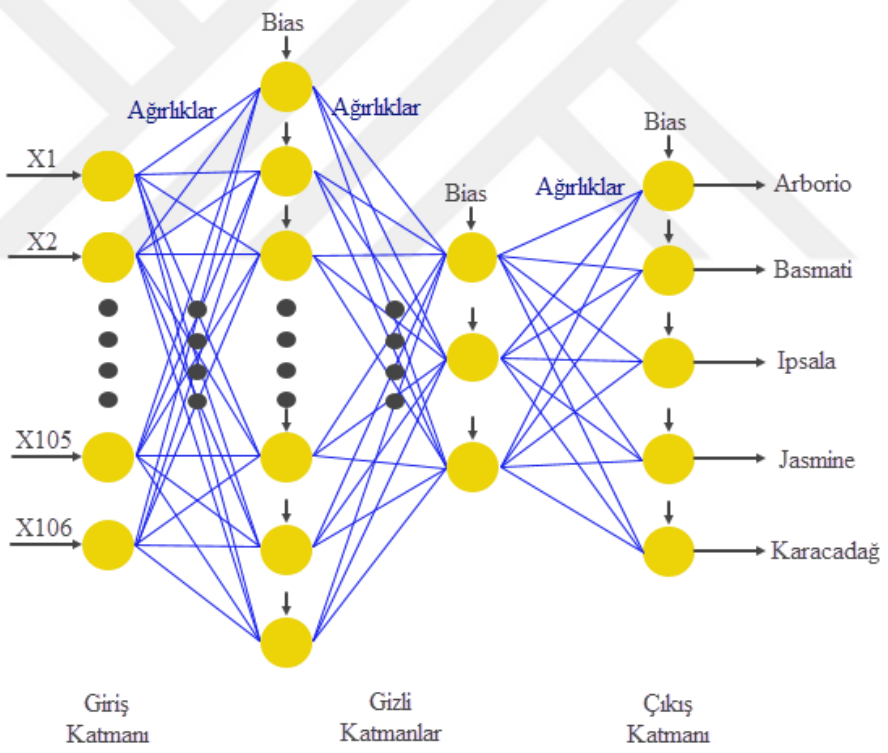
5.3.3. Lojistik regresyon

Lojistik regresyon (LR) yaygın olarak kullanılan istatistiksel modellerden birisidir. LR'de bağımlı değişken bir veya daha fazla değişkenden tahmin edilir. LR, bağımlı değişkenler ile bağımsız değişkenler arasındaki ilişkiyi netleştirir. LR'de değişkenlerin normal dağılım gerektirmesine ihtiyaç yoktur (Cruyff ve ark., 2016; Kalantar ve ark., 2018).

LR'de öngörülen değerler olasılıklar olduğu için LR, 0 ve 1 ile sınırlandırılmıştır. Bunun sebebi ise LR'nin sonuçlarda kendisini değil de olasılığını öngörmesidir (Wikipedia, 2019).

5.3.4. Çok katmanlı algılayıcılar

Günümüzde birçok yapay sinir ağı modeli belirli amaçlarda kullanılmak üzere geliştirilmiş olup, çok katmanlı algılayıcılar (MLP) bu modeller içerisinde en çok kullanım alanına sahip olanlardan birisidir. MLP'de nöronların dizilimi katmanlar halindedir ve iki adet ana katmanla birlikte bunların arasında yer alan bir de gizli katman bulunur. MLP bünyesinde birden fazla gizli katman bulundurabilir. Ana katmanlardan ilki olan giriş katmanı, verilerin okunduğu katman olup çözülmesi gereken probleme dair bilgileri barındırır. İkinci ana katman olan çıkış katmanı ise sınıfların belirlendiği ve ağ içerisinde işlenen bilgilere dair çıktıların alındığı katmandır. Gizli katman ise, ana katmanlar arasında yer alan veriler üzerinde ara işlemlerin yapıldığı katmandır (Sabancı ve Ünlerşen, 2016). Şekil 5.4'de MLP genel yapısı verilmiştir.



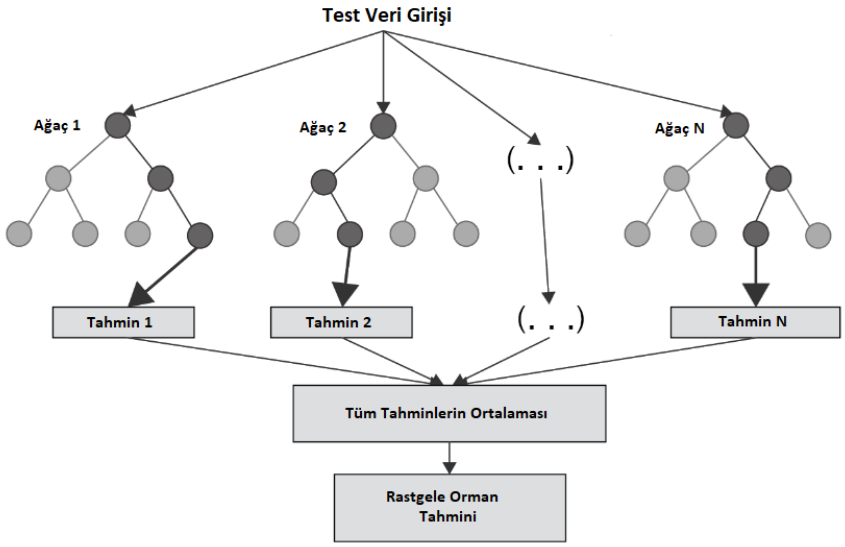
Şekil 5.4. MLP genel yapısı

MLP'de özellik sayısı kadar nöron bulunur ve veriler giriş katmanından çıkış katmanına doğru tek yönde bir veri akışı ile sağlanır. Ayrıca eğitim süresi boyunca ağ yapısında izlem ve değişiklik yapabilmek mümkündür (Arora, 2012).

5.3.5. Rastgele orman

Rastgele orman (RF) birden çok DT'den oluşan bir sınıflandırıcıdır. Yeni bir sınıflandırma yapmak için, her bir DT girdiler için bir sınıflandırma sağlar. Sonrasında RF sınıflandırmaları değerlendirerek en çok oya sahip olan tahmini seçer (Mao ve Wang, 2012).

RF, bir veri kümesinde çok sayıda değişken yönetebilme özelliğine sahiptir. Ayrıca, eksik verileri tahmin etmede oldukça başarılıdır. RF'nin en büyük dezavantajı, tekrarlana bilirlik eksikliğidir. Ayrıca, son modelin ve sonrasındaki sonuçların yorumlanabilmesi zordur. Bunun sebebi de birçok bağımsız karar ağacı içermesinden kaynaklanmaktadır (Dunham, 2009). Şekil 5.5'de RF genel yapısı gösterilmiştir.

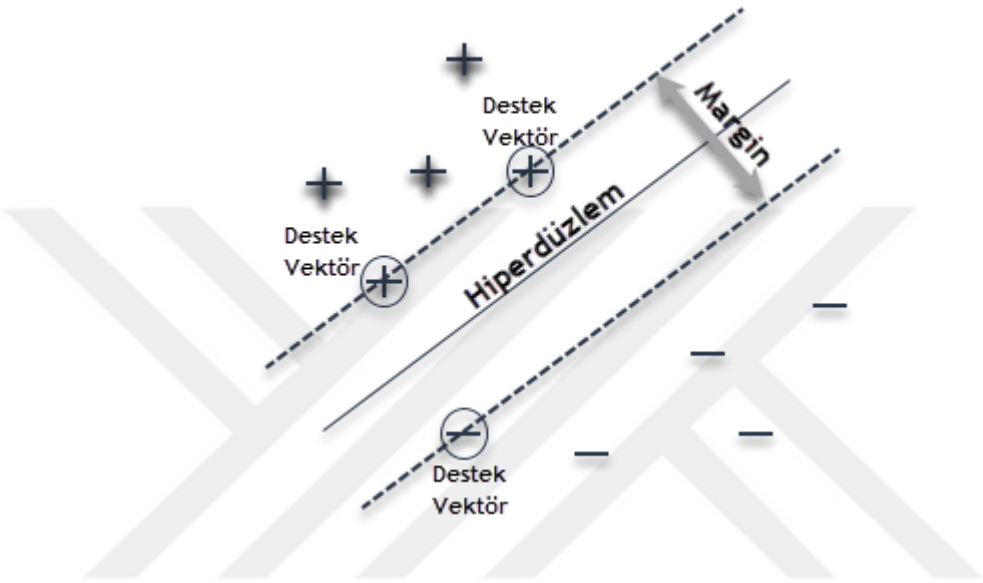


Şekil 5.5. RF genel yapısı (Chakure, 2019)

5.3.6. Destek vektör makinesi

Destek vektör makineleri (SVM), sınıflandırma ve regresyonlar için hiper bir düzlem oluşturan çekirdek (kernel) tabanlı bir yöntemdir. SVM, ayırma mekanizmaları ile veriyi iki boyutlu uzayda lineer, üç boyutlu uzayda düzlemsel ve çok boyutlu uzayda hiperdüzlem şeklinde sınıflandırma kabiliyetine sahiptir (Abhang ve ark., 2016; Kaynar ve ark., 2016). SVM sınıflara ait verileri birbirinden ayıran en iyi hiperdüzlemi bularak sınıflandırma işlemi gerçekleştirir.

Bir SVM için en iyi hiperdüzlem, Şekil 5.6'da gösterildiği gibi iki sınıf arasında en büyük margine sahip olanıdır (Mathworks, 2019b). Hiperdüzleme en yakın noktalar ise destek vektörleri olarak isimlendirilir. SVM'de eğitim verileri en uygun hiperdüzlemi bulmak için kullanılırken, test verileri ise hiperdüzlemin ayırdığı alanın hangi kısmında bulunuyorsa o kısmın sınıfına dahil edilerek sınıflandırma işlemini gerçekleştirmede kullanılır (Toptaş, 2018).



Şekil 5.6. SVM hiperdüzlem

SVM'ler diğer sınıflandırma algoritmalarına benzer özellikler taşır. Özellikle sinir ağlarına benzer ancak daha çok k-NN algoritması ile benzerlik taşır. K-NN algoritması gibi SVM de, algoritmaya sunulan örnek verilere dayanarak komşularını belirler ve yeni veriler için tahminlerin yapıldığını varsayar (Miner ve ark., 2014).

5.4. Bölüm Değerlendirmesi

Bu bölümde yapay zeka hakkında yapılan tanımlamalar ile yapay zekanın ilişkili olduğu disiplinler verilmiştir. Ayrıca yapay zeka tekniklerine ait en bilinen ve çalışmada kullanılan algoritmalara ait bilgilere yer verilmiştir.

6. MATERYAL VE YÖNTEM

Bu çalışmanın amacı, 5 çeşide ait pirinç tanelerinden görüntüler elde ederek morfolojik özellik, şekil özellikleri ve renk özellik çıkarımlarını gerçekleştirmektir. Ayrıca, elde edilen özelliklerin çeşitli yapay zeka teknikleri kullanılarak sınıflandırma işlemlerini gerçekleştirmektir. Şekil 6.1'de sınıflandırma akış şeması verilmiştir.

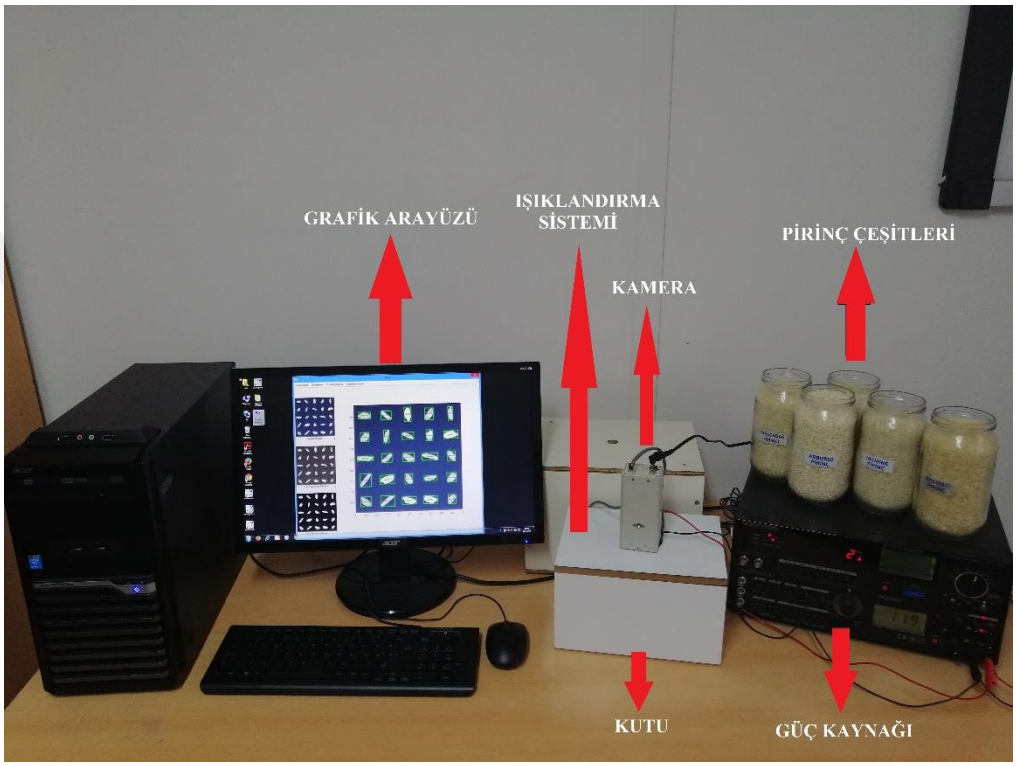


Şekil 6.1. Sınıflandırma akış şeması

6.1. Görüntünün Elde Edilmesi

Çalışmada kullanılan pirinçlere ait görüntüleri elde edebilmek için Şekil 6.2'de verilen düzenekten faydalanılmıştır. Görüntü almak için Ikegami marka CCD görüntüleme sensörüne sahip kamera kullanılmıştır. Kamera gelişmiş hassasiyet ve yüksek görüntü kalitesine sahiptir. 752(H)X582(V) PAL çözünürlüğünde görüntüleme yapmaktadır. Beyaz dengesi ve arka ışık düzeltmesi gibi özellikleri mevcuttur. 12V DC gerilimle beslenmekte ve 4.5W'ın altında güç tüketimi bulunmaktadır (Ikegami, 2019).

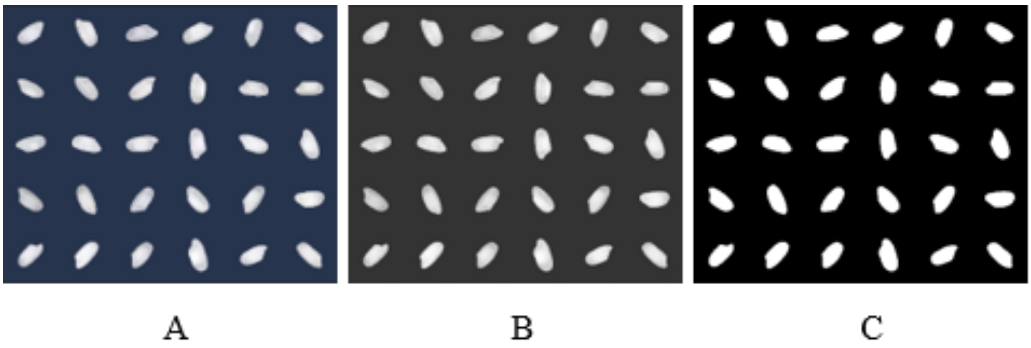
Çalışmada kullanılan kamera, içerisinde aydınlatma düzeneği bulunan ve dış ortamdan ışık almayı önleyecek yapıda kapalı bir kutu üzerine yerleştirilmiştir. Kutu zemin fonu, görüntünün rahatlıkla işlenebilmesi açısından siyah renk seçilmiştir. Kutu ölçüleri, 14 cm eninde ve 18 cm uzunluğunda bir alandan görüntü alınabilecek şekilde dizayn edilmiştir. Kameranın kutu zeminine olan yüksekliği 15 cm olarak ayarlanmıştır. Elde edilen görüntüler bilgisayara aktarılarak kaydedilmiştir.



Şekil 6.2. Görüntü elde etmek için kullanılan düzenek

6.2. Görüntü İşleme

Görüntü işleme aşamasında özellik çıkarma ve sınıflandırma işlemlerini en doğru şekilde gerçekleştirebilmek için görüntülerle ilgili ön işlemler açıklanmaktadır. Görüntü işleme MATLAB yazılımı yardımıyla gerçekleştirilmiştir. Kameradan alınan görüntüler, öncelikle gri tonlamalı görüntüye dönüştürülmüştür. Daha sonra, otsu metodu yardımıyla gri tonlamalı görüntünün global eşik seviyesi kullanılarak ikili görüntüye dönüştürülmüştür. Elde edilen ikili görüntüler üzerindeki istenmeyen nesneler kaldırılmış ve açma işlemi uygulanarak özellik çıkarımı aşamasına hazırlanmıştır. Şekil 6.3'de görüntü ön işlem aşamaları verilmiştir.



Şekil 6.3. Görüntü önişlem aşamaları
(A) Renkli görüntü. (B) Gri tonlamalı görüntü (C) Ön işlem sonrası ikili görüntü

6.3. Özellik Çıkarımı

Çalışmada MATLAB yazılımı kullanılarak 12 adet morfolojik, morfolojik özelliklerden faydalanılarak elde edilen 4 adet şekil ve beş farklı renk uzayı kullanılarak elde edilen 90 adet renk özellik çıkarımı yapılmıştır.

Morfolojik ve şekil özellikleri MATLAB regionprops fonksiyonu bileşenleri kullanılarak elde edilmiştir. Elde edilen özellik değerleri her bir pirinç tanesinin piksel sayısını ifade etmektedir. Çizelge 6.1'de morfolojik ve şekil özelliklerinin listesi verilmiştir.

Çizelge 6.1. Morfolojik ve şekil özellikleri listesi

Morfolojik Özellikler						**Şekil Özellikleri**	
1	Alan	**5**	Eksantriklik	**9**	Kapsam	**1**	Şekil_Faktörü_1
2	Çevre_Uzunluğu	**6**	Eşdeğer_Çap	**10**	En_Boy_oranı	**2**	Şekil_Faktörü_2
3	Ana_Eksen_Uzunluğu	**7**	Sertlik	**11**	Yuvarlaklık	**3**	Şekil_Faktörü_3
4	Küçük_Eksen_Uzunluğu	**8**	Dışbükey_Alan	**12**	Kompaktlık	**4**	Şekil_Faktörü_4

Morfolojik ve şekil özellikleri bileşenlerine ait açıklamalar aşağıda verilmiştir (Pazoki ve ark., 2014);

Alan (A): Pirinç tanesi alanının sınırları içerisindeki piksel sayısıdır.

Çevre Uzunluğu (Ç): Pirinç tanesi çevre sınır uzunluğunu verir.

Ana Eksen Uzunluğu (L): Pirinç tanesi üzerinde çizilebilen en uzun çizgidir.

Küçük eksen uzunluğu (l): Pirinç tanesi üzerinde ana eksene dik çizilebilen en uzun çizgidir.

Eksantriklik (Eks): Bölge ile aynı anlara sahip olan dairenin eksantrikliğini verir.

Eşdeğer Çap (EÇ): Pirinç tanesinin alanıyla aynı alana sahip bir dairenin çapıdır. Eşdeğer çap için hesaplama formülü Denklem 6.1'de verilmiştir.

$$\text{EÇ} = \sqrt{\frac{4xA}{\pi}} \tag{6.1}$$

Sertlik (S): Dışbükey gövdede bulunan piksellerin pirinç tanesi bölgesindeki piksellere oranıdır. Denklem 6.2'de hesaplama formülü verilmiştir.

$$\text{S} = \frac{\text{A}}{\text{DBA}} \tag{6.2}$$

Dışbükey Alan (DBA): Pirinç tanesi alanını barındırabilecek en küçük dışbükey poligonda piksel sayısıdır.

Kapsam (K): Sınırlayıcı kutudaki piksellerin pirinç tane bölgesinde bulunan piksellere oranıdır.

En Boy Oranı (EBO): Ana eksen uzunluğunun küçük eksen uzunluğuna bölümü olarak hesaplanır. Denklem 6.3'de hesaplama formülü verilmiştir.

$$\text{EBO} = \frac{\text{L}}{\text{l}} \tag{6.3}$$

Yuvarlaklık (Y): Alan ve çevreden faydalanılarak hesaplanır. Hesaplama formülü Denklem 6.4'de verilmiştir.

$$\text{Y} = \frac{4xAx\pi}{\text{Ç}^2} \tag{6.4}$$

Kompaktlık (Ko): Eşdeğer çapın ana eksen uzunluğuna bölümü ile hesaplanır. Denklem 6.5'de kompaktlık hesaplama formülü verilmiştir.

$$\text{Ko} = \frac{\text{EÇ}}{\text{L}} \tag{6.5}$$

Şekil Faktörü: Şekil özellikleri, morfolojik özelliklerden alan, ana eksen ve küçük eksen uzunlukları kullanılarak hesaplanır. Şekil faktörlerine ait hesaplama formülleri aşağıda verilmiştir (Pazoki ve ark., 2014).

Şekil Faktörü_1 (SF1): Ana eksen uzunluğunun alana bölümüyle hesaplanır. Hesaplama formülü Denklem 6.6'da verilmiştir.

$$SF1 = \frac{L}{A} \tag{6.6}$$

Şekil Faktörü_2 (SF2): Küçük eksen uzunluğunun alana bölümüyle hesaplanır. Hesaplama için gerekli formül Denklem 6.7'de verilmiştir.

$$SF2 = \frac{l}{A} \tag{6.7}$$

Şekil Faktörü_3 (SF3): Hesaplama formülü Denklem 6.8'de verildiği gibidir.

$$SF3 = \frac{A}{\left(\frac{L}{2}\right)^2 x\, \pi} \tag{6.8}$$

Şekil Faktörü_4 (SF4): Hesaplama formülü Denklem 6.9'da verildiği gibidir.

$$SF4 = \frac{A}{\frac{L}{2} x \frac{l}{2} x\, \pi} \tag{6.9}$$

Çalışmada kullanılan pirinç tanelerine ait renkli (RGB) görüntüler, MATLAB yazılımı yardımıyla RGB renk uzayından HSV, L*a*b*, YCbCr ve XYZ renk uzaylarına dönüştürülmüştür. Dönüşüm formülleri aşağıda verilmiştir (Chaudhary ve ark., 2012; Pazoki ve ark., 2014).

RGB-HSV Dönüşümü; HSV renk uzayı, renk özü-tonu (H), doygunluk (S) ve değer (V) olmak üzere üç parametreden oluşur. Denklem 6.10 ile Denklem 6.14 arasında RGB-HSV dönüşüm formülleri verilmiştir.

$$\mathrm{Max} = \mathrm{Max}(\mathrm{R}, \mathrm{G}, \mathrm{B}) \tag{6.10}$$

$$\mathrm{Min} = \mathrm{Min}(\mathrm{R}, \mathrm{G}, \mathrm{B}) \tag{6.11}$$

$$\mathrm{V} = \mathrm{Max} \tag{6.12}$$

$$\mathrm{S} = \frac{\mathrm{Max} - \mathrm{Min}}{\mathrm{Max}} \tag{6.13}$$

$$\mathrm{H} = \begin{cases} \frac{1}{6}\frac{\mathrm{G} - \mathrm{B}}{\mathrm{Max} - \mathrm{Min}}, & \mathrm{V} = \mathrm{R} \\ \frac{1}{6}\frac{\mathrm{B} - \mathrm{R}}{\mathrm{Max} - \mathrm{Min}} + \frac{1}{3}, & \mathrm{V} = \mathrm{G} \\ \frac{1}{6}\frac{\mathrm{R} - \mathrm{G}}{\mathrm{Max} - \mathrm{Min}} + \frac{2}{3}, & \mathrm{V} = \mathrm{B} \\ (\text{Eğer } \mathrm{H} < 0 \rightarrow H = H + 1) \end{cases} \tag{6.14}$$

*RGB-L*a*b* Dönüşümü;* L*a*b* renk uzayında L* değeri açıklığı ifade eder ve 0 siyahı, 100 ise beyazı gösterir. a* değeri kırmızı ile yeşili ifade eder. (+) a* kırmızıyı, (-) a* ise yeşili belirtmektedir. b* değeri ise sarı ile maviyi ifade eder. (+) b* sarıyı, (-) b* ise maviyi belirtmektedir. RGB-L*a*b* dönüşüm formülleri Denklem 6.15 ile Denklem 6.17 arasında verilmiştir.

$$\mathrm{L} = 0.2126\ x\ \mathrm{R} + 0.7152\ x\ \mathrm{G} + 0.0722\ x\ \mathrm{B} \tag{6.15}$$

$$\mathrm{A} = 1.4749\ x\ (0.2213\ x\ \mathrm{R} - 0.3390\ x\ \mathrm{G} + 0.1177\ x\ \mathrm{B}) + 128 \tag{6.16}$$

$$\mathrm{B} = 0.6245\ x\ (0.1949\ x\ \mathrm{R} + 0.6057\ x\ \mathrm{G} - 0.8006\ x\ \mathrm{B}) + 128 \tag{6.17}$$

RGB-YCbCr Dönüşümü; YCbCr renk uzayı, parlaklık (Y), mavi fark (Cb) ve kırmızı fark (Cr) bileşenlerinden oluşmaktadır. Denklem 6.18 ile Denklem 6.20 arasında RGB-YCbCr dönüşümüne ait formüller verilmiştir.

$$\mathrm{Y} = 0.299\ x\ \mathrm{R} + 0.587\ x\ \mathrm{G} + 0.114\ x\ \mathrm{B} \tag{6.18}$$

$$\mathrm{Cb} = -0.168\ x\ \mathrm{R} - 0.331\ x\ \mathrm{G} + 0.500\ x\ \mathrm{B} \tag{6.19}$$

$$\mathrm{Cr} = 0.500\ x\ \mathrm{R} - 0.418\ x\ \mathrm{G} - 0.081\ x\ \mathrm{B} \tag{6.20}$$

RGB-XYZ Dönüşümü; XYZ renk uzayında, X kırmızıyı, Z maviyi ve Y bileşeni de parlaklığı belirtmektedir. RGB-XYZ dönüşümüne ait formüller Denklem 6.21 ile Denklem 6.23 arasında verilmiştir.

$$X = 0.4124\ x\ R + 0.3576\ x\ G + 0.1805\ x\ B \quad (6.21)$$

$$Y = 0.2126\ x\ R + 0.7152\ x\ G + 0.722\ x\ B \quad (6.22)$$

$$Z = 0.0193\ x\ R + 0.1192\ x\ G + 0.9505\ x\ B \quad (6.23)$$

Dönüşüm işlemi sonrasında ise bu renk uzaylarına ait özellikler MATLAB'daki regionprops fonksiyonu kullanılarak ortalama yoğunluk (MeanIntensity) ve piksel değeri (PixelValue) bileşenlerinden alınan veriler ile çoğaltılmıştır. RGB, HSV, L*a*b*, YCbCr ve XYZ renk uzayları kullanılarak pirinç görüntülerine ait renk özelliklerinin, her bir renk kanalı için ortalama, standart sapma, çarpıklık, basıklık, entropi ve dalgacık ayrışması bileşenleri ile toplam 90 adet renk özelliği çıkartılmıştır (Arefi ve ark., 2011). Renk özelliklerin listesi Çizelge 6.2'de verilmiştir.

