KARAMANOĞLU MEHMETBEY ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

EKMEKLİK VE MAKARNALIK BUĞDAY TANELERİNİN YAPAY ZEKA TEKNİKLERİ KULLANILARAK SINIFLANDIRILMASI

YÜKSEK LİSANS TEZİ

Hakan ATÇEKEN

Elektrik-Elektronik Mühendisliği Anabilim Dalı

HAZİRAN 2020

KARAMANOĞLU MEHMETBEY ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

EKMEKLİK VE MAKARNALIK BUĞDAY TANELERİNİN YAPAY ZEKA TEKNİKLERİ KULLANILARAK SINIFLANDIRILMASI

YÜKSEK LİSANS TEZİ

Hakan ATÇEKEN
(190801079)

Elektrik Elektronik Mühendisliği Anabilim Dalı

Tez Danışmanı: Dr. Öğr. Üyesi Kadir SABANCI

HAZİRAN 2020

BİLİMSEL ETİĞEUYGUNLUK

Bu çalışmadaki tüm bilgilerin, akademik ve etik kurallara uygun bir şekilde elde edildiğini beyan ederim. Aynı zamanda bu kural ve davranışların gerektirdiği gibi, bu çalışmanın özünde olmayan tüm materyal ve sonuçları tam olarak aktardığımı ve referans gösterdiğimi belirtirim.

Hakan ATÇEKEN

ÖNSÖZ

Bitirme çalışmamın başından sonuna kadar emeği geçen ve beni bu konuya yönlendiren saygı değer hocam ve danışmanım Dr. Öğr. Üyesi Kadir SABANCI'ya, buğday numunelerinin temininde destek veren Karamanoğlu Mehmetbey Üniversitesi Biyomühendislik bölümünden Prof. Dr. Nevzat AYDIN, Arş. Gör. Mesut Ersin SÖNMEZ ve Bedrettin DEMİR'e, elektronik ve yazılım konusunda verdiği destekten dolayı Bilişim Teknolojileri Öğretmeni Fikret UYSAL'a, ayrıca yüksek lisans eğitim sürecimde beni maddi manevi destekleyen eşim Fadime ATÇEKEN'e tüm katkılarından ve hiç eksik etmedikleri desteklerinden dolayı teşekkür ederim.

(Karaman-2020) Hakan ATÇEKEN

İÇİNDEKİLER

Sayfa

ÖNSÖZ ... **iv**
İÇİNDEKİLER ... **v**
KISALTMALAR ... **vii**
ÇİZELGE LİSTESİ ... **viii**
ŞEKİL LİSTESİ ... **ix**
ÖZET ... **xi**
ABSTRACT ... **xii**
1. GİRİŞ ... **1**
2. KAYNAK ARAŞTIRMASI ... **5**
3. SAYISAL GÖRÜNTÜ ve GÖRÜNTÜ İŞLEME ... **9**
3.1 Görüntünün Tanımı ... 9
3.2 Görüntünün Sayısal Hale Getirilmesi ... 10
3.3 Renk Uzayları ... 10
3.4 Kameralar ... 14
3.4.1 CCD Kameralar ... 14
3.4.2 CMOS Kameralar ... 15
3.5 Görüntünün Oluşturulması ... 17
3.6 OpenCV Kütüphanesi ile Görüntü İşleme Teknikleri ... 19
3.6.1 Renk uzayı değiştirme ... 19
3.6.2 Gri-düzey skala ... 19
3.6.3 Görüntü eşik değeri ... 20
3.6.4 Sınırların tespiti ... 22
3.6.5 Nesnelerin şekil özelliklerinin belirlenmesi ... 23
3.6.6 Gri Seviye Eş Oluşum Matrisi (GLCM) ... 25
3.6.7 Yerel ikili örüntüler (LBP) ... 26
4. ÇALIŞMADA KULLANILAN YAZILIMLAR ... **28**
4.1 Python Programlama Dili ... 28
4.2 OpenCV Görüntü İşleme Kütüphanesi ... 28
4.3 WEKA Programı ... 29
5. SINIFLANDIRMADA KULLANILAN ALGORİTMALAR VE YÖNTEMLER ... **31**
5.1 Sınıflandırmada Kullanılan Yapay Zeka Teknikleri ... 31
5.1.1 Çok katmanlı algılayıcı algoritması ... 31
5.1.2 Destek vektör makineleri ... 32
5.1.1 K-En yakın komşu algoritması ... 34
5.2 Eğitim ve Test Verisi Seçiminde Kullanılan Teknikler ... 35
5.3 Karışıklık Matrisi (Confusion Matris) ... 37
6. MATERYAL VE METOT ... **41**
6.1 Buğdayların Seçilmesi ve Tanelerin Hazırlanması ... 41
6.2 Kamera ve Lens ... 42
6.3 Kullanılan Görüntü Alma Yazılımı ... 43
6.4 Çekim Platformunun Tasarımı ... 44
6.5 Buğday Görüntülerinin Elde edilmesi ... 48
6.6 Görüntü İşleme Yazılımı ve Kullanılan Kütüphaneler ... 50

6.7 Görüntü Ön İşleme Adımları 51
6.7.1 Buğday görüntülerin gri seviyeye dönüştürülmesi 52
6.7.2 Gri seviyeli buğday görüntülerinin ikili görüntüye dönüştürülmesi 53
6.7.3 Sınırların tespiti 54
6.7.4 Buğday tanelerinin görüntüde belirlenmesi 55
6.7.5 Histogram 56
6.8 Şekil Özelliklerinin Çıkarılması 56
6.9 Renk Özelliklerinin Çıkarılması 58
6.10 Doku Özelliklerinin Çıkarılması 60
6.11 Buğdaylara Ait Elde Edilen Veri Seti 61
6.12 WEKA Programı İle Buğday Veri Setinin Sınıflandırılması 62
6.12.1 Weka programında buğdayların sınıflandırılma aşamaları 63
6.12.2 MLP algoritması ile sınıflandırma 65
6.12.3 SVM algoritması ile sınıflandırma 66
6.12.4 kNN algoritması ile sınıflandırma 67
7. BULGULAR VE TARTIŞMA 68
7.1 Buğdayların Ekmeklik ya da Makarnalık Olarak Sınıflandırılması 69
7.1.1 Seçilen bir ekmeklik ve bir makarnalık buğdayın türüne göre sınıflandırılması 70
7.1.1.1 MLP algoritması ile yapılan sınıflandırma 70
7.1.1.2 SVM algoritması ile yapılan sınıflandırma sonuçları 71
7.1.1.3 kNN algoritmasına göre sınıflandırılması 73
7.1.1.4 Algoritma başarılarının karşılaştırılması 74
7.1.2 Tüm buğdayların ekmeklik ya da makarnalık durumuna göre sınıflandırılması 75
7.2 Buğdayların Çeşitlerine Göre Sınıflandırılması 76
7.2.1 Beş çeşit ekmeklik buğdayın kendi içinde sınıflandırılması 77
7.2.2 Beş çeşit makarnalık buğdayın kendi içinde sınıflandırılması 79
7.2.3 On farklı çeşitteki buğdayın sınıflandırılması 81
7.3 En başarılı özellikler istatistiği 83
8. SONUÇ VE ÖNERİLER 85
KAYNAKLAR 87
EKLER 93
ÖZGEÇMİŞ 96

KISALTMALAR

ADC	**:** Analog Dijital Çevirici (Analog Digital Converter)
AI	**:** Yapay Zeka (Artificial Intelligence)
AIT	**:** Yapay Zeka Teknikleri (Artificial Intelligence Techniques)
ANN	**:** Yapay Sinir Ağı (Artificial Neural Network)
CRT	**:** Katot Işın Tüpü (Cathode Ray Tube)
DP	**:** Doğru Pozitifler (True Possitive)
DPO	**:** Doğru Pozitiflerin Oranı (True Possitive Rate)
ES	**:** Elektromanyetik Spektrum
GLCM	**:** Gri Seviye Eş Oluşum Matrisi (Gray Level Co-occurrence Matrix)
HSI	**:** Renk Tonu, Doygunluk, Yoğunluk (Hue, Saturation, Intensity)
HSV	**:** Renk Tonu, Doygunluk, Değer (Hue, Saturation, Value)
kNN	**:** k En Yakın Komşu (k Nearest Neighborhood)
L*a*b*	**:** Parlaklık, Kırmızı/Yeşil, Sarı/Mavi (Lightness, Red/Green, Yellow/Blue)
LBP	**:** Yerel İkili Örüntü (Local Binary Pattern)
M-SVM	**:** Çok Çeşitli Destek Vektör Makineleri (Multi-class Support Vector Machines)
MCC	: Matthews Correlation Coefficient
MLP	**:** Çok Katmanlı Algılayıcı (Multilayer Perceptrons)
NIR	**:** Yakın Kızılötesi (Near Infrared)
NTSC	**:** Ulusal Televizyon Sistem Komitesi (National Television System Committee)
PAL	**:** Faz Alternatif Hatları (Phase Alternative Lines)
RGB	**:** Kırmızı, Yeşil, Mavi (Red, Green, Blue)
SIFT	**:** Scale-Invariant Feature Transform (Ölçek Değişmeyen Özellik Dönüşümü)
SVM	**:** Destek Vektör Makineleri (Support Vector Machine)
YCbCr	**:** Parlaklık, Mavi Fark Kroma, Kırmızı Fark Kroma (Luminance, Blue Difference Chroma, Red Difference Chroma)
YP	**:** Yanlış Pozitifler (False Possitive)
YPO	**:** Yanlış Pozitiflerin Oranı (False Possitive Rate)
YUV	**:** Parlaklık, Renklilik, Renklilik (Luminance, Chromaticity, Chromaticity)

ÇİZELGE LİSTESİ

Sayfa

Çizelge 1.1 : Çalışmada kullanılan buğdaylar çeşitleri ve miktarları 2
Çizelge 3.1 : CCD ve CMOS sensörlerin karşılaştırılması..... 17
Çizelge 3.2 : GLCM matrisinde bulunan istatistikler ve açıklaması. 26
Çizelge 5.1 : İkili sınıflandırma için hazırlanmış karışıklık matrisi. 37
Çizelge 5.2 : Çok sınıflı sınıflandırma için hazırlanmış karışıklık matrisi. 38
Çizelge 6.1 : Çalışmada kullanılan buğday çeşitleri ve türleri. 42
Çizelge 6.2 : Basler acA2500-14uc kamerasına ait teknik özellikleri. 43
Çizelge 6.3 : Buğdaylardan çıkarılan özellikler tablosu. 61
Çizelge 6.4 : Çıkarılan özelliklerin istatistiksel değerleri. 62
Çizelge 7.1 : Çalışmada kullanılan buğday çeşitleri ve tür özellikleri. 68
Çizelge 7.2 : Elde edilen buğday özellikleri. 69
Çizelge 7.3 : MLP algoritmasında farklı nöronlarda sınıflandırma başarısı. 71
Çizelge 7.4 : MLP algoritması karışıklık matrisi..... 71
Çizelge 7.5 : SVM (Poly Kernel) ile yapılan sınıflandırma sonuçları. 72
Çizelge 7.6 : SVM (Poly Kernel) algoritması karışıklık matrisi. 72
Çizelge 7.7 : SVM (PUK) ile yapılan sınıflandırma sonuçları. 73
Çizelge 7.8 : SVM (PUK) algoritması karışıklık matrisi. 73
Çizelge 7.9 : kNN algoritması farklı K değerleri ile sınıflandırma başarısı. 74
Çizelge 7.10 : kNN algoritması karışıklık matrisi. 74
Çizelge 7.11 : MLP, SVM ve kNN algoritmalarının kıyaslanması. 74
Çizelge 7.12 : Algoritmalar için en başarılı parametre değerleri..... 75
Çizelge 7.13 : Türe göre yapılan sınıflandırma başarı durumu. 75
Çizelge 7.14 : SVM algoritması karışıklık matrisi. 76
Çizelge 7.15 : Sınıflandırmada kullanılan algoritmalara ait parametre değerleri..... 76
Çizelge 7.16 : Beş çeşit ekmeklik buğdayın sınıflandırma sonuçları. 78
Çizelge 7.17 : Beş çeşit ekmeklik buğdayın SVM algoritması karşıklık matrisi. 79
Çizelge 7.18 : Sınıflandırmada kullanılan algoritmalara ait parametre değerleri..... 79
Çizelge 7.19 : Beş çeşit makarnalık buğdayın sınıflandırma sonuçları. 80
Çizelge 7.20 : SVM algoritması ile elde edilen karışıklık matrisi. 81
Çizelge 7.21 : Sınıflandırmada kullanılan algoritmalara ait parametre değerleri..... 81
Çizelge 7.22 : 10 farklı çeşit buğdayın sınıflandırma sonuçları. 82
Çizelge 7.23 : 10 farklı çeşitteki buğdayın SVM algoritması karışıklık matrisi. 82
Çizelge 7.24 : Sınıflandırmada kullanılan algoritmalara ait parametre değerleri..... 83
Çizelge 7.25 : Seçilen en iyi özellikler tablosu..... 84
Çizelge 7.26 : En başarılı özelliklerle tüm özellikler arasında başarı kıyaslaması.... 84

ŞEKİL LİSTESİ

Sayfa

Şekil 1.1 : Alınan buğday numuneleri. 3
Şekil 3.1 : Sayısal görüntü temsili ve eksenleri. 9
Şekil 3.2 : Örnekleme ve kuantalama (Erikçi, 2018). 10
Şekil 3.3 : Renk uzayları ağacı. 11
Şekil 3.4 : RGB renk uzayı gösterimi. 12
Şekil 3.5 : Işık şiddetine göre histogram grafiği (Sidra, 2020). 12
Şekil 3.6 : HSV renk uzayı modeli. 13
Şekil 3.7 : CMYK renk uzayı modeli. 13
Şekil 3.8 : YUV renk uzayı modeli. 14
Şekil 3.9 : CCD kamera sensörü (Anonim, 2019b). 15
Şekil 3.10 : CMOS sensörün yapısı (Anonim, 2019b). 16
Şekil 3.11 : Sayısal görüntünün oluşma süreci. 18
Şekil 3.12 : On altı bitlik gri-seviye skala ifadesi. 20
Şekil 3.13 : Örnek bir eşikleme çalışması (Anonim, 2019c). 21
Şekil 3.14 : Threshold metodu parametlerinin görsel gösterimi. 22
Şekil 3.15 : HuMoment komutunun farklı görüntülerdeki ürettiği sonuçlar. 24
Şekil 3.16 : GLCM doku özelliklerinin matris formunda gösterimi. 25
Şekil 3.17 : LBP Algoritması. 27
Şekil 3.18 : Örnek sayısı ve r yarıçaplı daire çeşitleri. 27
Şekil 4.1 : Weka programı standart ara yüzü. 30
Şekil 5.1 : MLP Algoritmasının yapısı 32
Şekil 5.2 : Temsili bir destek vektör çizgisi (Carrasco, 2019). 33
Şekil 5.3 : İki boyutlu ve üç boyutlu hale görselleştirilmiş veri seti. 34
Şekil 5.4 : Örnek bir komşuluk ilişki modeli. 35
Şekil 5.5 : Çapraz doğrulamada veri setinin belirlenme modeli. 36
Şekil 6.1 : Çalışmaya ait blok diyagram. 41
Şekil 6.2 : Elenmiş ve çeşitlerine göre ve paketlenmiş buğdaylar. 42
Şekil 6.3 : Basler acA2500-14uc kamera önden ve arkadan görünüşü. 43
Şekil 6.4 : Basler C125-0618-5M model F1.8 f6mm lens. 43
Şekil 6.5 : Pylon kamera ara yüz programı ekran görüntüsü. 44
Şekil 6.6 : Buğday tanelerinin fotoğraflandığı çekim düzeneği. 45
Şekil 6.7 : Aydınlatma için kullanılan led lambalar. 45
Şekil 6.8 : Çekim yapılan nesneler üzerine kapatılan çukur ayna. 46
Şekil 6.9 : Çekim ortamı aydınlatma düzeneği. 47
Şekil 6.10 : Işık şiddetini ayarlayan dimmer devresi. 48
Şekil 6.11 : Dimmer devresi öncesi ve sonrası buğday görüntüleri. 48
Şekil 6.12 : Görüntülerin dijital ortama aktarılması. 49
Şekil 6.13 : Karın üstü ve sırt üstü dizilmiş buğday taneleri. 49
Şekil 6.14 : Buğday görüntü alma düzeneği. 50
Şekil 6.15 : Python dili ile yazılan programdan bir görüntü. 51
Şekil 6.16 : Buğday görüntülerinin işleme aşamaları. 52
Şekil 6.17 : Buğdaylara ait gri seviye görüntü. 53
Şekil 6.18 : Buğdaylara ait ikili (siyah-beyaz) görüntü. 53
Şekil 6.19 : Buğdaylara ait filtrelenmiş görüntü 54
Şekil 6.20 : Buğday sınırlarının orijinal görüntü üzerinde gösterimi. 55

Şekil 6.21 : Buğdayların dışına çizilen dikdörtgenler. 55
Şekil 6.22 : Buğdayın en ve boyunu ölçmek için kullanılan dikdörtgen. 56
Şekil 6.23 : İki farklı buğday tanesine ait histogram grafiği. 56
Şekil 6.24 : Buğdayın en ve boyunun hesaplanması. 57
Şekil 6.25 : Buğdaylardan alınan köşegen uzunluğu. 57
Şekil 6.26 : Buğday tanelerinin dolgunluk hesaplanması. 57
Şekil 6.27 : Merkezleri işaretlenmiş buğday taneleri. 59
Şekil 6.28 : Merkez rengi olarak örnek alınan noktalar 59
Şekil 6.29 : Buğday üzerinden ortalama renk örneği alınan bölge. 60
Şekil 6.30 : Doku özelliklerini almak için kırpılmış bir buğday tanesi. 60
Şekil 6.31 : Weka programı veri seti dosyası yapısı. 63
Şekil 6.32 : Weka programında özelliklerin çeşit bazında görsel gösterimi. 64
Şekil 6.33 : Weka programında özelliklerin tür bazında görsel gösterimi. 64
Şekil 6.34 : Bir özelliğin koordinat düzlemi üzerindeki görünümü. 65
Şekil 6.35 : Tek gizli katmanlı MLP modeli. 65
Şekil 6.36 : Weka programında MLP sınıflandırma fonksiyonunun seçimi. 66
Şekil 6.37 : Weka sonuç çıktısı ekranı. 66
Şekil 6.38 : Weka programında SMO sınıflandırma fonksiyonunun seçimi. 66
Şekil 6.39 : Çekirdek fonksiyonun seçim ekranı. 67
Şekil 6.40 : kNN Sınıflandırma fonksiyonunun seçimi. 67
Şekil 7.1 : Türlerine göre sınıflandırma işlemine ait blok diyagram. 70
Şekil 7.2 : Buğdayların çeşitlerine göre sınıflandırılmasına ait blok diyagram. 77
Şekil 7.3 : Beş çeşit ekmeklik buğdayın sınıflandırılmasına ait blok diyagram. 77
Şekil 7.4 : Beş çeşit makarnalık buğdayın sınıflandırılmasına ait blok diyagram. 80

ÖZET

Yüksek Lisans Tezi

EKMEKLİK VE MAKARNALIK BUĞDAY TANELERİNİN YAPAY ZEKA TEKNİKLERİ KULLANILARAK SINIFLANDIRILMASI

Hakan ATÇEKEN

Karamanoğlu Mehmetbey Üniversitesi
Fen Bilimleri Enstitüsü
Elektrik Elektronik Mühendisliği Ana Bilim Dalı

Danışman: Dr. Öğr. Üyesi Kadir SABANCI

Haziran, 2020, 110 Sayfa

İnsanoğlunun hayatta kalması için en önemli besin kaynaklarından biri buğdaydır. Buğdaydan günümüzde ekmek, makarna, bulgur, pasta gibi en çok tüketilen besinler üretilmektedir. Bu süreçte buğdayın kalitesini iyi bir sınıflandırma süreci belirler. Makine görmesi kavramının insan hayatına girmesiyle birlikte sabit ve hareketli görüntülerin sayısallaştırılarak anlamlı sonuçlar elde edilmesi mümkün hale gelmiştir. Elde edilen sayısal veriler gelişmekte olan yapay zeka algoritmaları ile desteklendiğinde insanların gözle yapamadıkları işlemleri kolaylıkla yapabilen makineler gelişmeye başlamıştır. Bu çalışmada beşi ekmeklik (Cumhuriyet-75, Nevzatbey, Alpu 2001, Bayraktar 2000, Esperya) ve beşi makarnalık (Eminbey, Cesare, Çeşit-1252, Kunduru-1149, Kızıltan-91) toplam 10 farklı buğday çeşidinden 2014 adet buğday tanesi kullanılmıştır. Buğdaylara ait görüntüler Basler acA2500-14uc kamera ve Basler C125-0618-5M lens ile hazırlanan bir düzenek yardımıyla elde edilmiştir. Görüntüler Python programlama dili ve OpenCV kütüphanesi ile yazılan bir programla bilgisayar ortamında işlenerek her bir buğday tanesine ait şekil, renk ve doku olmak üzere 21 farklı özellik çıkarılmıştır. Bu özelliklerden elde edilen veri seti WEKA programı ile MLP, SVM ve kNN algoritmaları kullanılarak sınıflandırılmıştır. Rastgele seçilen bir ekmeklik ve bir makarnalık buğday, türüne göre yapılan sınıflandırmada %99,7468, 10 farklı çeşit buğday ekmeklik ya da makarnalık olma durumuna göre yapılan sınıflandırmada %96,1271 başarı elde edilmiştir. Makarnalık beş çeşit buğday kendi aralarında çeşitlerine göre yapılan sınıflandırma işleminde %95,3954, ekmeklik beş çeşit buğday kendi aralarında çeşitlerine göre sınıflandırılma işleminde %93,3729 başarı elde edilmiştir. Son olarak 10 farklı çeşit buğday kullanılarak çeşitlerine göre yapılan sınıflandırmada %91,3605 başarı elde edilmiştir. Tüm sınıflandırma işlemlerinde en yüksek doğruluk SVM algoritması ile elde edilmiştir.

Anahtar Kelimeler: Buğday sınıflandırma, görüntü işleme, yapay zeka, Python, OpenCV, buğday çeşitleri

ABSTRACT

MsThesis

CLASSIFICATION OF BREAD AND DURUM WHEAT KERNELS USING ARTIFICIAL INTELLIGENCE TECHNIQUES

Hakan ATÇEKEN

Karamanoğlu Mehmetbey University
Graduate School of Natural andAppliedSciences
Department of Electrical Electronics Engineering

Supervisor: Assistant professor Kadir SABANCI

June, 2020, 110 Pages

One of the most important food sources for human survival is wheat. Today, the most consumed foods such as bread, pasta, cracked wheat, and cake are produced and presented to the consumers. In this process, a good classification process determines the quality of wheat. With the concept of machine vision entering human life, it has become possible to obtain meaningful results by digitizing fixed and moving images. When the obtained numerical data is supported by developing machine learning algorithms, machines that can easily perform operations that people cannot do with the eyes have begun to develop. In this study, a total of 10 different wheat types were used, five of which were bread wheat (Cumhuriyet-75, Nevzatbey, Alpu 2001, Bayraktar 2000, Esperya) and five of durum wheat (Eminbey, Cesare, Çeşit-1252, Kunduru-1149, Kızıltan-91). The images were taken with Basler acA2500-14uc camera and Basler C125-0618-5M lenses from the wheat, the images were processed in a computer environment with a program written in Python and OpenCV. 21 different features were obtained for each wheat grain, then classified using MLP, SVM, and kNN algorithms with the WEKA program. A randomly selected bread and durum wheat were classified according to the type and success of 99.7468% were achieved. 10 different wheat varieties were classified according to their types and 96.1271% success was achieved. Five different types of durum wheat were classified according to their varieties and 95.3954% success was achieved and five different types of bread wheat were classified according to varieties and 93.3729% of success was achieved. Finally, 10 different kinds of wheat were classified according to their varieties and 91.3605% success was achieved. The best success in all classification studies has been achieved by using the SVM algorithm.

Keywords: Wheat Classification, image processing , artifical intelligence, Python, OpenCV, wheat varieties

1. GİRİŞ

İnsan beslenmesinde temel besin hiç şüphesiz buğdaydır. Dünya üzerinde buğdayın ekim alanları ve üretim kapasitesi, nüfus artışına paralel olarak artış göstermektedir. Ekmek, pasta, makarna gibi son ürünlerin kalitesi, büyük ölçüde bu ürünlerin yapımında kullanılan un, dolayısıyla da kullanılan buğdayın kalitesiyle doğru orantılıdır (Williams ve diğerleri, 1986). Buğday kalitesini belirleyen ana faktörlerden en önemlisi içerdiği protein miktarıdır. Makarnalık buğdaylar (Triticum durum) genel olarak camsı yapıda, taneleri sert ve protein miktarı fazladır (Güleç ve diğerleri, 2010). Ekmeklik buğdayların protein oranı makarnalık durum buğdayına göre düşük olup, nişasta oranı yüksek ve daha yumuşak yapıdadır. Makarna üretiminde kullanılan buğdayların ekmeklik buğdaylardan arındırılmış olması çok önemlidir. Makarnalık buğdaya karışan diğer çeşitlerden buğday taneleri protein oranını düşürmektedir. Aynı durum farklı türlerdeki buğday taneleri için de geçerlidir. Bu durumda buğdayların doğru olarak sınıflandırılmasının önemi artmaktadır (Yüksel ve diğerleri, 2011).

Tarımsal alanda her ne kadar makineleşme yaygınlaşsa da birçok işlem günümüzde insan gücü ile yapılmaktadır. Üretimin başından sonuna kadar insan faktörü birçok kez sürece müdahildir. Ürün kalitesinin belirlenmesi aşamasında yapılan sınıflandırma işlemlerinde, sınıflandırma kriterlerinin insanlar tarafından farklı uygulanması kalitenin ve fiyatlandırmanın yapılmasında farklı sonuçlar doğurmaktadır. Ürünlerde doğru sınıflandırma yapmak ürün kalitesi ve maliyet hesabı açısından çok önemlidir. Buğday kalitesi farklı kültürlerde buğday zincirinin farklı paydaşları tarafından tanımlanacak çok geniş bir konudur. Bazı çiftçiler için kalite yüksek fiyat almak için gereken bir durum iken, ekmek, makarna ve pasta üreticileri için en önemli temel unsurlar arasında yer alabilmektedir. Avustralya veya Kanada gibi ülkelerde hangi proteini içerdiğine bağlı daha karmaşık kalite derecelendirme sistemleri vardır (Blakeney ve diğerleri, 2009). Diğer ülkelerde orta düzey çiftçiler, ailelerini beslemek

için buğday üretmekte ve bu durumda buğday miktarı ve kalite göz ardı edilebilmektedir.

Türkiye buğday üretimi açısından çok geniş alanlara sahip bir ülkedir. Üretim ve buğday ihracatının hem buğday ve un hem de işlenmiş buğday ürünleri bakımından yüksek olması bu alanda birçok bilimsel çalışmayı da beraberinde getirmiştir. Günümüzde hububat kalitesinin belirlenmesi ve hububat sınıflandırmada, bilgi teknolojilerine dayalı kalite belirleme sistemleri geliştirilmeye devam etmektedir (Babalık, 2007). İnsanların kendi fiziksel yöntemleriyle yaptıkları seçim sistemlerine alternatif olarak geliştirilen dijital sistemler, genel anlamda buğday başakları ya da danelere ait sayısal görüntülerin dijital ortamda görüntü işleme ve makine görmesi teknolojisi kullanarak ürün öznel bilgilerinin elde edilmesi ve bu bilgilerin sınıflandırmada ve seçmede kullanılması prensibini benimsemektedir.

Bu tez çalışmasında Cumhuriyet-75, Nevzatbey, Bayraktar 2000, Esperya, Alpu 2001 çeşitlerinden beş adet ekmeklik ve Eminbey, Cesare, Çesit-1252, Kunduru-1149, Kızıltan-91 çeşitlerinden beş adet makarnalık olmak üzere toplam 10 farklı buğday çeşidi kullanılmıştır (Çizelge 1.1). Çalışma boyunca buğdayların literatür isimleri çeşit ifadesiyle, ekmeklik ya da makarnalık olma durumları tür olarak ifade edilmiştir.

Çizelge 1.1 : Çalışmada kullanılan buğdaylar çeşitleri ve miktarları

ÇEŞİT NO	BUĞDAY ADI	TÜR	ADET
1	Eminbey	Makarnalık	176
2	Cumhuriyet-75	Ekmeklik	210
3	Nevzatbey	Ekmeklik	194
4	Alpu 2001	Ekmeklik	209
5	Cesare	Makarnalık	216
6	Çesit-1252	Makarnalık	202
7	Bayraktar 2000	Ekmeklik	203
8	Kunduru-1149	Makarnalık	200
9	Kızıltan-91	Makarnalık	208
10	Esperya	Ekmeklik	196

10 farklı çeşitteki buğdayların görüntüleri hazırlanan bir düzenek yardımıyla yüksek çözünürlükte fotoğraflanmıştır. Elde edilen görüntüleri Python programlama dili ve OpenCV kütüphanesi kullanılarak işleyen bir yazılım hazırlanmış ve buğdayların özellikleri bir veri setinde toplanmıştır. Her bir buğday tanesinden şekil, renk ve doku

özelliklerden oluşan 21 farklı özellik çıkarılmıştır. Bu veri seti üzerinden yapay zeka algoritmalarından SVM, MLP ve kNN kullanılarak buğdaylar sınıflandırılmıştır.

Geliştirilen bu yazılımsal model ve veri işleme yaklaşımları ile endüstriyel anlamda buğday sınıflandırma işlemleri adına önemli bir referans çalışma niteliğinde olacaktır. Şekil 1.1'de tez çalışmasında kullanılan buğday numuneleri görülmektedir. Bu türler Karaman ve Konya bölgesinde en çok ekilen çeşitlerdendir.



Şekil 1.1 : Alınan buğday numuneleri.

Bu yüksek lisans tez çalışması giriş, kaynak araştırması, dijital görüntü kavramları ve görüntü işleme, çalışmada kullanılan yazılımlar, sınıflandırmada kullanılan algoritmalar ve yöntemler, materyal ve metot, bulgular ve tartışma, sonuç ve öneriler bölümleri olmak üzere sekiz bölüm, kaynaklar ve eklerden oluşmaktadır.

- Kaynak araştırması bölümünde buğday ve tohumların sınıflandırılması üzerine yapılmış çalışmalar incelenmiş ve literatür özeti verilmiştir.
- Dijital görüntü kavramları ve görüntü işleme kısmında görüntü oluşumu, dijital görüntü, makine görmesi gibi kavramlar üzerinde durulmuşutur. Dijital görüntü işleme süreçlerinde kullanılan yöntem ve teknikler detaylı anlatılmıştır.
- Çalışmada kullanılan yazılımlar bölümünde Python programlama dili, Weka programı ve görüntü işleme sürecinde kullanılan OpenCV kütüphanesi detaylı anlatılmıştır.

- Sınıflandırmada kullanılan makina öğrenmesi algoritmaları ve yöntemler bölümünde sınıflandırmada yapay zeka algoritmalarından en çok kullanılan Çok Katmanlı Algılayıcılar (MLP), Destek Vektör Makineleri (SVM) ve k – En Yakın Komşuluk (kNN) algoritmaları detaylı anlatılmıştır.
- Materyal ve metot kısmında buğday çeşitlerinin seçilmesi, buğday tanelerinin görüntülerinin alınması ve bu işlemler için hazırlanan düzenek, buğday sınıflandırmada kullanılan yazılımların kullanılması ve buğday tanelerinin sınıflandırılmasına kadar olan tüm süreç donanım hem de yazılımsal olarak anlatılmıştır.
- Bulgular ve tartışma bölümünde sınıflandırma çalışmasından elde edilen sayısal veriler paylaşılmış, bu en başarılı algoritmalar birbiri ile kıyaslanmıştır. Başarı ve başarısızlık nedenleri yorumlanmıştır.
- Sonuç ve öneriler kısmında çalışmadan elde edilen tüm sonuçlar özetlenmiş ve bundan sonra çalışma yapacak bilim insanlarına tavsiyeler sunulmuştur.

Eklerin olduğu bölümde ise çalışmada kullanılan buğday görüntüleri verilmiştir.

2. KAYNAK ARAŞTIRMASI

Yapay zeka algoritmaları ve görüntü işleme teknikleri kullanarak birçok gıdanın kalite incelemesi ve tür sınıflandırılması amacıyla birçok araştırmacı tarafından çalışmalar yapmıştır.

Berman ve diğerleri (2007) yaptıkları çalışmada, yakın kızılötesi hiperspektral (NIR) görüntü analizi yöntemi ile Avusturalya bölgesine ait buğday danelerinin sınıflandırmasını yaparak %95 oranında başarı elde etmişlerdir.

Pazoki ve diğerleri (2007) çalışmalarında, pirinç danelerinin sınıflandırılmasında yapay zeka tekniklerinden bulanık mantık ve yapay sinir ağlarına dayalı dijital sinir algoritmaları kullanmışlardır. Pirinç danelerinin morfolojik ve şekil özelliklerini ağlara giriş olarak uygulayıp beş çeşit pirinç sınıflandırması yapmışlardır.

Babalık ve diğerleri (2010) çalışmalarında, görüntü işleme teknikleri kullanarak durum buğdayının camsı özellikte olup olmadığını belirlenmesi konulu çalışmalarında buğdayların camsı ve camsı olmayan türlerini sınıflandırmışlardır.

Guevara ve diğerleri (2011) çalışmalarında, buğday ve arpa tohumlarının sınıflandırılmasında ayırımcı analiz ve kNN algoritmalarını kullanmışlar ve başarılı sonuçlar almışlardır.

Arefi ve diğerleri (2011) çalışmalarında, İran'ın Batı ve Kuzeybatısındaki çiftliklerde yaygın olarak bulunan dört büyük yabani ot tohumunun (common vetch, cleavers, cornflower ve great bur-parsley) kimlik tespiti dijital görüntü analizi ile gerçekleştirilmiştir. Tohumların renk (RGB ve HSV) ve morfoloji (Shape factor 1 ve Shape factor 2) gibi özelliklerinden faydalanılarak tanımlanması gerçekleştirilmiştir. Sonuçlara göre, toplam sınıflandırma doğruluğu %98,40 olarak hesaplanmıştır.

Zapotoczny (2013) yaptığı çalışmada, 20 değişik fiziksel özelliğe sahip buğday çeşidini adım adım ilerleyen analiz ve meta çoklu sınıflandırma yöntemlerini kullanarak sınıflandırmışlar ve %90 doğrulukta sonuca ulaşmışlardı.

Punn ve Bhalla (2013) tarafından yapılan çalışmada, SVM ve ANN olmak üzere iki makine öğrenme algoritması kullanarak buğday sınıflandırması yapılmıştır. Sınıflandırma için, buğday tanelerinin görüntüleri dijital kamera kullanılarak yakalanıp eşik işlemi gerçekleştirilmiştir. Bu aşamadan sonra, bu görüntülerden buğdayın alan, çevre, hacim vb. fiziksel özellikleri çıkarılmış ve makine öğrenme algoritmaları uygulanmıştır. Çalışma sonucunda SVM'nin doğruluğu %86,8, Sinir ağı ise %94,5 olarak hesaplanmıştır.

Maged Wafy ve diğerleri (2013) yaptıkları çalışmada, tohum türlerinin otomatik olarak bilgisayar tarafından tanınmasına yönelik bir çalışma gerçekleştirilmiştir. Bu çalışmada, buğday tohum örnekleri ile karıştırılan üç tür ot tohumunu tanımlamak için SIFT (Scale-Invariant Feature Transform) algoritması kullanılmıştır. Yabani ot tohumluklarının tespitinde doğruluk oranları sırasıyla%90,5, %89,2 ve %95,3 olarak elde edilmiştir.

Masoumi (2013)'nin yüksek lisans tezinde, Cumhuriyet-75 ekmeklik buğday çeşidinin bazı kalite kriterleri; kırık tane, yabancı ot (yabani hardal ve yabani yulaf), ve diğer hububat (mısır ve arpa), “MATLAB” programı yardımıyla makine görmesi ve ANN teknikleri kullanılarak belirlenmiştir. Buğday örneklerinin kalitesinin belirlenmesinde değerlendirme kriteri olarak tahıl morfolojisi, doku ve rengi dikkate alınmıştır. Doku özellikleri için, kontrast, homojenlik, korelasyon, enerji ve entropi hesaplanmıştır. Renk özellikleri için, görüntülerin ortalaması, varyans, standart sapma, çarpıklık ve basıklık değerleri RGB (Kırmızı, Yeşil, Mavi), NTSC ve l*a*b* renk uzaylarında çıkarılmıştır. Tezin soncunda, buğday kalitesinin belirlenmesinde genel başarı oranı %97 olarak elde edilmiştir.

Khoshroo ve diğerleri (2014) yaptıkları çalışmada, dört İran buğday çeşidinin sınıflandırılması, morfolojik özellikler ve yapay sinir ağları kullanılarak gerçekleştirilmiştir. Her bir tahıl görüntüsünden, görüntü işleme yöntemleri kullanılarak on morfolojik özellik çıkarılmıştır. Buğday çeşitlerinin sınıflandırılması

için, görüntülerden elde edilen dokuz önemli morfolojik özellik ANN için girdi olarak kullanılmıştır. En iyi ANN değerini sağlayan değerler kullanılarak buğday çeşitlerinin sınıflandırılması sonucu %85,72'lik genel sınıflandırma doğruluğunun elde edildiği ifade edilmiştir.

Taner ve diğerleri (2015) yaptıkları çalışmada, durum buğdayı çeşitlerinin sınıflandırmak için bir Yapay Sinir Ağı (ANN) geliştirilmiştir. Giriş parametresi olarak bin adet buğday danesi ağırlığı, geometrik çap, küresel form, buğday tanesinin yüzey alanı, hacmi, hacim ağırlığı, özgül ağırlık, renk ve porozite, çıkış parametresi olarak buğday çeşitleri kullanılmıştır. M-l modeli için R2 değeri %99,99, RMSE değeri 0,00074 ve ortalama nispi hata değeri %0,009 olarak bulunmuştur. M-l modeli ile elde edilen dijital sonuçların gerçek buğday verileri ile uyumlu olduğu görülmüştür.

Abdullah ve Quteishat (2015) yaptıkları çalışmada, önerilen sistem üç farklı buğday tohumunu ilgili sınıflara sınıflamayı amaçlamaktadır. Önerilen sistem sınıflandırma işlemi için Çok Katmanlı Yapay Sinir Ağları'nı kullanmıştır. ANN sistemine giriş olarak verilen özellikler, görüntü işleme sonucu elde edilen alan, minör eksen uzunluğu, ana eksen uzunluğu, eşdeğer çap, çevre ve entropidir. Deneysel sonuçlar, önerilen sınıflandırma sisteminin buğday tohumlarını yaklaşık %95'lik bir test doğruluğuyla sınıflandırmayı başarabildiğini göstermektedir.

Yaşar ve diğerleri (2016) yaptıkları çalışmada, buğday tohumlarının türleri yapay sinir ağı (ANN) yaklaşımıyla sınıflandırılmıştır. ANN sisteminde 7 giriş, 10 nöronlu bir gizli katman ve bir çıktı kullanılmıştır. X-ışını tekniği ile elde edilen geometrik özelliklerinin ölçülmesi ile karakterize edilen Kama, Rosa ve Canadian buğday çeşitleri analiz edilmiştir. Elde edilen özellikler alan, çevre, çekirdek uzunluğu, asimetri katsayısı, kompaktlık özellikleridir. ANN sonucu 210 adet verinin regresyon işleminde, eğitim sonucu %99,99, test sonucu ise %99,78 olarak elde edilmiştir.

Sabancı ve diğerleri (2016) yaptıkları çalışmada, UCI makine öğrenim veri tabanından elde edilen tohum veri seti kullanılmıştır. Çalışmanın amacı, tohum veri setinde tohum türlerinin birbirinden ayrılma işlemlerini gerçekleştirmektir. UCI makinesi öğrenme veri tabanından verileri toplanan üç farklı tohum kullanılmıştır. Daha sonra veri setine kNN, Naive Bayes, J48 ve MLP algoritmalarının uygulanmasıyla sınıflandırılmıştır.

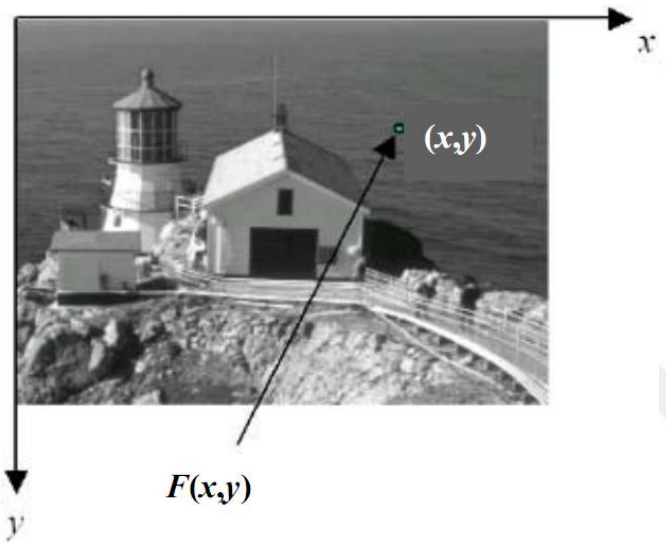
Sabancı ve diğerleri (2017) yaptıkları çalışmada, buğdayların sınıflandırılması, protein ve nişasta miktarlarının ölçülmesi ve kalite analizlerinin yapılması için hem cihazlar hem de yöntemler geliştirilmiştir. Buğday sınıflandırma üzerine yapılan bir çalışmada 12 ana özellik belirleyip, yapay sinir ağları kullanarak bazı türdeki buğdayların sınıflandırmasını yapmıştır.