Çizelge 6.2. Renk uzaylarından elde edilen özellik listesi

Renk Uzayı	Ortalama	Standart Sapma	Çarpıklık	Basıklık	Entropi	Dalgacık Ayrıştırması
RGB	Mean_RGB_R	StdDev_RGB_R	Skewness_RGB_R	Kurtosis_RGB_R	Entropy_RGB_R	Daub4_RGB_R
	Mean_RGB_G	StdDev_RGB_G	Skewness_RGB_G	Kurtosis_RGB_G	Entropy_RGB_G	Daub4_RGB_G
	Mean_RGB_B	StdDev_RGB_B	Skewness_RGB_B	Kurtosis_RGB_B	Entropy_RGB_B	Daub4_RGB_B
HSV	Mean_HSV_H	StdDev_HSV_H	Skewness_HSV_H	Kurtosis_HSV_H	Entropy_HSV_H	Daub4_HSV_H
	Mean_HSV_S	StdDev_HSV_S	Skewness_HSV_S	Kurtosis_HSV_S	Entropy_HSV_S	Daub4_HSV_S
	Mean_HSV_V	StdDev_HSV_V	Skewness_HSV_V	Kurtosis_HSV_V	Entropy_HSV_V	Daub4_HSV_V
L*a*b*	Mean_LAB_L	StdDev_LAB_L	Skewness_LAB_L	Kurtosis_LAB_L	Entropy_LAB_L	Daub4_LAB_L
	Mean_LAB_A	StdDev_LAB_A	Skewness_LAB_A	Kurtosis_LAB_A	Entropy_LAB_A	Daub4_LAB_A
	Mean_LAB_B	StdDev_LAB_B	Skewness_LAB_B	Kurtosis_LAB_B	Entropy_LAB_B	Daub4_LAB_B
YCbCr	Mean_ YCbCr_Y	StdDev_ YCbCr_Y	Skewness_ YCbCr_Y	Kurtosis_ YCbCr_Y	Entropy_ YCbCr_Y	Daub4_ YCbCr_Y
	Mean_YCbCr_Cb	StdDev_ YCbCr _Cb	Skewness_ YCbCr_Cb	Kurtosis_ YCbCr_Cb	Entropy_ YCbCr_Cb	Daub4_ YCbCr_Cb
	Mean_ YCbCr_Cr	StdDev_ YCbCr_Cr	Skewness_ YCbCr_Cr	Kurtosis_ YCbCr_Cr	Entropy_ YCbCr_Cr	Daub4_ YCbCr_Cr
XYZ	Mean_XYZ_X	StdDev_XYZ_X	Skewness_XYZ_X	Kurtosis_XYZ_X	Entropy_XYZ_X	Daub4_XYZ_X
	Mean_XYZ_Y	StdDev_XYZ_Y	Skewness_XYZ_Y	Kurtosis_XYZ_Y	Entropy_XYZ_Y	Daub4_XYZ_Y
	Mean_XYZ_Z	StdDev_XYZ_Z	Skewness_XYZ_Z	Kurtosis_XYZ_Z	Entropy_XYZ_Z	Daub4_XYZ_Z

Renk özelliklerine uygulanan bileşenlere ait açıklamalar aşağıda verilmiştir (Arefi ve ark., 2011);

Ortalama (Ort): Ortalama yoğunluk değeridir. (N değişken vektörü, X giriş verisini temsil etmektedir). Denklem 6.24'de hesaplama formülü verilmiştir.

$$\mathrm{Ort} = \frac{1}{N}\sum_{i=1}^{N} Xi \quad (6.24)$$

Standart Sapma (SS): Piksel Değerlerinin standart sapmasını döndürür. Standart sapma varyansın (V) kareköküdür. Hesaplama formülleri aşağıda verilmiştir.

$$V = \frac{1}{N-1}\sum_{i=1}^{N}(Xi - Ort)^2 \tag{6.25}$$

$$SS = \sqrt{V} \tag{6.26}$$

Çarpıklık (Çr): Piksel Değerlerinin çarpıklık değerini döndürür. Çarpıklık için hesaplama formülü Denklem 6.27'de verilmiştir.

$$Çr = \frac{\frac{1}{N-1}\sum_{i=1}^{N}(Xi - Ort)^3}{SS^3} \tag{6.27}$$

Basıklık (B): Piksel Değerlerinin basıklık değerini döndürür. Denklem 6.28'de basıklık hesaplama formülü verilmiştir.

$$B = \frac{\frac{1}{N-1}\sum_{i=1}^{N}(Xi - Ort)^4}{SS^4} - 3 \tag{6.28}$$

Entropi (E): Piksel Değerlerinin entropisini döndürür. Entropi, görüntü dokusunu karakterize etmek amacıyla kullanılan istatiksel bir ölçümdür. Denklem 6.29'da verilen p_i, i durumunun olasılığını, m ise durum sayısını temsil etmektedir.

$$E = -\sum_{i=1}^{m} p_i \log_2 p_i \tag{6.29}$$

Dalgacık Ayrıştırması: İki boyutlu dalgacık kullanılarak piksel değerinden matrisin dalgacık ayrıştırma düzeyini döndürür. Wavedec2 fonksiyonu kullanılmış ve dalgacık sırası db4 seçilmiştir.

6.4. Performans Ölçümleri

Sınıflandırma problemleri için gerekli olan yeni bir modelin oluşturulması veya mevcut modellerin kullanılması ve bu model üzerinde başarıya ulaşmak, doğru tahminlerin sayısı ile hesaplanır. Bu, modelin iyi olup olmadığı tahmininden ziyade sınıflandırmanın doğruluğu üzerinde etkilidir. Bu nedenle karmaşıklık matrisi sınıflandırmanın öngörü değerlendirmelerini açıklamak için kullanılır. Test verileri üzerinde bir sınıflandırma modeli ile gerçekleştirilen tahmini sınıflarla gerçek sınıflar hakkında bilgi sağlayan matris karmaşıklık matrisidir (Çataloluk, 2012; Cinar ve Koklu, 2019). Çizelge 6.3.'de ikili sınıflandırma için kullanılan karmaşıklık matrisi, Çizelge 6.4'de çok sınıflı sınıflandırma için kullanılan karmaşıklık matrisi verilmiştir (Hossin ve Sulaiman, 2015).

Çizelge 6.3. İkili sınıflandırma için kullanılan karmaşıklık matrisi

		Tahmini Sınıf	
		Pozitif	Negatif
Gerçek sınıf	Pozitif	Doğru pozitif (dp)	Yanlış negatif (yn)
	Negatif	Yanlış pozitif (yp)	Doğru negatif (dn)

Çizelge 6.4. Çok sınıflı sınıflandırma için kullanılan karmaşıklık matrisi

		Tahmini Sınıf				
		S_1	S_2	S_3	***	S_n
Gerçek Sınıf	S_1	**D_1**	Y_{12}	Y_{13}	***	Y_{1n}
	S_2	Y_{21}	**D_2**	Y_{23}	***	Y_{2n}
	S_3	Y_{31}	Y_{32}	**D_3**	***	Y_{3n}
	***	***	***	***	***	***
	S_n	Y_{n1}	Y_{n2}	Y_{n3}	***	**D_n**

(S: Sınıf, D: Doğru, Y: Yanlış)

Bir sınıflandırmanın doğruluğu, doğru tanınan sınıf örneklerinin (doğru pozitifler) sayısını, sınıfa ait olmayan doğru tanınan örneklerin sayısını (doğru negatifler) ve sınıfa yanlış atanmış (yanlış pozitifler) veya sınıf örnekleri olarak tanınmayan örnekleri (yanlış negatifler) hesaplayarak değerlendirilebilir (Sokolova ve Lapalme, 2009).

İkili sınıflandırma performans ölçümleri için karmaşıklık matrisi kullanılarak hesaplanan doğruluk, hatırlama, özgüllük, hassasiyet, hata oranı ve F1 skoru (F1), gibi

başarı kriterlerinin hesaplama formülleri Çizelge 6.5.'de verilmiştir (Hossin ve Sulaiman, 2015).

Çizelge 6.5. İkili sınıflandırma için performans ölçümleri ve hesaplama formülleri

No	Performans Ölçümü	Formül	
1	Doğruluk	$\frac{dp+dn}{dp+yp+dn+yn}x100$	(6.30)
2	Hata Oranı	$\frac{yp+yn}{dp+yp+dn+yn}x100$	(6.31)
3	Hatırlama	$\frac{dp}{dp+yn}x100$	(6.32)
4	Özgüllük	$\frac{dn}{dn+yp}x100$	(6.33)
5	Hassasiyet	$\frac{dp}{dp+yp}x100$	(6.34)
6	F1-Skoru	$\frac{2x\frac{dp}{dp+yp}x\frac{dp}{dp+dn}}{\frac{dp}{dp+yp}+\frac{dp}{dp+yn}}x100$	(6.35)

Çizelge 6.5'de bahsi geçen ikili sınıflandırma için performans ölçümlerinin açıklamaları aşağıda verilmiştir (Hossin ve Sulaiman, 2015);

Doğruluk: Değerlendirmeye giren tüm örnekler üzerindeki doğru tahminlerin oranını ölçmede kullanılır.

Hata Oranı: Değerlendirmeye giren tüm örnekler üzerinden yanlış tahminlerin oranını ölçmede kullanılır.

Hatırlama: Doğru sınıflandırılan pozitif değerlerin oranını ölçmede kullanılır.

Özgüllük: Doğru sınıflandırılmış negatif değerlerin oranını ölçmede kullanılır.

Hassasiyet: Doğru sınıflandırılan pozitif örnekler üzerindeki tahmin edilen toplam pozitif örneklere oranı ölçmede kullanılır.

F1-Skoru: Hatırlama ve hassasiyet ölçümlerinin harmonik ortalamasını verir.

Çok sınıflı sınıflandırma performans ölçümleri için karmaşıklık matrisi kullanılarak hesaplanan Ortalama Doğruluk, Ortalama Hatırlama, Ortalama Hassasiyet, Ortalama Hata Oranı ve Ortalama F1-Skoru için hesaplama formülleri Çizelge 6.6'da verilmiştir (Hossin ve Sulaiman, 2015).

Çizelge 6.6. Çok sınıflı sınıflandırma için performans ölçümleri ve hesaplama formülleri

No	Performans Ölçümü	Formül	
1	Ortalama Doğruluk	$\frac{\sum_{i=1}^{1} \frac{dp_i + dn_i}{dp_i + yn_i + yp_i + dn_i}}{l} x100$	(6.36)
2	Ortalama Hata Oranı	$\frac{\sum_{i=1}^{1} \frac{yp_i + yn_i}{dp_i + yn_i + yp_i + dn_i}}{l} x100$	(6.37)
3	Ortalama Hassasiyet	$\frac{\sum_{i=1}^{1} \frac{dp_i}{dp_i + yp_i}}{l} x100$	(6.38)
4	Ortalama Hatırlama	$\frac{\sum_{i=1}^{1} \frac{dp_i}{dp_i + yn_i}}{l} x100$	(6.39)
5	Ortalama F1-Skoru	$\frac{2x \frac{\sum_{i=1}^{1} \frac{dp_i}{dp_i + yp_i}}{l} x \frac{\sum_{i=1}^{1} \frac{dp_i}{dp_i + yn_i}}{l}}{\frac{\sum_{i=1}^{1} \frac{dp_i}{dp_i + yp_i}}{l} + \frac{\sum_{i=1}^{1} \frac{dp_i}{dp_i + yn_i}}{l}} x100$	(6.40)

Çizelge 6.6'da bahsi geçen çok sınıflı sınıflandırma için performans ölçümlerinin açıklamaları aşağıda verilmiştir (Hossin ve Sulaiman, 2015);

Ortalama Doğruluk: Sınıflandırmadaki tüm sınıfların ortalama etkinliğini ölçmek için kullanılır.

Ortalama Hata Oranı: Sınıflandırmadaki tüm sınıfların ortalama hata oranını ölçmek için kullanılır.

Ortalama Hassasiyet: Her sınıf için hassasiyet ortalamasını ölçmek için kullanılır.

Ortalama Hatırlama: Her sınıf için hatırlama ortalamasını ölçmek için kullanılır.

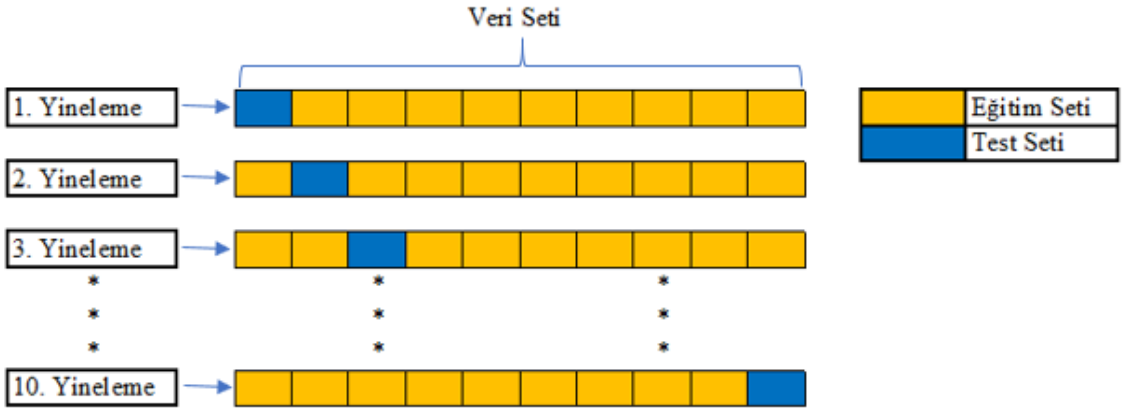
Ortalama F1-Skoru: Her sınıf için F1-skoru ortalamasını ölçmek için kullanılır.

6.5. Çapraz Doğrulama

Model geliştirme verilerinin yetersiz olduğu veri madenciliği ve yapay zeka tekniklerinde, modelin genelleme yeteneğini kontrol etmek için kullanılabilecek en yaygın prosedür k-kat çapraz doğrulama yöntemidir (Singh ve Panda, 2011).

Çapraz doğrulama, sınıflandırmanın güvenirliğini artırmak amacıyla geliştirilen bir hata tahmini yöntemidir. Çapraz doğrulama, veri setini, eğitim ve sınama için belirlenen sayıda alt kümeye rastgele olacak şekilde bölerek çalışır. Alt kümelerden birisi test seti kabul edilerek sistem kalan setlerle eğitilir. Bu işlem k sayısı kadar tekrarlanır ve

sistem test edilir (Gupta, 2017). Şekil 6.4'de çapraz doğrulamanın çalışma mantığı gösterilmiştir.



Şekil 6.4. Çapraz doğrulama çalışma mantığı

Şekil 6.4.'de verilen örnekte, yineleme sayısı (k) 10 olarak seçilmiştir. Bu örnekte veri seti 10 bölüme ayrılmıştır. Dokuz bölüm sırayla eğitim verisi olarak alınmış ve bir tanesi de test verisi olarak kullanılmıştır. İşlem tüm alt kümeler için yinelenir ve sistem testi tamamlanmış olur (Berrar, 2018).

6.6. Kappa Testi

Kappa testi, iki ya da ikiden fazla gözlemci arasında bulunan uyuma bakarak güvenilirlik ölçmede kullanılan istatistiki bir yöntemdir. Kappa katsayısı, sadece iki gözlemci arasında bulunan uyuma bakıyorsa Cohen'in, ikiden fazla gözlemci arasında bulunan uyuma bakıyorsa Fleis'in kappa katsayısı kullanılmalıdır. Sonuç yalnızca kappa katsayısı olarak nitelendirilirse, bu Cohen'in kappa katsayısıdır (Kılıç, 2015).

Kappa katsayı değerleri -1 ve +1 arasında değişkenlik gösterebilir. Değer +1 olduğunda gözlemciler arasındaki uyum için tamamen uyumlu, 0 olduğunda şansa bağlı, -1 olduğunda ise uyumun tamamen ters olduğu şeklinde yorumlanabilir. Çizelge 6.7'de kappa katsayı değer aralıklarına göre yorumlama tablosu verilmiştir (Landis ve Koch, 1977; Kılıç, 2015).

Çizelge 6.7. Kappa katsayı değer aralıklarına göre yorumlama tablosu

Kappa Değer Aralığı	Yorum
<0,00	Ters/Kötü Uyum
0.01-0.20	Önemsiz Uyum
0.21-0.40	Zayıf Uyum
0.41-0.60	Orta Düzeyde Uyum
0.61-0.80	İyi Düzeyde Uyum
0.81-1.00	Çok İyi Düzeyde Uyum

6.7. Pirinç Veriseti

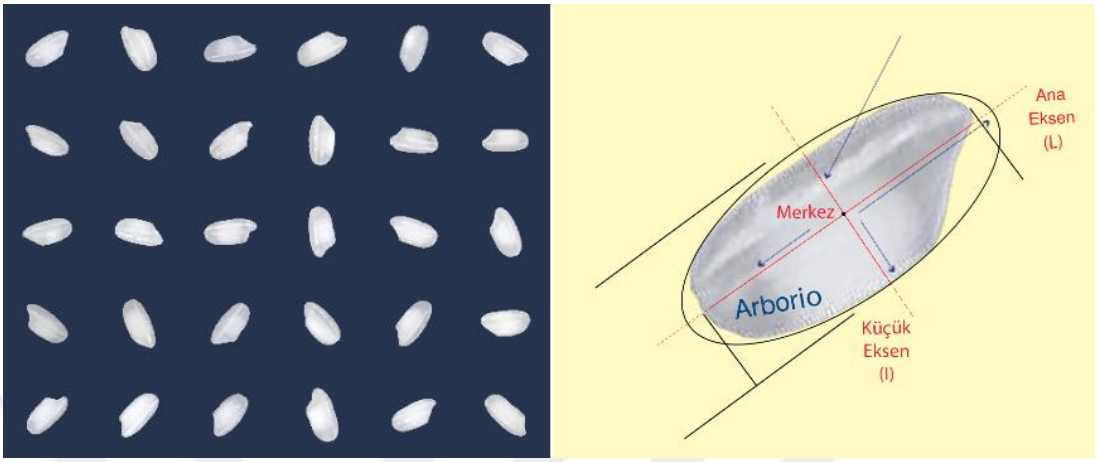
Çalışmada toplam beş farklı pirinç çeşidi kullanılmıştır. Pirinç çeşitleri Metro Chef markasıyla satılan Arborio, Basmati, İpsala, Jasmine ve Karacadağ olarak seçilmiştir. Çalışmada kullanılan pirinç çeşitlerine ait teknik bilgiler Çizelge 6.8'de verilmiştir.

Çizelge 6.8. Pirinç çeşitlerine ait teknik özellikler

Çeşit Adı	Tane Uzunluğu (mm)	Tane Genişliği (mm)	10 gr'a Karşılık Tane Adedi
Arborio	6-7.5	3-4	303
Basmati	8.5-11.5	3.5-4.5	507
İpsala	9-11	4-5.5	425
Jasmine	6.5-10	2.5-3.5	547
Karacadağ	4.5-6	3-4	513

Çalışmamızda, her pirinç çeşidine ait 15 bin adet pirinç tanesi görüntüsü elde edilmiştir. Toplamda 75 bin adet pirinç tanesine ait veri üzerinde çalışmalar gerçekleştirilmiştir.

Çalışmada kullanılan Arborio çeşidine ait görüntü örnekleri Şekil 6.5'de verilmiştir. Morfolojik ve şekil özelliklerine ait istatistiki bilgileri ise Çizelge 6.9'da verilmiştir.

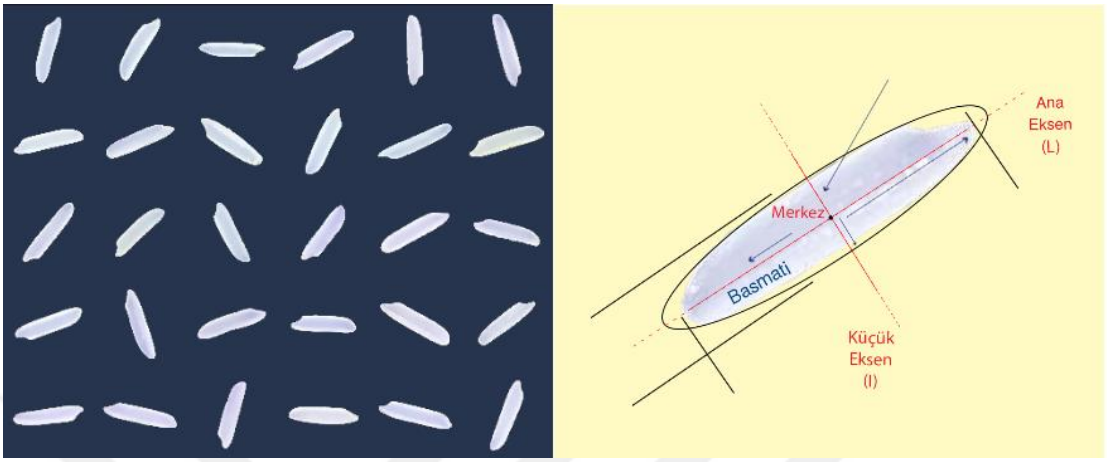


Şekil 6.5. Arborio çeşidine ait görüntü

Çizelge 6.9. Arborio çeşidi için morfolojik ve şekil özelliklerine ait istatistiki bilgiler

Özellik	Minimum	Ortalama	Maksimum	Standart Sapma	Çarpıklık	Basıklık
Alan	4,666	7,531.72	10,336	781.1792	-0.4525	0.3685
Çevre	269.03	339.8524	395.894	18.4993	-0.5754	0.5491
Ana Eksen Uzunluğu	97.8148	137.5845	166.4845	8.0226	-0.5999	0.8186
Küçük Eksen Uzunluğu	45.6124	70.4594	86.7822	4.6157	-0.6583	0.8279
Eksantriklik	0.6639	0.8574	0.9494	0.0214	-0.9719	4.8166
Eşdeğer Çapı	77.0775	97.7905	114.7179	5.1676	-0.631	0.6368
Sertlik	0.9394	0.9766	0.9912	0.0068	-0.8178	0.5135
Dışbükey Alan	4,758	7,712.89	10,537	807.1189	-0.4404	0.3354
Kapsam	0.4628	0.6833	0.8482	0.0609	0.4171	-0.8458
En Boy Oranı	1.3373	1.9581	3.1827	0.1336	0.4896	2.6305
Yuvarlaklık	0.637	0.8177	0.9364	0.0261	-0.0553	0.9233
Kompaktlık	0.5551	0.7114	0.8559	0.0238	0.103	1.9298
Şekil Faktörü_1	0.0148	0.0184	0.0284	0.0013	1.2194	2.7985
Şekil Faktörü_2	0.0077	0.0094	0.0135	0.0006	1.102	2.4745
Şekil Faktörü_3	0.3081	0.5066	0.7326	0.034	0.3006	2.1372
Şekil Faktörü_4	0.9585	0.9876	0.9987	0.005	-0.6146	0.7341

Çalışmada kullanılan Basmati çeşidine ait görüntü örnekleri Şekil 6.6'da verilmiştir. Morfolojik ve şekil özelliklerine ait istatistiki bilgileri ise Çizelge 6.10'da verilmiştir.

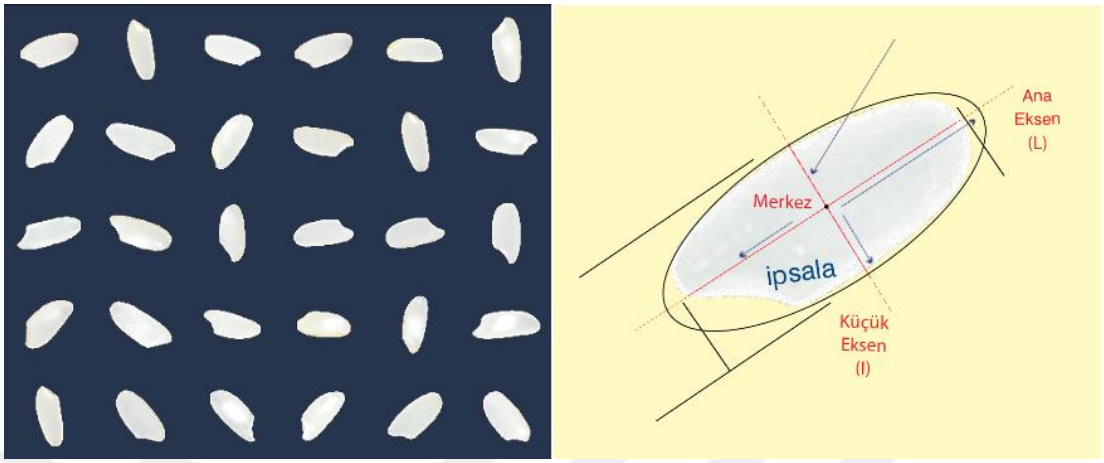


Şekil 6.6. Basmati çeşidine ait görüntü

Çizelge 6.10. Basmati çeşidi için morfolojik ve şekil özelliklerine ait istatistiki bilgiler

Özellik	Minimum	Ortalama	Maksimum	Standart Sapma	Çarpıklık	Basıklık
Alan	4,996	7,563.94	10,835	862.1709	-0.0173	-0.2244
Çevre	315.324	426.9058	515.519	28.0444	-0.2519	-0.1373
Ana Eksen Uzunluğu	136.7606	202.3362	255.6472	14.8203	-0.3145	0.0635
Küçük Eksen Uzunluğu	34.673	48.4943	63.7871	3.7793	-0.0928	0.0478
Eksantriklik	0.9173	0.9702	0.9868	0.0064	-1.3871	4.6278
Eşdeğer Çapı	79.7565	97.9748	117.4545	5.6257	-0.1713	-0.1848
Sertlik	0.8775	0.9701	0.9907	0.0074	-1.5679	6.4033
Dışbükey Alan	5,142	7,797.52	11,198	891.1227	-0.0211	-0.2273
Kapsam	0.2788	0.5038	0.8888	0.1438	0.8361	-0.4332
En Boy Oranı	2.5114	4.1942	6.1795	0.4117	0.0411	0.586
Yuvarlaklık	0.3925	0.5216	0.7253	0.036	0.5374	1.384
Kompaktlık	0.4006	0.4853	0.625	0.0242	0.6129	1.4635
Şekil Faktörü_1	0.0203	0.0269	0.0369	0.0021	0.5254	0.4738
Şekil Faktörü_2	0.0051	0.0065	0.0095	0.0005	0.8159	1.2391
Şekil Faktörü_3	0.1605	0.2361	0.3907	0.0239	0.8458	2.1578
Şekil Faktörü_4	0.8962	0.9808	0.999	0.0084	-0.9985	2.8281

Çalışmada kullanılan İpsala çeşidine ait görüntü örnekleri Şekil 6.7'de verilmiştir. Morfolojik ve şekil özelliklerine ait istatistiki bilgileri ise Çizelge 6.11'de verilmiştir.