Ayrıca Bagheri ve Nikparast (2017)'nin yaptıkları çalışmada, bilgisayar tabanlı tohum tanımlamanın öneminden ve bu konuda yapılmış çeşitli çalışmalardan bahsetmiştir. Yapay öğrenme için tohumları tanımlamada şekil, boyut, renk ve doku gibi morfolojik özelliklerin kullanıldığını belirtmiş ve ayrıca tohum tanımlama için kullanılan yaklaşımları da ele almıştır.

3. SAYISAL GÖRÜNTÜ ve GÖRÜNTÜ İŞLEME

3.1 Görüntünün Tanımı

Görüntü, genlik değeri uzamsal koordinat düzlemi üzerindeki herhangi bir (x, y) noktasının yoğunluğu veya gri seviyesi olan bir iki boyutlu bir fonksiyon olan f(x,y) şeklinde tanımlanabilir(Gonzalez ve Woods, 2002). Eğer bu (x, y) noktalarının genlik değerleri sonlu değerler ve (x,y) noktaları ayrık nicelikler ise bu görüntü sayısal görüntüdür. Şekil 3.1'de verilen bir resim için belirlenen x,y noktasının fonksiyonunu temsil etmektedir.



Şekil 3.1 : Sayısal görüntü temsili ve eksenleri.

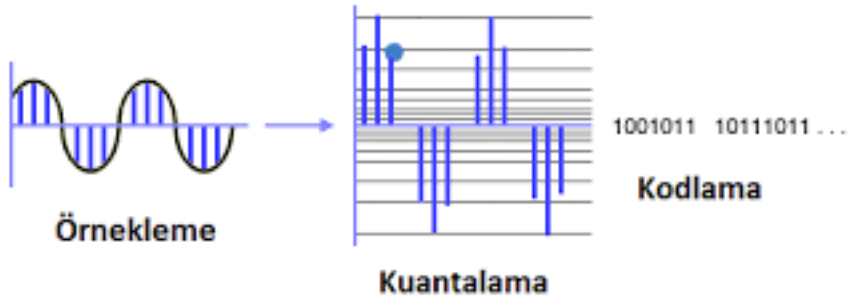
Sayısal görüntü işleme günümüzde neredeyse her alanda kullanılmaktadır. Fotoğraf işleyen yazılımlardan güvenlik kameralarına kadar pek çok uygulamanın konusu haline gelmiştir. Bu uygulamalara medikal görüntüleme, uydu görüntüleme ve akıllı sistemler örnek gösterilebilir. Sayısal görüntü işleme tekniği gelişen teknoloji ile birlikte giderek daha fazla önem kazanmış ve yeni çalışmaların önemli bir parçası haline gelmiştir. Uygulamada kullanılan temel görüntü işleme yöntemlerine geçmeden önce sayısal görüntü ile ilgili temel bilgileri daha geniş ele almak gerekmektedir (Kızılkaya, 2007).

Görüntü işleme süreci, daha gelişmiş ya da anlamlı bir görüntü elde etmek için ya da görüntüden yararlı bazı bilgilerin çıkarımı için görüntüler üzerinde sayısal işlemleri

gerçekleştirmektir. Bu süreç; giriş öğesinin bir görüntü ve çıkış öğesinin matematiksel veri ya da bir görüntü olduğu bir dijital veri işleme türüdür. Son yıllarda görüntü işleme teknikleri hızla büyüyen kimi zaman da korkutucu halde karşımıza çıkan teknolojiler arasında yer almaktadır. Özellikle mühendislik ve bilgisayar bilimlerinde temel araştırma alanları arasında yer almaktadır.

3.2 Görüntünün Sayısal Hale Getirilmesi

Algılayıcılardan alınan veri, görüntüsü algılanan nesneye bağlı olarak değişen sürekli gerilim dalgasıdır (Gonzalez ve Woods, 2002). Sayısal görüntüyü elde edebilmek için algılayıcıdan alınan verinin sayısallaştırılması gerekmektedir. Görüntüyü sayısallaştırma iki işlem içerir. Bu işlemler örnekleme ve kuantalamadır (Şekil 3.1). Bir görüntü x-y düzlemi üzerindeki genlik değeri sürekli bir f(x,y) fonksiyonu ile dağılmış olabilir. Bu görüntüyü sayısallaştırabilmek için fonksiyonun koordinat düzlemi değişkenlerini ve genlik değerlerini ayrık hale getirmek gerekmektedir. Koordinat sistemindeki değişkenleri ayrık hale getirmek örnekleme, genlik değerlerini ayrıl hale getirmek iste kuantalama olarak tanımlanır (Gonzalez ve Woods, 2002).

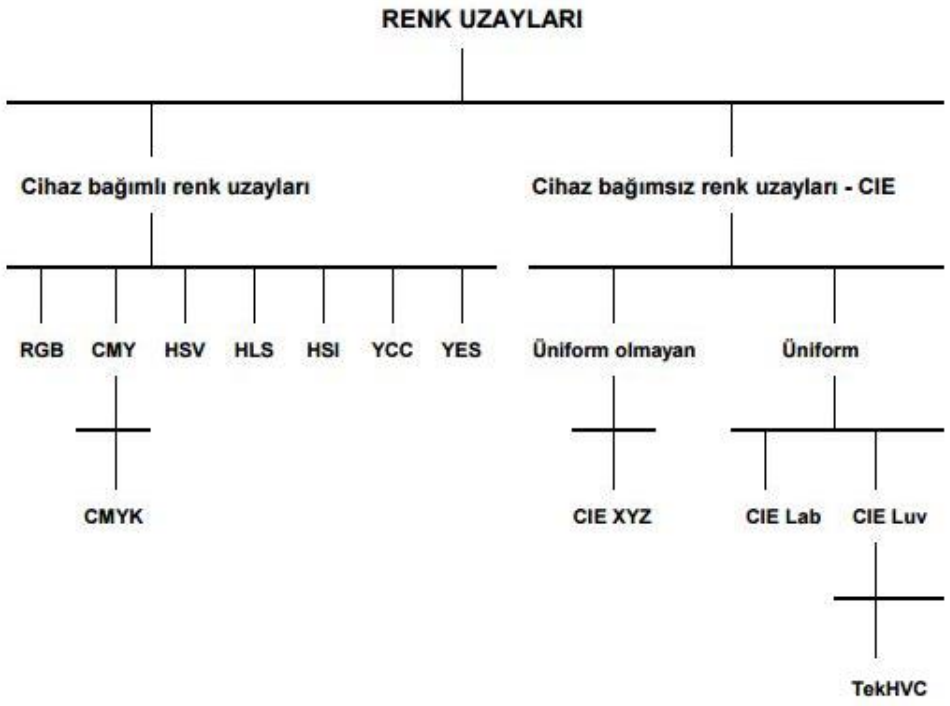


Şekil 3.2 : Örnekleme ve kuantalama (Erikçi, 2018).

3.3 Renk Uzayları

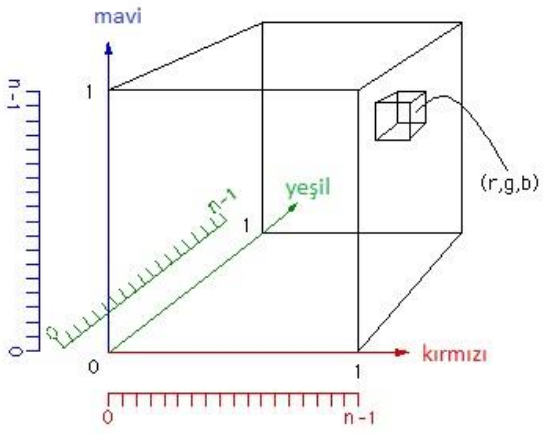
Dijital ortama aktarılan renk çeşitliliğinin çok fazla olması nedeniyle bu renklerin gruplama gerekliliği ortaya çıkmıştır. Bu renkleri gruplamak ve standart hale getirmek için renk uzayı (color space) kavramı doğmuştur (Şekil 3.3). Her renk uzayı, renk grubunu tanımlamak için kendine özgü bir teknik yapıya sahiptir. Siyah beyaz bir görüntüyü dijitalleştirmek için çok fazla veriye gerek yoktur. Görüntüdeki renkler

siyah ve beyaz olmak üzere 2 adet değişkene sahiptir. Çözünürlüğü kadar renk olduğu düşünüldüğünde bu kadar 1 ya da 0 kullanmak yeterlidir. Öte yandan renkli bir resim üzerinde farklı renk tonları olacağı için 1 ve 0 ile bu görüntüyü tanımlamak zayıf kalacaktır. Renk tonlarının işin içine girdiği durumlar için çeşitli renk uzayları belirlenmiştir (Pişkin, 2016a). Renk uzayları üç boyutlu olarak kurgulanmıştır. Renkli bir görüntü üzerindeki piksellerin her biri 3 renk kanalından oluşmaktadır (Toptaş, 2017).



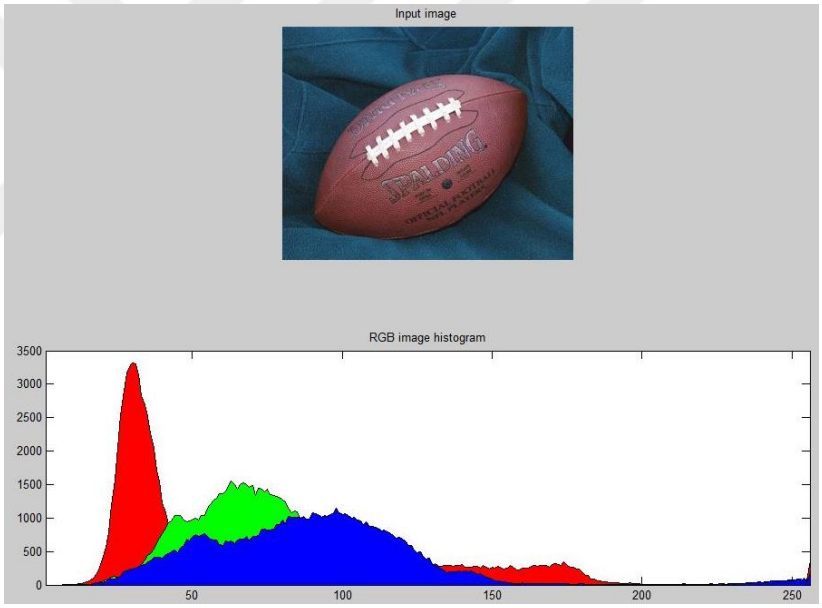
Şekil 3.3 : Renk uzayları ağacı.

RGB Renk Uzayı: Kırmızı (red), yeşil (green) ve mavi (blue) renklerin İngilizce baş harfi ile adlandırılan bu renk uzayı ile her bir renk kırmızı, yeşil, mavi olmak üzere üç sayısal değer ile ifade edilmektedir. Renkler bir küp olarak tanımlanır bu tanımla sayesinde 3 değişkenli bir dizi elde edilir. Bu dizi elemanları olan pikseller, bir rengi tutabilmek için 3 rengin belirli yoğunlukta karıştırılması ile elde edilen renk kodunu barındırırlar (Pişkin, 2016a).



Şekil 3.4 : RGB renk uzayı gösterimi.

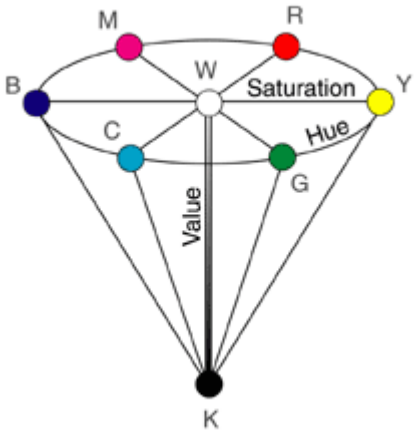
Ayrıca RGB renk uzayında her bir renk sensörü farklı bir hassasiyetlere sahiptir. Şekil 3.5'te bir top üzerine düşen ışığın yansıtma oranlarına göre renkleri histogram grafiğinde verilmiştir.



Şekil 3.5 : Işık şiddetine göre histogram grafiği (Sidra, 2020).

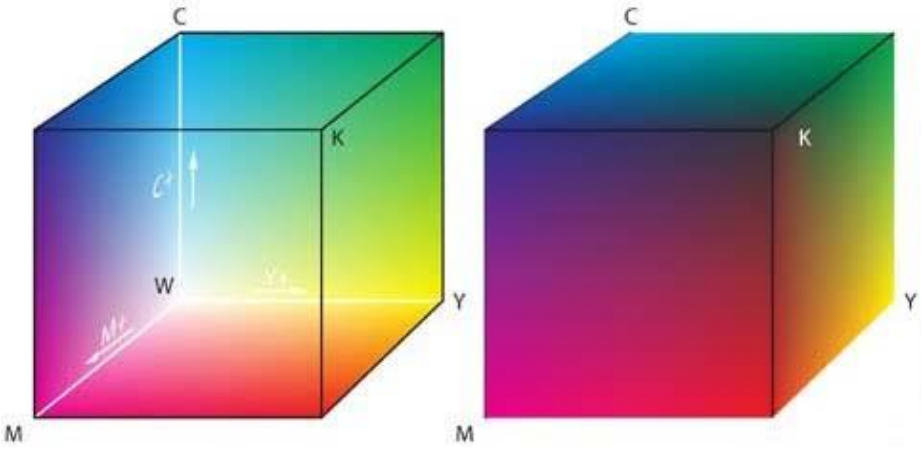
HSV Renk Uzayı: HSV renk uzayı renk tonu, doygunluk ve parlaklık olarak adlandırılan **H**ue, **S**aturation, **V**alue kelimelerinin baş harflerinden oluşmakta ve bu üç

unsurdan meydana gelmektedir. Renkler bu üç değerin karıştırılması ile elde edilir. Renk tanımları bu üç değerinde tutulduğu dizilerde saklanır (Pişkin, 2016a).



Şekil 3.6 : HSV renk uzayı modeli.

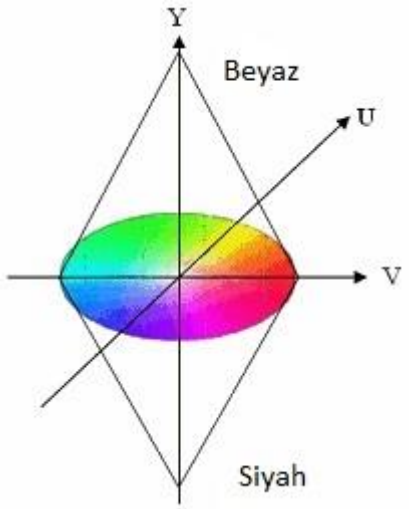
CMYK Renk Uzayı: **C**yan, **M**agenta, **Y**ellow, **K**ey renklerinin kısaltmasıdır. Buradaki *key* siyah rengi temsil etmektedir. CMYK renk uzayı, dijital renk tanımlamaları için belirtilen bu dört rengi karıştırarak yapmaktadır. Günümüzde kullanılan baskı teknolojilerinin neredeyse tamamı bu renk uzayını kullanmaktadır (Pişkin, 2016a).



Şekil 3.7 : CMYK renk uzayı modeli.

YUV Renk Uzayı: **Y** Luminance, **U** Chrominance1, **V** Chrominance2 ifadelerinin kısaltması olan bu renk uzayı YUV değerlerinden alınan bir dizi ile ifade edilir. Y

değeri siyah – beyaz tabanlı, U ve V değerleri ise mavi tabanlı renklilik ve kırmızı tabanlı renkliliği temsil eder. Renkler bu üç kavram ile temsil edilerek oluşturulurlar.



Şekil 3.8 : YUV renk uzayı modeli.

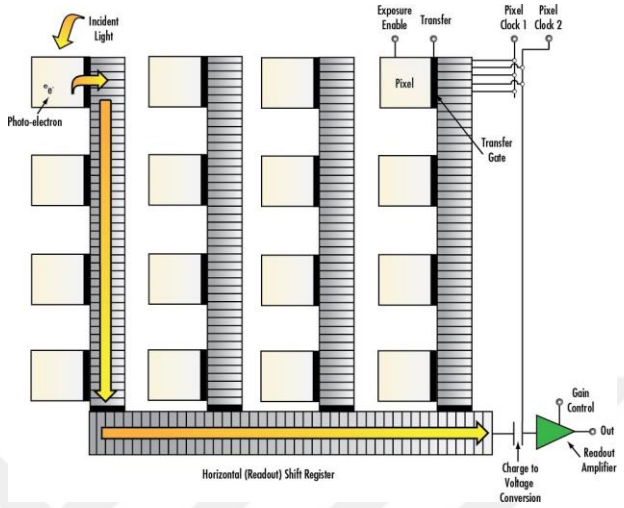
Dijital görüntü işlemede en önemli renk uzayları yukarda sayılanlarıdır. Görüntü işleme aşamalarında kullanılan bir renk uzayından diğerine dönüşümler yapmak mümkündür. Özellikle görüntü işleme yazılımları bu konuda oldukça yeteneklidir (Pişkin, 2016a).

3.4 Kameralar

3.4.1 CCD Kameralar

CCD (The Charge-Coupled Device), 1969 yılında ABD New Jersey'deki Bell Labs'teki bilim insanları tarafından icat edilmiştir. Yıllar boyunca, dijital astrofotografçılıktan makine görmesine kadar fotoğraf çekimi için yaygın bir teknoloji olmuştur. CCD sensörü, bir dizi ışığa duyarlı algılayıcı içeren bir silikon yongadır. Şekil 3.9'da sensörün yapısı görülmektedir. Şarj-bağlı cihaz (charge-coupled) terimi aslında şarj paketlerinin çip üzerinde fotositlerden okumaya, bir kaydırma tetiği (register) kavramına benzer bir kaydırma yazmacına taşınması yöntemini ifade eder. Frekans darbeleri, bir kondansatör tarafından bir voltaja dönüştürülmeden önce şarj paketlerini sensör çipleri üzerinde hareket ettirmek için potansiyel çukurlar oluşturur (Russ 2016). CCD sensörünün kendisi bir analog cihazdır, ancak dijital kameralardaki

çip birler veya sıfırlar şeklinde analog dijital dönüştürücü (ADC) vasıtasıyla çıkış hemen dijital bir sinyale dönüştürülür. Analog kameralarda, her bir bölgeden gelen voltaj, görüntünün yeniden yapılandırılması için sinyal zincirinde bir noktada eklenen sinyal darbeleriyle belirli bir sırada okunur (Anonim, 2019b).



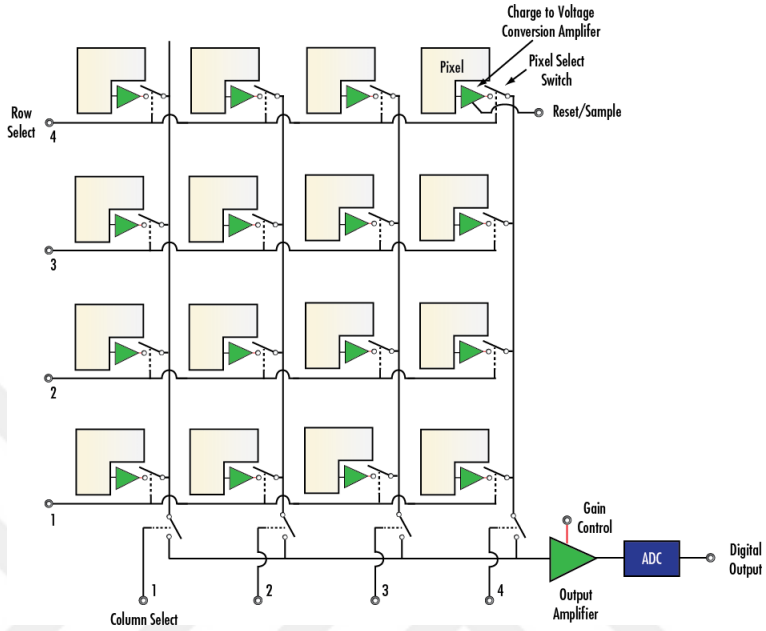
Şekil 3.9 : CCD kamera sensörü (Anonim, 2019b).

CCD sensörlerinin kabiliyetleri, transfer edilebilecekleri hızla sınırlıdır. Bu nedenle elektrik sinyal transferi CCD kameraların hız bakımından dezavantajlı duruma düşürmektedir. Hal böyle iken bu durum aynı zamanda CCD'nin yüksek hassasiyet ve piksel-piksel yüksek tutarlılıkta veri vermesine de yol açar. Her şarj paketi aynı voltaj dönüşümünü gördüğünden, CCD ışığa duyarlı bölgeleri arasında çok düzgündür.