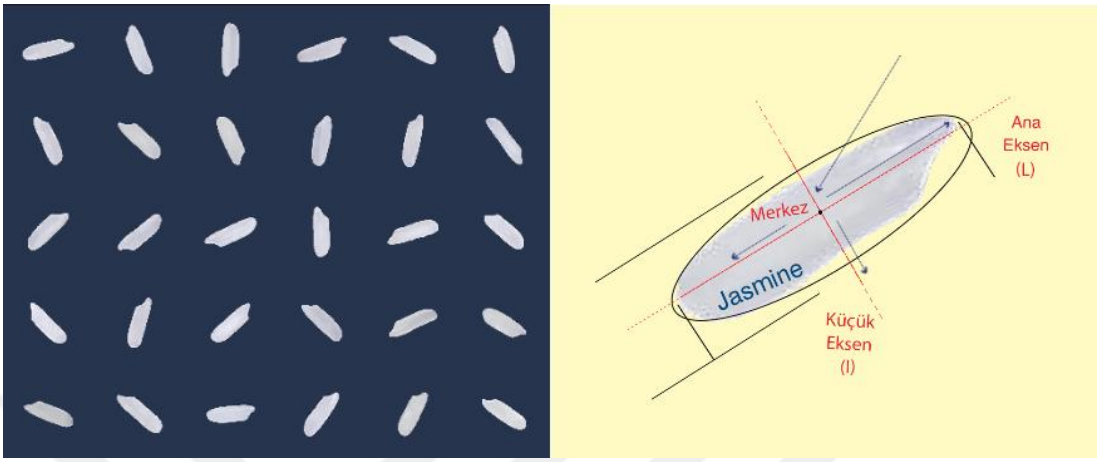


Şekil 6.7. İpsala çeşidine ait görüntü

Çizelge 6.11 İpsala çeşidi için morfolojik ve şekil özelliklerine ait istatistiki bilgiler

Özellik	Minimum	Ortalama	Maksimum	Standart Sapma	Çarpıklık	Basıklık
Alan	8,277	14,048.65	21,019	1,493.60	-0.3	0.2751
Çevre	361.258	476.4978	593.698	25.6224	-0.3858	0.5899
Ana Eksen Uzunluğu	150.1548	197.0714	247.1038	11.1519	-0.2676	0.5783
Küçük Eksen Uzunluğu	62.105	91.8166	113.4411	6.2955	-0.6003	0.5467
Eksantriklik	0.7882	0.8838	0.9537	0.0159	0.082	1.0509
Eşdeğer Çapı	102.6577	133.549	163.5916	7.2079	-0.4836	0.499
Sertlik	0.9391	0.9775	0.9911	0.0066	-0.4647	-0.0272
Dışbükey Alan	8,422	14,373.35	21,633	1,531.84	-0.2938	0.2712
Kapsam	0.4811	0.6629	0.8485	0.0747	0.4447	-0.9838
En Boy Oranı	1.6249	2.153	3.3246	0.148	1.0685	2.6398
Yuvarlaklık	0.6188	0.7757	0.8948	0.0256	-0.5835	1.5165
Kompaktlık	0.5481	0.6781	0.7786	0.0221	-0.5966	1.355
Şekil Faktörü_1	0.0113	0.0141	0.0205	0.001	1.096	2.009
Şekil Faktörü_2	0.0052	0.0066	0.0085	0.0004	0.7094	1.2554
Şekil Faktörü_3	0.3004	0.4603	0.6063	0.0296	-0.4498	1.1494
Şekil Faktörü_4	0.9528	0.9868	0.9987	0.005	-0.3798	0.5116

Çalışmada kullanılan Jasmine çeşidine ait görüntü örnekleri Şekil 6.8'de verilmiştir. Çeşide ait morfolojik ve şekil özelliklerine dair istatistiki bilgileri ise Çizelge 6.12'de verilmiştir.

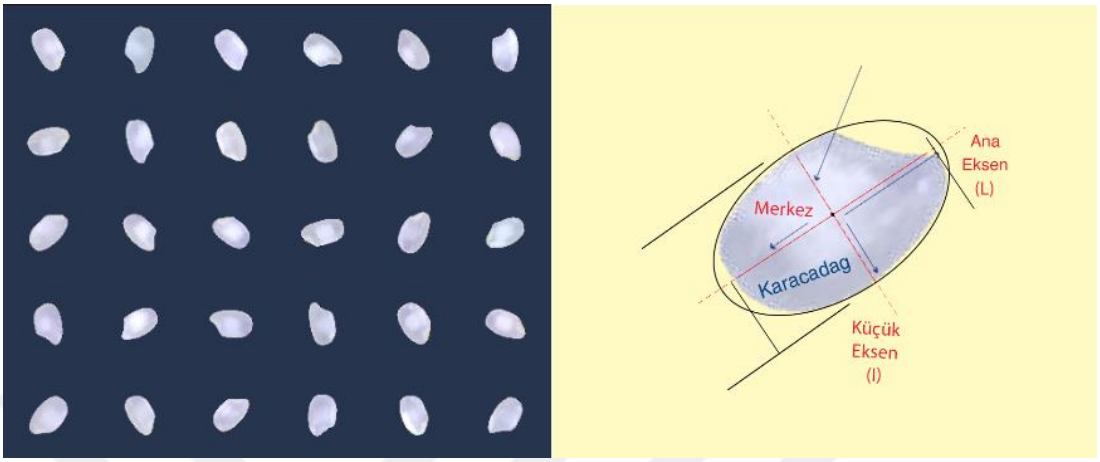


Şekil 6.8. Jasmine çeşidine ait görüntü

Çizelge 6.12. Jasmine çeşidi için morfolojik ve şekil özelliklerine ait istatistiki bilgiler

Özellik	Minimum	Ortalama	Maksimum	Standart Sapma	Çarpıklık	Basıklık
Alan	3,929	6,267.31	12,430	1,800.34	1.4812	0.5651
Çevre	261.04	347.7815	523.891	49.1774	1.3798	0.4025
Ana Eksen Uzunluğu	106.0622	157.0765	243.8224	22.7591	1.3403	0.5038
Küçük Eksen Uzunluğu	38.8685	50.9507	79.2672	6.849	1.3173	0.5542
Eksantriklik	0.8124	0.945	0.9749	0.0093	-0.73	3.7978
Eşdeğer Çapı	70.7288	88.5446	125.8029	11.8175	1.4185	0.3484
Sertlik	0.9047	0.9725	0.9901	0.0068	-0.974	2.6273
Dışbükey Alan	4,032	6,442.76	12,809	1,841.54	1.481	0.5717
Kapsam	0.3628	0.5898	0.9017	0.121	0.5599	-0.9152
En Boy Oranı	1.715	3.0892	4.4926	0.2519	0.3896	0.8178
Yuvarlaklık	0.5061	0.6419	0.8725	0.034	0.1278	0.3963
Kompaktlık	0.47	0.565	0.7591	0.023	0.1113	0.718
Şekil Faktörü_1	0.0165	0.0259	0.0329	0.003	-0.9978	-0.1046
Şekil Faktörü_2	0.0053	0.0084	0.0121	0.001	-1.0536	-0.0962
Şekil Faktörü_3	0.2209	0.3197	0.5762	0.0261	0.2801	1.0934
Şekil Faktörü_4	0.9123	0.9813	0.9988	0.0069	-0.8945	2.2343

Çalışmada kullanılan son çeşit olan Karacadağ çeşidine ait görüntü örnekleri Şekil 6.9'da verilmiştir. Morfolojik ve şekil özelliklerine ait istatistiki bilgileri ise Çizelge 6.13'de verilmiştir.



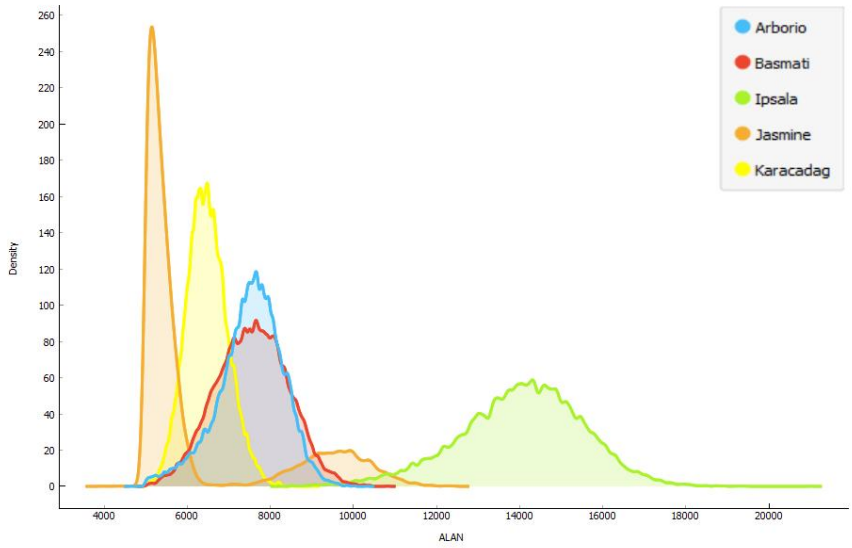
Şekil 6.9. Karacadağ çeşidine ait görüntü

Çizelge 6.13. Karacadağ çeşidi için morfolojik ve şekil özelliklerine ait istatistiki bilgiler

Özellik	Minimum	Ortalama	Maksimum	Standart Sapma	Çarpıklık	Basıklık
Alan	5,014	6,484.38	9,053	495.5896	0.2597	0.1275
Çevre	262.372	299.8098	354.371	11.8513	0.2572	0.0976
Ana Eksen Uzunluğu	96.9683	114.9591	146.3295	5.5351	0.2885	0.2136
Küçük Eksen Uzunluğu	54.0399	72.4257	87.4875	3.6547	-0.2869	0.6037
Eksantriklik	0.6277	0.7739	0.9041	0.0324	-0.2001	0.4063
Eşdeğer Çapı	79,9001	90,7974	107,3622	3,464	0,1437	0,0497
Sertlik	0,9474	0,9828	0,9921	0,0055	-1,3887	1,7242
Dışbükey Alan	5,110	6,597.79	9,188	500.7093	0.2635	0.1269
Kapsam	0.5809	0.7263	0.8301	0.0365	0.2243	-0.5409
En Boy Oranı	1.2845	1.5908	2.3401	0.103	0.6858	1.5149
Yuvarlaklık	0.7521	0.9056	0.98	0.023	-0.4829	0.58
Kompaktlık	0.6513	0.7906	0.8799	0.0249	-0.2903	0.6061
Şekil Faktörü_1	0.0147	0.0178	0.0236	0.0009	0.6736	1.3193
Şekil Faktörü_2	0.0087	0.0112	0.0133	0.0005	0.0292	-0.0139
Şekil Faktörü_3	0.4242	0.6256	0.7743	0.0392	-0.172	0.4605
Şekil Faktörü_4	0.9675	0.9912	0.9988	0.0045	-0.9543	0.7453

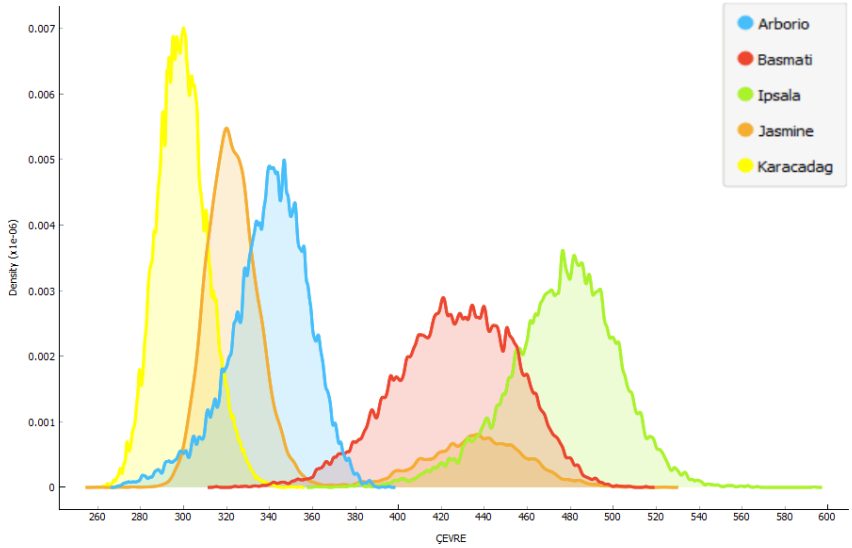
Çalışmada kullanılan pirinç çeşitlerinin morfolojik ve şekil özelliklerini çıkarmada kullanılan özelliklerin her biri için yoğunluk dağılım grafikleri aşağıda verilmiştir.

Alan özelliğine ait yoğunluk dağılım grafiği Şekil 6.10'da verilmiştir. Şekil incelendiğinde alan özelliğinde İpsala çeşidinin diğer çeşitlerden ayrıldığı, Arborio ve Basmati çeşitlerinin ise kesiştiği görülmektedir.



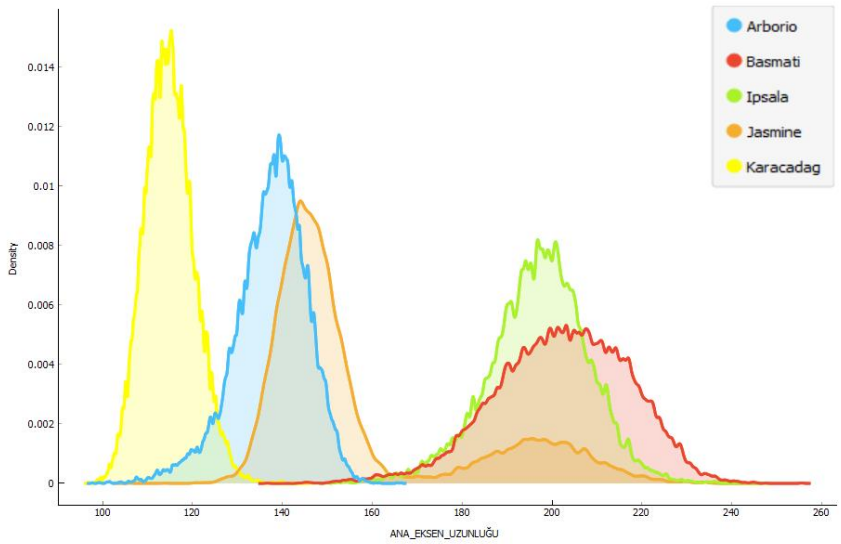
Şekil 6.10. Alan özelliğine ait yoğunluk dağılım grafiği

Çevre özelliğine ait yoğunluk dağılım grafiği Şekil 6.11'de verilmiştir. Şekil incelendiğinde Karacadağ ve İpsala çeşitlerinin iki ayrı noktada toplandıkları görülmektedir. Ayrıca çevre özellikleri bakımından Jasmine çeşidinin büyük çoğunluğunun Arborio çeşidi ile, geriye kalanların ise Basmati çeşidi ile kesiştiği görülmektedir.



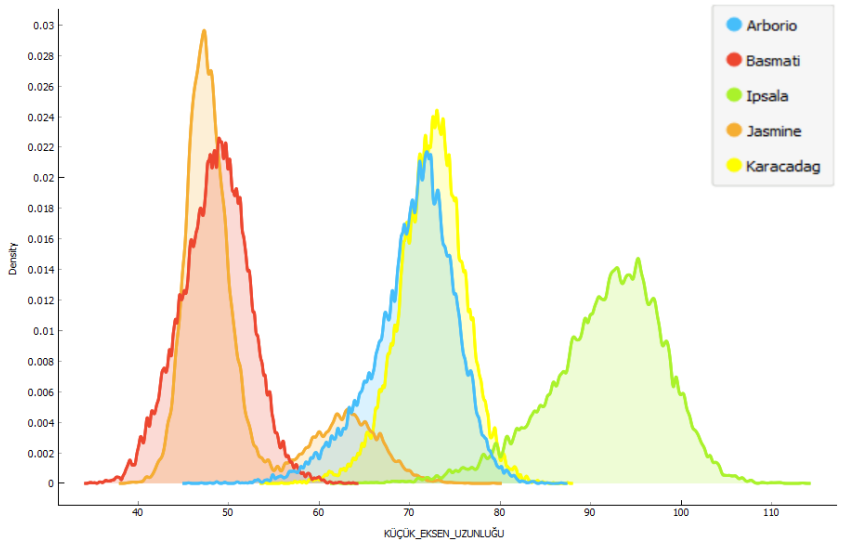
Şekil 6.11. Çevre özelliğine ait yoğunluk dağılım grafiği

Ana eksen uzunluğu özelliğine ait yoğunluk dağılım grafiği Şekil 6.12'de verilmiştir. Şekil 6.12 incelendiğinde Karacadağ çeşidinin diğer çeşitlerden ayrıldığını söylemek mümkündür. Ayrıca İpsala ve Basmati çeşitleri ile Jasmine çeşidinin az bir miktarının ana eksen uzunluğu özellikleri bakımından kesiştikleri görülmektedir.



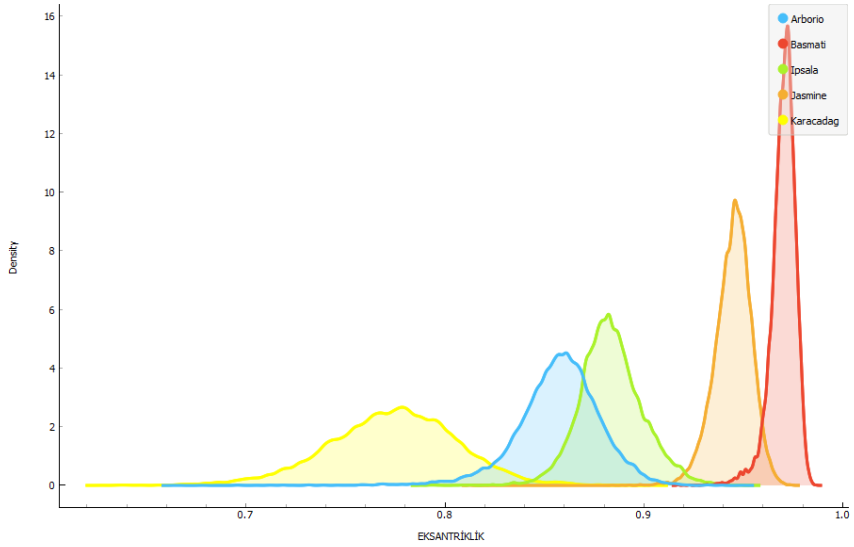
Şekil 6.12. Ana eksen uzunluğu özelliğine ait yoğunluk dağılım grafiği

Küçük eksen uzunluğu özelliğine ait yoğunluk dağılım grafiği Şekil 6.13'de verilmiştir. Şekil incelendiğinde küçük eksen uzunluğu bakımından İpsala çeşidinin diğer çeşitlerden ayrıldığı görülmektedir. Karacadağ çeşidi ile Arborio çeşidi, Basmati çeşidi ile de Jasmine çeşidinin neredeyse tamamen kesiştiklerini söylemek mümkündür.



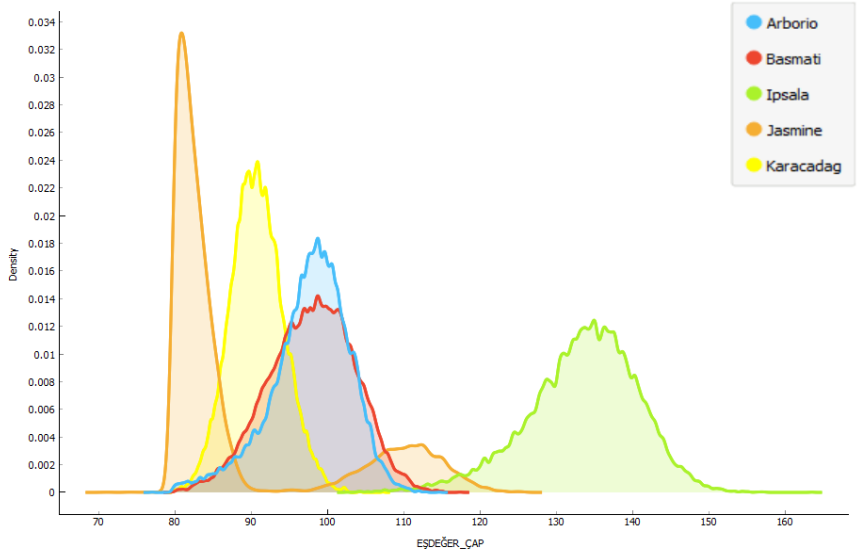
Şekil 6.13. Küçük eksen uzunluğu özelliğine ait yoğunluk dağılım grafiği

Eksantriklik özelliğine ait yoğunluk dağılım grafiği Şekil 6.14'de verilmiştir. Şekil 6.14 incelendiğinde İpsala ve Arborio çeşitlerinin yoğunluk olarak daha fazla kesişim alanlarının bulunduğu görülmektedir.



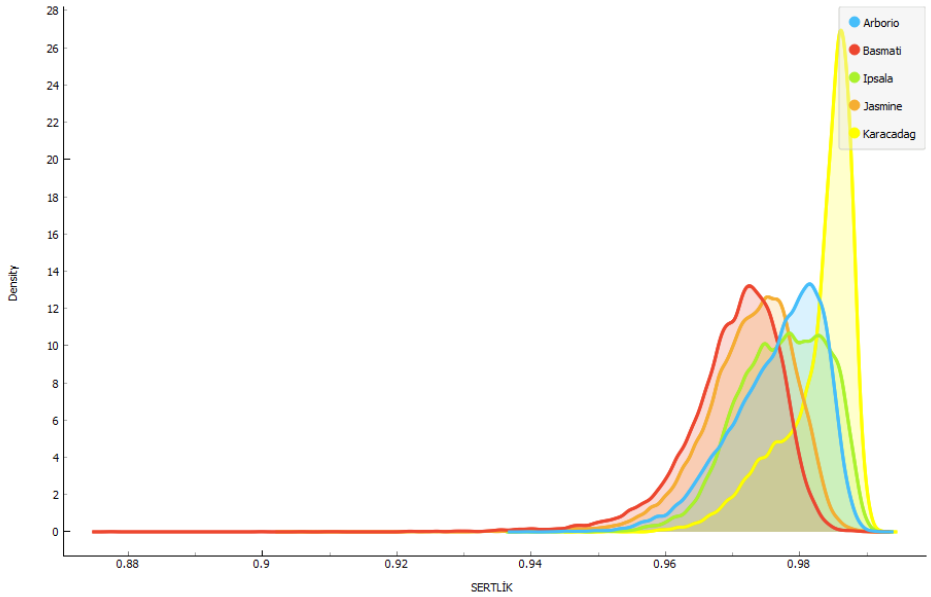
Şekil 6.14. Eksantriklik özelliğine ait yoğunluk dağılım grafiği

Eşdeğer çap özelliğine ait yoğunluk dağılım grafiği Şekil 6.15'de verilmiştir. Şekli incelediğimizde eşdeğer çap özelliği bakımından Arborio ve Basmati çeşitlerinin neredeyse tamamen kesiştiği, İpsala çeşidinin ise diğer çeşitlerden ayrıldığı görülmektedir.



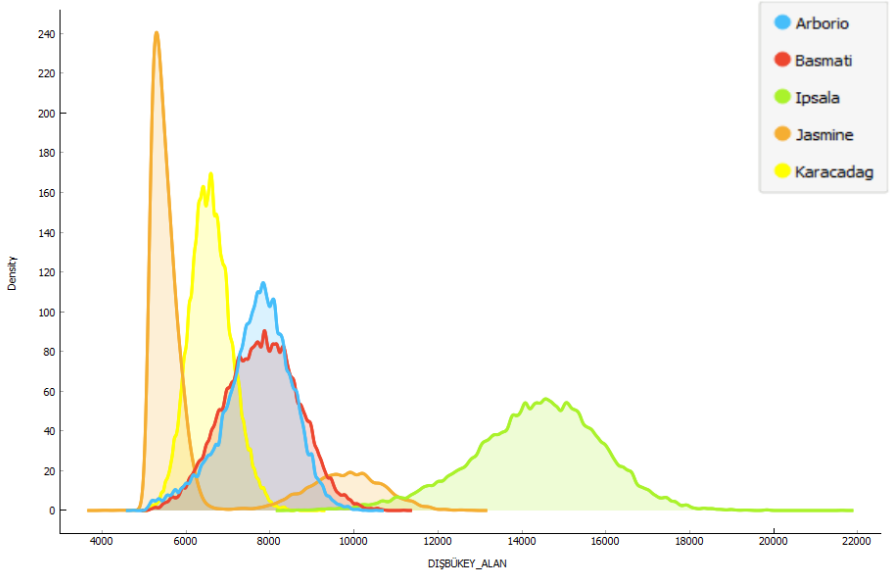
Şekil 6.15. Eşdeğer çap özelliğine ait yoğunluk dağılım grafiği

Sertlik özelliğine ait yoğunluk dağılım grafiği Şekil 6.16'da verilmiştir. Şekil incelendiğinde sertlik özelliği bakımından tüm çeşitlerin birbirleriyle kesiştiği söylenebilir.