3.4.2 CMOS Kameralar

CMOS (Complementary Metal Oxide Semiconductor), tamamlayıcı metal oksit özellikte yarı iletken, 1963 yılında Frank Wanlass tarafından icat edilmiştir. Wanlass, 1967'ye kadar bu keşfi için bir patent almamış ve 1990'lara kadar görüntüleme uygulamaları için yaygın olarak kullanılmıştır. Bir CMOS sensöründe, ışığa duyarlı pikselin yükü piksel alanındaki bir voltaja dönüştürülür ve sinyal, çip, dijital-analog dönüştürücüler (DAC) üzerinde sıra ve sütunla çoğaltılır. Tasarımının doğası gereği, CMOS kameralar dijital yapıda bir cihazdır (Russ 2016). Her algılayıcı esasen bir fotodiyot ve üç transistörden oluşur. Pikselin sıfırlanması veya etkinleştirilmesi, amplifikasyon ve şarj dönüşümü, seçim veya çoğaltama işlevlerini gerçekleştirir. Şekil 3.10'da görüldüğü gibi bu dijital yapı, CMOS sensörlerinin yüksek hızla işlem

yapabilmesini sağlar. Bu durum aynı zamanda düşük voltajın ihtiyacını da beraberinde getirse de çoklu şarj-voltaj dönüşüm devrelerinde meydana gelen tutarsızlıklar nedeniyle yüksek sabit tekrar gürültüsü çeklinde hatalar oluşabilmektedir (Anonim, 2019b).



Şekil 3.10 : CMOS sensörün yapısı (Anonim, 2019b).

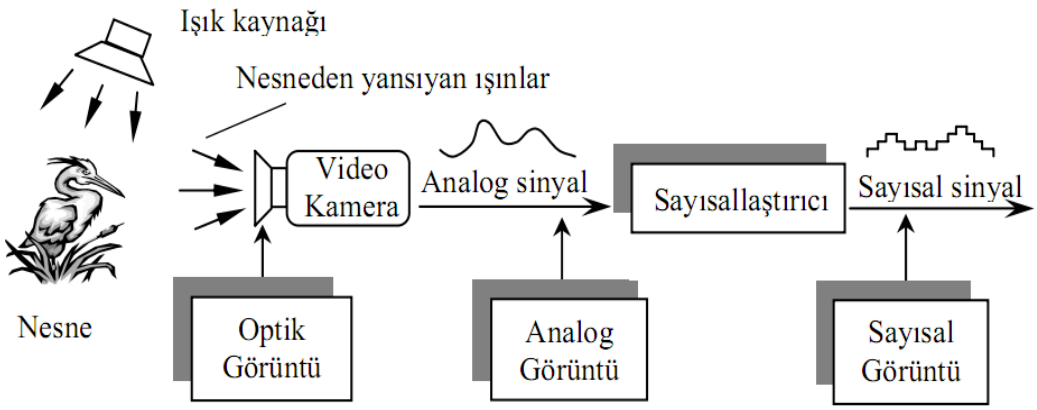
Bir CMOS Sensörünün çoğullama yapılandırması çoğu zaman elektronik bir panjurla birleştirilir. Bununla birlikte, piksel alanındaki ilave transistörlerle, tüm piksellerin aynı anda maruz bırakıldığı ve ardından art arda okunduğu bir çekim gerçekleştirilebilir. Bir CMOS sensör, daha az akım nedeniyle, eşdeğer bir CCD sensörüne kıyasla düşük güç tüketimi avantajı sağlamaktadır. Ayrıca, CMOS sensörün görüntüde kumlamalar oluşturmadan yüksek ışık seviyelerini örnekleyebilme kabiliyeti, metal kaynak dikişlerini bile görüntüleyebilen özel yüksek dinamik aralıklı kameralarda kullanılmasını sağlar. Dijital CCD kameralar ek olarak çipsiz ADC devresi gerektirdiğinden, CMOS kameralar dijital CCD kameralara göre daha küçük tasarımlarda üretilebilmektedir. CCD ve CMOS sensörlerin karşılaştırması için Çizelge 3.1'de verilmiştir.

Çizelge 3.1 : CCD ve CMOS sensörlerin karşılaştırılması.

Sensör	CCD	CMOS
Piksel Sinyali	Electron Paketi	Voltaj
Çip Sinyali	Analog	Dijital
Doluluk oranı	Yüksek	Orta
Duyarlılık	Orta	Orta – Yüksek
Gürültü Seviyesi	Düşük	Orta – Yüksek
Dinamik Aralık	Yüksek	Orta
Tekdüzelik	Yüksek	Düşük
Çözünürlük	Düşük – Yüksek	Düşük – Yüksek
Hız	Orta - Yüksek	Yüksek
Güç Tüketimi	Orta – Yüksek	Düşük
Karmaşıklık	Düşük	Orta
Fiyat	Orta	Orta

3.5 Görüntünün Oluşturulması

Bilimsel çalışmalarda dijital görüntünün oluşturulması algılayıcılar yardımıyla yapılmaktadır. Bu algılayıcılar, radyo teleskopları gibi gerçek görüntünün görünür ışık boyutunda olmadığı frekans boyutundan anlamlandırılmış görüntülere dönüştürüldüğü sistemler olabileceği gibi, CCD ya da CMOS kamera sensörleri ile görünür ışık demetinin sayısallaştırılarak makine ortamına aktarılması şeklinde de olmaktadır (Şekil 3.11).



Şekil 3.11 : Sayısal görüntünün oluşma süreci.

Kameralarla elde edilen görüntü alma sürecindeki başarı kameralardan alınan görüntülerin dijital kalitesine bağlıdır. Kamera kaliteleri doğrudan görüntü kalitelerini etkilemiştir. Ancak en kaliteli kameralar ve lensler ile çekilmiş olsa dahi insan görmesinin üstünde bir makine görmesi ihtiyacı mutlaka vardır. Örneğin makro aleme bakmak için teleskop ya da mikro aleme bakmak için mikroskop gibi optik özellikli cihazlar normalde insan gözünün gördüğünden çok küçük ya da çok büyük nesneleri görerek algılamamızı sağlamaktadır. Elektromanyetik tayf üzerinde görünebilir frekans aralığı (400 - 700 nanometre) dışındaki ultraviyole ve kızılötesi ışınları, radyo dalgaları ve X-ışınlarını ve algılamamızı sağlayan sensörler üretilmektedir. Bu farklı frekanstaki dalgaların da sayısallaştırılması ile bizim göremediğimiz ama anlamlı görüntüler de elde edilebilir (Russ, 2016). Son yıllarda radyo teleskobu diye adlandırılan frekans toplayan dev çanak antenler uzayın yaymış olduğu ışınları ve dalgaları toplayarak anlamlı sonuçlar üretmek için veriler hazırlamaktadır. Bilgisayar bilimi sayesinde bu veriler bir yıldız ya da gezegenin keşfine kapı açmaktadır.

İnsanların göz ve beyni yardımıyla görüntülerden elde ettikleri görsel bilgi ile teknik ve bilimsel ya da adli amaçlı kullanılmak üzere görüntüleme sistemleri ile elde edilen bilgi arasında çok fark vardır. İnsanlar makinelere göre daha kötüdür demek doğru olmasa da insan görüntü yakalayan ve işleyen bir cihazın elde ettiği somut bilgiyi sürekli yakalayamaz. Nesnelerin renklerini ve parlaklıklarını, görüntü içindeki özel durumları anlamada makinelere göre insanlar daha iyi değillerdir. Makineler nesneleri sayısallaştırarak sonuçlara ulaşırken insanlar görüntüleri karşılaştırarak bir sonuç çıkarmaktadır. Makine görmesi denilen olgu; nesnelerin özelliklerinin

sayısallaştırılarak kıyaslama, seçme, ayırt etme gibi işlemler içermektedir. Makineler sayısallaştırdıkları bu bilgileri yorumlamada zorluk çekerler. Örneğin bir görüntü üzerine düşen ışığın şiddeti görüntünün renklerinin algılanmasında farklı sonuçlar üretirken makineler bu farklılıklar karşısında yanılgıya düşmektedirler. Bu yüzden basit görüntüler üzerinde çalışan mikro, endüstriyel kontrol, uydu ve görüntü işleme sistemlerinin doğruluğu daha fazladır (Russ, 2016).

3.6 OpenCV Kütüphanesi ile Görüntü İşleme Teknikleri

Bilgisayar ortamına aktarılan görüntülerin anlamlı dijital veriler haline getirilmesi işlemine görüntü işleme denilmektedir. Görüntü işleme için yaygın olarak OpenCV kütüphanesi kullanılmaktadır. Bu kütüphanenin birçok komutu sayesinde görüntülerin uzunlukları ölçülebilmekte, çap çevre vb. değerleri hesaplanabilmekte ve görüntülerdeki yüz ve insanlar tespit edilebilmektedir (Bradski ve diğerleri, 2008).

Görüntü işleme süreçlerinde görüntünün sayısal hale getirilmesi, görüntüdeki nesnelerin sınırlarının tespiti, görüntüden veriler elde edilebilmesi veya görüntü üzerindeki istenmeyen cisimlerin kaldırılması gibi işlemler için birçok teknik kullanılmaktadır.

3.6.1 Renk uzayı değiştirme

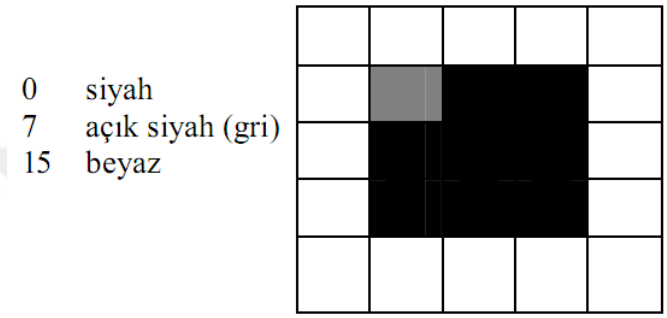
Bu işlem bir giriş görüntüsünü bir renk uzayından diğerine dönüştürür. RGB renk uzayından dönüşüm gerçekleşmesi durumunda, kanalların sırası açıkça belirtilmelidir (RGB veya BGR). OpenCV'deki varsayılan renk formatı genellikle RGB olarak adlandırılır, ancak aslında BGR'dir (baytlar ters çevrilir). Standart (24 bit) renkli bir görüntüdeki ilk bayt 8 bitlik Mavi, ikinci bayt Yeşil ve üçüncü bayt Kırmızı olacaktır. Dördüncü, beşinci ve altıncı bayt daha sonra ikinci piksel (Mavi, sonra Yeşil, sonra Kırmızı) olacaktır. Bu işlem için OpenCV de cvtColor() komutu kullanılmaktadır (García ve diğerleri, 2015).

3.6.2 Gri-düzey skala

Görüntü üzerindeki aydınlatma değerlerinin farklı seviyelerde olması, piksel düzeylerinin farklı olmasındandır. Bir görüntü siyah-beyaz tonlardan meydana

geliyorsa, görüntü üzerindeki her bir piksel noktası gri-düzey skala renk değerleri olarak tanımlanır. Görüntü üzerindeki noktalar farklı olduğundan, her bir aydınlatma seviyesi için gerekli veri bitlerinin yerleşimi farklıdır. Bu gibi birbirinden farklı düzeylerden meydana gelen görüntülere gri-düzey veya gri-düzey skala denilmektedir (Yaman, 2000).

16 Farklı gri-ton yani dört bitlik yani aydınlanma değeri için her bir piksel noktanın içerdiği gri-seviye parlaklık değerleri Şekil 3.12'de görülmektedir.



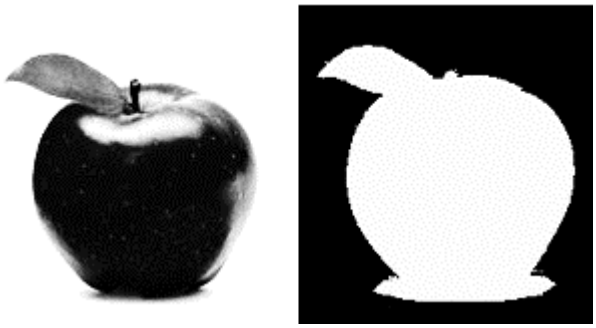
15	15	15	15	15
15	7	0	0	15
15	0	0	0	15
15	0	0	0	15
15	15	15	15	15

Şekil 3.12 : On altı bitlik gri-seviye skala ifadesi.

Şekil 3.12'de 4 bit/piksel yani bir pikselin değerini ifade etmek için 4 bit kullanılmıştır. 0 ile 15 arasında 16 gri-düzey değerleri mevcuttur (Yaman, 2000).

3.6.3 Görüntü eşik değeri

Eşikleme (thresholding) giriş olarak verilen görüntüyü binari (ikili) görüntüye çevirmek için kullanılan bir yöntemdir. İkili görüntü (binary), görüntünün siyah ve beyaz olarak tanımlanmasıdır. Bu yöntem görüntü üzerindeki gürültüleri azaltmak veya nesne belirlemek gibi amaçlar için kullanılmaktadır (Dawson-Howei, 2014). Seçilen görüntü üzerinde uygulanan thresholding tipine bağlı olarak, pikselleri verilen eşik değerine göre siyah ya da beyaz olarak işaretlenir. Piksellerin arasında siyah beyaz ya da beyaz siyah geçişi görülüyorsa bu bölümde eşik değeri değişiyor dolayısıyla burada bir sınır çizgisi var anlamına gelmektedir (García ve diğerleri, 2015). Şekil 3.13'de bir elmanın beyaz zeminden eşikleme ile ayrılarak sınırlarının tespiti yapılmıştır.

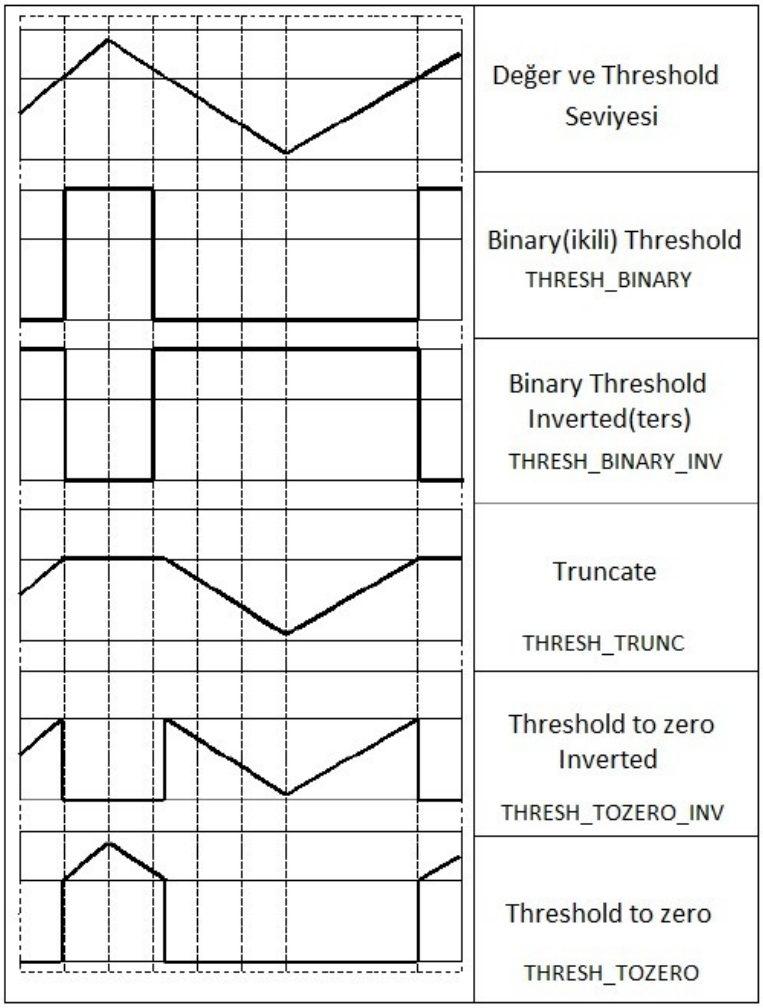


Şekil 3.13 : Örnek bir eşikleme çalışması (Anonim, 2019c).

Eşikleme genellikle sınır belirlemede yaygın kullanılan bir yöntemdir. Eşik değeri olarak bir global değer kullanılabilir. Ancak bu her durumda (bir görüntünün farklı alanlarda farklı aydınlatma koşulları olması gibi) iyi sonuç alınamayabilir. Bu durumda, uyarlanabilir eşikleme (Adaptive Thresholding) sorunu çözebilmektedir. Burada algoritma, etrafındaki küçük bir bölgeye göre bir pikselin eşiğini belirler. Bu nedenle, aynı görüntüye ait farklı bölgelerdeki dokular için farklı ışık eşikleri üretilmektedir. Bu sistem farklı aydınlatmaya sahip resimler için çok daha iyi sonuçlar vermektedir (Pişkin, 2016b).

OpenCV içerisindeki sık kullanılan eşikleme tipleri aşağıda sıralanmıştır. Ayrıca Şekil 3.14'de Threshold metodu parametreleri görsel olarak gösterilmiştir.

- THRESH_BINARY
- THRESH_BINARY_INV
- THRESH_TRUNC
- THRESH_TOZERO
- THRESH_TOZERO_INV



Şekil 3.14 : Threshold metodu parametlerinin görsel gösterimi.

3.6.4 Sınırların tespiti

Sınırlar, bir görsel üzerindeki aynı renk veya renk yoğunluğuna sahip ard arda gelen tüm noktaları birleştiren bir sayısal eğri olarak açıklanabilir. Görüntü işlemede sınır tespiti en önemli aşamalardan biridir. Plaka okuma, insan tanıma, nesne yakalama gibi neredeyse her görüntü işleme sürecinde ilk yapılan sınır tespitidir (Mordvintsev ve Abid, 2014)

Bir görüntüdeki sınırları bulmak için OpenCV *cv2.findContours* işlevi kullanılır Bu yöntem üç parametre gerektirir. Birincisi, kenarları bulmak istediğimiz görüntüdür. *Cv2.findContours* yöntemi yıkıcı bir yöntem olduğundan kullanılan görüntüyü bozacaktır. İkinci parametre *cv2.RETR_TREE*, OpenCV'de konturlar arasındaki hiyerarşiyi (ilişki) hesaplamasını sağlar. Böylelikle sınırları belirlenen bir nesne

sınırları ayrı ayrı dizi elemanı olarak tutmaktadır. Bir döngü yardımıyla kenarları bulunmuş görüntünün içindeki bağımsız kenarlar okunur. Bu okunan nesneler görüntünün içinden çıkarılmış nesneler olarak bağımsız işlem yapmada kullanılmaktadır (García ve diğerleri, 2015).

3.6.5 Nesnelerin şekil özelliklerinin belirlenmesi

Bir görüntü işinde sınırları belirlenmiş alanlar bir döngü ile okunabilmektedir. Bu döngü her okunduğunda bir nesne ele alınmakta ve o nesnenin özellikleri okunabilmektedir. Nesnelerin x eksenindeki piksel değeri ve y eksenindeki piksel değeri belli olduğundan buradaki minimum ve maksimum noktalar bulunarak nesnenin boyu eni ölçülebilir. OpenCV kütüphanesi nesneleri alanını hesaplamak üzere *contourArea*, çevresini hesaplamak üzere *arcLength* komutlarını sunmaktadır. Ayrıca bulunan nesnenin merkez noktasını hesaplamak için *moments* komutu kullanılmaktadır. Bu komut sayesinde nesnenin x ve y piksel koordinatlarındaki merkezi bulunabilmektedir (Li ve diğerleri, 2012).