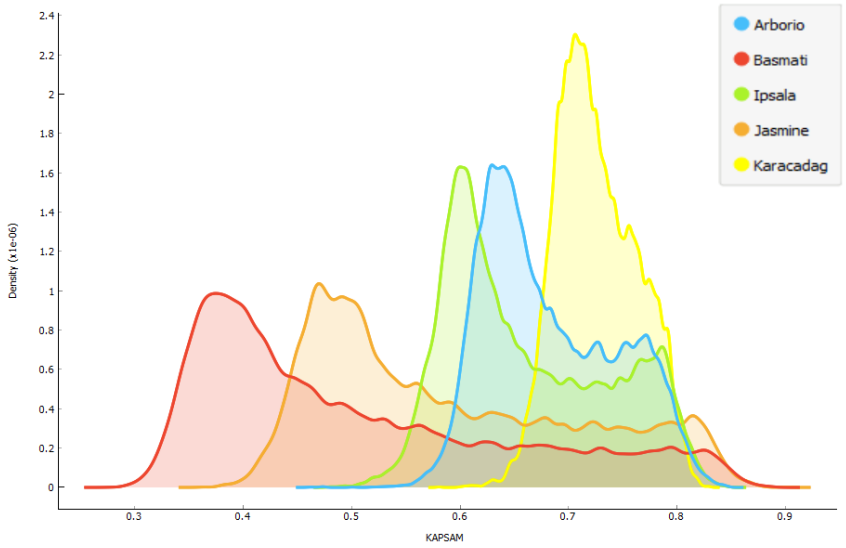
Şekil 6.16. Sertlik özelliğine ait yoğunluk dağılım grafiği

Dışbükey alan özelliğine ait yoğunluk dağılım grafiği Şekil 6.17'de verilmiştir. Dışbükey alan özelliği bakımından Arborio ve Basmati çeşitlerinin kesiştiği, İpsala çeşidinin ise diğer çeşitlerden ayrıldığı görülmektedir.



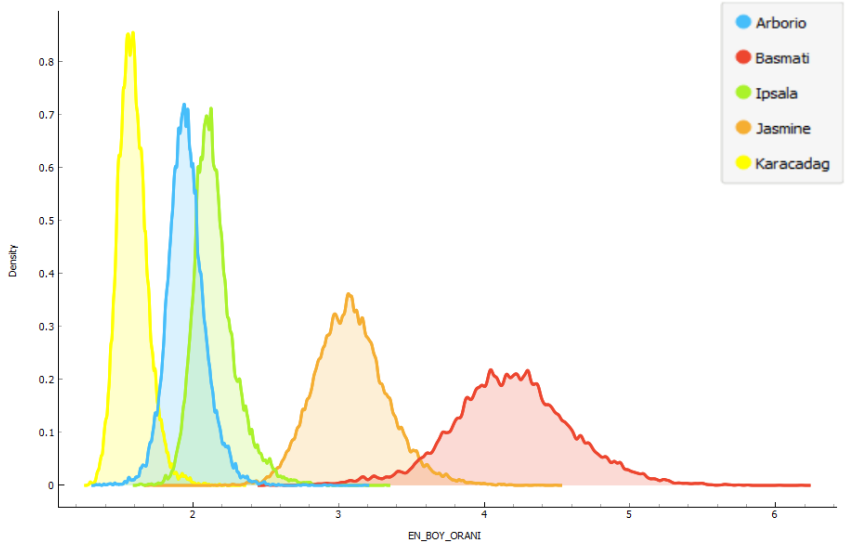
Şekil 6.17. Dışbükey alan özelliğine ait yoğunluk dağılım grafiği

Kapsam özelliğine ait yoğunluk dağılım grafiği Şekil 6.18'de verilmiştir. Şekil incelendiğinde tüm çeşitlerin birbiriyle kesişim alanlarının olduğu görülmektedir. Kapsam alanı en geniş çeşidin Basmati, en dar çeşidin ise Karacadağ olduğu görülmektedir.



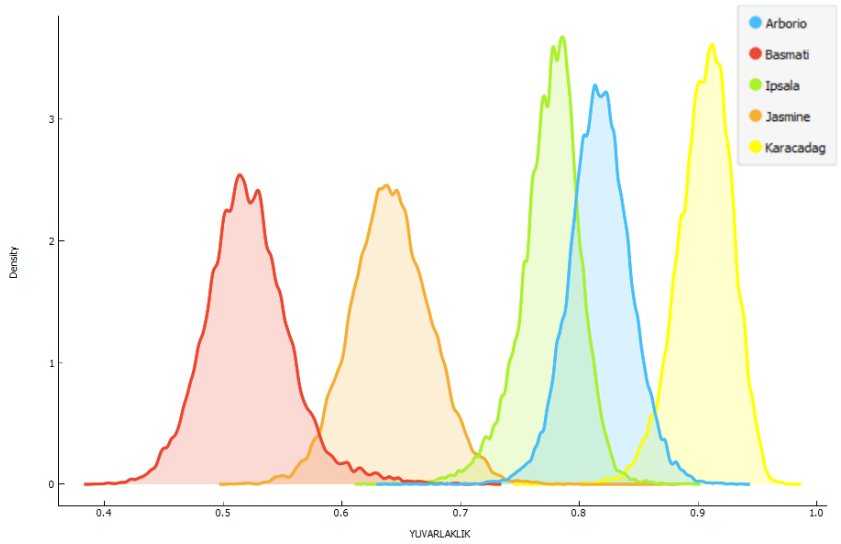
Şekil 6.18. Kapsam özelliğine ait yoğunluk dağılım grafiği

En-boy oranı özelliğine ait yoğunluk dağılım grafiği Şekil 6.19'da verilmiştir. Şekil incelendiğinde Arborio ve İpsala çeşitlerinin diğer çeşitlere göre en fazla kesişim alanına sahip oldukları görülmektedir. Basmati ve Jasmine çeşitlerinin ise en-boy oranı özelliği bakımından diğer çeşitlerden ayrıldıkları görülmektedir.



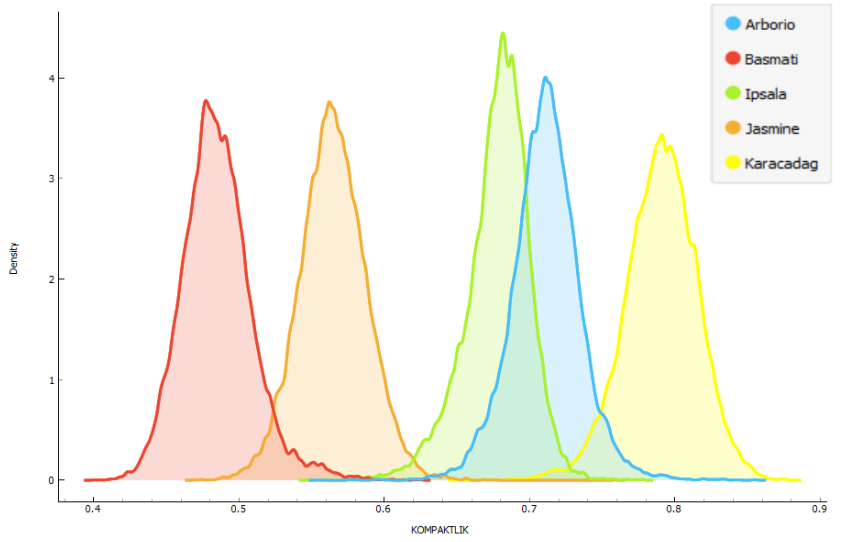
Şekil 6.19. En-boy oranı özelliğine ait yoğunluk dağılım grafiği

Yuvarlaklık özelliğine ait yoğunluk dağılım grafiği Şekil 6.20'de verilmiştir. Şekil incelendiğinde Arborio ve İpsala çeşitlerinin diğer çeşitlere göre daha fazla kesişim alanlarının bulunduğu görülmektedir. Basmati, Jasmine ve Karacadağ çeşitlerinin ise yuvarlaklık özelliği bakımından ayrıldıkları görülmektedir.



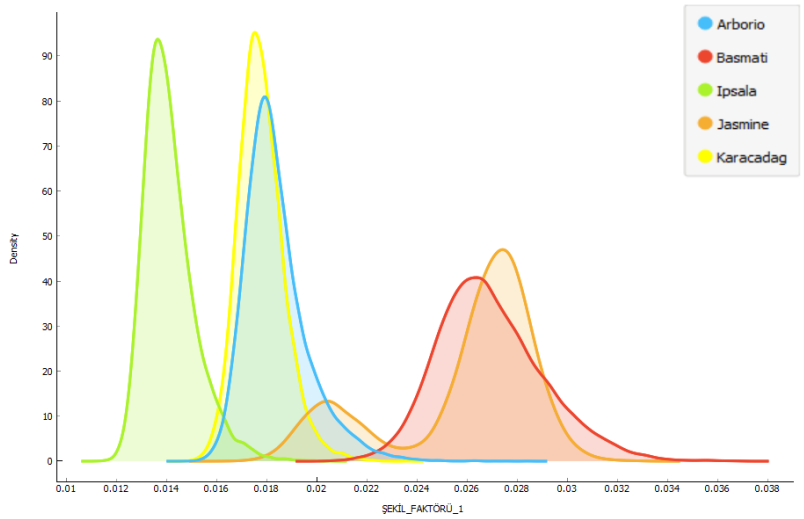
Şekil 6.20. Yuvarlaklık özelliğine ait yoğunluk dağılım grafiği

Kompaktlık özelliğine ait yoğunluk dağılım grafiği Şekil 6.21'de verilmiştir. Şekil 6.21'de yuvarlaklık özelliğine benzer şekilde kompaktlık özelliğinde de Arborio ve İpsala çeşitlerinin daha fazla kesişim alanlarının bulunduğu, diğer çeşitlerin ise ayrıldıkları görülmektedir.



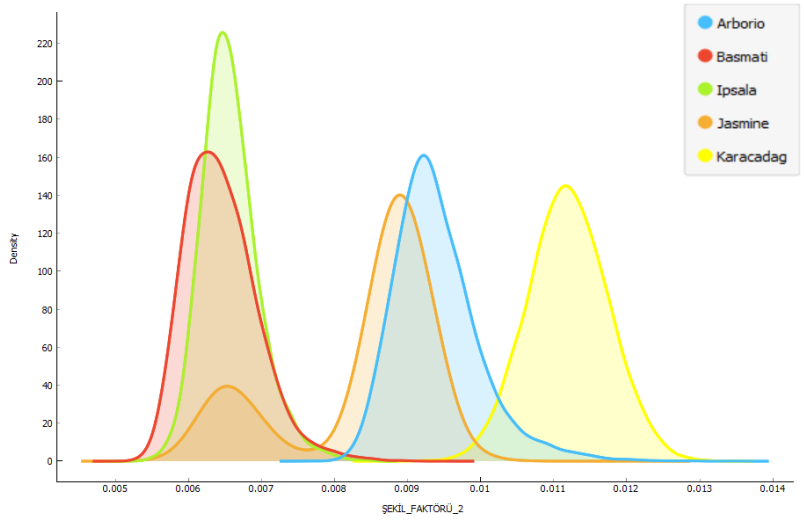
Şekil 6.21. Kompaktlık özelliğine ait yoğunluk dağılım grafiği

Şekil faktörü 1 özelliğine ait yoğunluk dağılım grafiği Şekil 6.22'de verilmiştir. Şekilde Karacadağ ile İpsala çeşitlerinin ve Basmati ile Jasmine çeşitlerinin neredeyse tamamen kesiştiği görülmektedir. İpsala çeşidinin ise diğer çeşitlerden ayrıldığı görülmektedir.



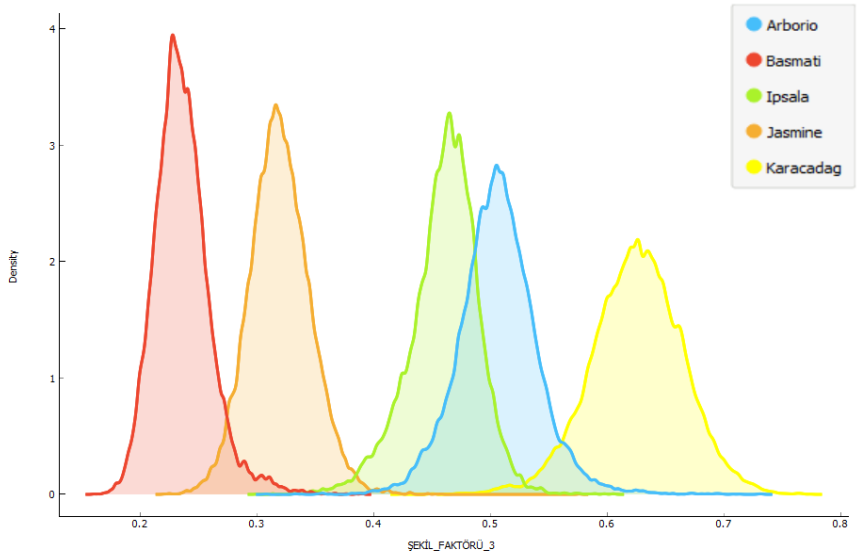
Şekil 6.22. Şekil faktörü 1 özelliğine ait yoğunluk dağılım grafiği

Şekil faktörü 2 özelliğine ait yoğunluk dağılım grafiği Şekil 6.23'de verilmiştir. Şekil incelendiğinde Basmati ve İpsala çeşitleri ile Jasmine çeşidinin az bir miktarının kesiştikleri görülmektedir. Ayrıca Arborio çeşidi ile Jasmine çeşidinin büyük çoğunluğunun da neredeyse tamamen kesiştikleri görülmektedir. Karacadağ çeşidinin ise diğer çeşitlerden ayrıldığı görülmektedir.



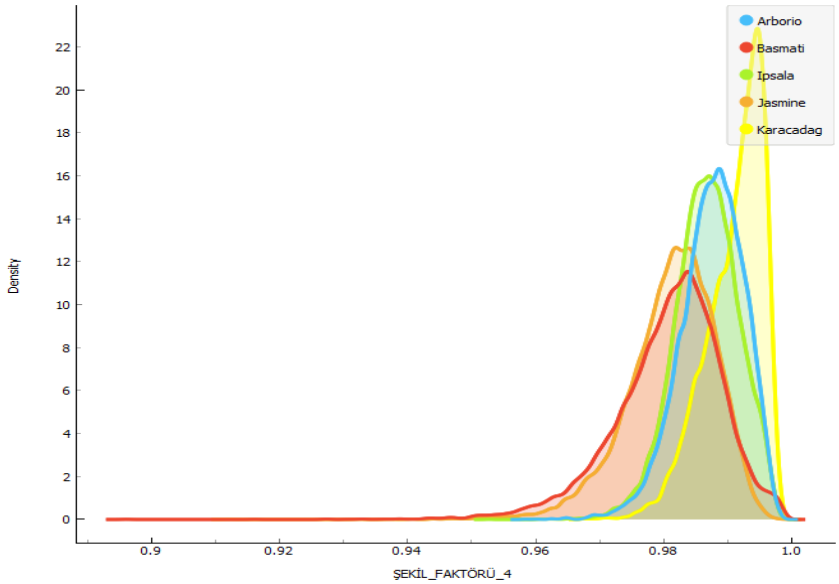
Şekil 6.23. Şekil faktörü 2 özelliğine ait yoğunluk dağılım grafiği

Şekil faktörü 3 özelliğine ait yoğunluk dağılım grafiği Şekil 6.24'de verilmiştir. Şekil incelendiğinde Arborio ve İpsala çeşitlerinin şekil faktörü 3 özelliğinde diğer çeşitlere göre daha fazla kesiştiği görülmektedir. Ayrıca Basmati, Jasmine ve Karacadağ çeşitlerinin büyük çoğunluğunun tamamen ayrıldıkları görülmektedir.



Şekil 6.24. Şekil faktörü 3 özelliğine ait yoğunluk dağılım grafiği

Şekil faktörü 4 özelliğine ait yoğunluk dağılım grafiği Şekil 6.25'de verilmiştir. Şekil 6.25 incelendiğinde şekil faktörü 4 özelliği bakımından tüm çeşitlerin birbiriyle kesiştiği görülmektedir.



Şekil 6.25. Şekil faktörü 4 özelliğine ait yoğunluk dağılım grafiği

Çalışmada kullanılan pirinç çeşitlerininin her biri için ayrı ayrı verilen morfolojik ve şekil özellikleri istatistiki bilgilerine ek olarak, tüm çeşitlerin bir arada olduğu toplam 75,000 adet pirinç tanesi için morfolojik, şekil ve renk özelliklerine ait istatistiki bilgiler Çizelge 6.14'de verilmiştir.

Çizelge 6.14. Tüm çeşitler için morfolojik, şekil ve renk özelliklerine ait istatistiki bilgiler

No	Özellik	Minimum	Ortalama	Maksimum	Standart Sapma	Çarpıklık	Basıklık
1	Alan	3,929	8,379.20	21,019	3,119.21	1.2189	0.2882
2	Çevre	261.04	378.1695	593.698	70.597	0.3784	-1.2991
3	Ana Eksen Uzunluğu	96.9683	161.8055	255.6472	36.461	0.1279	-1.4311
4	Küçük Eksen Uzunluğu	34.673	66.8293	113.4411	16.6893	0.2691	-0.9539
5	Eksantriklik	0.6277	0.8861	0.9868	0.0719	-0.5488	-0.636
6	Eşdeğer Çapı	70.7288	101.7313	163.5916	17.8741	1.0127	-0.0988
7	Sertlik	0.8775	0.9759	0.9921	0.008	-0.7854	1.8152
8	Dışbükey Alan	4,032	8,584.86	21,633	3,189.30	1.2145	0.2798
9	Kapsam	0.2788	0.6332	0.9017	0.1238	-0.6361	-0.4527
10	En Boy Oranı	1.2845	2.5971	6.1795	0.969	0.8026	-0.5591
11	Yuvarlaklık	0.3925	0.7325	0.98	0.1386	-0.3623	-1.0926
12	Kompaktlık	0.4006	0.6461	0.8799	0.1108	-0.1976	-1.1811
13	Şekil Faktörü_1	0.0113	0.0206	0.0369	0.0053	0.3516	-1.2157
14	Şekil Faktörü_2	0.0051	0.0084	0.0135	0.0019	0.277	-1.2157
15	Şekil Faktörü_3	0.1605	0.4297	0.7743	0.1411	0.0087	-1.1657
16	Şekil Faktörü_4	0.8962	0.9855	0.999	0.0073	-1.0799	2.7359
17	Mean_RGB_R	153.8	216.398	252.1837	13.3083	0.2342	-0.5234
18	Mean_RGB_G	157.2499	218.2058	252.3231	13.6464	0.2281	-0.6209
19	Mean_RGB_B	160.1584	227.9184	252.1085	10.6825	-0.5402	0.2319
20	StdDev_RGB_R	6.8171	15.3428	29.9674	3.4542	0.1086	-0.5677
21	StdDev_RGB_G	6.4117	15.4498	30.7654	3.5626	0.0513	-0.5205
22	StdDev_RGB_B	6.4175	15.4778	30.858	3.4686	0.0932	-0.3951
23	Skewness_RGB_R	-6.9388	-1.7785	0.9179	0.9487	-0.7312	0.4464
24	Skewness_RGB_G	-7.9118	-1.9385	0.7719	1.1119	-1.0563	1.0603
25	Skewness_RGB_B	-6.9382	-2.3601	1.1624	0.951	-0.39	-0.0583
26	Kurtosis_RGB_R	1.8413	11.9555	75.2016	7.4795	1.5759	2.9093
27	Kurtosis_RGB_G	1.8781	12.9443	89.3631	9.303	1.9358	4.5437
28	Kurtosis_RGB_B	1.8852	14.4673	71.9804	7.7546	1.299	2.6695
29	Entropy_RGB_R	-1,36E+10	-4,43E+09	-1,47E+09	2,24E+09	-1.3145	0.3964
30	Entropy_RGB_G	-1,38E+10	-4,51E+09	-1,55E+09	2,27E+09	-1.2476	0.2445
31	Entropy_RGB_B	-1,32E+10	-4,82E+09	-1,61E+09	1,99E+09	-1.1093	0.1689
32	Daub4_RGB_R	76.8436	108.1788	126.1056	6.658	0.2351	-0.5238
33	Daub4_RGB_G	78.5723	109.0821	126.1697	6.8276	0.2288	-0.6214
34	Daub4_RGB_B	80.0278	113.9363	126.0672	5.3433	-0.5392	0.229
35	Mean_HSV_H	0.0341	0.5477	0.8171	0.1856	-1.3173	0.0519
36	Mean_HSV_S	0.0014	0.0606	0.2417	0.0367	0.4267	-0.7421
37	Mean_HSV_V	0.6281	0.8981	0.9906	0.0434	-0.5804	0.106

No	Özellik	Minimum	Ortalama	Maksimum	Standart Sapma	Çarpıklık	Basıklık
38	StdDev_HSV_H	0.0021	0.0642	0.4103	0.0614	2.078	5.1374
39	StdDev_HSV_S	0.003	0.0191	0.0939	0.0105	1.0525	0.5996
40	StdDev_HSV_V	0.0251	0.0603	0.1184	0.0136	0.0581	-0.503
41	Skewness_HSV_H	-70.8665	-4.7977	25.0218	7.1947	-1.3219	4.0856
42	Skewness_HSV_S	-2.7134	0.0194	6.9277	1.0434	0.8717	0.8201
43	Skewness_HSV_V	-7.9104	-2.4893	0.7774	1.0516	-0.5561	0.2247
44	Kurtosis_HSV_H	1.0093	131.8412	5.504.56	261.9851	5.5243	46.9331
45	Kurtosis_HSV_S	1.2751	4.6014	76.7594	2.8191	4.1803	35.0858
46	Kurtosis_HSV_V	1.885	15.4024	89.2129	9.05	1.5768	3.6972
47	Entropy_HSV_H	262.2016	2,309.98	4,868.36	602.8766	-0.3309	0.4003
48	Entropy_HSV_S	1.6196	184.7795	975.8339	159.4672	1.1109	0.9359
49	Entropy_HSV_V	137.2792	1,246.24	4,814.08	468.0433	0.662	0.5961
50	Daub4_HSV_H	0.0172	0.2738	0.4087	0.0928	-1.3173	0.0518
51	Daub4_HSV_S	0.0007	0.0303	0.1208	0.0183	0.4267	-0.7418
52	Daub4_HSV_V	0.3139	0.449	0.4951	0.0217	-0.5788	0.1021
53	Mean_LAB_L	164.7042	222.2155	252.5057	11.801	0.1584	-0.574
54	Mean_LAB_A	118.2685	128.7591	134.9238	2.3522	-1.4086	3.4522
55	Mean_LAB_B	107.3037	122.9208	140.5676	4.8736	0.0887	-0.8352
56	StdDev_LAB_L	5.8407	14.1272	27.4407	3.2473	0.0105	-0.5068
57	StdDev_LAB_A	0.1061	0.9399	3.2582	0.396	0.7919	-0.06
58	StdDev_LAB_B	0.0	2.2151	10.8211	1.327	1.0337	0.3072
59	Skewness_LAB_L	-7.9113	-2.0838	0.6713	1.0723	-0.9676	0.8708
60	Skewness_LAB_A	-8.2952	0.1146	9.2085	0.9142	-0.0629	0.7586
61	Skewness_LAB_B	-3.1682	0.5295	8.5405	0.9971	0.2693	0.895
62	Kurtosis_LAB_L	1.9187	13.8507	89.816	9.3466	1.8296	4.0838
63	Kurtosis_LAB_A	1	4.2824	85.7886	2.3616	4.5529	65.7742
64	Kurtosis_LAB_B	0.9999	4.7306	73.882	2.9661	3.694	29.8098
65	Entropy_LAB_L	-1,39E+10	-4,65E+09	-1,69E+09	2,25E+09	-1.2554	0.2758
66	Entropy_LAB_A	-3,27E+09	-1,34E+09	-6,29E+08	4,75E+08	-1.2301	0.3996
67	Entropy_LAB_B	-3,47E+09	-1,25E+09	-5,47E+08	5,70E+08	-1.3045	0.322
68	Daub4_LAB_L	82.3006	111.0883	126.2651	5.9049	0.1592	-0.5748
69	Daub4_LAB_A	59.1379	64.3794	67.459	1.1756	-1.409	3.4536
70	Daub4_LAB_B	53.6538	61.4615	70.284	2.4356	0.0891	-0.8349
71	Mean_YCbCr_Y	150.4745	203.8867	232.55	10.8661	0.1382	-0.5441
72	Mean_YCbCr_Cb	116.642	132.4831	146.8554	4.3203	-0.1078	-0.8464
73	Mean_YCbCr_Cr	114.724	126.4034	133.0762	2.3508	-2.5254	7.2388
74	StdDev_YCbCr_Y	5.5892	13.1638	25.4601	2.9794	0.0621	-0.4935
75	StdDev_YCbCr_Cb	0.0	1.969	9.4741	1.1542	1.026	0.3329
76	StdDev_YCbCr_Cr	0.0	0.7544	4.1673	0.4073	1.2608	2.3222
77	Skewness_YCbCr_Y	-7.5318	-1.9555	0.8661	1.0143	-0.9465	0.8552
78	Skewness_YCbCr_Cb	-7.5012	-0.4714	120.6575	1.2269	17.507	1,526.02
79	Skewness_YCbCr_Cr	-9.5813	1.7344	116.3182	7.8688	8.1093	72.5775
80	Kurtosis_YCbCr_Y	1.8717	12.8945	83.3924	8.5364	1.7961	3.9484
81	Kurtosis_YCbCr_Cb	1	5.1287	14,559.16	58.3584	220.1377	52,636.73
82	Kurtosis_YCbCr_Cr	0.9999	67.69	13,529.95	560.1777	11.444	145.0333

No	Özellik	Minimum	Ortalama	Maksimum	Standart Sapma	Çarpıklık	Basıklık
83	**Entropy_YCbCr_Y**	-1,15E+10	-3,86E+09	-1,38E+09	1,86E+09	-1.2598	0.2959
84	**Entropy_YCbCr_Cb**	-3,22E+09	-1,41E+09	-6,65E+08	4,39E+08	-0.9979	0.0922
85	**Entropy_YCbCr_Cr**	-3,29E+09	-1,30E+09	-6,00E+08	5,04E+08	-1.3003	0.4479
86	**Daub4_YCbCr_Y**	75.1918	101.9254	116.2873	5.4369	0.1391	-0.5449
87	**Daub4_YCbCr_Cb**	58.3238	66.2405	73.4247	2.1591	-0.1081	-0.8461
88	**Daub4_YCbCr_Cr**	57.3634	63.2021	66.5391	1.175	-2.5259	7.2413
89	**Mean_XYZ_X**	0.3198	0.6841	0.9276	0.0838	0.1899	-0.5239
90	**Mean_XYZ_Y**	0.3384	0.7144	0.977	0.0942	0.293	-0.5787
91	**Mean_XYZ_Z**	0.3842	0.8427	1.0613	0.0863	-0.3714	-0.1616
92	**StdDev_XYZ_X**	0.0483	0.0979	0.1949	0.0213	0.3779	-0.3846
93	**StdDev_XYZ_Y**	0.0497	0.1033	0.2119	0.0231	0.3855	-0.4311
94	**StdDev_XYZ_Z**	0.0533	0.1163	0.2262	0.0252	0.2634	-0.3409
95	**Skewness_XYZ_X**	-5.7217	-1.1577	1.6876	0.8228	-0.9473	1.1369
96	**Skewness_XYZ_Y**	-6.1703	-1.1312	1.6338	0.9002	-1.0683	1.3254
97	**Skewness_XYZ_Z**	-5.9538	-1.504	1.8644	0.8295	-0.6169	0.57
98	**Kurtosis_XYZ_X**	1.6937	8.2797	53.9629	5.2984	1.7544	3.8905
99	**Kurtosis_XYZ_Y**	1.698	8.3067	58.7763	5.7698	1.9101	4.5628
100	**Kurtosis_XYZ_Z**	1.691	9.274	49.4251	5.1514	1.436	3.3613
101	**Entropy_XYZ_X**	764.2551	2,588.90	6,322.97	743.4779	1.309	1.3118
102	**Entropy_XYZ_Y**	343.7069	2,367.18	5,835.09	596.1722	1.3253	2.5313
103	**Entropy_XYZ_Z**	-2,074.59	1,489.69	5,615.51	828.0021	0.3848	1.1058
104	**Daub4_XYZ_X**	0.1597	0.3419	0.4639	0.0419	0.1908	-0.5244
105	**Daub4_XYZ_Y**	0.169	0.3571	0.4886	0.0471	0.2937	-0.579
106	**Daub4_XYZ_Z**	0.1918	0.4212	0.5302	0.0431	-0.3704	-0.1635

6.8. Bölüm Değerlendirmesi

Bu bölümde çalışmada kullanılan görüntülerin elde edildiği düzenek hakkında bilgiler verilmiş, görüntü ön işlem aşamalarına değinilmiştir. Ayrıca özelliklerin çıkarılması aşamasında kullanılan morfolojik, şekilsel ve renk özelliklerine ait açıklamalar ile formülleri verilerek beş renk uzayından çoğaltılan renk özellikleri açıklanmıştır. Sınıflandırma için kullanılan karmaşıklık matrisi ve performans ölçümlerine ait hesaplama formülleri verilmiş, çapraz doğrulama ve kappa katsayıları açıklanmıştır. Pirinç veri seti olarak çalışmada kullanılan pirinçler hakkında teknik detaylar paylaşılmış ve çeşitli istatistiki bilgiler verilmiştir. Ayrıca morfolojik ve şekil özelliklerini çıkarmada kullanılan özelliklere ait yoğunluk dağılım grafikleri verilmiştir.

7. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

Çalışmada kullanılan pirinç çeşitlerine ait toplam 75 bin adet pirinç tanesi görüntüsünden, Çizelge 6.1'de verilen morfolojik ve şekil özellikleri listesinde bulunan özelliklerden öncelikle 12 adet morfolojik özellik çıkarımı yapılmıştır. Elde edilen 12 özelliğe ait veriler üzerinde k-NN, DT, LR, MLP, RF ve SVM algoritmaları kullanılarak sınıflandırma işlemleri gerçekleştirilmiştir. Sınıflandırma doğruluğunu artırma adına 12 adet morfolojik özelliğe ek olarak, Çizelge 6.1'de verilen 4 adet şekil özelliğide eklenerek toplamda 16 adet özelliğe ait veriler üzerinde k-NN, DT, LR, MLP, RF ve SVM algoritmaları ile sınıflandırma işlemleri gerçekleştirilmiştir. Literatürde yapılan çalışmaları incelediğimizde elde ettiğimiz sonuçlar göz önüne alındığında morfolojik özelliklerin şekil ve renk özellikleri ile birlikte değerlendirildiği zaman başarının daha da artacağı düşünülerek Çizelge 6.2'de verilen renk özellik listesindeki 90 adet renk özellik çıkarımı yapılmıştır. Renk özellikleri öncelikle morfolojik ve şekil özelliklerinden bağımsız olarak değerlendirmeye alınmış ve 90 adet özelliğe ait veriler üzerinde k-NN, DT, LR, MLP, RF ve SVM algoritmaları kullanılarak sınıflandırma işlemleri gerçekleştirilmiştir. Daha sonra ise elde edilen morfolojik, şekil ve renk özelliklerinin bir arada değerlendirildiği toplam 106 adet özellik çıkarımı yapılarak k-NN, DT, LR, MLP, RF ve SVM algoritmaları ile sınıflandırma işlemleri gerçekleştirilmiştir.

Çalışmada, 12 adet morfolojik, 16 adet morfolojik ve şekil, 90 adet renk ve 106 adet morfolojik, şekil ve renk özellik çıkarımlarına ait veriler için algoritmalardan elde edilen sınıflandırma sonuçlarına ait karmaşıklık matrisi ve performans ölçüm değerleri sırasıyla verilmiştir.

7.1. K-En Yakın Komşu Algoritması Sonuçları

7.1.1. Morfolojik özelliklerden elde edilen sonuçlar

Morfolojik özellikler kullanılarak elde edilen 12 adet özelliğe ait k-en yakın komşu algoritması sonuçlarını incelediğimizde, 72,863 adet pirinç tanesi doğru olarak sınıflandırılmıştır. 2,137 adet pirinç tanesi ise yanlış olarak sınıflandırılmıştır. Algoritmaya ait kappa katsayısı ise 0.964 olarak elde edilmiştir. k-en yakın komşu karmaşıklık matrisine ait Çizelge 7.1'de verilen sonuçlar incelendiğinde morfolojik özellikler açısından en düşük doğruluk değerine sahip olan Arborio çeşidini Karacadağ,

Jasmine ve Basmati çeşitleri takip etmektedir. İpsala çeşidinin ise en yüksek doğruluk değerine sahip olduğu görülmektedir.

Çizelge 7.1. Morfolojik özelliklere ait k-en yakın komşu algoritması karmaşıklık matrisi

		Tahmini Sınıf				
		Arborio	**Basmati**	**İpsala**	**Jasmine**	**Karacadağ**
Gerçek Sınıf	**Arborio**	**14,313**	1	21	49	616
	Basmati	0	**14,620**	0	380	0
	İpsala	27	0	**14,920**	53	0
	Jasmine	47	380	61	**14,511**	1
	Karacadağ	500	0	0	1	**14,499**

Algoritmaya ait Çizelge 7.2'de verilen morfolojik özelliklerin değerlendirildiği performans ölçümleri sonucunda ortalama sınıflandırma doğruluğunun %97.15 olduğu görülmektedir.

Çizelge 7.2. Morfolojik özelliklere ait
k-en yakın komşu algoritması ortalama performans ölçümleri

Performans Ölçümleri	Yüzde (%)
Doğruluk	97.15
Hata	2.85
Hassasiyet	97.20
Hatırlama	97.20
F1-Skor	97.20

7.1.2. Morfolojik ve şekil özelliklerinden elde edilen sonuçlar

Morfolojik ve şekil özellikleri kullanılarak elde edilen 16 adet özelliğe ait k-en yakın komşu algoritması sonuçlarını incelediğimizde, 72,925 adet pirinç tanesi doğru olarak sınıflandırılmıştır. 2,075 adet pirinç tanesi ise yanlış olarak sınıflandırılmıştır. Algoritmaya ait kappa katsayısı ise 0.965 olarak elde edilmiştir. Çizelge 7.3'de verilen k-en yakın komşu karmaşıklık matrisine ait sonuçlar incelendiğinde morfolojik ve şekil özellikleri açısından İpsala çeşidinin diğer pirinç çeşitleri içerisinde en az karışan çeşit, Arborio çeşidinin ise en çok karışan çeşit olduğu görülmektedir.

Çizelge 7.3. Morfolojik ve şekil özelliklerine ait
k-en yakın komşu algoritması karmaşıklık matrisi

		Tahmini Sınıf				
		Arborio	**Basmati**	**İpsala**	**Jasmine**	**Karacadağ**
Gerçek Sınıf	**Arborio**	**14,324**	1	18	44	613
	Basmati	0	**14,634**	0	366	0
	İpsala	30	0	**14,925**	45	0
	Jasmine	29	388	44	**14,538**	1
	Karacadağ	496	0	0	0	**14,504**

Algoritmaya ait Çizelge 7.4'de verilen morfolojik ve şekil özelliklerinin değerlendirildiği performans ölçümleri sonucunda ortalama sınıflandırma doğruluğunun %97.23 olduğu görülmektedir.

Çizelge 7.4. Morfolojik ve şekil özelliklerine ait
k-en yakın komşu algoritması ortalama performans ölçümleri

Performans Ölçümleri	Yüzde (%)
Doğruluk	97.23
Hata	2.77
Hassasiyet	97.20
Hatırlama	97.20
F1-Skor	97.20

7.1.3. Renk özelliklerinden elde edilen sonuçlar

Renk özellikleri kullanılarak elde edilen 90 adet özelliğe ait k-en yakın komşu algoritması sonuçlarını incelediğimizde, 73,631 adet pirinç tanesi doğru olarak, 1,369 adet pirinç tanesi ise yanlış olarak sınıflandırılmıştır. Algoritmaya ait kappa katsayısı ise 0.977 olarak elde edilmiştir. K-en yakın komşu algoritması karmaşıklık matrisine ait Çizelge 7.5'de verilen sonuçlarda renk özellikleri açısından İpsala çeşidine ait sadece 1 adet pirinç görüntüsü yanlış olarak sınıflandırıldığı görülmektedir. Diğer çeşitler ile en fazla karışan pirinç çeşidinin ise Karacadağ olduğu görülmektedir.

Çizelge 7.5. Renk özelliklerine ait k-en yakın komşu algoritması karmaşıklık matrisi

		Tahmini Sınıf				
		Arborio	**Basmati**	**İpsala**	**Jasmine**	**Karacadağ**
Gerçek Sınıf	**Arborio**	**14,712**	9	0	262	17
	Basmati	43	**14,590**	1	37	329
	İpsala	1	0	**14,999**	0	0
	Jasmine	219	8	0	**14,747**	26
	Karacadağ	57	297	0	63	**14,583**

Algoritmaya ait Çizelge 7.6'da verilen renk özelliklerinin değerlendirildiği performans ölçümleri sonucunda ortalama sınıflandırma doğruluğunun %98.17 olduğu görülmektedir.

Çizelge 7.6. Renk özelliklerine ait
k-en yakın komşu ortalama performans ölçümleri

Performans Ölçümleri	Yüzde (%)
Doğruluk	98.17
Hata	1.83
Hassasiyet	98.20
Hatırlama	98.20
F1-Skor	98.20

7.1.4. Morfolojik, şekil ve renk özelliklerinden elde edilen sonuçlar

Morfolojik, şekil ve renk özellikleri kullanılarak elde edilen 106 adet özelliğe ait k-en yakın komşu algoritması sonuçlarını incelediğimizde, 75,000 pirinç tanesinden 74,850 adedi doğru olarak sınıflandırılmıştır. Sadece 150 adet pirinç tanesi yanlış olarak sınıflandırılmıştır. Algoritmaya ait kappa katsayısı ise 0.998 olarak elde edilmiştir. Çizelge 7.7'de verilen morfolojik, şekil ve renk özelliklerinin bir arada değerlendirildiği k-en yakın komşu algoritmasına ait karmaşıklık matrisi sonuçları incelendiğinde İpsala çeşidinin tamamının diğer pirinç çeşitlerinden ayrıldığı görülmektedir.

Çizelge 7.7. Morfolojik, şekil ve renk özelliklerine ait
k-En yakın komşu algoritması karmaşıklık matrisi

		Tahmini Sınıf				
		Arborio	**Basmati**	**İpsala**	**Jasmine**	**Karacadağ**
Gerçek Sınıf	**Arborio**	**14,947**	0	0	34	19
	Basmati	0	**14,963**	0	37	0
	İpsala	0	0	**15,000**	0	0
	Jasmine	23	3	0	**14,973**	1
	Karacadağ	32	0	0	1	**14,967**

Algoritmaya ait Çizelge 7.8'de verilen morfolojik, şekil ve renk özelliklerinin birlikte değerlendirildiği performans ölçümleri sonucunda ortalama sınıflandırma doğruluğunun %99.80 olduğu görülmektedir.

Çizelge 7.8. Morfolojik, şekil ve renk özelliklerine ait k-En yakın komşu algoritması ortalama performans ölçümleri

Performans Ölçümleri	Yüzde (%)
Doğruluk	99.80
Hata	0.20
Hassasiyet	99.80
Hatırlama	99.80
F1-Skor	99.80

7.2. Karar Ağacı Algoritması Sonuçları

7.2.1. Morfolojik özelliklerden elde edilen sonuçlar

Morfolojik özellikler kullanılarak elde edilen 12 adet özelliğe ait karar ağacı algoritması sonuçlarını incelediğimizde, 73,366 pirinç tanesi doğru olarak sınıflandırılmıştır. Yanlış olarak sınıflandırmaya girenlerin sayısı ise 1,634 adettir. Algoritmaya ait kappa katsayısı ise 0.973 olarak elde edilmiştir. Çizelge 7.9'da verilen morfolojik özelliklerden elde edilen karar ağacı algoritması karmaşıklık matrisine ait sonuçlar incelendiğinde Arborio ile Karacadağ çeşitlerinin diğerleriyle en fazla karışan çeşitler oldukları görülmektedir. Diğer pirinç çeşitleri içerisinde en az karışan çeşidin ise İpsala olduğu görülmektedir.

Çizelge 7.9. Morfolojik özelliklere ait karar ağacı algoritması karmaşıklık matrisi

		Tahmini Sınıf				
		Arborio	**Basmati**	**İpsala**	**Jasmine**	**Karacadağ**
Gerçek Sınıf	**Arborio**	**14,459**	0	12	30	499
	Basmati	1	**14,688**	0	311	0
	İpsala	31	0	**14,909**	60	0
	Jasmine	33	250	31	**14,685**	1
	Karacadağ	374	0	0	1	**14,625**

Algoritmaya ait Çizelge 7.10'da verilen morfolojik özelliklerin değerlendirildiği performans ölçümleri sonucunda ortalama sınıflandırma doğruluğunun %97.82 olduğu görülmektedir.

Çizelge 7.10. Morfolojik özelliklere ait karar ağacı algoritması ortalama performans ölçümleri

Performans Ölçümleri	Yüzde (%)
Doğruluk	97.82
Hata	2.18
Hassasiyet	97.80
Hatırlama	97.80
F1-Skor	97.80

7.2.2. Morfolojik ve şekil özelliklerinden elde edilen sonuçlar

Morfolojik ve şekil özellikleri kullanılarak elde edilen 16 adet özelliğe ait karar ağacı algoritması sonuçlarını incelediğimizde, 73,359 adet pirinç tanesi doğru olarak sınıflandırılmıştır. 1,641 adet pirinç tanesi ise yanlış olarak sınıflandırılmıştır. Algoritmaya ait kappa katsayısı ise 0.973 olarak elde edilmiştir. Çizelge 7.11'de verilen karar ağacı algoritması karmaşıklık matrisine ait sonuçlar incelendiğinde morfolojik ve şekil özellikleri açısından en çok karışan çeşitler Arborio ile Karacadağ çeşitleridir. Ardından Jasmine ile Basmati çeşidi gelmektedir. İpsala çeşidinin ise en az karışan çeşit olduğu görülmektedir.

Çizelge 7.11. Morfolojik ve şekil özelliklerine ait karar ağacı algoritması karmaşıklık matrisi

		Tahmini Sınıf				
		Arborio	**Basmati**	**İpsala**	**Jasmine**	**Karacadağ**
Gerçek Sınıf	**Arborio**	**14,484**	0	13	35	468
	Basmati	1	**14,677**	0	322	0
	İpsala	27	0	**14,935**	37	1
	Jasmine	25	267	31	**14,676**	1
	Karacadağ	412	0	0	1	**14,587**

Algoritmaya ait Çizelge 7.12'de verilen morfolojik ve şekil özelliklerinin değerlendirildiği performans ölçümleri sonucunda ortalama sınıflandırma doğruluğunun %97.81 olduğu görülmektedir.

Çizelge 7.12. Morfolojik ve şekil özelliklerine ait karar ağacı algoritması ortalama performans ölçümleri

Performans Ölçümleri	Yüzde (%)
Doğruluk	97.81
Hata	2.19
Hassasiyet	97.80
Hatırlama	97.80
F1-Skor	97.80

7.2.3. Renk özelliklerinden elde edilen sonuçlar

Renk özellikleri kullanılarak elde edilen 90 adet özelliğe ait karar ağacı algoritması sonuçlarını incelediğimizde, pirinç tanelerinden 73,284 adedinin doğru olarak sınıflandırıldığı görülmektedir. Yanlış olarak sınıflandırmaya giren pirinç tanesi sayısı ise 1,716 adettir. Algoritmaya ait kappa katsayısı ise 0.971 olarak elde edilmiştir. Karar ağacı algoritması karmaşıklık matrisine ait Çizelge 7.13'de verilen sonuçlar incelendiğinde renk özellikleri açısından diğer çeşitler ile en az karışanın İpsala, en fazla karışanın ise Basmati çeşidi olduğu görülmektedir.

Çizelge 7.13. Renk özelliklerine ait karar ağacı algoritması karmaşıklık matrisi

		Tahmini Sınıf				
		Arborio	**Basmati**	**İpsala**	**Jasmine**	**Karacadağ**
Gerçek Sınıf	**Arborio**	**14,664**	46	3	234	53
	Basmati	50	**14,450**	2	39	459
	İpsala	2	3	**14,992**	2	1
	Jasmine	195	29	4	**14,718**	54
	Karacadağ	51	421	0	68	**14,460**

Algoritmaya ait Çizelge 7.14'de verilen renk özelliklerinin değerlendirildiği performans ölçümleri sonucunda ortalama sınıflandırma doğruluğunun %97.71 olduğu görülmektedir.

Çizelge 7.14. Renk özelliklerine ait karar ağacı algoritması ortalama performans ölçümleri

Performans Ölçümleri	Yüzde (%)
Doğruluk	97.71
Hata	2.29
Hassasiyet	97.70
Hatırlama	97.70
F1-Skor	97.70

7.2.4. Morfolojik, şekil ve renk özelliklerinden elde edilen sonuçlar

Morfolojik, şekil ve renk özellikleri kullanılarak elde edilen 106 adet özelliğe ait karar ağacı algoritması sonuçlarına bakıldığında, pirinç taneleri içerisinde 234 adedi yanlış, 74,766 adedi ise doğru olarak sınıflandırılmıştır. Kappa katsayı değeri 0.996 olarak elde edilmiştir.

Çizelge 7.15'de morfolojik, şekil ve renk özelliklerinin birlikte değerlendirildiği karar ağacı algoritmasına ait karmaşıklık matrisi verilmiştir. Karmaşıklık matrisi sonuçlarına bakıldığında, 5 çeşit içinde en az karışan çeşidin İpsala, diğer çeşitlere göre daha fazla karışanlar ise Arborio ve Jasmine çeşitlerinin olduğu görülmektedir.

Çizelge 7.15. Morfolojik, şekil ve renk özelliklerine ait karar ağacı algoritması karmaşıklık matrisi

		Tahmini Sınıf				
		Arborio	**Basmati**	**İpsala**	**Jasmine**	**Karacadağ**
Gerçek Sınıf	**Arborio**	**14,924**	0	4	38	34
	Basmati	0	**14,954**	1	45	0
	İpsala	5	1	**14,990**	4	0
	Jasmine	24	38	5	**14,932**	1
	Karacadağ	33	0	0	1	**14,966**

Algoritmaya ait morfolojik, şekil ve renk özelliklerinin birlikte değerlendirildiği ortalama performans ölçümleri Çizelge 7.16'da verilmiştir. Karar ağacı algoritmasına ait ortalama doğruluk %99.69 olarak elde edilmiştir.

Çizelge 7.16. Morfolojik, şekil ve renk özelliklerine ait karar ağacı algoritması ortalama performans ölçümleri

Performans Ölçümleri	Yüzde (%)
Doğruluk	99.69
Hata	0.31
Hassasiyet	99.70
Hatırlama	99.70
F1-Skor	99.70

7.3. Lojistik Regresyon Algoritması Sonuçları

7.3.1. Morfolojik özelliklerden elde edilen sonuçlar

Morfolojik özellikler kullanılarak elde edilen 12 adet özelliğe ait lojistik regresyon algoritması sonuçlarını incelediğimizde, 73,369 adet pirinç tanesi doğru olarak sınıflandırılmıştır. Yanlış olarak sınıflandırmaya girenlerin sayısı ise 1,631 adettir. Algoritmaya ait kappa katsayısı 0.973 olarak elde edilmiştir. Çizelge 7.17'de verilen lojistik regresyon algoritması karmaşıklık matrisine ait sonuçlar incelendiğinde İpsala çeşidinin diğer pirinç çeşitlerinin içerisinde en yüksek doğruluk değerine, Arborio çeşidinin ise en düşük doğruluk değerine sahip olduğu görülmektedir.

Çizelge 7.17. Morfolojik özelliklere ait lojistik regresyon algoritması karmaşıklık matrisi

		Tahmini Sınıf				
		Arborio	**Basmati**	**İpsala**	**Jasmine**	**Karacadağ**
Gerçek Sınıf	**Arborio**	**14,463**	0	8	32	497
	Basmati	0	**14,634**	0	365	1
	İpsala	26	0	**14,937**	37	0
	Jasmine	20	260	25	**14,694**	1
	Karacadağ	358	0	0	1	**14,641**

Algoritmaya ait Çizelge 7.18'de verilen morfolojik özelliklerin değerlendirildiği performans ölçümleri sonucunda ortalama sınıflandırma doğruluğunun %97.83 olduğu görülmektedir.

Çizelge 7.18. Morfolojik özelliklere ait lojistik regresyon algoritması ortalama performans ölçümleri

Performans Ölçümleri	**Yüzde (%)**
Doğruluk	97.83
Hata	2.17
Hassasiyet	97.80
Hatırlama	97.80
F1-Skor	97.80

7.3.2. Morfolojik ve şekil özelliklerinden elde edilen sonuçlar

Morfolojik ve şekil özellikleri kullanılarak elde edilen 16 adet özelliğe ait lojistik regresyon algoritması sonuçlarını incelediğimizde, pirinç tanelerinin 73,370 adedi doğru olarak sınıflandırılmıştır. 1,630 adet pirinç tanesi ise yanlış olarak sınıflandırılmıştır. Algoritmaya ait kappa katsayısı ise 0.973 olarak elde edilmiştir. Çizelge 7.19'da verilen lojistik regresyon karmaşıklık matrisine ait sonuçlar incelendiğinde morfolojik ve şekil özellikleri açısından Arborio çeşidinin en düşük doğruluk değerine sahip olduğu görülmektedir. En yüksek doğruluk değerinin ise İpsala çeşidine ait olduğu görülmektedir.

Çizelge 7.19. Morfolojik ve şekil özelliklerine ait lojistik regresyon algoritması karmaşıklık matrisi

		Tahmini Sınıf				
		Arborio	**Basmati**	**İpsala**	**Jasmine**	**Karacadağ**
Gerçek Sınıf	**Arborio**	**14,470**	0	8	31	491
	Basmati	0	**14,631**	0	368	1
	İpsala	23	0	**14,941**	36	0
	Jasmine	18	268	29	**14,684**	1
	Karacadağ	356	0	0	0	**14,,644**

Algoritmaya ait Çizelge 7.20'de verilen morfolojik ve şekil özelliklerinin değerlendirildiği performans ölçümleri sonucunda ortalama sınıflandırma doğruluğunun %97.83 olduğu görülmektedir.

Çizelge 7.20. Morfolojik ve şekil özelliklerine ait lojistik regresyon algoritması ortalama performans ölçümleri

Performans Ölçümleri	Yüzde (%)
Doğruluk	97.83
Hata	2.17
Hassasiyet	97.80
Hatırlama	97.80
F1-Skor	97.80

7.3.3. Renk özelliklerinden elde edilen sonuçlar

Renk özellikleri kullanılarak elde edilen 90 adet özelliğe ait lojistik regresyon algoritması sonuçlarını incelediğimizde, pirinç tanelerinin 74,441 adedinin doğru olarak

sınıflandırıldığı görülmektedir. Yanlış olarak sınıflandırmaya giren pirinç tanesi sayısı ise 559 adettir. Algoritmaya ait kappa katsayısı 0.991 olarak elde edilmiştir. Lojistik regresyon algoritması karmaşıklık matrisine ait Çizelge 7.21'de verilen sonuçlar incelendiğinde renk özellikleri açısından İpsala çeşidinin hatasız olarak diğer çeşitlerden ayrıldığı görülmektedir. Çeşitler içinde en fazla karışanın ise Arborio olduğu görülmektedir.

Çizelge 7.21. Renk özelliklerine ait lojistik regresyon algoritması karmaşıklık matrisi

		Tahmini Sınıf				
		Arborio	**Basmati**	**İpsala**	**Jasmine**	**Karacadağ**
Gerçek Sınıf	**Arborio**	**14,842**	8	1	134	15
	Basmati	16	**14,859**	0	22	103
	İpsala	0	0	**15,000**	0	0
	Jasmine	104	18	0	**14,865**	13
	Karacadağ	17	95	0	13	**14,875**

Algoritmaya ait Çizelge 7.22'de verilen renk özelliklerinin değerlendirildiği performans ölçümleri sonucunda ortalama sınıflandırma doğruluğunun %99.25 olduğu görülmektedir.