Merkezi momentler değişmemesi nesnelerin özelliklerinin tespiti için yeterli değildir. Ölçek ve rotasyona benzemeyen momentler HuMoments komutu ile hesaplamak mümkündür.
HuMoments (başka bir ifadeyle Humoment değişmezleri), görüntü dönüşümlerine değişmeyen merkezi momentler kullanılarak hesaplanan 7 sayı kümesidir. İlk altı özelliğin, ölçek ve rotasyon ve aynalama durumlarında değişmez olduğu kanıtlanmıştır. Yedinci özellik görüntü aynalandığında değişmektedir (García ve diğerleri, 2015). Hu moment komutu Denklem 3.1'deki gibi formulize edilmiştir. Bir nesnenin kendine has şeklini en doğru veren parametreler seçilebilir. Nesneye ait HuMoment sonuçları sınıflandırmada faydalı sonuçlar vermektedir. Şekil 3.15'de HuMoment ile işlendiğinde S harfi her ne kadar yatık olsa da yoğunlukları aynı olduğundan birbiriyle aynı değeri üretecektir (Mallick, 2018, Bapat, 2018).

$$h_0 = \eta_{20} + \eta_{02}$$

$$h_1 = (\eta_{20} - \eta_{02})^2 + 4\eta_{11}^2$$

$$h_2 = (\eta_{30} - 3\eta_{12})^2 + (3\eta_{21} - \eta_{03})^2$$

$$h_3 = (\eta_{30} + \eta_{12})^2 + (\eta_{21} - \eta_{03})^2$$

$$h_4 = (\eta_{30} - 3\eta_{12})(\eta_{30} + \eta_{12})[(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2] + (3\eta_{21} - \eta_{03})[3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2]$$

$$h_5 = (\eta_{20} - \eta_{02})[(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2 + 4\eta_{11}(\eta_{30} + \eta_{12})(\eta_{21} + \eta_{03})]$$

$$h_6 = (3\eta_{21} - \eta_{03})(\eta_{30} + \eta_{12})[(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2] + (\eta_{30} - 3\eta_{12})(\eta_{21} + \eta_{03})[3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] \quad (3.1)$$

id	Image	H[0]	H[1]	H[2]	H[3]	H[4]	H[5]	H[6]
K0		2.78871	6.50638	9.44249	9.84018	-19.593	-13.1205	19.6797
S0		2.67431	5.77446	9.90311	11.0016	-21.4722	-14.1102	22.0012
S1		2.67431	5.77446	9.90311	11.0016	-21.4722	-14.1102	22.0012
S2		2.65884	5.7358	9.66822	10.7427	-20.9914	-13.8694	21.3202
S3		2.66083	5.745	9.80616	10.8859	-21.2468	-13.9653	21.8214
S4		2.66083	5.745	9.80616	10.8859	-21.2468	-13.9653	-21.8214

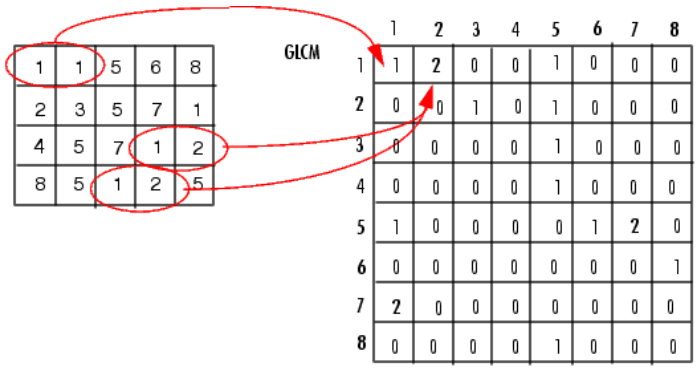
Şekil 3.15 : HuMoment komutunun farklı görüntülerdeki ürettiği sonuçlar.

3.6.6 Gri Seviye Eş Oluşum Matrisi (GLCM)

Bir görüntüdeki piksellerin uzamsal ortam ilişkilerini dikkate alan dokuyu incelemek için istatistiksel bir yöntem olan GLCM (Gray-Level Co-Occurrence Matrix) gri düzey uzamsal bağımlılık matrisi olarak dilimize çevrilen gri düzey ortak oluşum matrisidir (Haralik ve diğerleri, 1973). GLCM fonksiyonları, bir görüntüde belirli değerlere sahip ve belirtilen bir uzamsal ilişkide görüntü dokusundaki piksel çiftlerinin ne sıklıkta tekrarlandığını hesaplayarak, bir GLCM oluşturarak ve daha sonra bu matristen sayısal ve istatistiksel ölçümler çıkararak bir görüntünün dokusunu analiz ederek karakterini çıkarır. N × N boyutunda bir I görüntüsü verildiğinde, birlikte meydana gelme, P matrisi aşağıdaki Formül 3.2 ile tanımlanabilir (Zhu ve Zhang, 2010).

$$P(i,j) = \sum_{x=1}^{N} \sum_{y=1}^{N} \begin{cases} 1, eğer\ I(x,y) = i\ ve\ I(x + \Delta_x + \Delta_y) = j \\ 0, diğer\ durumlar \end{cases} \tag{3.2}$$

Burada ofset (Δx, Δy), ilgilenilen piksel ile komşusu arasındaki mesafeyi belirtir. Ofset (Δx, Δy) parametresi, birlikte oluşma matrisini dönüşe duyarlı hale getirir. Şekil 3.16'te GLCM Doku özelliklerinin matris formunda gösterimi verilmiştir (Eleyan ve Demirel, 2011).



Şekil 3.16 : GLCM doku özelliklerinin matris formunda gösterimi.

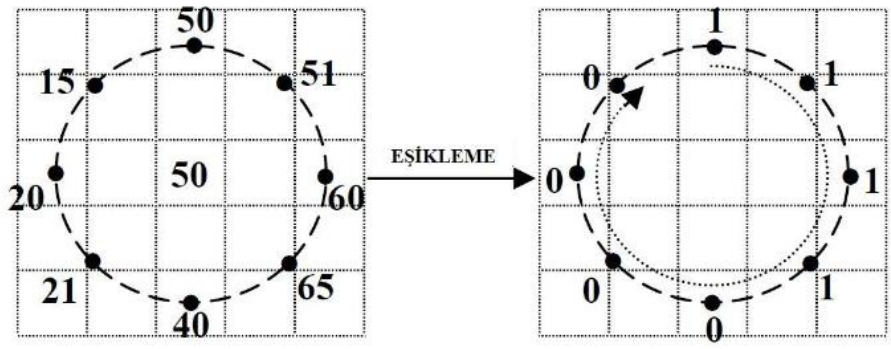
GLCM sayısal matrislerini oluşturduktan sonra, *graycomatrix* ve *graycoprops* komutlarını kullanarak görüntülerden birkaç istatistik çıkarabilmektedir. Bu istatistik verileri görüntünün dokusu hakkında veriler verir. Aşağıdaki Çizelge 3.2'te istatistikler, açıklamaları ve formülleri verilmiştir (Madhura ve Dheeraj, 2013).

Çizelge 3.2 : GLCM matrisinde bulunan istatistikler ve açıklaması.

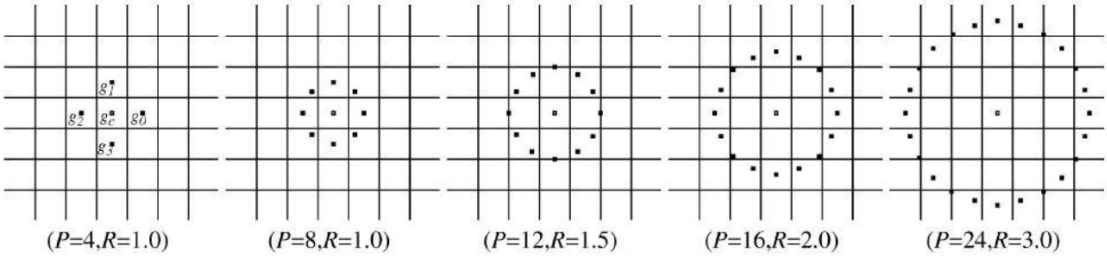
Doku İstatistiği	Açıklama	Formül
Contrast	Gri düzeyli birlikte oluşma matrisindeki yerel varyasyonları ölçer.	$Contrast = \sum_{i,j=0}^{N-1} P_{ij}(i-j)^2$
Entropy	Entropi, İçerik bilgisi veren bir ölçüdür. Yoğunluk dağılımının rastgelelik durumunu ölçer.	$Entropy = \sum_{i,j=0}^{N-1} -ln(P_{ij})P_{ij}$
Correlation	Belirtilen piksel çiftlerinin birleşme olasılığı oluşumunu ölçer.	$Correlation = \sum_{i,j=0}^{N-1} P_{ij} \frac{(i-\mu)(j-\mu)}{\sigma^2}$
Energy	GLCM'deki kare elemanların toplamını sağlar. Tekdüzelik veya açısal ikinci moment olarak da bilinir.	$Energy = \sum_{i,j=0}^{N-1} (P_{ij})^2$
Homogeneity	GLCM verilerindeki elemanların GLCM çaprazlamasına dağılımının yakınlığını ölçer.	$Homogeneity = \sum_{i,j=0}^{N-1} \frac{P_{ij}}{1+(i-j)^2}$

3.6.7 Yerel ikili örüntüler (LBP)

LBP fonksiyonu, gri tonlamalı seviyeden bağımsız bir doku modelleme yöntemidir. LBP operatörü örneklenen görüntünün her pikseli için bir özel etiket oluşturmaktadır ve bu etiketler binari bir ve sıfırlardan meydana gelmektedir. Bu etiketler merkez pikselin N x N komşuluğundaki tüm piksellerin karşılaştırılmasıyla oluşmaktadır (Şekil 3.17). Genel olarak LBP P,R üç farklı dairesel komşulukla tanımlanabilir. P komşu sayını belirtirken, R ise örnekleme yarıçapını temsil eder. Şekil 3.16’ te çeşitli LBP operatörleri gösterilmektedir.



Şekil 3.17 : LBP Algoritması.



Şekil 3.18 : Örnek sayısı ve r yarıçaplı daire çeşitleri.

Aşağıdaki formülde (X_c,Y_c) verilen pikselin yerini, i_p ve i_c merkez pikselin gri seviyesini ifade eder. s fonksiyonu x değerinin 0 dan küçük ya da büyük eşit olma durumuna göre tanımlanmıştır.

$$LBP_{P,R}(x_C, y_c) = \sum_{P=0}^{P-1} s(i_P, i_C)\, 2^P \qquad s(x) = \begin{cases} 1, eğer\ x \geq 0 \\ 2, eğer\ x < 0 \end{cases} \qquad (3.3)$$

4. ÇALIŞMADA KULLANILAN YAZILIMLAR

4.1 Python Programlama Dili

Python, özellikle bilim dünyasında yaygın kullanılan genellikle bilimsel amaçlı, yüksek seviyeli bir programlama betik dilidir (Oliphant, 2007). Python ilk olarak 1991 yılında Guido van Rossum tarafından tasarlanmış ve Python Yazılım Vakfı tarafından ilerleyen süreçte geliştirilmiştir. Temel olarak kod okunabilirliğine ve az komutla daha çok kod yazma mantığı üzerine kurulu olan Python, sözdizimi programcıların daha az kod satırında kavramları ifade etmelerini sağlamaktadır (Rossum, 1995).

Python dili, açık kaynak bir yazılımdır. C dili üzerinden geliştirilmiştir. Günümüzde geniş bir standart kütüphaneye sahip olması bu dilin kullanımını yaygınlaştırmıştır. Mühendislik alanlarından ekonomi ve finansa kadar birçok alanda Python dili ile çözümler üretilmektedir. Özellikle Linux tabanlı gömülü sistemlerde standart bir paket olarak gelen Python derleyicisi ile rahatlıkla gömülü cihazlar kontrol edilerek istenilen prototipler yapılabilmektedir. Ayrıca Python dilinin internet ile haberleşebilen yapısı ve destekleyici kütüphaneleri sayesinde veri haberleşmesi teknolojilerinde de alt yapı olarak kullanılmaktadır (Aytekin, 2018).

4.2 OpenCV Görüntü İşleme Kütüphanesi

OpenCV (Open Source Computer Vision) kütüphanesi açık kaynaklı görüntü işleme işlemlerini gerçekleştiren bir yazılım kütüphanesi olarak nitelendirilebilir (Bradski ve diğerleri, 2008). Bu kütüphane 1999'da İntel firması tarafından ilk geliştirme sürecine başlanmıştır. Itseez, Willow, Nvidia, AMD, Google vb. şirket ve uluslararası toplulukların desteği ile OpenCV nin gelişimi halen devam etmektedir. Yazılımın ilk sürümü OpenCV alfa; 2000'de piyasaya çıkmıştır. İlk süreçte C programlama dili ile geliştirilmiş sonrasında gelişimini C++ dili ile devam ettirmiştir. BSD lisansı ile altında geliştirildiğinden açık kaynak bir kütüphanedir. OpenCV'nin, Açık kaynak BSD lisansına sahip olması bu kütüphanenin projelerde ücretsiz kullanımına olanak vermektedir (Pisarevsky, 2007). OpenCV herhangi bir platforma bağımlı değildir. Bu

özelliği sayesinde Linux, FreeBSD, Android, Mac OS, Windows ve iOS işletim sistemleri ile birlikte çalışabilmektedir (Bradski ve diğerleri, 2000).

Video analitiği, OpenCV arka plan kaldırma, filtreler, desen eşleştirme ve sınıflandırma gibi temel yapı taşları için kullanılmaktadır. Gerçek zamanlı video analitiği yetenekleri; nesneler, hayvanlar, insanlar, araç plakaları, hayvan türleri ve yüzler, gözler, dudaklar, çene vb. gibi yüz özelliklerinin sınıflandırma, tanıma ve tespit ve izleme işlemleri için kullanılmaktadır.

Bilgisayar platformlarında takılı olan bazı kameralar daha iyi sürücüler nedeniyle daha iyi çalışsa da, OpenCV için çalışan bir kamera, bir video ya da bir fotoğraf üzerinden işleme yapmak mümkündür.

Dünya üzerinde bilim insanları ve geliştiriciler OpenCV'yi bir sinir ağı arka ucuyla birleştirdiklerinde, bilgisayarlı görmenin gerçek gücünü ortaya çıkmış oldu. Bu yaklaşımı kullanan OpenCV, geliştiricilerin yenilikçi ve güçlü yeni vizyon uygulamaları oluşturmalarına olanak sağlamak için Konvolüsyonel Sinir Ağları (CNN) ve Derin Sinir Ağları (DNN) ile birlikte çalışmaktadır (Rosebrock, 2017).

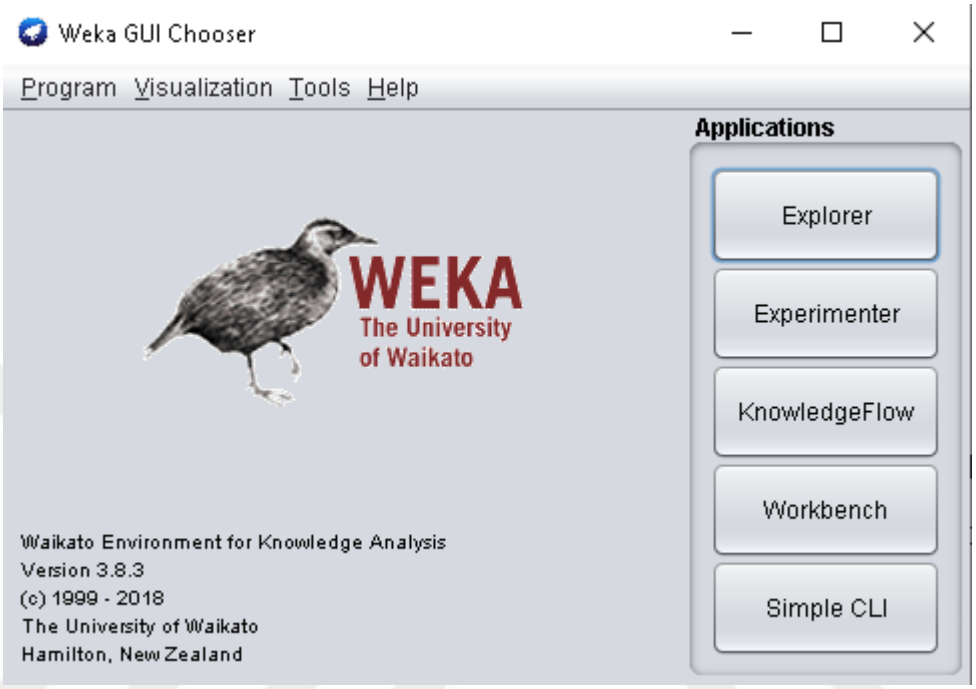
OpenCV, gerçek zamanlı görüntü ve videonun işlenmesinin yanı sıra analitik ve makine öğrenmesi yetenekleri sağlayan bir yazılım aracıdır. BSD lisanslı açık kaynak bir kütüphane olan OpenCV'i kullanan geliştiriciler, programlarının bir parçası olarak 2D ve 3D'de görüntü ve video işleme için kullanılan birçok gelişmiş bilgisayarlı görüntü algoritmasına erişebilirler. Bu algoritmalar tüm dünyada çok hızlı bir şekilde gelişim göstermektedir (Petrovic, 2007).

4.3 WEKA Programı

Weka, çeşitli makine öğrenme algoritmaları içeren açık kaynak bir platformdur .Weka temel olarak, Yapar sinir ağları ve veri madenciliği görevleri için kullanılan makine öğrenme algoritmaları topluluğudur (Dener, 2009).

Weka, Yeni Zelanda'da bulunan Waikato Üniversitesi'nde geliştirilmiş, Java programlama dili ile yazılmıştır (Şekil 4.1). Weka popüler bir makine öğrenim paketidir. Weka, GNU altında sağlanan ücretsiz bir yazılımdır. Weka yazılımı, bu

fonksiyonelliğe kolay erişim için grafiksel kullanıcı arayüzleriyle birlikte, veri analizi ve öngörüsel modelleme için bir görselleştirme araçları ve algoritmaları koleksiyonu içerir. Weka, gerçek dünyadaki veri madenciliği problemlerini sayısallaştırıp sanal dünyada çözmek için tasarlanmış bir programdır. Java ile yazılmış olduğundan neredeyse her platformda çalışır.



Şekil 4.1 : Weka programı standart ara yüzü.

Weka içeriğinde; veri ön işleme süreci, regresyon, sınıflandırma, kümeleme, birleştirme kuralları ile verilerin görselleştirilmesi için araçlar barındırmaktadır (Sahoo, 2013). Aynı zamanda yeni makine öğrenim planları geliştirmek için de uygun bir yapıya sahiptir.

Veri kümenizdeki çeşitli gizli katmanları algılamak ve birçok veri girdisinden en belirleyici faktörleri bulmak için de kullanılabilir (Srivastava, 2013).

5. SINIFLANDIRMADA KULLANILAN ALGORİTMALAR VE YÖNTEMLER

5.1 Sınıflandırmada Kullanılan Yapay Zeka Teknikleri

Bu çalışmada buğday taneleri MLP, SVM ve kNN algoritmaları kullanılarak sınıflandırılmıştır.

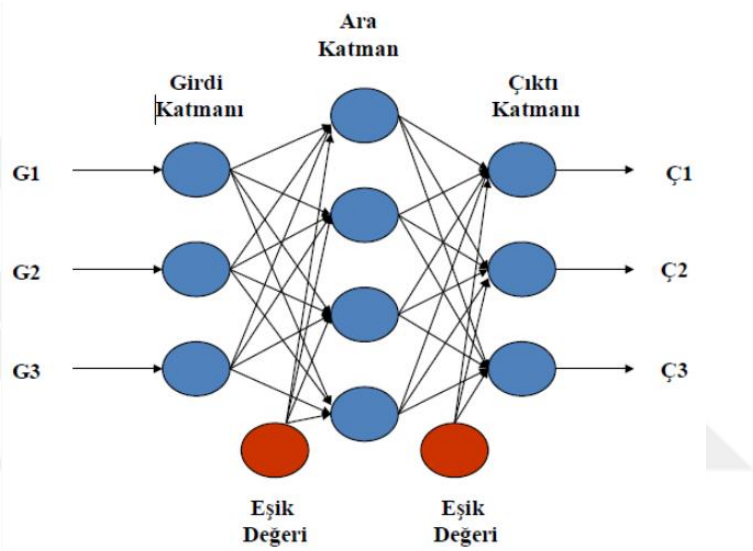
5.1.1 Çok katmanlı algılayıcı algoritması

Yapay sinir ağları (ANN), insan beynindeki merkezi sinir sistemini taklit eden bilgi işleme yöntemidir (Koçer, 2007). Bu konu üzerinde yapılan ilk çalışmalarda beyindeki nöronların modellenmesi ve bilgisayar sistemlerinde uyarlanması ile başlamıştır (Zak, 2003). Nöronlar birbirine bağlanması sonucu oluşturulan yapı her bir nöron, girdisinin değerini ifade eden sayısallaştırılmış bir ağırlığa sahiptir. Ağırlıklar, Yapay Sinir Ağlarındaki uzun süreli belleğin temel unsurudur. Bir yapay sinir ağı, bu nöron ağırlıklarının defalarca ayarlanması sayesinde öğrenme olayını gerçekleştirir. Ağ için tasarlanacak en uygun mimari, ağın problemi öğrenmesi için yeterince büyük boyutlarda, genelleme yapmaya imkan verecek kadar da küçük olmalıdır (Haykin, 2009). En ideal mimariden daha küçük tasarlanmış bir ağ problemi istenildiği kadar iyi öğrenemez. Bunun yanı sıra daha büyük bir ağ ise eğitim verisini çok iyi öğrenir ki buda modeli ezberlemesine yol açacaktır. Ezberlenme ANN'de istenmeyen bir durumdur ki bu durum genelleme yeteneğinin gelişmesinin önünde bir engel teşkil edecektir. Yapay sinir ağının yapısı küçük boyutta seçilip öğrenme sürecinde büyüme gözleniyor ise büyüyen/yapıcı bir yaklaşım, aksine ağın yapısı büyük seçilip öğrenme süresince küçülme gözleniyor ise budama/yıkıcı bir yaklaşım izlenmiştir (Haykin, 2011).