Çizelge 7.22. Renk özelliklerine ait lojistik regresyon algoritması ortalama performans ölçümleri

Performans Ölçümleri	Yüzde (%)
Doğruluk	99.25
Hata	0.75
Hassasiyet	99.30
Hatırlama	99.30
F1-Skor	99.30

7.3.4. Morfolojik, şekil ve renk özelliklerinden elde edilen sonuçlar

Morfolojik, şekil ve renk özellikleri kullanılarak elde edilen 106 adet özelliğe ait lojistik regresyon algoritması sonuçları incelendiğinde 74,846 pirinç tanesi doğru, 154 pirinç tanesi yanlış olarak sınıflandırılmıştır. Algoritmanın kappa katsayısı 0.997 olarak elde edilmiştir. Çizelge 7.23'de verilen morfolojik, şekil ve renk özelliklerinin birlikte değerlendirildiği lojistik regresyon karmaşıklık matrisi incelendiğinde çeşitler içerisinde

en az karışanın İpsala, en fazla karışanın ise Jasmine ve Arborio çeşitlerinin olduğu görülmektedir.

Çizelge 7.23. Morfolojik, şekil ve renk özelliklerine ait lojistik regresyon algoritması karmaşıklık matrisi

		Tahmini Sınıf				
		Arborio	**Basmati**	**İpsala**	**Jasmine**	**Karacadağ**
Gerçek Sınıf	**Arborio**	**14,952**	4	1	31	12
	Basmati	4	**14,975**	0	21	0
	İpsala	2	1	**14,995**	2	0
	Jasmine	30	24	0	**14,945**	1
	Karacadağ	19	0	0	2	**14,979**

Lojistik regresyon algoritmasına ait morfolojik, şekil ve renk özelliklerinin birlikte değerlendirilerek elde edildiği ortalama performans ölçümleri Çizelge 7.24'de verilmiştir. Algoritmanın ortalama sınıflandırma doğruluğu %99.79 olarak elde edilmiştir.

Çizelge 7.24. Morfolojik, şekil ve renk özelliklerine ait lojistik regresyon algoritması ortalama performans ölçümleri

Performans Ölçümleri	Yüzde (%)
Doğruluk	99.79
Hata	0.21
Hassasiyet	99.80
Hatırlama	99.80
F1-Skor	99.80

7.4. Çok Katmanlı Algılayıcı Algoritması Sonuçları

7.4.1. Morfolojik özelliklerden elde edilen sonuçlar

Morfolojik özellikler kullanılarak elde edilen 12 adet özelliğe ait çok katmanlı algılayıcı algoritması sonuçlarını incelediğimizde, 73,038 adet pirinç tanesi doğru olarak sınıflandırılmıştır. Yanlış olarak sınıflandırmaya girenlerin sayısı ise 1,962 adettir. Algoritmaya ait kappa katsayısı 0.967 olarak elde edilmiştir. Çizelge 7.25'de verilen çok katmanlı algılayıcı algoritması karmaşıklık matrisine ait sonuçlar incelendiğinde İpsala çeşidinin diğer pirinç çeşitleri içerisinde en yüksek doğruluk değeriyle ayrıldığı

görülmektedir. Arborio ve Jasmine çeşitlerinin ise diğer çeşitlerle daha fazla karıştıkları görülmektedir.

Çizelge 7.25. Morfolojik özelliklere ait çok katmanlı algılayıcı algoritması karmaşıklık matrisi

		Tahmini Sınıf				
		Arborio	**Basmati**	**İpsala**	**Jasmine**	**Karacadağ**
Gerçek Sınıf	**Arborio**	**14,387**	0	14	51	548
	Basmati	0	**14,671**	0	329	0
	İpsala	26	7	**14,927**	40	0
	Jasmine	28	553	31	**14,387**	1
	Karacadağ	334	0	0	0	**14,666**

Algoritmaya ait Çizelge 7.26'da verilen morfolojik özelliklerin değerlendirildiği performans ölçümleri sonucunda ortalama sınıflandırma doğruluğunun %97.38 olduğu görülmektedir.

Çizelge 7.26. Morfolojik özelliklere ait
çok katmanlı algılayıcı algoritması ortalama performans ölçümleri

Performans Ölçümleri	Yüzde (%)
Doğruluk	97.38
Hata	2.62
Hassasiyet	97.40
Hatırlama	97.40
F1-Skor	97.40

7.4.2. Morfolojik ve şekil özelliklerinden elde edilen sonuçlar

Morfolojik ve şekil özellikleri kullanılarak elde edilen 16 adet özelliğe ait çok katmanlı algılayıcı algoritması sonuçlarını incelediğimizde, pirinç tanelerinin 73,132 adedi doğru olarak sınıflandırılmıştır. 1,868 adet pirinç tanesi ise yanlış olarak sınıflandırılmıştır. Algoritmaya ait kappa katsayısı ise 0.969 olarak elde edilmiştir. Çizelge 7.27'de verilen çok katmanlı algılayıcı algoritması karmaşıklık matrisine ait sonuçlar incelendiğinde morfolojik ve şekil özellikleri açısından en çok karışan çeşidin Jasmine, diğer çeşitler ile en az karışan çeşidin ise Ipsala olduğu görülmektedir.

Çizelge 7.27. Morfolojik ve şekil özelliklerine ait
çok katmanlı algılayıcı algoritması karmaşıklık matrisi

		Tahmini Sınıf				
		Arborio	**Basmati**	**İpsala**	**Jasmine**	**Karacadağ**
Gerçek Sınıf	**Arborio**	**14,455**	0	11	36	498
	Basmati	0	**14,706**	0	294	0
	İpsala	25	2	**14,941**	32	0
	Jasmine	36	506	76	**14,381**	1
	Karacadağ	351	0	0	0	**14,649**

Algoritmaya ait Çizelge 7.28'de verilen morfolojik ve şekil özelliklerinin değerlendirildiği performans ölçümleri sonucunda ortalama sınıflandırma doğruluğunun %97.51 olduğu görülmektedir.

Çizelge 7.28. Morfolojik ve şekil özelliklerine ait
çok katmanlı algılayıcı algoritması ortalama performans ölçümleri

Performans Ölçümleri	Yüzde (%)
Doğruluk	97.51
Hata	2.49
Hassasiyet	97.50
Hatırlama	97.50
F1-Skor	97.50

7.4.3. Renk özelliklerinden elde edilen sonuçlar

Renk özellikleri kullanılarak elde edilen 90 adet özelliğe ait çok katmanlı algılayıcı algoritması sonuçlarını incelediğimizde, 74,366 adet pirinç tanesinin doğru olarak sınıflandırıldığı görülmektedir. Yanlış olarak sınıflandırmaya giren pirinç tanesi ise 634 adettir. Algoritmaya ait kappa katsayısı ise 0.989 olarak elde edilmiştir. Çok katmanlı algılayıcı algoritması karmaşıklık matrisine ait Çizelge 7.29'da verilen sonuçlara bakıldığında renk özellikleri açısından İpsala çeşidinin yalnızca bir tanesi hariç kalanının sınıflandırıldığı görülmektedir. Diğer pirinç çeşitleri ile en fazla karışan çeşidin ise Arborio olduğu görülmektedir.

Çizelge 7.29. Renk özelliklerine ait çok katmanlı algılayıcı algoritması karmaşıklık matrisi

		Tahmini Sınıf				
		Arborio	**Basmati**	**İpsala**	**Jasmine**	**Karacadağ**
Gerçek Sınıf	**Arborio**	**14,803**	8	0	177	12
	Basmati	15	**14,836**	1	16	132
	İpsala	0	1	**14,999**	0	0
	Jasmine	130	10	1	**14,839**	20
	Karacadağ	21	79	0	11	**14,889**

Algoritmaya ait Çizelge 7.30'da verilen renk özelliklerinin değerlendirildiği performans ölçümleri sonucunda ortalama sınıflandırma doğruluğunun %99.15 olduğu görülmektedir.

Çizelge 7.30. Renk özelliklerine ait çok katmanlı algılayıcı ortalama performans ölçümleri

Performans Ölçümleri	Yüzde (%)
Doğruluk	99.15
Hata	0.85
Hassasiyet	99.20
Hatırlama	99.20
F1-Skor	99.20

7.4.4. Morfolojik, şekil ve renk özelliklerinden elde edilen sonuçlar

Morfolojik, şekil ve renk özellikleri kullanılarak elde edilen 106 adet özelliğe ait çok katmanlı algılayıcı algoritması sonuçları incelendiğinde 75,000 pirinç tanesi içerisinde 74,930 adedi doğru olarak sınıflandırılmıştır. Yalnızca 70 adet pirinç tanesi yanlış olarak sınıflandırılmıştır. Kappa katsayı değeri ise 0.999 olarak elde edilmiştir. Morfolojik, şekil ve renk özelliklerine ait çok katmanlı algılayıcı karmaşıklık matrisi Çizelge 7.31'de verilmiştir. Tablo incelendiğinde İpsala çeşidinin tamamının sınıflandırıldığı görülmektedir.

Çizelge 7.31. Morfolojik, şekil ve renk özelliklerine ait çok katmanlı algılayıcı algoritması karmaşıklık matrisi

		Tahmini Sınıf				
		Arborio	**Basmati**	**İpsala**	**Jasmine**	**Karacadağ**
Gerçek Sınıf	**Arborio**	**14,971**	0	0	18	11
	Basmati	0	**14,985**	0	15	0
	İpsala	0	0	**15,000**	0	0
	Jasmine	9	4	0	**14,986**	1
	Karacadağ	12	0	0	0	**14,988**

Çizelge 7.32'de algoritmaya ait morfolojik, şekil ve renk özelliklerinin birlikte değerlendirilmesi ile elde edilen performans ölçümleri verilmiştir. Ortalama sınıflandırma doğruluğu, çalışmada kullanılan diğer algoritmalar içerisinde en yüksek değer olan %99.91 olarak elde edilmiştir.

Çizelge 7.32. Morfolojik, şekil ve renk özelliklerine ait çok katmanlı algılayıcı algoritması ortalama performans ölçümleri

Performans Ölçümleri	Yüzde (%)
Doğruluk	99.91
Hata	0.09
Hassasiyet	99.90
Hatırlama	99.90
F1-Skor	99.90

7.5. Rastgele Orman Algoritması Sonuçları

7.5.1. Morfolojik özelliklerden elde edilen sonuçlar

Morfolojik özellikler kullanılarak elde edilen 12 adet özelliğe ait rastgele orman algoritması sonuçlarını incelediğimizde, 75,000 adet pirinç tanesinden 73,489 adet doğru, 1,511 adet ise yanlış olarak sınıflandırılmıştır. Algoritmaya ait kappa katsayısı ise 0.975 olarak elde edilmiştir. Çizelge 7.33'de verilen rastgele orman algoritması karmaşıklık matrisine ait sonuçlar incelendiğinde İpsala çeşidinin diğer pirinç çeşitleri içerisinde en az karışan çeşit olduğu görülmektedir. Arborio ile Karacadağ çeşitleri ve Jasmine ile de Basmati çeşitlerinin daha çok karıştığı görülmektedir.

Çizelge 7.33. Morfolojik özelliklere ait rastgele orman algoritması karmaşıklık matrisi

		Tahmini Sınıf				
		Arborio	**Basmati**	**İpsala**	**Jasmine**	**Karacadağ**
Gerçek Sınıf	**Arborio**	**14,492**	0	11	36	461
	Basmati	1	**14,713**	0	286	0
	İpsala	22	0	**14,929**	49	0
	Jasmine	20	250	32	**14,697**	1
	Karacadağ	341	0	0	1	**14,658**

Algoritmaya ait Çizelge 7.34'de verilen performans ölçümleri sonucunda %97.99 ile morfolojik özelliklerin değerlendirildiği diğer algoritmalar içerisinde en yüksek ortalama sınıflandırma doğruluğuna ulaşılmıştır.

Çizelge 7.34. Morfolojik özelliklere ait rastgele orman algoritması ortalama performans ölçümleri

Performans Ölçümleri	Yüzde (%)
Doğruluk	97.99
Hata	2.01
Hassasiyet	98.00
Hatırlama	98.00
F1-Skor	98.00

7.5.2. Morfolojik ve şekil özelliklerinden elde edilen sonuçlar

Morfolojik ve şekil özellikleri kullanılarak elde edilen 16 adet özelliğe ait rastgele orman algoritması sonuçlarını incelediğimizde, pirinç tanelerinin 73,528 adedi doğru olarak sınıflandırılmıştır. 1,472 adet pirinç tanesi ise yanlış olarak sınıflandırılmıştır. Algoritmaya ait kappa katsayısı ise 0.976 olarak elde edilmiştir. Çizelge 7.35'de verilen morfolojik ve şekil özellikleri ile elde edilen rastgele orman karmaşıklık matrisine ait sonuçlar incelendiğinde en az karışan çeşidin İpsala olduğu, en fazla karışan çeşidin ise Arborio olduğu görülmektedir.

Çizelge 7.35. Morfolojik ve şekil özelliklerine ait rastgele orman algoritması karmaşıklık matrisi

		Tahmini Sınıf				
		Arborio	**Basmati**	**İpsala**	**Jasmine**	**Karacadağ**
Gerçek Sınıf	**Arborio**	**14,508**	0	11	31	450
	Basmati	0	**14,716**	0	284	0
	İpsala	22	0	**14,937**	41	0
	Jasmine	20	255	30	**14,694**	1
	Karacadağ	326	0	0	1	**14,673**

Algoritmaya ait Çizelge 7.36'da verilen ortalama performans ölçümleri sonucunda %98.04 ile morfolojik ve şekil özelliklerinin değerlendirildiği diğer algoritmalar içerisinde en yüksek ortalama sınıflandırma doğruluğuna ulaşıldığı görülmektedir.

Çizelge 7.36. Morfolojik ve şekil özelliklerine ait rastgele orman algoritması ortalama performans ölçümleri

Performans Ölçümleri	Yüzde (%)
Doğruluk	98.04
Hata	1.96
Hassasiyet	98.00
Hatırlama	98.00
F1-Skor	98.00

7.5.3. Renk özelliklerinden elde edilen sonuçlar

Renk özellikleri kullanılarak elde edilen 90 adet özelliğe ait rastgele orman algoritması sonuçlarını incelediğimizde, pirinç tanelerinin 74,027 adedinin doğru olarak sınıflandırıldığı görülmektedir. Yanlış olarak sınıflandırmaya giren pirinç tanesi sayısı ise 973 adettir. Algoritmaya ait kappa katsayısı ise 0.984 olarak elde edilmiştir. Rastgele orman algoritması karmaşıklık matrisine ait Çizelge 7.37'de verilen sonuçlara bakıldığında renk özellikleri açısından İpsala çeşidinin tamamının sınıflandırıldığı görülmektedir. Diğer pirinç çeşitleri ile en fazla karışan çeşidin ise Basmati olduğu görülmektedir.

Çizelge 7.37. Renk özelliklerine ait rastgele orman algoritması karmaşıklık matrisi

		Tahmini Sınıf				
		Arborio	**Basmati**	**İpsala**	**Jasmine**	**Karacadağ**
Gerçek Sınıf	**Arborio**	**14,784**	8	0	190	18
	Basmati	29	**14,681**	0	17	273
	İpsala	0	0	**15,000**	0	0
	Jasmine	101	11	0	**14,867**	21
	Karacadağ	44	228	0	33	**14,695**

Algoritmaya ait Çizelge 7.38'de verilen renk özelliklerinin değerlendirildiği performans ölçümleri sonucunda ortalama sınıflandırma doğruluğunun %98.70 olduğu görülmektedir.

Çizelge 7.38. Renk özelliklerine ait rastgele orman ortalama performans ölçümleri

Performans Ölçümleri	Yüzde (%)
Doğruluk	98.70
Hata	1.30
Hassasiyet	98.70
Hatırlama	98.70
F1-Skor	98.70

7.5.4. Morfolojik, şekil ve renk özelliklerinden elde edilen sonuçlar

Morfolojik, şekil ve renk özellikleri kullanılarak elde edilen 106 adet özelliğe ait rastgele orman algoritması sonuçları incelendiğinde toplam 75,000 pirinç tanesinden 91 adedi yanlış olarak, geriye kalan 74,909 adedi ise doğru olarak sınıflandırılmıştır. Rastgele orman kappa katsayı değeri ise 0.999 olarak elde edilmiştir.

Çizelge 7.39'da rastgele orman algoritması için morfolojik, şekil ve renk özelliklerine ait karmaşıklık matrisi verilmiştir. Morfolojik, şekil ve renközellikleri bakımından İpsala çeşidinin neredeyse tamamının sınıflandırıldığı görülmektedir.

Çizelge 7.39. Morfolojik, şekil ve renk özelliklerine ait rastgele orman algoritması karmaşıklık matrisi

		Tahmini Sınıf				
		Arborio	**Basmati**	**İpsala**	**Jasmine**	**Karacadağ**
Gerçek Sınıf	**Arborio**	**14,969**	0	0	21	10
	Basmati	0	**14,981**	0	19	0
	İpsala	1	0	**14,999**	0	0
	Jasmine	16	3	0	**14,981**	0
	Karacadağ	21	0	0	0	**14,979**

Çizelge 7.40'da verilen rastgele orman algoritması için morfolojik, şekil ve renk özelliklerine ait ortalama performans ölçümleri incelendiğinde %99.88 ortalama sınıflandırma doğruluğu elde edildiği görülmektedir.

Çizelge 7.40. Morfolojik, şekil ve renk özelliklerine ait rastgele orman algoritması ortalama performans ölçümleri

Performans Ölçümleri	Yüzde (%)
Doğruluk	99.88
Hata	0.12
Hassasiyet	99.90
Hatırlama	99.90
F1-Skor	99.90

7.6. Destek Vektör Makinesi Algoritması Sonuçları

7.6.1. Morfolojik özelliklerden elde edilen sonuçlar

Morfolojik özellikler kullanılarak elde edilen 12 adet özelliğe ait destek vektör makinesi algoritması sonuçlarını incelediğimizde, 72,765 adet pirinç tanesi doğru olarak sınıflandırılmıştır. Yanlış olarak sınıflandırmaya girenlerin sayısı ise 2,235 adettir. Algoritmaya ait kappa katsayısı ise 0.963 olarak elde edilmiştir. Çizelge 7.41'de verilen destek vektör makinesi algoritması karmaşıklık matrisine ait sonuçlar incelendiğinde İpsala çeşidinin diğer pirinç çeşitleri içerisinden en yüksek doğruluk değeri ile ayrıldığı görülmektedir. Diğer çeşitler içerisinde en fazla karışan çeşidin Basmati olduğu görülmektedir.

Çizelge 7.41. Morfolojik özelliklere ait destek vektör makinesi algoritması karmaşıklık matrisi

		Tahmini Sınıf				
		Arborio	**Basmati**	**İpsala**	**Jasmine**	**Karacadağ**
Gerçek Sınıf	**Arborio**	**14,411**	0	2	48	539
	Basmati	0	**14,323**	0	677	0
	İpsala	38	0	**14,910**	52	0
	Jasmine	32	458	23	**14,486**	1
	Karacadağ	365	0	0	0	**14,635**

Algoritmaya ait Çizelge 7.42'de verilen morfolojik özelliklerin değerlendirildiği performans ölçümleri sonucunda ortalama sınıflandırma doğruluğunun %97.02 olduğu görülmektedir.

Çizelge 7.42. Morfolojik özelliklere ait destek vektör makinesi ortalama performans ölçümleri

Performans Ölçümleri	Yüzde (%)
Doğruluk	97.02
Hata	2.98
Hassasiyet	97.00
Hatırlama	97.00
F1-Skor	97.00

7.6.2. Morfolojik ve şekil özelliklerinden elde edilen sonuçlar

Morfolojik ve şekil özellikleri kullanılarak elde edilen 16 adet özelliğe ait destek vektör makinesi algoritması sonuçlarını incelediğimizde, 73,067 adet pirinç tanesi doğru olarak, 1,933 adedi ise yanlış olarak sınıflandırılmıştır. Algoritmaya ait kappa katsayısı 0.968 olarak elde edilmiştir. Çizelge 7.43'de verilen destek vektör makinesi algoritması karmaşıklık matrisine ait sonuçlar incelendiğinde morfolojik ve şekil özellikleri açısından en çok karışan çeşit Arborio, diğer çeşitler ile en az karışan çeşidin ise Ipsala olduğu görülmektedir.

Çizelge 7.43. Morfolojik ve şekil özelliklerine ait destek vektör makinesi algoritması karmaşıklık matrisi

		Tahmini Sınıf				
		Arborio	**Basmati**	**İpsala**	**Jasmine**	**Karacadağ**
Gerçek Sınıf	**Arborio**	**14,426**	0	3	46	525
	Basmati	0	**14,488**	0	512	0
	İpsala	39	0	**14,922**	39	0
	Jasmine	33	355	22	**14,589**	1
	Karacadağ	358	0	0	0	**14,642**

Algoritmaya ait Çizelge 7.44'de verilen morfolojik ve şekil özelliklerinin değerlendirildiği performans ölçümleri sonucunda ortalama sınıflandırma doğruluğunun %97.42 olduğu görülmektedir.

Çizelge 7.44. Morfolojik ve şekil özelliklerine ait destek vektör makinesi ortalama performans ölçümleri

Performans Ölçümleri	Yüzde (%)
Doğruluk	97.42
Hata	2.58
Hassasiyet	97.40
Hatırlama	97.40
F1-Skor	97.40

7.6.3. Renk özelliklerinden elde edilen sonuçlar

Renk özellikleri kullanılarak elde edilen 90 adet özelliğe ait destek vektör makinesi algoritması sonuçlarını incelediğimizde, pirinç tanelerinin 73,929 adedi doğru olarak, 1,071 adedi ise yanlış olarak sınıflandırılmıştır. Algoritmaya ait kappa katsayısı

ise 0.982 olarak elde edilmiştir. Çizelge 7.45'de verilen destek vektör makinesi algoritması karmaşıklık matrisine ait sonuçlar incelendiğinde renk özellikleri açısından İpsala çeşidine ait sadece 1 adet pirinç görüntüsü yanlış sınıflandırılmıştır. Diğer çeşitler ile en fazla karışan pirinç çeşidinin ise Basmati olduğu görülmektedir.

Çizelge 7.45. Renk özelliklerine ait destek vektör makinesi algoritması karmaşıklık matrisi

		Tahmini Sınıf				
		Arborio	**Basmati**	**İpsala**	**Jasmine**	**Karacadağ**
Gerçek Sınıf	**Arborio**	**14,749**	5	0	237	9
	Basmati	39	**14,677**	0	76	208
	İpsala	1	0	**14,999**	0	0
	Jasmine	121	70	0	**14,800**	9
	Karacadağ	31	196	0	69	**14,704**

Algoritmaya ait Çizelge 7.46'da verilen renk özelliklerinin değerlendirildiği performans ölçümleri sonucunda ortalama sınıflandırma doğruluğunun %98.57 olduğu görülmektedir.

Çizelge 7.46. Renk özelliklerine ait destek vektör makinesi ortalama performans ölçümleri

Performans Ölçümleri	Yüzde (%)
Doğruluk	98.57
Hata	1.43
Hassasiyet	98.60
Hatırlama	98.60
F1-Skor	98.60

7.6.4. Morfolojik, şekil ve renk özelliklerinden elde edilen sonuçlar

Morfolojik, şekil ve renk özellikleri kullanılarak elde edilen 106 adet özelliğe ait destek vektör makinesi sınıflandırma sonuçları incelendiğinde, pirinç tanelerin 74,885 adedi doğru olarak, 155 adedi ise yanlış olarak sınıflandırılmıştır. Destek vektör makinesi kappa katsayı değeri ise 0.998 olarak elde edilmiştir.

Çizelge 7.47'de verilen morfolojik, şekil ve renk özellikleri için destek vektör makinesi algoritmasına ait karmaşıklık matrisi incelendiğinde İpsala çeşidinin tamamının sınıflandırıldığı görülmektedir.

Çizelge 7.47. Morfolojik, şekil ve renk özelliklerine ait destek vektör makinesi algoritması karmaşıklık matrisi

		Tahmini Sınıf				
		Arborio	**Basmati**	**İpsala**	**Jasmine**	**Karacadağ**
Gerçek Sınıf	**Arborio**	**14,973**	0	0	18	9
	Basmati	0	**14,946**	0	54	0
	İpsala	0	0	**15,000**	0	0
	Jasmine	8	12	0	**14,979**	1
	Karacadağ	12	0	0	1	**14,987**

Çizelge 7.48'de destek vektör makinesi algoritması için morfolojik, şekil ve renk özelliklerine ait ortalama performans ölçümleri verilmiştir. Destek vektör makinesi ortalama sınıflandırma doğruluğu %99.85 olarak elde edilmiştir.

Çizelge 7.48. Morfolojik, şekil ve renk özelliklerine ait destek vektör makinesi algoritması ortalama performans ölçümleri

Performans Ölçümleri	Yüzde (%)
Doğruluk	99.85
Hata	0.15
Hassasiyet	99.80
Hatırlama	99.80
F1-Skor	99.80

7.7. Tüm Algoritmalara Ait Performans Ölçüm Sonuçları

7.7.1. Morfolojik özelliklerden elde edilen sonuçlar

Çalışmada kullanılan tüm algoritmalar için karmaşıklık matrisi kullanılarak yalnızca morfolojik özelliklerin değerlendirilmesi ile elde edilen doğruluk, hata, hassasiyet, hatırlama ve F1-skor ortalama performans ölçümleri ve kappa katsayı değerleri Çizelge 7.49'da verilmiştir.