Yapay Sinir Ağları genel olarak tek katmanlı algılayıcılar ile çok katmanlı algılayıcılar şeklinde ikiye ayrılmaktadır.

Tek katmanlı algılayıcılı yapay sinir ağları genellikle doğrusal problemlerin çözümünde yaygın kullanılmaktadır. Bu modelde sadece girdi katmanı ve çıktı katmanı bulunmaktadır. Katmanların nöron sayısı bir ya da daha fazla olabilmektedir.

Bu algoritma tek katmanlı algılayıcıların doğrusal olmayan problemlerin çözümünde beklenen başarının elde edilememesi üzerine geliştirilmiştir. Çok Katmanlı Algılayıcı (MLP), veri girişlerinin yapıldığı girdi katmanı standart olarak bulunmaktadır. Bu modelde bir veya birden fazla ara katman (gizli katman da denilir) ve son olarak bir çıktı (sonuç) katmanı bulunmaktadır (Şekil 5.1). MLP'da katmanlar arası geçişler ileri yönlü ve geri yönlü yayılım olarak adlandırılmaktadır. İleri yayılım kısmında, ağın çıktısı ve hata değerleri hesaplanır. Geri yönlü yayılım kısmında ise katmanlar arası hesaplanan hatanın en aza indirilmesi için katmanlar arası ilişki ağırlık katsayı değerleri yeniden güncellenir (Öztemel, 2003).



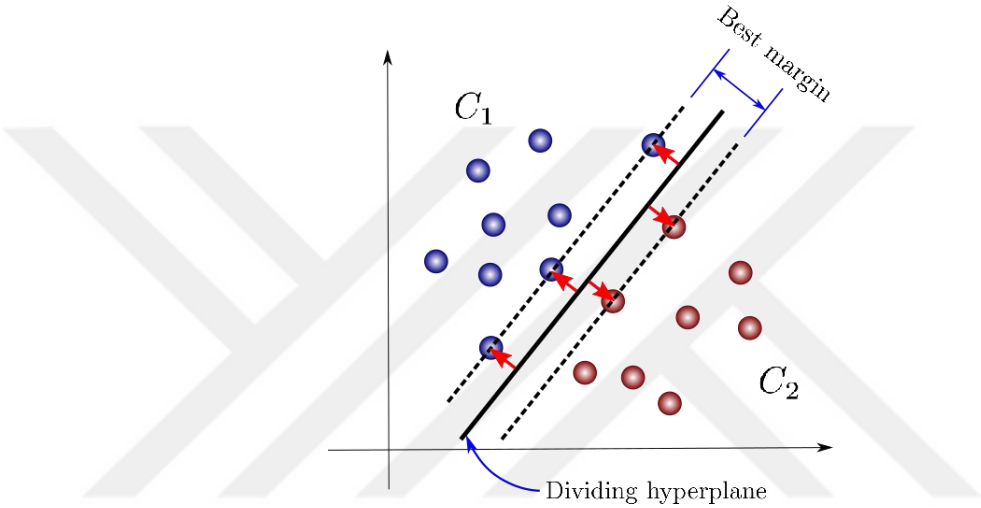
Şekil 5.1 : MLP Algoritmasının yapısı

5.1.2 Destek vektör makineleri

Sınıflandırma işlemlerinde en çok kullanılan yöntemlerden biri Destek Vektör Makineleri (SVM) algoritmasıdır. SVM algoritması istatistiksel öğrenme teorisine dayalı olup parametrik özellikli olmayan bir yöntemdir (Vapnik, 1995). SVM ikili sınıflandırmalar için geliştirilmiş bir yöntem olup az sayıda örnekleme verisi ile daha doğru sınıflandırma yapmak mümkündür (Foody ve Mathur, 2004). Özellik uzayında sınıf verileri arasındaki sınırı belirlemek için çeşitli algoritmalar kullanılmaktadır. İlk etapta iki sınıflı doğrusal durumdaki veriler için geliştirilmiş olan bu metot sonraki süreçte çok sınıflı ve doğrusal durumda olmayan verilerin sınıflandırılmasında kullanılmaya başlanmıştır. Temel prensipte iki sınıfı veri kümelerini gruplayarak birbirinden ayırabilen hayali bir düzlemin çizilmesine dayanmaktadır (Vapnik, 1995).

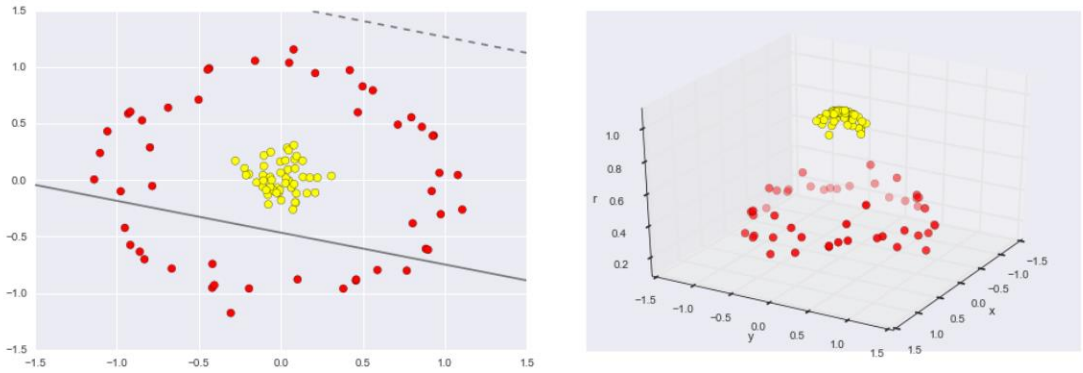
Bu yöntem kernel (çekirdek) fonksiyonları kullanılarak çok boyutlu özellik uzayında çalışma özelliğine sahiptir. Sonuç olarak bu yöntemden elde edilen sonuçlar seçilen kernel türüne ve kernel parametrelerine bağlıdır (Kavzoglu ve Çölkesen, 2009).

SVM algoritmasında Şekil 5.2'de de gösterildiği gibi uzay sınıfları arasına hiper destek vektör çizgileri atarak verileri sınıflandırmaya çalışır. Bu vektör çizgilerine yakınlığına göre veriler farklı sınıflarda ele alınır. Atılan vektör çizgilerinin koordinatları sürekli güncellenerek en uygun sınıflandırma vektörü bulunmaya çalışılır.



Şekil 5.2 : Temsili bir destek vektör çizgisi (Carrasco, 2019).

Bazı sınıflandırmalar ise Şekil 5.2'de verildiği gibi doğrusal bir vektör ile ayrılmazlar. Bir veri setine baktığımızda ayırmak için ortadan yukarıya doğru bir yükselme veya aşağıya doğru çökme gibi durumlarda bir üçüncü boyut ihtiyacı doğmaktadır. Çekirdek fonksiyonu bu gibi durumlarda sınıflandırmayı daha verimli hale getirmektedir. Şekil 5.3'de bu veri seti görselleştirilmiştir (Anonim, 2019a).



Şekil 5.3 : İki boyutlu ve üç boyutlu hale görselleştirilmiş veri seti.

SVM algoritmalarında kullanılan çekirdek fonksiyonları şöyle sıralanabilir;

- Normalized Polynomial Kernel (NP)
- Polynomial Kernel (PK)
- Radial Basis Function Kernel (RBF)
- Pearson VII function based Universal Kernel (PUK)

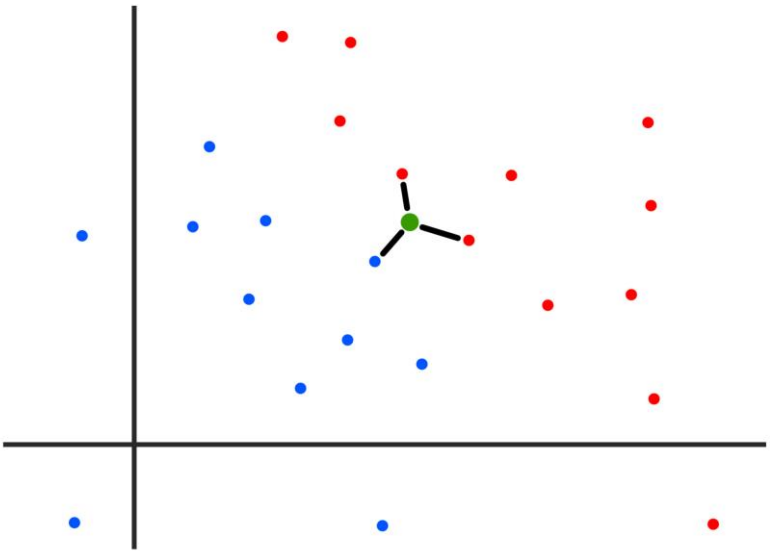
Çekirdek fonksiyonlar sınıflandırmada verileri birbirinden doğrusal (linear) ya da doğrusal olmayan (non lineer) biçimde ayrılması durumunda sınıflandırmayı daha verimli hale getirmektedir (Abakar ve Yu, 2014).

5.1.1 K-En yakın komşu algoritması

K-En yakın komşu algoritması (kNN); veri sınıflandırmasında kullanılan bu yönteme göre sınıflandırma sırasında girdi olarak kullanılan özelliklerden, sınıflandırılmak istenen yeni verinin daha önce işleme giren verilerden k tanesine veri uzayındaki yakınlığına bakılması ile yapılan sınıflandırma algoritmasıdır. kNN algoritmasın kullanmak için bir eğitime ihtiyaç duyulmamaktadır. Sınıflandırmanın başarısında komşuluk değeri etkilidir. En yakın komşuluk durumu problemden probleme değişkenlik göstermektedir (Anchalia, 2014).

Örneğin 3 komşulu (k = 3 için) yeni gelen bir veri sınıflandırılmak istenirse bu durumda eski iterasyonlarda sınıflandırılmış mevcut elemanlardan kendisine en yakın 3 tanesi ile kıyaslanır. Ele alınan bu veri hangi komşu veriye daha yakın ise o verinin

sınıfına dahil edilir. Yakınlık belirlenirken genelde öklit mesafesi kullanılmaktadır. Şekil 5.4'te örnek bir veri 3 komşu ile kıyaslanmaktadır.



Şekil 5.4 : Örnek bir komşuluk ilişki modeli.

K değeri seçilirken komşuluk açısından aynı yakınlığa düşmemesi için k değeri tek sayı olarak seçilir. Böylece yeni gelen veri mutlaka bir sınıfa daha yakın olacaktır.

5.2 Eğitim ve Test Verisi Seçiminde Kullanılan Teknikler

Sınıflandırma işleminin doğru yapılması için yapay sinir ağının eğitilmesi gerekmektedir. Eğitim için kullanmak üzere sınıflandırma veri setinin bir kısmı kullanılmaktadır. Yaygın olarak şu iki görüş benimsenmektedir.

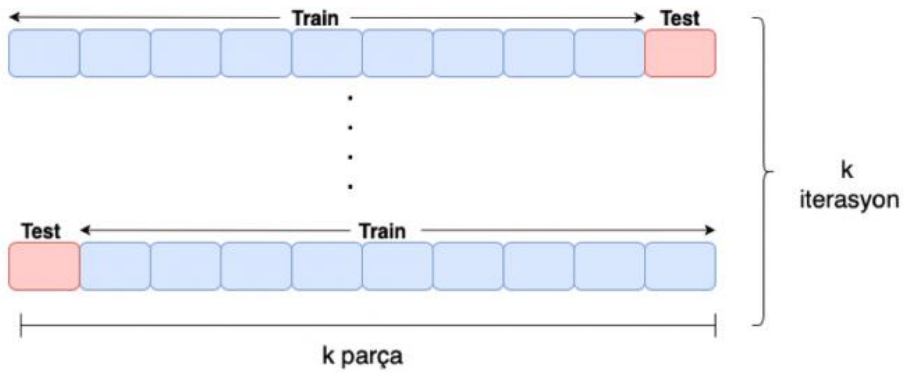
Birincisi çapraz doğrulama tekniği olup bu teknikte veri setinin %90 (katlama sayısına bağlı olarak) kısmı eğitim için, %10 kısmı ise test için kullanılmaktadır. Bu veriler 10 kez değiştirilmekte ve her seferinde test verisi farklı %10 dan seçilmektedir.

İkinci olarak veri setinin üçte ikisi eğitim için kullanılırken üçte biri de test için kullanılmaktadır. Bu oran istenildiğinde değiştirilebilmektedir. Ayrıca eğitim ve test verileri ayrı ayrı veri setleri halinde hazırlanarak da sınıflandırma yapılmaktadır.

Bu tez çalışmasında çapraz doğrulama ve karışıklık matrisi kullanılmıştır.

Literatürlerde Çapraz doğrulama yöntemi (k-fold cross) olarak isimlendirilmektedir. K kadar katlanan verilerin 1/k kadarının test diğerinin eğitim için kullanılması ile gerçekleşir. Genellikle makine öğrenmesi modellerinin başarıları analizlerinin değerlendirilmesi için kullanılır. Bu yöntemde veri seti ikiye ayrılır. Eğitim ve test seti olarak ayrılan verilerin analizinde bu yöntem çalıştırılacak algoritma modelinin başarısını önemli ölçüde etkilemektedir. Veri analizlerinde en yaygın kullanılan yöntemlerden biri veri setinin %65'i eğitim için, %35'i test için kullanıldığı yöntemlerdir. Cross Validation yönteminde ise eğitim ve test kümelerinin belirlenen k değeri adedince katlanarak değiştirilmesidir. Bu yöntem kullanılırken k değeri belirlenir. Bu k değeri kadar veri parçalanarak test ve eğitim verilerine ayrılır. Genellikle birçok yazılımda k değeri 10 olarak verilmektedir.

Şekil 5.5'de görüldüğü gibi veri seti 10 parçaya bölünmüştür. Bu verini 9 parçası eğitim verisi ve 1 parçası test verisi olarak kullanılacaktır. Bir sonraki adımda 10 parçadan ikinci parça test verisi olarak belirlenecek ve diğer 9 parça eğitim için kullanılacaktır. Her defasında bir adım kayarak tüm veriler eğitime katılmış olması sağlanacaktır. Bu yöntem verinin aynı zamanda test içinde kullanılmasını sağlamaktadır (Küçük, 2019).



Şekil 5.5 : Çapraz doğrulamada veri setinin belirlenme modeli.

Bu model sonucunda 10 farklı küme ile modeli çalıştırmış olacağız ve her bir işlemden ayrı ayrı 10 sonuç elde edeceğiz. Bu sonuçların aritmetik ortalaması alınarak hata veya başarı matrisi hakkında bir sonuca varılabilir. Bu metris doğruluk (accuracy) veya hata (error) oranı olarak karşımıza çıkacaktır. Cross validation yöntemi çok fazla tercih

edilmektedir. Bu model kullanılarak tüm veri seti üzerinde test ve eğitim işlemi gerçekleştiği için modelin başarısı üzerinde çok fazla etkilidir.

Sonuç olarak k katlamalı çapraz doğrulama yönetiminde k adedince yöntem çalıştırılır. Her adımda veri kümesinin 1/k kadarı ve daha önceki iterasyonda test için kullanılmamış parçası test için kullanılmaktadır. Geri kalan kısmı eğitim için kullanılır.

5.3 Karışıklık Matrisi (Confusion Matris)

Bir karışıklık matrisi, gerçek değerlerin bilinmekte olduğu bir dizi eğitim ve verisi üzerinde, herhangi bir sınıflandırma tekniğinin performansını tanımlamak için kullanılan bir çapraz tablodur. Test veri seti üzerinde bir sınıflandırma algoritması ile gerçekleştirilen tahmini sınıflandırma ile gerçek sınıf arasındaki ilişkiyi veren matris karışıklık matrisidir (Çataloluk, 2012; Cinar ve Koklu, 2019). Karışıklık matrisini anlamak oldukça kolaydır. Çizelge 5.1'de ikili sınıflandırma için hazırlanmış bir karışıklık matrisi verilmiştir. Çizelge 5.2'de çok sınıflı bir veri modelini sınıflandırma için kullanılan karışıklık matrisi verilmiştir (Hossin ve Sulaiman, 2015; Çınar, 2019).

Çizelge 5.1 : İkili sınıflandırma için hazırlanmış karışıklık matrisi.

		Tahmini Sınıf	
		Pozitif	Negatif
Gerçek Sınıf	Pozitif	Doğru Pozitif (DP)	Yanlış Negatif (YN)
	Negatif	Yanlış Pozitif (YP)	Doğru Negatif (DN)

Çizelge 5.2 : Çok sınıflı sınıflandırma için hazırlanmış karışıklık matrisi.

		Tahmini Sınıf				
		C_1	C_2	C_3	***	C_n
Gerçek Sınıf	C_1	D_1	Y_{12}	Y_{13}	***	Y_{1n}
	C_2	Y_{21}	D_2	Y_{23}	***	Y_{2n}
	C_3	Y_{22}	Y_{32}	D_3	***	Y_{3n}
	***	***	***	***	***	***
	C_n	Y_{n1}	Y_{n2}	Y_{n3}	***	D_n

(C: Sınıf, D: Doğru, Y: Yanlış)

Bir sınıflandırma çalışmasının doğruluğu doğru olarak sınıflandırılan örneklerin (DP) sayısını, doğru olarak sınıflandırılan ancak doğru olmayan örneklerin (DN) sayısını ve sınıfa yanlış atanamış örnekleri (YP) veya sınıf örnekleri olarak tanınmayan (YN) örnekleri hesaplayarak değerlendirilir (Sokolova ve Lapalme, 2009).

Karışıklık matrisinden hesaplanan bazı oranlar vardır. DP, DN, YP ve YN'nin birbirleriyle ilişkisini gösteren bu terminolojiler Denklem 5.1'de verilmiştir (Özkan ve diğerleri, 2017).

$$Toplam\ örnek = \mathrm{DP} + \mathrm{DN} + \mathrm{YP} + \mathrm{YN} \qquad 5.1$$

Doğruluk (Accuracy): Sınıflandırma yönteminin ne sıklıkta doğru tahmin ettiğini göstermektedir. Toplam pozitif ve toplam negatiflerin toplamının tüm veri seti sayısına bölünmesi ile hesaplanmaktadır (Denklem 5.2).

$$Doğruluk = \frac{\mathrm{DP} + \mathrm{DN}}{\mathrm{DP} + \mathrm{DN} + \mathrm{YP} + \mathrm{YN}}\ x\ 100 \qquad 5.2$$

Doğru Pozitiflerin Oranı (True Possitive Rate): Doğru pozitiflerin oranı (DPO) sınıflandırma fonksiyonunun ne kadar gerçekte pozitif olan değeri doğru şekilde tahmin ettiğinin bir ölçüsüdür (Denklem 5.3).

$$TP\ Rate = \frac{\mathrm{DP}}{TP + FN}\ x\ 100 \qquad 5.3$$

Yanlış Pozitiflerin Oranı (False Possitive Rate): Yanlış pozitiflerin oranı (YPO) Gerçekte değeri sıfır olmasına rağmen bir şeklinde tahmin edilen nesnelerin oranıdır (Denklem 5.4).

$$FP\ Rate = \frac{\mathrm{DN}}{\mathrm{YP} + \mathrm{DN}}\ x\ 100 \qquad 5.4$$

Hatırlama (Recall) : Hatırlama değeri tüm pozitif sınıflardan ne kadar doğru tahmin ettiğimizi gösterir (Denklem 5.5). Hatırlama ne zaman pozitif olduğu, ne sıklıkta doğru tahmin ettiği hakkında bir fikir verir. Bu değer başarı için mümkün olduğunca yüksek olmalıdır.

$$\mathrm{Hatırlama} = \frac{\mathrm{DP}}{\mathrm{DP}\ +\ \mathrm{YN}}\ x\ 100 \qquad 5.5$$

Hassasiyet (Precision): Tüm veri sınıflarından, doğru tahmin edilen veri adedinin bir ölçüsüdür (Denklem 5.6). Bu değerin en yüksek olması beklenir.

$$Hassasiyet = \frac{\mathrm{DP}}{\mathrm{DP} + \mathrm{YP}} x\ 100 \qquad 5.6$$

Kappa Katsayısı (Cohen's Kappa): Sınıflandırıcının performansının bir göstergesidir. Diğer bir deyişle, doğruluk ve boş hata oranı arasında büyük bir fark varsa, bir modelin yüksek bir Kappa puanı olacaktır. Cohen's Kappa sadece iki sınıflandırıcı arasında karşılaştırma yapmaya yarar, eğer ikiden fazla sınıflandırıcı varsa Fleiss's Kappa kullanılır.

F1 Puanı (F1 Score): Bu değer, doğru pozitif değerlerin oranları ve oluşan hassasiyetin harmonik ortalaması ile hesaplanır (Denklem 5.7). Sınıflandırma fonksiyonunun ne kadar performanslı olduğunun bir ölçüsüdür ve sınıflandırma fonksiyonlarının kıyaslanmasında sıklıkla kullanılır.

$$\text{F1 Puanı} = \frac{2 \text{ x Hassasiyet x DPO}}{\text{Hassasityet} + \text{DPO}} x\ 100 \qquad 5.7$$

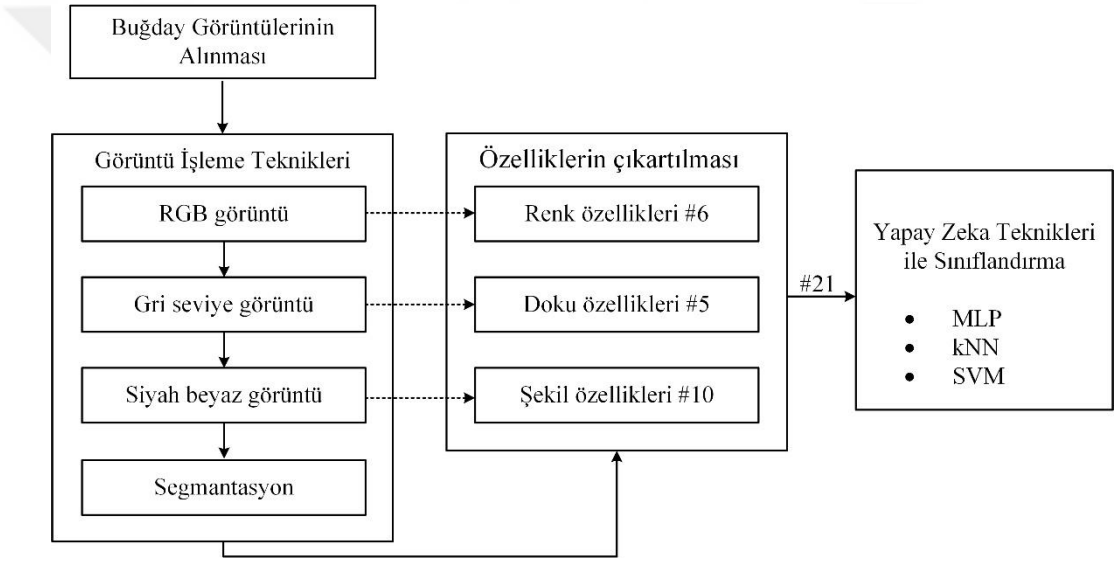
MCC (Matthews Correlation Coefficient): MCC, 1975 yılında biyokimyacı Brian W. Matthews tarafından bulunan makine öğrenmesi algoritmalarında kullanılan bir sınıflandırma kalite ölçüm aracıdır (Matthews, 1975). MCC, onlarca yıl önce geliştirilen Karl Pearson'un phi katsayısına eşdeğer bir katsayı olsa da MCC terimi birçok sınıflandırma çalışmasında yaygın olarak kullanılmaktadır (Cramir, 1946). MCC katsayısının hesaplaması Formül 5.8'de gösterilmiştir.

$$\text{MCC} = \frac{DP\ x\ DN - YP\ x\ YN}{\sqrt{(DP + YP)(DP + YN)(DN + YP)(DN + YN)}} \qquad 5.8$$

6. MATERYAL VE METOT

Bu çalışmada 10 faklı buğday çeşidine ait buğday tanelerinin görüntüleri alınmış, bilgisayar ortamında görüntü işleme yöntemleri kullanılarak buğday tanelerinin şekil, renk ve doku özellikleri çıkarılarak bir veri seti oluşturulmuştur. Bu veri seti üzerinden MLP, SVM ve kNN yapay zeka teknikleri kullanılarak buğdaylar sınıflandırılmıştır.

Kullanılan donanım ve yazılımlar, buğdayların seçilmesinden görüntülerin alınmasına, görüntülerin işlenmesinden veri setinin oluşturulmasına ve yapay zeka teknikleri kullanılarak sınıflandırılmasına kadar tüm süreçte kullanılan materyal ve metot aşağıda detaylı olarak verilmiştir. Şekil 6.1'de çalışmaya ait blok diyagram verilmiştir.



Şekil 6.1 : Çalışmaya ait blok diyagram.

6.1 Buğdayların Seçilmesi ve Tanelerin Hazırlanması

Çalışmada kullanılacak olan 10 farklı çeşit buğday numuneleri Karaman Ticaret Borsası'ndan ve Karamanoğlu Mehmetbey Üniversitesi Biyomühendislik Bölümü'nden temin edilmiştir. Buğdaylar çeşitlerine göre ayrı kaplara konularak etiketleme yapılmıştır. Her çeşit buğday için öncelikle eleme işlemi gerçekleştirilmiş, her buğday çeşidi 2,2 mm, 2,5 mm ve 2,8 mm olarak ayrılmıştır. 2,2 mm olan buğdaylar çok küçük olduğu, kırık parçalar içerdiği ve şekilleri bozuk olduğundan dolayı tercih edilmemiştir. Görüntü almak üzere sadece 2,5 ve 2,8 mm lik buğdaylar

kullanılmıştır. Çizelge 6.1'de buğday isimleri ve türleri verilmiştir. Bu çizelgede kullanılan çeşit numarası, sınıflandırma boyunca buğday çeşidini, tür kodları ekmeklik ya da makarnalık olma durumunu temsil edecektir. 2,5mm ve 2,8 mm olan buğdaylar Şekil 6.2'de görüldüğü gibi paketlenmiştir.

Çizelge 6.1 : Çalışmada kullanılan buğday çeşitleri ve türleri.

ÇEŞİT NO	BUĞDAY ADI	TÜR	TÜR KODU
1	Eminbey	Makarnalık	1
2	Cumhuriyet-75	Ekmeklik	2
3	Nevzatbey	Ekmeklik	2
4	Alpu 2001	Ekmeklik	2
5	Cesare	Makarnalık	1
6	Çesit-1252	Makarnalık	1
7	Bayraktar 2000	Ekmeklik	2
8	Kunduru-1149	Makarnalık	1
9	Kızıltan-91	Makarnalık	1
10	Esperya	Ekmeklik	2



Şekil 6.2 : Elenmiş ve çeşitlerine göre ve paketlenmiş buğdaylar.

6.2 Kamera ve Lens

Buğday görüntülerinin alınması için BASLER marka acA2500-14uc model CMOS kamera kullanılmıştır. Kameraya ait teknik özellikler Çizelge 6.2'de, kameranın önden ve arkadan görünüşü Şekil 6.3'de verilmiştir. Kameranın bilgisayara bağlanabilmesi için bilgisayarda USB 3 genişleme yuvası olması gerekmektedir (Anonim, 2018).

Çizelge 6.2 : Basler acA2500-14uc kamerasına ait teknik özellikleri.

Özellik	Değer	Özellik	Değer
Arayüz	USB3 Vision	FPS	14
Format	1/2.5 in.	Sensör tipi	CMOS Rolling Shutter
Lens Montaj	C-Mount	Sensor	MT9P031
Çözünürlük MP	5	Piksel ara (µm) :	2.2 X 2.2
Çözünürlük	2592 x 1944	U X G X Y (mm) :	48.2 X 29 X 29
Çalışma sıcaklığı	0 - 50 °C	Otomatik Iris	Yok



Şekil 6.3 : Basler acA2500-14uc kamera önden ve arkadan görünüşü.

Bu kameranın görüntü alması için ek olarak 6mm BASLER marka C125-0618-5M F1.8-f6mm model lens kullanılmıştır (Şekil 6.4). Bu lens üzerinde manuel diyafram kontrolü, manuel netleme özelliği bulunmaktadır. Lens bombesi yapmadan görüntü alma özelliğine sahip bir lenstir.

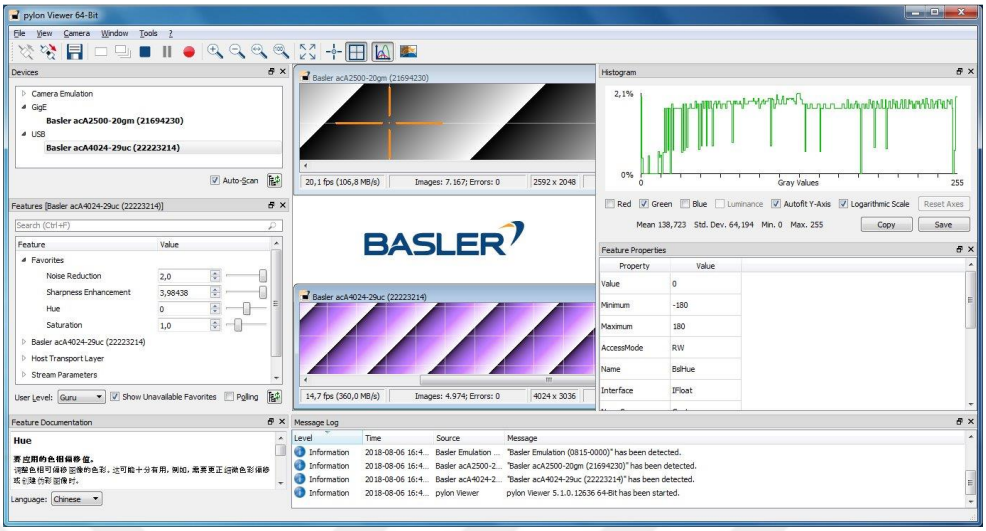


Şekil 6.4 : Basler C125-0618-5M model F1.8 f6mm lens.

6.3 Kullanılan Görüntü Alma Yazılımı

Görüntüler alınırken BASLER firmasının orijinal yazılımı olan *Basler Pylon 5* yazılımı kullanılmıştır. Uygulama birçok işletim sistemini (Windows, macOS, Linux (ARM), Linux (x86)) desteklemektedir. Hangi kamera bağlantı ara yüzü (GigE, USB 3.0, MIPI için BCON veya LVDS için BCON) veya hangi Basler kamera veya kamera modülünün olduğu fark etmeksizin Pylon yazılımı her zaman aynı görüntüyü elde

edebilmektedir. Basler kameralar Pylon ara yüzü sayesinde gömülü sistemler üzerinden kontrol edilebilmektedir (Şekil 6.5).



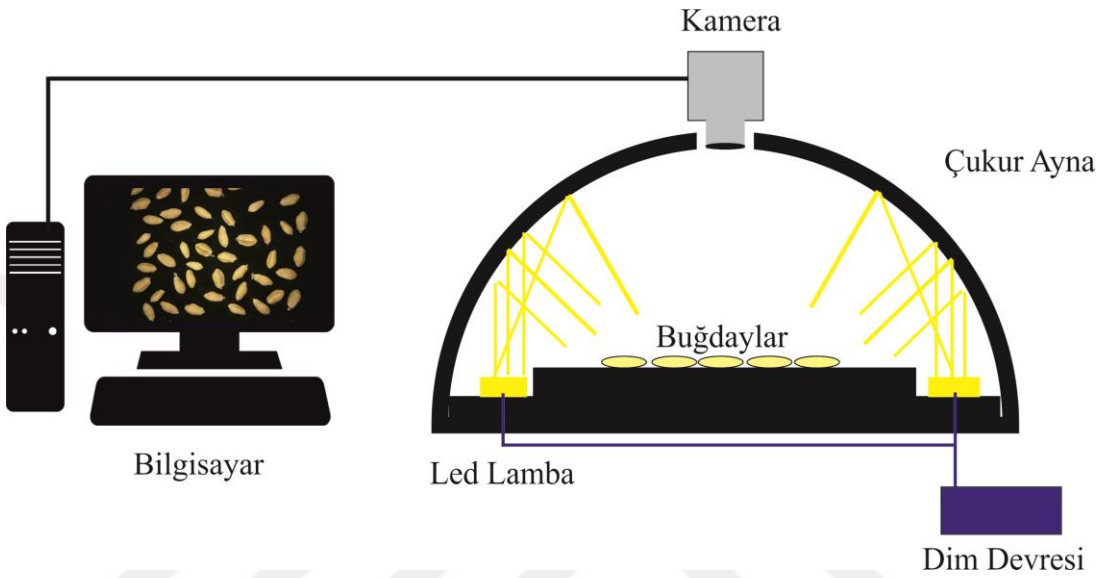
Şekil 6.5 : Pylon kamera ara yüz programı ekran görüntüsü.

Yazılım üzerinden kameranın çekimi sırasında kullandığı birçok özellik değiştirilebilmektedir. Buğday görüntüleri alınırken gerçek renklerini elde etmek için renk ayarları manuel olarak düzenlenmiştir. Yapılan renk ve ışık ayarları tüm çekimlerde sabit değerlerde tutulmuştur.

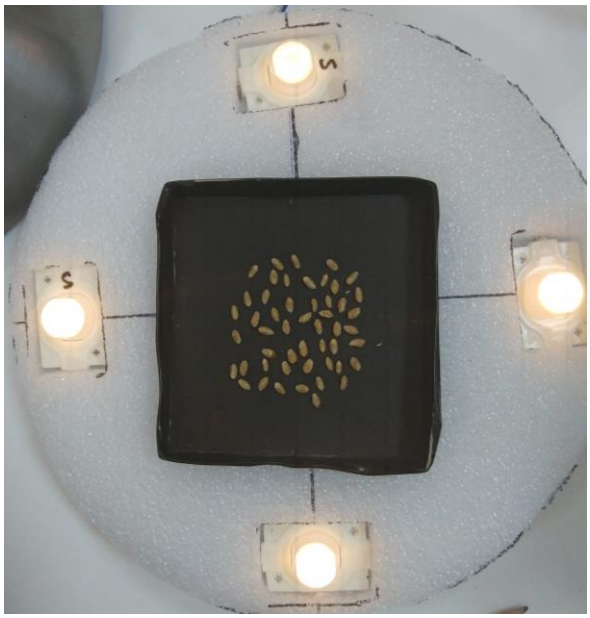
6.4 Çekim Platformunun Tasarımı

Yapılan çalışmanın dış ortam değişkenlerinden (ışık şiddeti, değişken gölgeler ve yansımalar) arınmış olarak buğday örneklerinin standart değerlerde görüntülenmesi gerekmektedir. Bu ortamın oluşturulması çekim için en önemli unsurlardan biridir. Bu standardı sağlamak için literatür taramaları sonucunda buğdayların hiç gölge oluşturmadan fotoğraflanması için bir çekim ortamı tasarlamıştır. Singh ve diğerleri (2010) ve Mandal (2018) yılında yaptıkları bilimsel çalışmalarda yer alan pirinç ve buğday fotoğrafları için oluşturdukları çekim sistemlerinden örnek alınarak çukur ayna mantığında Şekil 6.6'da görüldüğü gibi yeni bir sistem geliştirilmiştir. Gelişme süresince uygun ışık kaynağı, ışık şiddetinin ayarlanması, fotoğraf çekim yüksekliğinin sabitlenmesi, fotoğraf çekimleri sırasında kameraya direk olarak giren ışıkların oluşturduğu gürültülerin engellenmesi gibi birçok optimizasyon işlemleri gerçekleştirilmiştir. Şekil 6.7'de gösterilen led lambalar sayesinde yerden aydınlatma

sağlanmış üst kısmına kapatılan çukur aynaya ışık yansıtılarak buğdayların üzerine düşmesi sağlanmıştır. Buğdaylar en uygun odak noktasına yerleştirilerek en dengeli ışığın gelmesi sağlanmıştır. Şekil 6.6'da buğdaylarına alt kısmında görülen siyah bölge EPP köpükden oluşmuştur. Led lambalar bu köpük içine gömülmüş ve yanal ışığın buğdayların üzerine gelmesi engellenmiştir. Şekil 6.7'de led lambaların yerleşeceği oyuklar görülmektedir.



Şekil 6.6 : Buğday tanelerinin fotoğraflandığı çekim düzeneği.



Şekil 6.7 : Aydınlatma için kullanılan led lambalar.

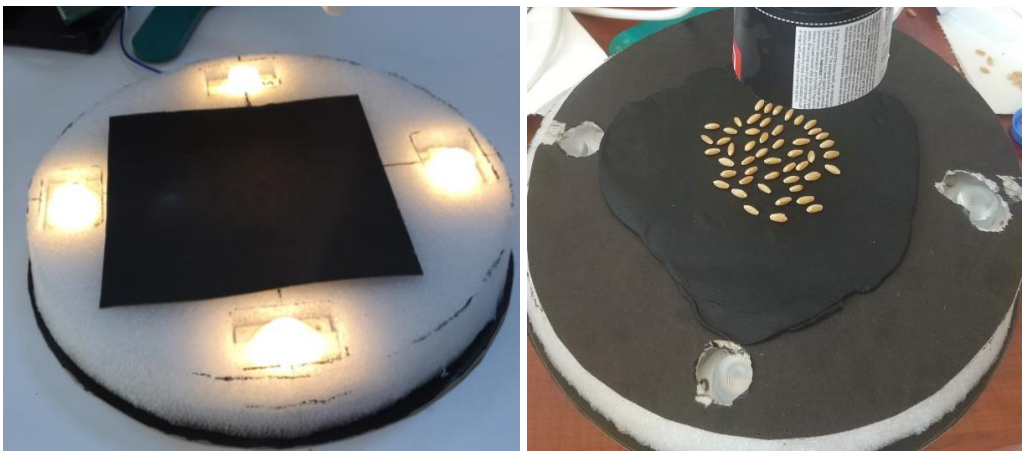
Küresel ayna için 9 cm derinliğinde 20 cm çapa sahip paslanmaz çelikten IKEA firması tarafından üretilmiş krom malzeme kullanılmıştır (Şekil 6.8). Ürünün çukur kısmının orta noktasına 80 mm çapında bir delik açılarak kameranın bu delikten görüntü alması sağlanmıştır. Bu delikten kamera ile çekim yapılmış ve kameranın yüksekliği bir kamera tutucu yardımıyla sabit yükseklikte ayarlanmıştır. Bu sabit yükseklik değerine göre kameranın manuel netleme özelliği sayesinde kamera en net noktasına getirilmiştir. Bu ölçü ve uzaklıklar tüm çekimler boyunca sabit tutulmuştur.



Şekil 6.8 : Çekim yapılan nesneler üzerine kapatılan çukur ayna.

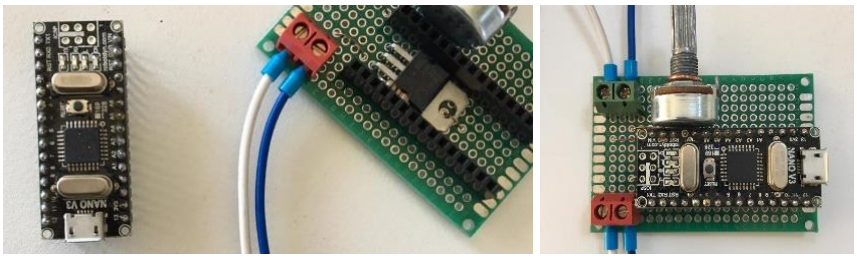
Geliştirilen bu yeni sistemi diğerlerinden ayıran özellik kullanılan led teknolojisine sahip aydınlatma ve bu lambaların şiddetinin ayarlanabilir olmasıdır. Dört adet led ışık EPP köpük taban içerisine yerleştirilerek zemine sabitlenmiştir (Şekil 6.9). Fotoğraflama esnasındaki kameraya gelen ışık parlamalarını önlemek için zemin siyah mat karton ile kaplanmıştır. Buğdayların sırt ve karın üzerine oturmalarını sağlamak için altına siyah oyun hamuru kullanılmış ve oyun hamuruna sabitlenmiştir. Siyah tercih edilmesinin diğer bir nedeni görüntü işlenirken ikili (siyah-beyaz,0-1) formatına çevrime işleminde oluşabilecek gürültülerin engellenmesi içindir. Oyun hamurunun

siyah olması buğdayların mevcut yüzeylerinde siyah bölgelerin olmaması görüntünün zeminden net olarak ayrılmasını sağlamaktadır.



Şekil 6.9 : Çekim ortamı aydınlatma düzeneği.

Led lamba teknolojisinde voltaj azaltılarak dim (şiddet azaltma) işlemi şiddetinde kısma açma yapılamamaktadır. Ancak led ışıkların ışık şiddetinin ayarlanması için ledlere geren voltajın sıklığını değiştirerek led lambanın daha zayıf yanması sağlanabilmektedir. Bu işlemi gerçekleştirmek için led ışıkları kontrol eden bir devre tasarlanmıştır. Bu basit devre tasarımı ile ışık şiddeti buğdayların detaylarını yok etmeyecek şekilde kısılmış ve sabitlenmiştir. Devre için 1kΩ'luk direnç, 10KΩ'luk potansiyometre, çift taraflı delikli plaket ve TIP41C transistör kullanılmıştır (Şekil 6.10). Arduino nano kontrol kartında PWM pinleri kullanılarak analog olarak potansiyometreden okunan değer PWM sinyanline çevrilerek ledlerin dimlenmesi sağlanmıştır. Bu sayede buğdayların üzerine düşürülen ışığın buğday görüntüsünde fazla ışık şiddetinden kaynaklı parlamalar giderilebilmiş ve kameradan alınacak olan en net görüntü elde edilmiştir. Potansiyometrenin sabitlenmesi ile çekilen her bir resim için ortam ışık şiddeti eşit şekilde tutulmuştur. Işık şiddetinin değişmemesi görüntü işleme tekniklerinde farklı renk ve doku özelliklerinin ortaya çıkmasına neden olacağından çok önemlidir. Şekil 6.11'de dimmer devresi öncesi ve sonrası buğdaylar üzerine düşen ışık gösterilmektedir.