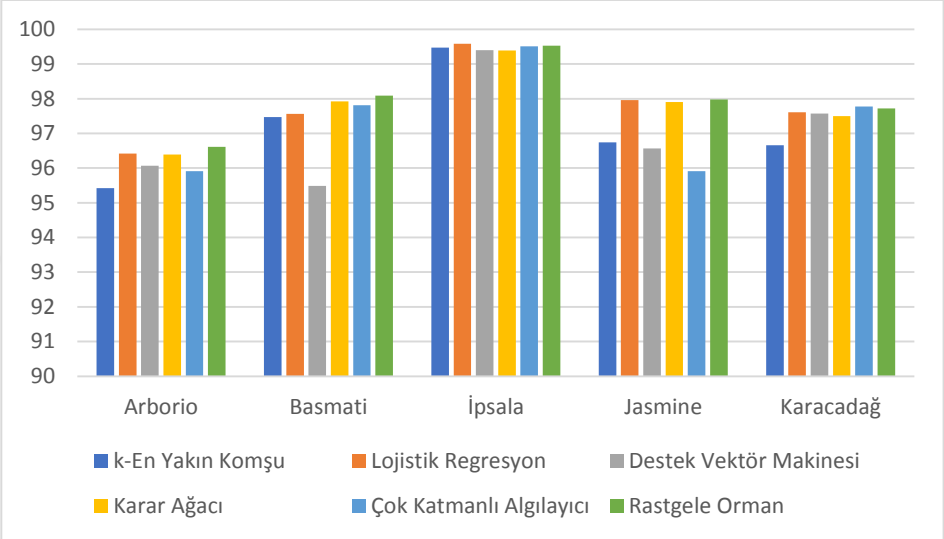
Çizelge 7.49. Morfolojik özellikler için sınıflandırmada kullanılan tüm algoritmalara ait ortalama performans ölçümleri ve kappa katsayı değerleri

Performans Ölçümleri	Rastgele Orman	Lojistik Regresyon	Karar Ağacı	Çok Katmanlı Algılayıcı	k-En Yakın Komşu	Destek Vektör Makinesi
Doğruluk (%)	97.99	97.83	97.82	97.38	97.15	97.02
Hata (%)	2.01	2.17	2.18	2.62	2.85	2.98
Hassasiyet (%)	98.00	97.80	97.80	97.40	97.20	97.00
Hatırlama (%)	98.00	97.80	97.80	97.40	97.20	97.00
F1-Skor (%)	98.00	97.80	97.80	97.40	97.20	97.00
Kappa katsayısı	0.975	0.973	0.973	0.967	0.964	0.963

Çizelge 7.49'da verilen ortalama performans ölçüm değerleri incelendiğinde tüm algoritmalar için sınıflandırma başarılarının %97'nin üzerinde olduğu görülmektedir.

En iyi sınıflandırma doğruluğunun %97.99 ile rastgele orman algoritmasına ait olduğu görülmektedir. En düşük sınıflandırma doğruluğu ise %97.02 ile destek vektör makinesi algoritmasına aittir.

En iyi sınıflandırma başarısına sahip rastgele orman algoritmasına ait Çizelge 7.33'de verilen morfolojik özelliklerin değerlendirildiği karmaşıklık matrisi incelendiğinde, Arborio, Basmati, İpsala, Jasmine ve Karacadağ pirinç çeşitlerine ait doğruluk oranları sırasıyla, %96.61, %98.09, %99.53, %97.98, %97.72 olduğu görülmektedir. Şekil 7.1'de çalışmada kullanılan pirinç çeşitleri için morfolojik özelliklerden elde edilen sınıflandırma algoritmalarına ait doğruluk oranları gösterilmektedir.



Şekil 7.1. Çalışmada kullanılan tüm pirinç çeşitleri için morfolojik özelliklerden elde edilen sınıflandırma algoritmalarına ait doğruluk oranları

Rastgele orman algoritmasında, çeşitler arasında en yüksek doğruluk oranına sahip olan İpsala pirinç çeşidinin diğer algoritmalarda da en yüksek doğruluk oranlarına ulaştığı görülmektedir. Arborio çeşidinin ise diğer çeşitlere göre daha düşük doğruluk oranına sahip olduğu görülmektedir.

7.7.2. Morfolojik ve şekil özelliklerinden elde edilen sonuçlar

Çalışmada kullanılan tüm algoritmalar için karmaşıklık matrisi kullanılarak morfolojik ve şekil özelliklerinin bir arada kullanılması ile elde edilen doğruluk, hata, hassasiyet, hatırlama ve F1-skor ortalama performans ölçümleri ve kappa katsayı değerleri Çizelge 7.50'de verilmiştir.

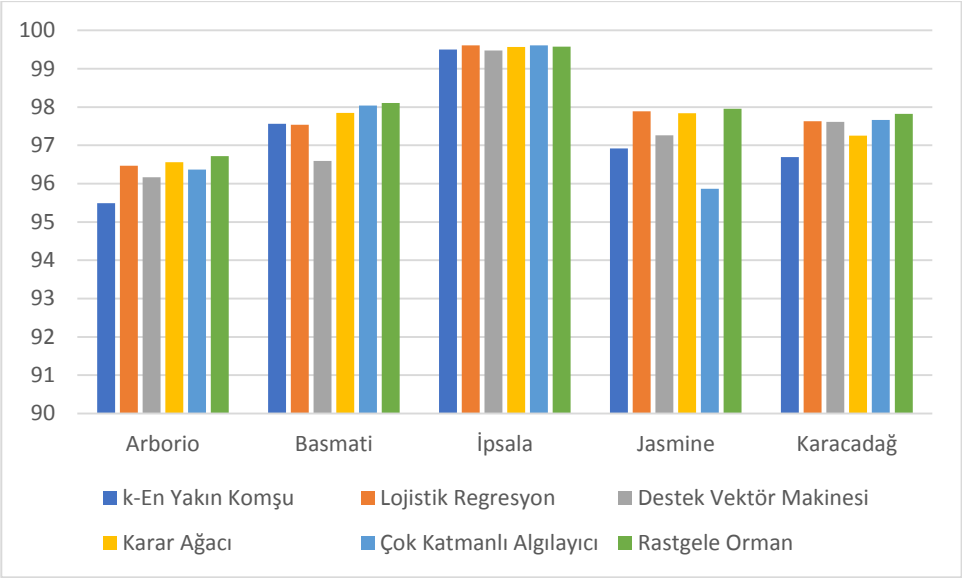
Çizelge 7.50. Morfolojik ve şekil özellikleri için sınıflandırmada kullanılan tüm algoritmalara ait ortalama performans ölçümleri ve kappa katsayı değerleri

Performans Ölçümleri	Rastgele Orman	Lojistik Regresyon	Karar Ağacı	Çok Katmanlı Algılayıcı	Destek Vektör Makinesi	k-En Yakın Komşu
Doğruluk (%)	98.04	97.83	97.81	97.51	97.42	97.23
Hata (%)	1.96	2.17	2.19	2.49	2.58	2.77
Hassasiyet (%)	98.00	97.80	97.80	97.50	97.40	97.20
Hatırlama (%)	98.00	97.80	97.80	97.50	97.40	97.20
F1-Skor (%)	98.00	97.80	97.80	97.50	97.40	97.20
Kappa katsayısı	0.976	0.973	0.973	0.969	0.968	0.965

Çizelge 7.50'de verilen ortalama performans ölçüm değerleri incelendiğinde tüm algoritmalar için %97'nin üzerinde sınıflandırma başarısı elde edildiği görülmektedir.

En iyi sınıflandırma doğruluğunun %98.04 ile rastgele orman algoritmasına ait olduğu görülmektedir. En düşük sınıflandırma doğruluğu ise %97.23 ile k-en yakın komşu algoritmasına aittir.

En iyi sınıflandırma başarısına sahip rastgele orman algoritmasına ait Çizelge 7.35'de verilen morfolojik ve şekil özelliklerinin bir arada değerlendirildiği karmaşıklık matrisi incelendiğinde, Arborio, Basmati, İpsala, Jasmine ve Karacadağ pirinç çeşitlerine ait doğruluk oranları sırasıyla, %96.72, %98.11, %99.58, %97.96, %97.82 olduğu görülmektedir. Şekil 7.2'de çalışmada kullanılan pirinç çeşitleri için morfolojik ve şekil özelliklerinden elde edilen sınıflandırma algoritmalarına ait doğruluk oranları gösterilmektedir.



Şekil 7.2. Çalışmada kullanılan tüm pirinç çeşitleri için morfolojik ve şekil özelliklerinden elde edilen sınıflandırma algoritmalarına ait doğruluk oranları

Yalnızca morfolojik özellikler kullanılarak elde edilen sınıflandırma doğruluk oranlarında olduğu gibi morfolojik ve şekil özelliklerinden elde edilen sınıflandırma doğruluk oranlarına bakıldığında da çeşitler arasında en yüksek doğruluk oranına İpsala pirinç çeşidinin sahip olduğu görülmektedir. Arborio çeşidinin ise diğer pirinç çeşitlerine göre daha düşük doğruluk oranına sahip olduğu görülmektedir.

7.7.3. Renk özelliklerinden elde edilen sonuçlar

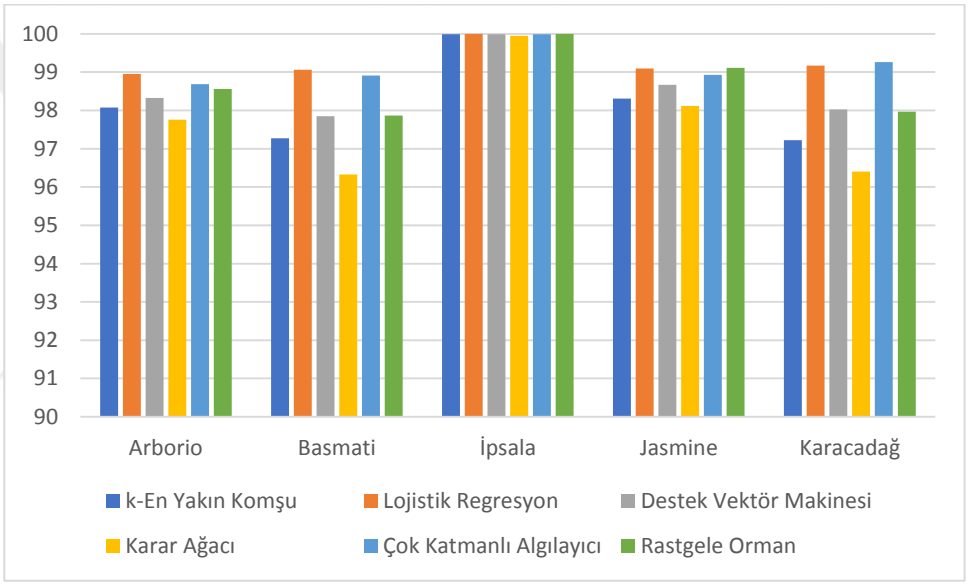
Çalışmada kullanılan tüm algoritmalar için karmaşıklık matrisi kullanılarak yalnızca renk özelliklerinin değerlendirilmesi ile elde edilen doğruluk, hata, hassasiyet, hatırlama ve F1-skor ortalama performans ölçümleri ve kappa katsayı değerleri Çizelge 7.51'de verilmiştir.

Çizelge 7.51. Renk özellikleri için sınıflandırmada kullanılan tüm algoritmalara ait ortalama performans ölçümleri ve kappa katsayı değerleri

Performans Ölçümleri	Lojistik Regresyon	Çok Katmanlı Algılayıcı	Rastgele Orman	Destek Vektör Makinesi	k-En Yakın Komşu	Karar Ağacı
Doğruluk (%)	99.25	99.15	98.70	98.57	98.17	97.71
Hata (%)	0.75	0.85	1.30	1.43	1.83	2.29
Hassasiyet (%)	99.30	99.20	98.70	98.60	98.20	97.70
Hatırlama (%)	99.30	99.20	98.70	98.60	98.20	97.70
F1-Skor (%)	99.30	99.20	98.70	98.60	98.20	97.70
Kappa katsayısı	0.991	0.989	0.984	0.982	0.977	0.971

Çizelge 7.51'de verilen ortalama performans ölçüm değerleri incelendiğinde en iyi sınıflandırma doğruluğunun %99.25 lojistik regresyon algoritmasına ait olduğu görülmektedir. En düşük sınıflandırma doğruluğu ise %97.71 ile karar ağacı algoritmasına aittir.

En iyi sınıflandırma başarısına sahip lojistik regresyon algoritmasına ait Çizelge 7.21'de verilen renk özelliklerinin değerlendirildiği karmaşıklık matrisi incelendiğinde, Arborio, Basmati, İpsala, Jasmine ve Karacadağ pirinç çeşitlerine ait doğruluk oranları sırasıyla, %98.95, %99.06, %100, %99.10, %99.17 olduğu görülmektedir. Şekil 7.3'de çalışmada kullanılan pirinç çeşitleri için renk özelliklerinden elde edilen sınıflandırma algoritmalarına ait doğruluk oranları gösterilmektedir.



Şekil 7.3. Çalışmada kullanılan tüm pirinç çeşitleri için renk özelliklerinden elde edilen sınıflandırma algoritmalarına ait doğruluk oranları

Lojistik regresyon algoritmasında, çeşitler arasında %100 doğruluk oranına sahip olan İpsala pirinç çeşidinin diğer algoritmalarda da en yüksek doğruluk oranlarına ulaştığı görülmektedir. Arborio ve Basmati çeşitlerinin ise diğer çeşitlere göre daha düşük doğruluk oranına sahip olduğu görülmektedir.

7.7.4. Morfolojik, şekil ve renk özelliklerinden elde edilen sonuçlar

Çalışmada kullanılan tüm algoritmalar için karmaşıklık matrisi kullanılarak morfolojik, şekil ve renk özelliklerinin birlikte değerlendirilmesi ile elde edilen doğruluk,

hata, hassasiyet, hatırlama ve F1-skor ortalama performans ölçümleri ve kappa katsayı değerleri Çizelge 7.52'de verilmiştir.

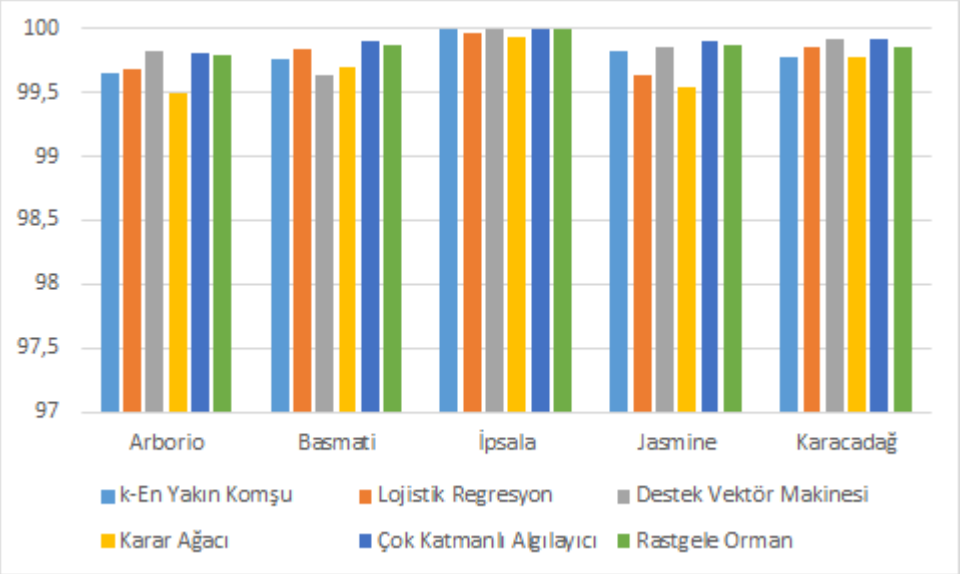
Çizelge 7.52. Morfolojik, şekil ve renk özellikleri için sınıflandırmada kullanılan tüm algoritmalara ait ortalama performans ölçümleri ve kappa katsayı değerleri

Performans Ölçümleri	Çok Katmanlı Algılayıcı	Rastgele Orman	Destek Vektör Makinesi	k-En Yakın Komşu	Lojistik Regresyon	Karar Ağacı
Doğruluk (%)	99.91	99.88	99.85	99.80	99.79	99.69
Hata (%)	0.09	0.12	0.15	0.20	0.21	0.31
Hassasiyet (%)	99.90	99.90	99.80	99.80	99.80	99.70
Hatırlama (%)	99.90	99.90	99.80	99.80	99.80	99.70
F1-Skor (%)	99.90	99.90	99.80	99.80	99.80	99.70
Kappa katsayısı	0.999	0.999	0.998	0.998	0.997	0.996

Çizelge 7.52'de verilen ortalama performans ölçüm değerleri incelendiğinde tüm algoritmalar için sınıflandırma başarılarının %99'un üzerinde olduğu görülmektedir.

En iyi sınıflandırma doğruluğu %99.91 ile çok katmanlı algılayıcı algoritmasına aittir. En düşük sınıflandırma doğruluğu ise %99.69 ile karar ağacı algoritmasına aittir. Performans ölçümleri parametrelerine bakıldığında çok katmanlı algılayıcı algoritmasının en iyi değerlere sahip olduğu görülmektedir. Sınıflandırma algoritmalarında F1-skor değerinin yüksek olması, algoritmanın sınıflandırma başarısı açısından iyi bir performans gösterdiğinin kanıtı niteliğindedir.

En iyi sınıflandırma başarısına sahip çok katmanlı algılayıcı algoritmasına ait Çizelge 7.31'deki morfolojik, şekil ve renk özelliklerinin birlikte değerlendirildiği karmaşıklık matrisi incelendiğinde, Arborio, Basmati, İpsala, Jasmine ve Karacadağ pirinç çeşitlerine ait doğruluk oranları sırasıyla, %99.81, %99.99, %100, %99.91, %99.92 olduğu görülmektedir. Şekil 7.4'de çalışmada kullanılan pirinç çeşitleri için elde edilen sınıflandırma algoritmalarına ait doğruluk oranları gösterilmektedir.

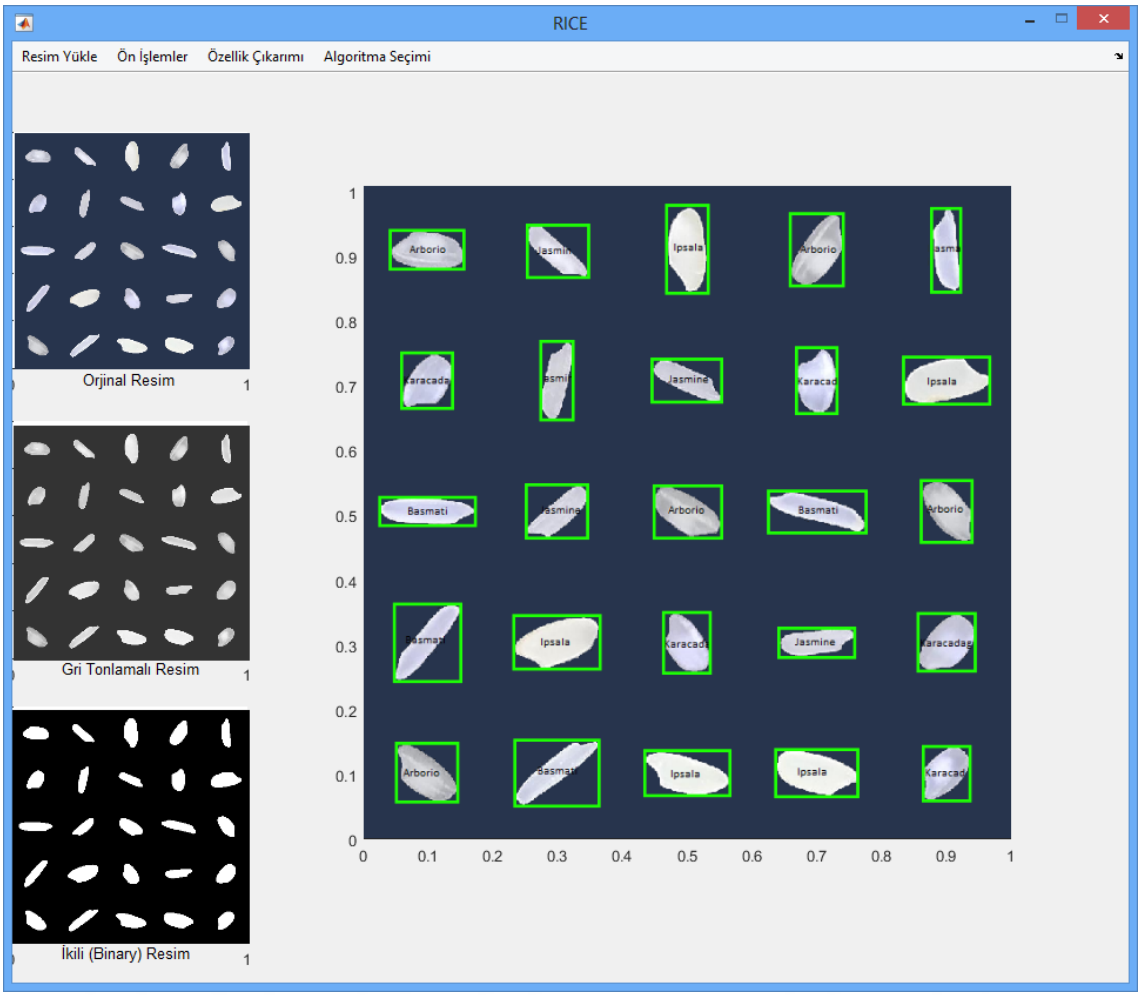


Şekil 7.4. Çalışmada kullanılan tüm pirinç çeşitleri için morfolojik, şekil ve renk özelliklerinden elde edilen sınıflandırma algoritmalarına ait doğruluk oranları

Çok katmanlı algılayıcılar algoritmasında, çeşitler arasında %100 doğruluk oranına sahip olan İpsala pirinç çeşidinin diğer algoritmalarda da en yüksek doğruluk oranlarına ulaştığı görülmektedir. Arborio ve Basmati çeşitlerinin ise diğer çeşitlere göre daha düşük doğruluk oranına sahip olduğu görülmektedir.

7.8. Grafik Arayüzü Tasarımı

Çalışmadan elde edilen verileri kullanarak, özellik çıkarımında kullanılan pirinç çeşitlerine ait tane görüntülerinden farklı olan yeni görüntüler üzerinde sınıflandırma yapabilmek için MATLAB GUI ortamında bir arayüz geliştirilmiştir. Şekil 7.5'de pirinç sınıflandırmada kullanılan arayüze ait ekran görüntüsü verilmiştir.



Şekil 7.5. Pirinç sınıflandırmada kullanılan MATLAB GUI arayüzü

Geliştirilen arayüz yardımıyla farklı pirinç çeşitlerine ait tanelerin bir arada bulunduğu görüntü, resim yükle menüsü kullanılarak sisteme yüklenir. Sisteme alınan renkli görüntü, ön işlemler menüsünden öncelikle gri tonlamalı görüntüye dönüştürülür. Ardından ikili görüntüye çevrilir ve istenmeyen maddelerden arındırılarak özellik çıkarımına hazırlanır. Özellik çıkarım menüsünden özellik kümesi seçilir ve elde edilen özelliklere göre oluşturulan veri setine algoritma seçim menüsünde bulunan algoritmalardan seçim yapılarak sınıflandırma işlemi gerçekleştirilir. Sınıflandırma sonucunda görüntü üzerinde bulunan pirinç tanesi hangi çeşide ait ise etiketlenerek ekrana yazdırılır.

7.9. Bölüm Değerlendirmesi

Bu bölümde, çalışmada kullanılan yapay zeka tekniklerinden elde edilen karmaşıklık matrisi ve performans ölçüm değerlerinin sonuçları verilmiştir. Her sınıflandırma algoritması için morfolojik özelliklerin tek başına değerlendirildiği, morfolojik ve şekil özelliklerinin birlikte değerlendirildiği, yalnızca renk özelliklerinin değerlendirildiği ve morfolojik, şekil ve renk özelliklerinin birlikte değerlendirildiği sonuçlar incelenerek sınıflandırmaya giren çeşitlerin karmaşıklık matrisinden elde edilen sonuçları tablolar halinde verilmiştir. Algortimalara ait ortalama performans ölçümü başarı kriterleri hakkında elde edilen sonuçlar da paylaşılarak açıklanmıştır. Ayrıca tüm algoritmalardan elde edilen sonuçlar bir arada değerlendirilerek tablo ve grafikler halinde verilmiştir.

Ayrıca MATLAB GUI ortamında geliştirilen arayüz ile sınıflandırma sonucunda pirinç tanelerinin çeşidinin belirlenmesi ve etiketlenmesi işlemi anlatılmıştır.

8. SONUÇLAR VE ÖNERİLER

8.1 Sonuçlar

Bu tez çalışmasında, pirinç tanelerinin sınıflandırılması için 5 farklı pirinç çeşidi için toplam 75,000 adet pirinç tanesi görüntüsü elde edilmiştir. Bu görüntüler MATLAB yazılımı yardımıyla ön işlemlerden geçirilerek görüntü üzerinde bulunabilecek istenmeyen maddelerden arındırılmış ve özellik çıkarımı aşamasına hazırlanmıştır.

Sınıflandırma aşamasından önce ön işlemlerden geçirilmiş görüntüler üzerinde 12 adet morfolojik özellik, morfolojik özelliklere ek olarak 4 adet şekil özelliğide eklenerek elde edilen toplam 16 adet morfolojik ve şekil özelliği, 5 farklı renk uzayından elde edilen toplam 90 adet renk özelliği ve son olarak morfolojik, şekil ve renk özelliklerinin birlikte değerlendirildiği toplam 106 adet özellik çıkarımı gerçekleştirilmiştir. Morfolojik özellikler, MATLAB yazılımında regionprops bileşenleri kullanılarak elde edilmiş ve şekil özellikleride bu morfolojik özellikler kullanılarak elde edilmiştir. Renk özellikleri için RGB, HSV, L*a*b, YCbCr ve XYZ renk uzayları kullanılmıştır. MATLAB yazılımı ile her RGB görüntüsü için piksel değerleri kullanılarak diğer renk uzaylarına dönüşüm işlemleri gerçekleştirilmiştir. Renk dönüşüm işlemi sonrasında 5 adet renk uzayına ait veriler, ortalama, standart sapma, çarpıklık, basıklık, entropi ve dalgacık ayrışması bileşenleri kullanılarak toplamda 90 adet renk özelliği elde edilmiştir.

Sınıflandırma için en çok kullanılan yapay zeka tekniklerinden olan k-NN, DT, LR, MLP, RF ve SVM algoritmalarından faydalanılmıştır. Algoritmalara ait karmaşıklık matrisi çıkarımları yapılmış ve performans değerlendirilmesi gerçekleştirilmiştir. Algoritmaların genelleme yeteneğini kontrol etmek için kullanılan çapraz doğrulama yineleme kat sayısı 10 olarak seçilmiştir.

Morfolojik özellikler, morfolojik özelliklere ek olarak şekil özelliklerinin birlikte değerlendirildiği özellikler, renk özellikleri ve son olarak morfolojik, şekil ve renk özelliklerinin birlikte değerlendirildiği özellik kümeleri için algoritmalara ait sınıflandırma doğrulukları Çizelge 8.1’de verilmiştir.

Çizelge 8.1. Çalışmada kullanılan özellik kümeleri ve algoritmalardan elde edilen ortalama sınıflandırma doğruluk yüzdeleri

Özellik Kümesi	Rastgele Orman	Lojistik Regresyon	Çok Katmanlı Algılayıcı	Karar Ağacı	k-En Yakın Komşu	Destek Vektör Makinesi
Morfolojik	**97.99**	97.83	97.38	97.82	97.15	97.02
Morfolojik ve Şekil	**98.04**	97.83	97.51	97.81	97.23	97.42
Renk	98.70	**99.25**	99.15	97.71	98.17	98.57
Morfolojik, Şekil ve Renk	99.88	99.79	**99.91**	99.69	99.80	99.85

Yalnızca morfolojik özellikler değerlendirilerek tüm algoritmalarda %97'nin üzerinde bir başarı yakalanmıştır. En yüksek sınıflandırma doğruluğu ise %97.99 ile rastgele orman algoritmasına aittir. Morfolojik özelliklerden elde edilen başarıyı artırabilme adına şekil özellikleri de eklenerek, 16 adet morfolojik ve şekil özellik çıkarımı yapılmış ve en yüksek sınıflandırma doğruluğu olarak rastgele orman algoritması ile %98.04 başarı elde edilmiştir. Literatürde yapılan çalışmaları incelediğimizde, morfolojik ve şekil özelliklerinin yanında renk özellikleride eklenerek gerçekleştirilen sınıflandırmalar sonrası başarının daha da artacağı düşünülerek, çalışmada pirinç tanelerine ait renkli görüntüler üzerinde 90 adet renk özellik çıkarımları yapılmış ve en yüksek sınıflandırma doğruluğu olarak lojistik regresyon algoritması ile %99.25 başarı elde edilmiştir. Son olarak morfolojik, şekil ve renk özelliklerinin bir arada olduğu toplam 106 adet özellik çıkarımı yapılarak tüm algoritmalarda %99 üzerinde bir sınıflandırma başarısı elde edilmiştir. En yüksek sınıflandırma doğruluğu ise %99.91 ile çok katmanlı algılayıcı algoritmasına aittir. Sınıflandırma algoritmalarından elde edilen F1-skor değerlerinin yüksek olduğu görülmektedir. Bu durum kullanılan algoritmaların sınıflandırma başarısı açısından iyi bir performans gösterdiğinin kanıtı niteliğindedir. Ayrıca sınıflandırma algoritmalarına ait güvenirlilik ölçmede kullanılan kappa katsayı değerleri incelendiğinde çok iyi düzeyde uyum sağlandığı yorumuna ulaşılabilmektedir. Elde ettiğimiz sınıflandırma sonuçlarında görülüyor ki, çalışmada kullanılan özelliklerin niteliklerinin ve sayısının artması, sınıflandırma başarısına olumlu yönde katkı sağlamıştır. Kullanılan algoritmalara ait karmaşıklık matrisi ve performans ölçüm değerleri incelendiğinde, İpsala çeşidinin tüm özellik kümelerinde en yüksek performans değerlerine ulaştığı görülmektedir. Arborio çeşidinin ise diğer çeşitlere göre daha düşük doğruluk oranına sahip olduğu görülmektedir. Elde edilen sonuçlar, bu çalışmanın çeşitli pirinç çeşitlerini sınıflandırmak için başarıyla kullanılabileceğini göstermektedir.

8.2 Öneriler

Çalışmada kullanılan 106 özellik ile diğer pirinç çeşitleri üzerinde özellik çıkarımları gerçekleştirilebilir.

Elde edilen veriler kullanılarak pirinç çeşitlerini ayırt edebilmek için otomatik görüntü alan bir sistem tasarlanarak, boylama (kalibrasyon) veya çeşitler içerisinden istenmeyen maddelerin ayrıştırılması gibi işlemler gerçekleştirilebilen bir makine tasarlanabilir.

Çalışmada kullanılan özellikler içerisinde belirleyici olanlar tespit edilerek sınıflandırma işlemi o özellikler ile gerçekleştirilebilir.

Pirinç çeşit sayısı artırılarak pirinçlere ait özellikler için bir veri tabanı oluşturulabilir. Bu veri tabanı mobil bir uygulamaya adapte edilerek tarım alanında kullanıma sunulabilir ve pirinç çeşitlerinin belirlenmesi, fiziksel özellikleri vb. bilgilere anlık olarak ulaşılabilmesi sağlanabilir.

KAYNAKLAR

Abhang, P., Gawali, B. ve Mehrotra, S., 2016, Technical aspects of brain rhythms and speech parameters, *Introduction to EEG-and Speech-Based Emotion Recognition*, 51-79.

Abinov, A. G., 1989, İnsan ve Makine, In, Eds, *Moskova*: Znaniye, p. 48.

Abirami, S., Neelamegam, P. ve Thanjavur India, K. H., 2014, Analysis of rice granules using image processing and neural network pattern recognition tool.

Aggarwal, A. K. ve Mohan, R., 2010, Aspect ratio analysis using image processing for rice grain quality, *International journal of food engineering*, 6 (5).

Akbulut, S., 2016, Görüntü Analizi İle Granüler Zemin Özelliklerinin Belirlenmesi. 1. Ulusal Genç Geoteknik Mühendisleri Sempozyumu Erzurum.

Aktan, S., 2004, Sayısal görüntü analizinin (Digital İmage Analysis) hayvancılıkta kullanım olanakları ve metodolojisi. 4, *Ulusal Zootekni Bilim Kongresi, SDU Ziraat Fakultesi Zootekni Bolümü*, 160-165.

Akyürek, 2018, Ön temizleme ve eleme makinaları, https://akyurekltd.com/tr/Uc-Tekneli-Hassas-Temizleme-Eleme-Makinasi-141s.html: [Ziyaret Tarihi: 29 Ocak 2019].

Amor, N. B., Benferhat, S. ve Elouedi, Z., 2006, Qualitative classification with possibilistic decision trees, In: Modern Information Processing, Eds: Elsevier, p. 159-169.

Arefi, A., Motlagh, A. M. ve Teimourlou, R. F., 2011, Wheat class identification using computer vision system and artificial neural networks, *International Agrophysics*, 25 (4), 319-325.

Arora, R., 2012, Comparative analysis of classification algorithms on different datasets using WEKA, *International Journal of Computer Applications*, 54 (13).

Babalık, A., Baykan, Ö. K., İşcan, H., Babaoğlu, İ. ve Fındık, O., 2010, Effects of Feature Selection Using Binary Particle Swarm Optimization on Wheat Variety Classification, *International Conference on Advances in Information Technology*, 11-17.

Baykan, Ö., Babalık, A. ve Botsalı, F., 2005, Yapay sinir ağı kullanarak buğday türü tanınması. 4, *Uluslararası İleri Teknolojiler Sempozyumu, Konya, Eylül*, 28-30.

Berrar, D., 2018, Cross-validation, *Encyclopedia of Bioinformatics and Computational Biology*, 1, 542-545.

Beyaz, A., 2014, Görüntü İşleme Teknikleri Kullanılarak Zeytin Varyetelerinin Tanımlanması, Doktora Tezi, *Ankara Üniversitesi*, Ankara.

Cercone, N. ve McCalla, G., 1984, Artificial intelligence: Underlying assumptions and basic objectives, *Journal of the American Society for Information Science*, 35 (5), 280-290.

Chakure, A., 2019, Random Forest Regression, https://towardsdatascience.com/random-forest-and-its-implementation-71824ced454f: [Ziyaret Tarihi: 12 Eylül 2019].

Chaudhary, P., Chaudhari, A. K., Cheeran, A. ve Godara, S., 2012, Color transform based approach for disease spot detection on plant leaf, *International Journal of Computer Science Telecommunications*, 3 (6), 65-70.

Chen, S., Xiong, J., Guo, W., Bu, R., Zheng, Z., Chen, Y., Yang, Z. ve Lin, R. J. J. o. C. S., 2019, Colored rice quality inspection system using machine vision, 88, 87-95.

Chen, X., Xun, Y., Li, W. ve Zhang, J., 2010, Combining discriminant analysis and neural networks for corn variety identification, *Computers and electronics in agriculture*, 71, S48-S53.

Choudhary, R., Paliwal, J. ve Jayas, D., 2008, Classification of cereal grains using wavelet, morphological, colour, and textural features of non-touching kernel images, *Biosystems engineering*, 99 (3), 330-337.

Cinar, I. ve Koklu, M., 2019, Classification of Rice Varieties Using Artificial Intelligence Methods, *International Journal of Intelligent Systems and Applications in Engineering*, 7 (3), 188-194.

Copeland, B. J., 2018, Artificial intelligence, https://www.britannica.com/technology/artificial-intelligence: [Ziyaret tarihi: 23 Ocak 2019].

Cruyff, M. J., Böckenholt, U., Van Der Heijden, P. G. ve Frank, L. E., 2016, A review of regression procedures for randomized response data, including univariate and multivariate logistic regression, the proportional odds model and item response model, and self-protective responses, In: Handbook of Statistics, Eds: Elsevier, p. 287-315.

Çataloluk, H., 2012, Gerçek tıbbi veriler üzerinde veri madenciliği yöntemlerini kullanarak hastalık teşhisi, *Bilecik Üniversitesi, Fen Bilimleri Enstitüsü*.

Çetinkaya, A. ve Çetinkaya Saray, T., 2019, Görüntü işleme, Resim işleme, Image processing, https://www.academia.edu/10271834/G%C3%B6r%C3%BCnt%C3%BC_%C4%B0%C5%9Fleme_Resim_%C4%B0%C5%9Fleme_image_processing: [Ziyaret Tarihi: 28 Ocak 2019].

Çevik, R., 2019, Kömür Kalori Değerlerinin Renk Uzayı (R.G.B. ve H.S.V.) Ölçüm Değerleriyle İlişkilendirilmesi, Yüksek Lisans Tezi, *Zonguldak Bülent Ecevit Üniversitesi*, Zonguldak.

Demirbaş, H. Y. ve Dursun, İ., 2007, Buğday tanelerinin bazı fiziksel özelliklerinin görüntü işleme tekniğiyle belirlenmesi, *Tarım Bilimleri Dergisi*, 13 (3), 176-185.

Dubey, B., Bhagwat, S., Shouche, S. ve Sainis, J., 2006, Potential of artificial neural networks in varietal identification using morphometry of wheat grains, *Biosystems engineering*, 95 (1), 61-67.

Dunham, K., 2009, Chapter 6-Phishing, SMishing, and Vishing, *Mobile Malware Attacks and Defense*, 125-196.

Ebrahimi, E., Mollazade, K. ve Babaei, S., 2014, Toward an automatic wheat purity measuring device: A machine vision-based neural networks-assisted imperialist competitive algorithm approach, *Measurement*, 55, 196-205.

Ekinci, E., 2016, Kurubaklagil ve Tahıl Ürünlerinin Sağlık Üzerine Etkileri, https://www.slideshare.net/Ethmekinci/kurubaklagl-ve-tahil-rnlernn-salik-zerne-etkler: [Ziyaret tarihi: 28 Ocak 2019].

Erbay, F., 2011, A comparative evaluation of super–resolution methods on color images, Master Thesis, *Middle East Technical University*, Ankara.

Erkoç, M. F., 2008, Yapay Zeka Perspektifinde Eğitime Yönelik Uzman Sistem Modellemesi, Yüksek Lisans Tezi, *Marmara Üniversitesi*, İstanbul.

Farahani, L., 2012, Discrimination of some cultivars of durum wheat (Triticum durum Desf.) using image analysis, *International Research Journal of Applied and Basic Sciences*, 3 (7), 1375-1380.

García-Mateos, G., Hernández-Hernández, J., Escarabajal-Henarejos, D., Jaén-Terrones, S. ve Molina-Martínez, J., 2015, Study and comparison of color models for automatic image analysis in irrigation management applications, *Agricultural water management*, 151, 158-166.

Genesereth, M. R. ve Nilsson, N. J., 1987, Logical foundations of artificial, *Intelligence. Morgan Kaufmann*, 2.

Gonzalez, R. C. ve Woods, R. E., 2002, Processing, *Prentice-Hall*.

Guevara-Hernandez, F. ve Gil, J. G., 2011, A machine vision system for classification of wheat and barley grain kernels, *Spanish Journal of Agricultural Research* (3), 672-680.

Gunasekaran, S., Cooper, T., Berlage, A. ve Krishnan, P., 1987, Image processing for stress cracks in corn kernels, *Transactions of the ASAE*, 30 (1), 266-0273.

Gupta, P., 2017, Cross-Validation in Machine Learning, https://towardsdatascience.com/cross-validation-in-machine-learning-72924a69872f: [Ziyaret Tarihi: 10 Eylül 2019].

Han, Y., Feng, Y. ve Weller, C. L., 1996, Frequency domain image analysis for detecting stress cracks in corn kernels, *Applied Engineering in Agriculture*, 12 (4), 487-492.

Hossin, M. ve Sulaiman, M., 2015, A review on evaluation metrics for data classification evaluations, *International Journal of Data Mining & Knowledge Management Process*, 5 (2), 1.

Ibraheem, N. A., Hasan, M. M., Khan, R. Z. ve Mishra, P. K., 2012, Understanding color models: a review, *ARPN Journal of science technology*, 2 (3), 265-275.

IGC, 2019, https://www.igc.int/en/default.aspx: [Ziyaret tarihi: 27 Ocak 2019].

Ikegami, 2019, https://www.ikegami.com: [Ziyaret tarihi: 14 Mart 2019].

IUBÜ, 2012, Tarla Bitkilerinin Sınıflandırılması, Isparta Uygulamalı Bilimler Üniversitesi Tarla Bitkileri Bölümü, http://ziraat.isparta.edu.tr/assets/uploads/sites/138/files/tarla-bitkilerinin-siniflandirilmasi-17122012.pdf: [Ziyaret tarihi: 27 Ocak 2019].

Kalantar, B., Pradhan, B., Naghibi, S. A., Motevalli, A. ve Mansor, S., 2018, Assessment of the effects of training data selection on the landslide susceptibility mapping: a comparison between support vector machine (SVM), logistic regression (LR) and artificial neural networks (ANN), *Geomatics, Natural Hazards and Risk*, 9 (1), 49-69.

Kalaycı, T. E., 2018, Kimlik hırsızı web sitelerinin sınıflandırılması için makine öğrenmesi yöntemlerinin karşılaştırılması, *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 24 (5), 870-878.

Kaur, H. ve Singh, B., 2013, Classification and grading rice using multi-class SVM, *International Journal of Scientific and Research Publications*, 3 (4), 1-5.

Kaya, E., 2017, Dinamik Video Görüntülerinden Durum Buğday Tohumunun YSA Algoritması ile Sınıflandırılması, Yüksek Lisans Tezi, *Selçuk Üniversitesi*, Konya.

Kaynar, O., Görmez, Y., Yıldız, M. ve Albayrak, A., 2016, Makine öğrenmesi yöntemleri ile Duygu Analizi, *International Artificial Intelligence and Data Processing Symposium (IDAP'16), September*, 17-18.

Kılıç, S., 2015, Kappa test, *Journal of Mood Disorders*, 5 (3), 142.

Kiratiratanapruk, K. ve Sinthupinyo, W., 2011, Color and texture for corn seed classification by machine vision, *Intelligent Signal Processing and Communications Systems (ISPACS), 2011 International Symposium on*, 1-5.

Koschan, A. ve Abidi, M., 2008, Color spaces and color distances, In: Digital Color Image Processing, Eds: Wiley, p. 37-44.

Kumar, B. A., Jairam, R., Arkatkar, S. S. ve Vanajakshi, L., 2019, Real time bus travel time prediction using k-NN classifier, *Transportation Letters*, 11 (7), 362-372.

Landis, J. R. ve Koch, G. G., 1977, The measurement of observer agreement for categorical data, *Biometrics*, 159-174.

Luo, X., Jayas, D. ve Symons, S., 1999, Identification of damaged kernels in wheat using a colour machine vision system, *Journal of cereal science*, 30 (1), 49-59.

Mao, W. ve Wang, F., 2012, New advances in intelligence and security informatics, Academic Press, p. 91-102.

Mathworks, 2019a, Image processing techniques, https://ch.mathworks.com/?s_tid=gn_logo: [Ziyaret tarihi: 28 Ocak 2019].

Mathworks, 2019b, Support Vector Machines for Binary Classification, https://ch.mathworks.com/help/stats/support-vector-machines-for-binary-classification.html#bsr5b42: [Ziyaret Tarihi: 12 Eylül 2019].

Megep, 2010, Kuru Bakliyatları ve Tahıl Tanelerini Ayıklama. Ankara, MEB.

Megep, 2011, Gıda Teknolojisi-Kuru Bakliyatlar ve Tahıl Tanelerinde Kalibrasyon. Ankara, MEB.

Megep, 2016, Tarım-Serin İklim Tahılları. Ankara, MEB.

Mendoza, F., Dejmek, P. ve Aguilera, J. M., 2006, Calibrated color measurements of agricultural foods using image analysis, *Postharvest Biology Technology*, 41 (3), 285-295.

Miner, L., Bolding, P., Hilbe, J., Goldstein, M., Hill, T., Nisbet, R., Walton, N. ve Miner, G., 2014, Practical predictive analytics and decisioning systems for medicine: Informatics accuracy and cost-effectiveness for healthcare administration and delivery including medical research, Academic Press, p. 239-259.

Mutafçılar, Z. Ç., 2019, Türkiye'de tescilli çeltik çeşitlerinin moleküler karakterizasyonu, *Trakya Üniversitesi Fen Bilimleri Enstitüsü*.

Nabiyev, V. V., 2005, Yapay Zeka, 1, In, Eds, *Ankara*: Seçkin Yayıncılık, p. 33-35.

Nadkarni, P., 2016, Clinical Research Computing: A Practitioner's Handbook, Academic Press, p. 187-204.

Nenov, V. V., 1999, Pratik Psikoloji, In, Eds, *Moskova*: Vlados, p. 27.

Odakblog, 2018, LAB Renk Değerleri Nedir?, https://blog.odakkimya.com.tr/lab-renk-degerleri-nedir%F0%9F%94%8D/: [Ziyaret Tarihi: 20 Ekim 2019].

OuYang, A.-G., Gao, R.-j., Sun, X.-d., Pan, Y.-y. ve Dong, X.-l., 2010, An automatic method for identifying different variety of rice seeds using machine vision technology, *Natural Computation (ICNC), 2010 Sixth International Conference on*, 84-88.

Ozan, A., Güllü, A. ve Uçar, E., 2015, Classification of rice grains using image processing and machine learning techniques, *International Scientific Conference*.

Özkan, Y., 2008, Veri Madenciliği Yöntemleri, Papatya Yayıncılık ve Eğitim AŞ, *İstanbul, Türkiye*.

Pazoki, A., Farokhi, F. ve Pazoki, Z., 2014, Classification of rice grain varieties using two Artificial Neural Networks (MLP and Neuro-Fuzzy), *The Journal of Animal & Plant Sciences*, 24 (1), 336-343.

Perihanoğlu, G. M., 2015, Dijital Görüntü İşleme Teknikleri Kullanılarak Görüntülerden Detay Çıkarımı, Yüksek Lisans Tezi, *İstanbul Teknik Üniversitesi*, İstanbul.

Pourreza, A., Pourreza, H., Abbaspour-Fard, M.-H. ve Sadrnia, H., 2012, Identification of nine Iranian wheat seed varieties by textural analysis with image processing, *Computers and electronics in agriculture*, 83, 102-108.

Pratt, W. K., 2001, Digital image processing, John Wiley & Sons, Inc.

Richman, J. S., 2011, Multivariate neighborhood sample entropy: a method for data reduction and prediction of complex data, In: Methods in enzymology, Eds: Elsevier, p. 397-408.

Sá, A., Almeida, A., Rocha, B., Mota, M., Souza, J. ve Dentel, L., 2011, Lightning Forecast Using Data Mining Techniques on Hourly Evolution of the Convective Available Potential Energy, *Brazilian Congress on Computational Intelligence, Fortaleza, November*, 8-11.

Sabancı, K. ve Ünlerşen, M. F., 2016, Farklı Boyuttaki Elmaların KNN ve MLP Algoritmaları Kullanılarak Sınıflandırılması, *Proceedings Book*, 781.

Seasort, 2018, Rice, Wheat and Cereals, http://www.seasort.com/en/riso-grano-cereali.htm#top: [Ziyaret tarihi: 29 Ocak 2019].

Sethy, P. K. ve Chatterjee, A., 2018, Rice Variety Identification of Western Odisha Based on Geometrical and Texture Feature, *International Journal of Applied Engineering Research ISSN*, 0973-4562.

Silva, C. S. ve Sonnadara, U., 2013, Classification of rice grains using neural networks.

Singh, G. ve Panda, R. K., 2011, Daily sediment yield modeling with artificial neural network using 10-fold cross validation method: a small agricultural watershed, Kapgari, India, *International Journal of Earth Sciences and Engineering*, 4 (6), 443-450.

Sokolova, M. ve Lapalme, G., 2009, A systematic analysis of performance measures for classification tasks, *Information processing management*, 45 (4), 427-437.

Soylu, E., 2019, Veri Madenciliği, http://web.karabuk.edu.tr/emelkocak/indir/MTM326/veri_madenciliği.pdf: [Ziyaret Tarihi: 08 Eylül 2019].

Szczypiński, P. M. ve Zapotoczny, P., 2012, Computer vision algorithm for barley kernel identification, orientation estimation and surface structure assessment, *Computers and electronics in agriculture*, 87, 32-38.

Szczypiński, P. M., Klepaczko, A. ve Zapotoczny, P., 2015, Identifying barley varieties by computer vision, *Computers and electronics in agriculture*, 110, 1-8.

Şapaloğlu, A., 2015, Pirinç üretim-tüketim zincirinde pazarlama kanallarının yapısı ve pirinç pazarlama marjları: Edirne ili örneği, *Namık Kemal Üniversitesi*.

Tin, M. M., Mon, K. L., Win, E. P. ve Hlaing, S. S., 2018, Myanmar Rice Grain Classification Using Image Processing Techniques, *International Conference on Big Data Analysis and Deep Learning Applications*, 324-332.

TMO, 2019, 2018 Hububat Sektör Raporu, http://www.tmo.gov.tr/Upload/Document/hububatsektorraporu2018.pdf: [Ziyaret tarihi: 27 Nisan 2019].

Toptaş, B., 2017, Yangın/Alev Renk Özellikleri Kullanılarak Orman Yangınlarının Tespiti, Yüksek Lisans Tezi, *İnönü Üniversitesi*, Malatya.

Toptaş, M., 2018, Orman Yangınlarının Görüntü İşleme Yöntemleri ile Tespit Edilmesi ve Sınıflandırılması, Yüksek Lisans Tezi, *İnönü Üniversitesi*, Malatya.

TÜİK, 2019, Bitkisel Üretim İstatistikleri Veri Tabanı, http://www.tuik.gov.tr/PreTabloArama.do?metod=search&araType=vt: [Ziyaret tarihi: 27 Nisan 2019].

Ünal, B., 2009, Yapay Zeka Yardımı ile Redüktör Seçimi, Yüksek Lisans Tezi, *Gazi Üniversitesi*, Ankara.

Visen, N. S., Paliwal, J., Jayas, D. ve White, N., 2003, Image analysis of bulk grain samples using neural networks, *2003 ASAE Annual Meeting*, 1.

Wang, Q., 2017, Color-based Human Hand Segmentation Based on Smart Classification of Dynamic Environments.

Wikipedia, 2019, Logistic regression, https://en.wikipedia.org/wiki/Logistic_regression: [Ziyaret Tarihi: 11 Eylül 2019].

Wu, D. ve Sun, D.-W., 2013, Colour measurements by computer vision for food quality control–A review, *Trends in Food Science & Technology*, 29 (1), 5-20.

Xia, X., Fan, C., Lu, S.-J. ve Hou, L.-L., 2010, The analysis of wheat appearance quality based on digital image processing, *Environmental Science and Information Application Technology (ESIAT), 2010 International Conference on*, 231-234.

Yadav, B. ve Jindal, V., 2001, Monitoring milling quality of rice by image analysis, *Computers and electronics in agriculture*, 33 (1), 19-33.

Zapotoczny, P., Zielinska, M. ve Nita, Z., 2008, Application of image analysis for the varietal classification of barley:: Morphological features, *Journal of cereal science*, 48 (1), 104-110.

Zhixing, S., Hong, C., Jiangtao, L. ve Juan, F., 2008, Characteristic parameters to identify varieties of corn seedsby image processing, *Transactions of the Chinese Society of Agricultural Engineering*, 2008 (6).

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı	**:**	İlkay ÇINAR
Uyruğu	**:**	T.C.
Doğum Yeri ve Tarihi	**:**	KONYA-09.09.1987
Telefon	**:**	0 555 587 88 09
Faks	**:**	
e-mail	**:**	ilkay_cinar@hotmail.com

EĞİTİM

Derece		**Adı, İlçe, İl**	**Bitirme Yılı**
Lise	:	Adil Karaağaç Anadolu Teknik Lisesi, KONYA	2006
Lisans	:	Selçuk Üniversitesi, Teknik Eğitim Fakültesi, Bilgisayar Sistemleri Öğretmenliği, KONYA	2012
		Selçuk Üniversitesi, Teknoloji Fakültesi, Bilgisayar Mühendisliği Bölümü, KONYA	2018
Yüksek Lisans	:	Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Ana Bilim Dalı, KONYA	2019

İŞ DENEYİMLERİ

Yıl	**Kurum**	**Görevi**
2013-2014	Selçuk Üniversitesi	Bilgi İşlem Per.
2013-	Seçkon İş Güvenliği	İSG Uzmanı (B)

YABANCI DİLLER

İngilizce - YÖKDİL: 66,25 (Kasım-2019)

YAYINLAR

1. CINAR, I., OZKAN, I.A. and KOKLU, M.**,** (2018). *Fuzzy Logic Based Controller Design for Control of Ventilation Systems*, International Conference on Engineering Technologies (ICENTE'18), 26-28 October, 2018, ISBN: 978-605-68537-3-9, Konya, TURKEY.
2. CINAR, I., KOKLU, M. and OZKAN, I.A. (2018). Investigation of Occupational Health and Safety Awareness of Workers in Metal Industry (Konya Province Example). Sosyal Bilimler Dergisi, 8 (16), 349-364. DOI: 10.31834/kilissbd.457309
3. CINAR, I., and KOKLU, M. (2019). *Classification of Rice Varieties Using Artificial Intelligence Methods.* International Journal of Intelligent Systems and Applications in Engineering, 7(3), 188-194. **(Yüksek Lisans tezinden yapılmıştır.)**