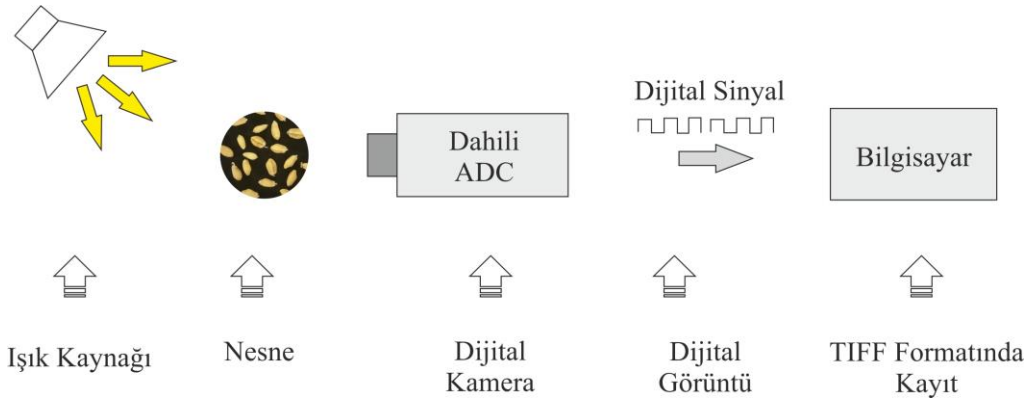
Şekil 6.10 : Işık şiddetini ayarlayan dimmer devresi.



Şekil 6.11 : Dimmer devresi öncesi ve sonrası buğday görüntüleri.

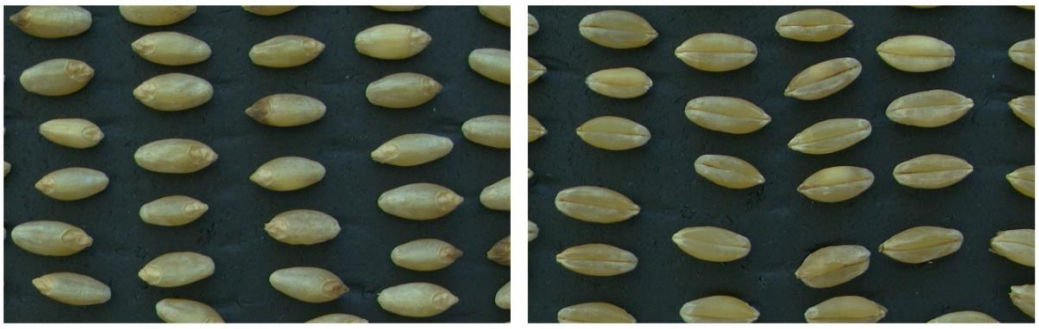
6.5 Buğday Görüntülerinin Elde edilmesi

Buğdayların görüntülerinin alınması için hazırlanan düzenek temelde bir buğday görüntüsü üzerine yeteri kadar ışık düşürerek buğdayların dijital bir kamera ve buna bağlı lens yardımıyla görüntülenmesini sağlamaktadır. Görüntüler kamera içerisinde bulunan dahili Analog Dijital Çevirici (DAC) yardımıyla sayısal hale getirilmektedir. Bu sayısal bilgi USB 3.0 arayüzü aracılığıyla bilgisayar ortamına aktarılmakta ve görüntüler kaliteli TIFF formatonda bilgisayara kaydedilmektedir. Şekil 6.12'te görüntülerin sayısallaştırılma süreci gösterilmiştir.



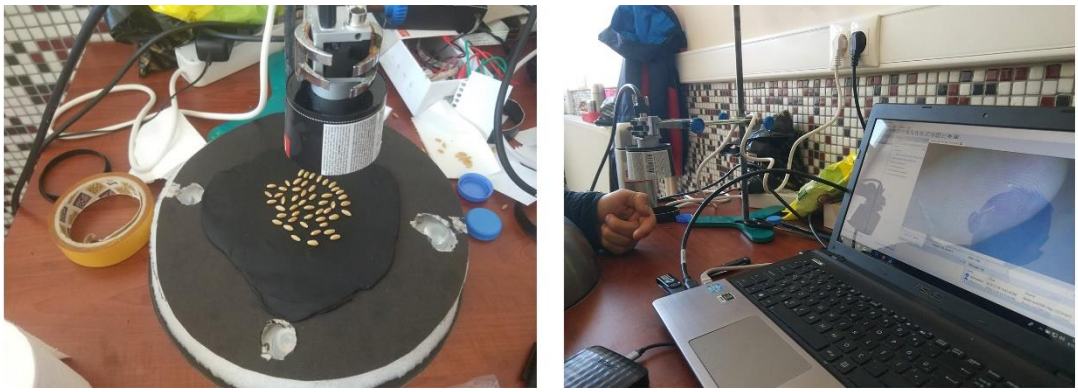
Şekil 6.12 : Görüntülerin dijital ortama aktarılması.

Çekim düzeneği üzerine aynı çeşitten olan buğdaylar Şekil 6.13'de görüldüğü gibi birbirlerine temas etmeyecek şekilde dizilmiştir. Daha sonra düzeneğin üzerindeki çelik küresel ayna kapatılarak delikten kamera yardımıyla fotoğraflar çekilmiştir. İlk dizilimde buğdaylar sırt üstü şekilde fotoğraflanmış sonra aynı buğdaylar karın üstü getirilerek tekrar fotoğraflanmıştır.



Şekil 6.13 : Karın üstü ve sırt üstü dizilmiş buğday taneleri.

Buğdaylardan birkaç kare çekim alındıktan sonra içerisindeki buğday taneleri çıkartılarak yeni buğday taneleri koyulmuştur. Her çekilen fotoğraf klasörlerlerle ayrılarak depolanmıştır. Her buğdaydan 2,5 mm ve 2,8 mm boyutunda ve hem sırt üzeri hem karın üzeri olmak üzere dört adet fotoğraf alınmıştır. Her bir dizilimde yaklaşık 50 adet buğday koyulmuş, böylece her buğday çeşidinden 200 adet buğdayın fotoğraflanması sağlanmıştır. Fotoğraf çekimlerinde sabit bir ışık şiddeti kullanılmıştır. Fotoğrafların çekimden sonra kaliteleri test edilmiş titreme ve bulanıklaşma gibi durumlarda fotoğraf çekimleri tekrarlanmıştır. Şekil 6.14'te buğday görüntü alma düzeneği verilmiştir.



Şekil 6.14 : Buğday görüntü alma düzeneği.

6.6 Görüntü İşleme Yazılımı ve Kullanılan Kütüphaneler

Görüntü işleme sürecinde Python programlama dili üzerinde kodlama yapılmış ve gerekli görüntü işleme kütüphaneleri çağrılmıştır. Bunlardan ilki OpenCV'dir. OpenCV birçok programlama dili üzerinde çalışmaktadır. Bilimsel çevrelerce kabul görmüş, hızlı ve esnek programlama dili olan Python tercih edilmiştir. Bu tez çalışmasında Python dilinin en son versiyonlarından olan 3.6 versiyonu kullanılmıştır.

Dizi kontrolünü sağlamak için NumPy kütüphanesi kullanılmıştır. Matplotlib kütüphanesi Python için en popüler veri görselleştirme paketlerinden biridir. PyLab aslında Matplotlib'in içine yerleştirilmiştir ve kullanıcı için Matlab programına benzer bir deneyim sunar. Matplotlib ve NumPy kütüphanelerini kullanan PyLab kütüphanesi very görselleştirme ve modellemede önem arz etmektedir.

Imutils kütüphanesi, OpenCV ve Python 3 ile çeviri, döndürme, yeniden boyutlandırma, iskeletleştirme ve Matplotlib görüntülerini daha kolay görüntüleme gibi temel görüntü işleme işlevlerini yapmak için bir dizi kullanışlılık işlevi sağlamaktadır.

Argparse kütüphanesi, kullanıcı dostu komut satırı arayüzleri yazmayı kolaylaştıran bir kütüphanedir.

Python'da kullanılan en önemli kütüphanelerden biri de Math kütüphanesidir. Math kütüphanesi en popüler matematiksel işlevlerden bazıları tanımlanmıştır.

Bu tez çalışmasında OpenCV, Numpy, Pylab, Math, Matplotlib, Argparse, imutils, scikit-image, openpyxl kütüphaneleri kullanılmıştır. Projede görüntülerin işlenmesinde en önemli kütüphane OpenCV kütüphanesidir. Şekil 6.15'de python dili ile yazılan programdan bir ekran görüntüsü verilmiştir.

```python
import cv2
import numpy as np
import pylab
import math
from matplotlib import pyplot as plt
import argparse
import imutils
import os
import openpyxl
from skimage import data
from skimage import io
from skimage import feature, io

#from PyQt5.QtWidgets import QWidget, QApplication, QLabel, QPushButton, QVBoxLayout
from PyQt5.QtWidgets import*
from PyQt5.QtCore import*

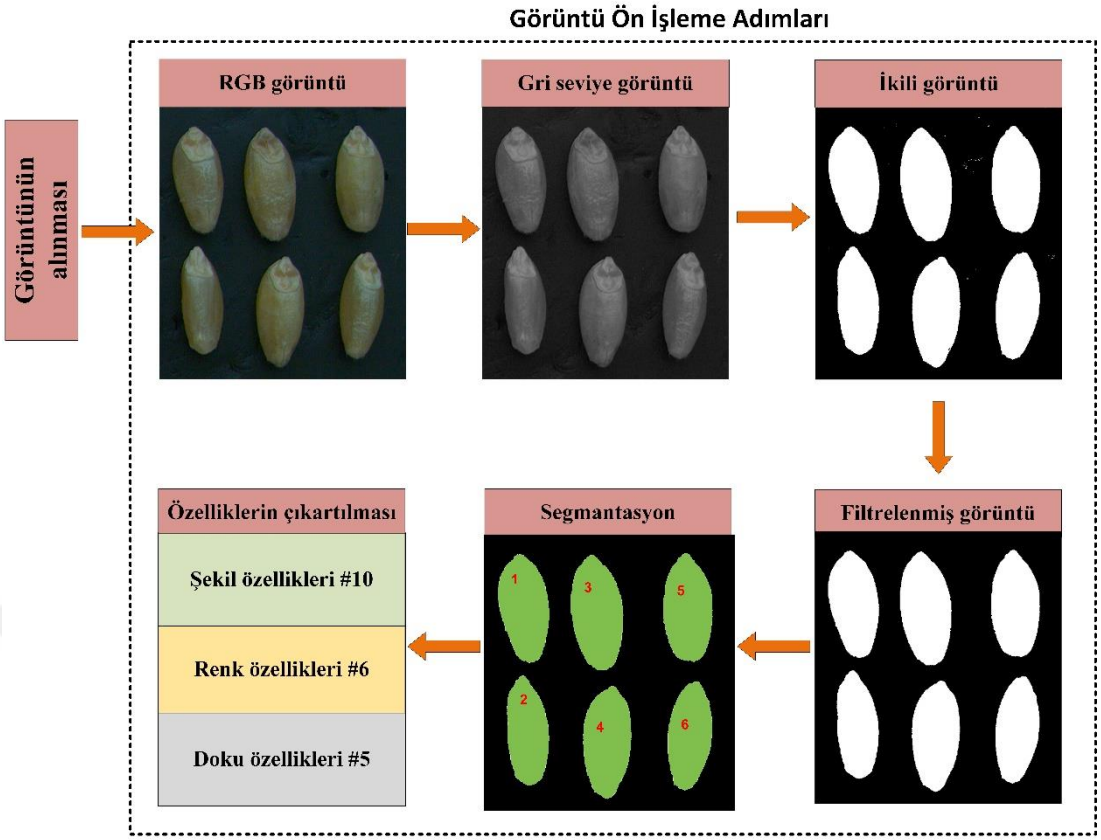
#Standart Değişkenler
buyutmeKatsayisi=1
merkezNoktasi = 5
maxHuMoment=0.25;
minHuMoment=0.2;
wheatStatus = "Standart"
```

Şekil 6.15 : Python dili ile yazılan programdan bir görüntü.

6.7 Görüntü Ön İşleme Adımları

TIFF dijital fotoğraf formatında çekilen buğday fotoğrafları ayrı ayrı klasörlerde depolanmıştır. Görüntü işleme yazılımı ile tüm buğday görüntüleri otomatik bir döngü ile tek tek açılarak her buğday tanesinin özellikleri görüntü işleme teknikleri kullanılarak çıkartılmıştır.

Buğday fotoğrafları hazırlanan bu yazılımda otomatik açılarak her buğday tanesine ait şekil, renk ve doku özellikleri çıkartılmakta ve Microsoft Excel dosya formatında bilgisayara kaydedilmektedir. Buğday tanelerine ait özellikleri elde edilmesi için gerçekleştirilen görüntü işleme aşamaları Şekil 6.16'da verilmiştir.

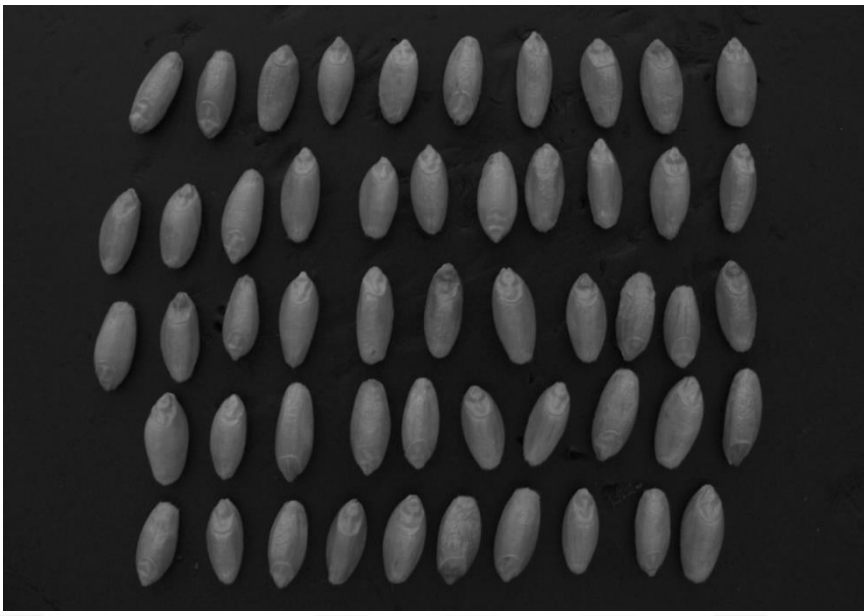


Şekil 6.16 : Buğday görüntülerinin işleme aşamaları.

6.7.1 Buğday görüntülerin gri seviyeye dönüştürülmesi

Kamera ile çekilen RGB buğday görüntüleri Python programlama dili ve OpenCV kütüphanesi kullanılarak hazırlanan görüntü işleme yazılımında gri seviyeli görüntüye dönüştürülmüştür.

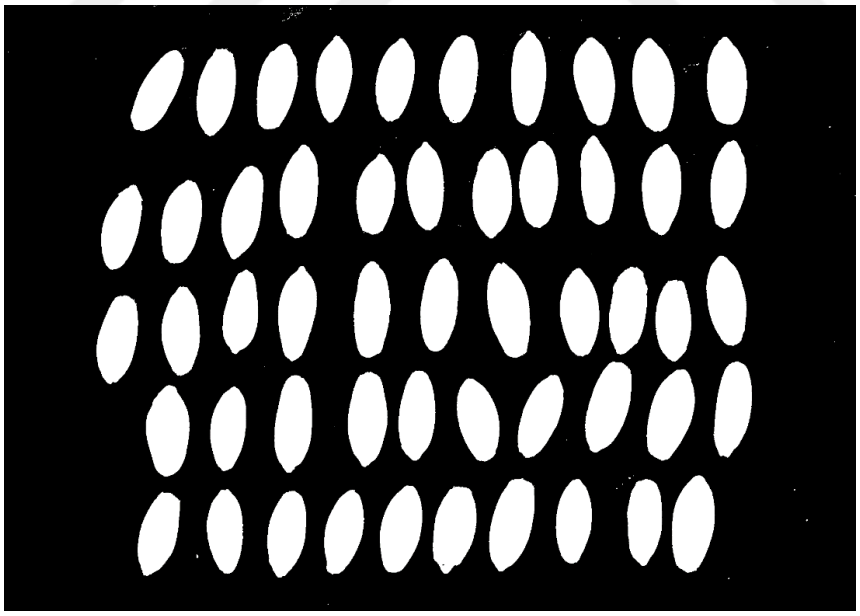
Bir çeşide ait buğday fotoğrafları tek tek yazılımda otomatik olarak açılmıştır. Açılan her buğday fotoğrafı önce Şekil 6.17'de görüldüğü gibi gri seviyeli görüntüye dönüştürülmüştür.



Şekil 6.17 : Buğdaylara ait gri seviye görüntü.

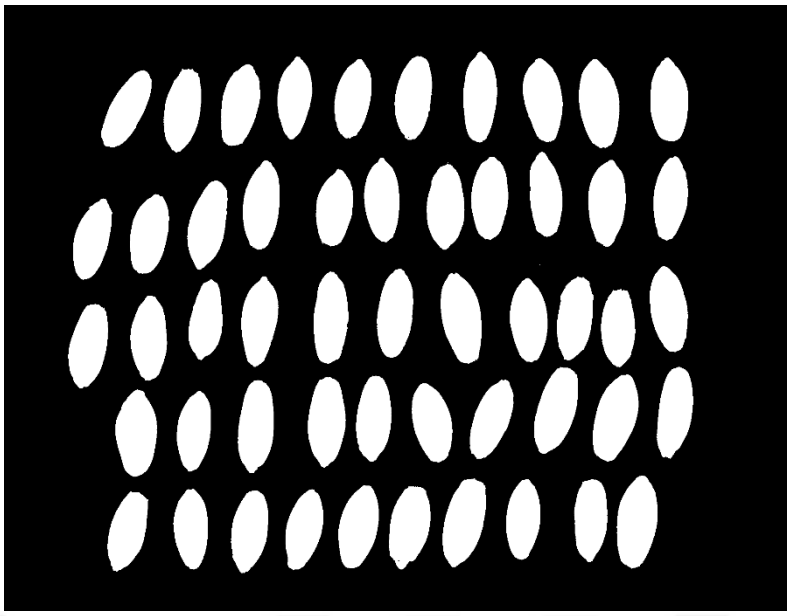
6.7.2 Gri seviyeli buğday görüntülerinin ikili görüntüye dönüştürülmesi

Gri seviyeye çevrilen buğday görüntüleri *threshold()* komutu THRESH_BINARY parametresi kullanılarak ikili (siyah-beyaz) görüntüye çevrilmiştir. Bu komut ve parametre sonucunda Şekil 6.18'de buğdaylara ait ikili görüntü verilmiştir.



Şekil 6.18 : Buğdaylara ait ikili (siyah-beyaz) görüntü.

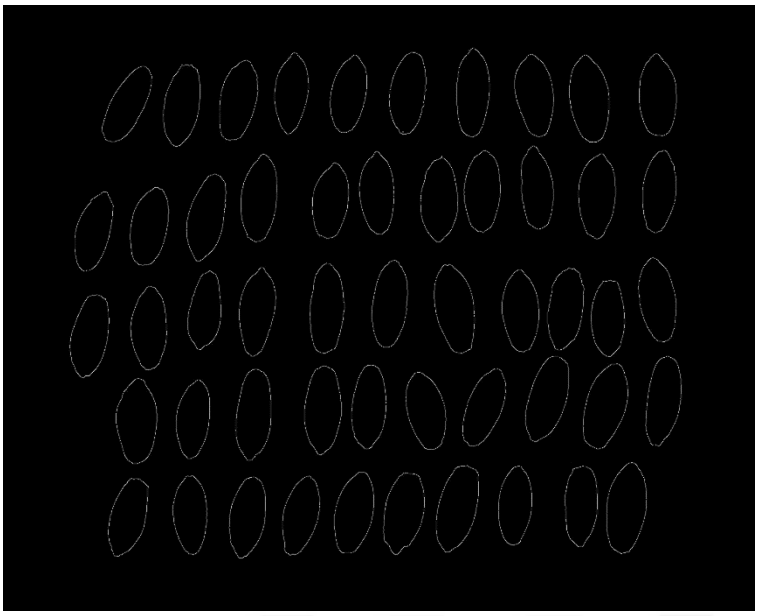
İkili görüntüde bulunan gürültüler Şekil 6.19'da görüldüğü gibi filtrelenerek temizlenmiştir.



Şekil 6.19 : Buğdaylara ait filtrelenmiş görüntü

6.7.3 Sınırların tespiti

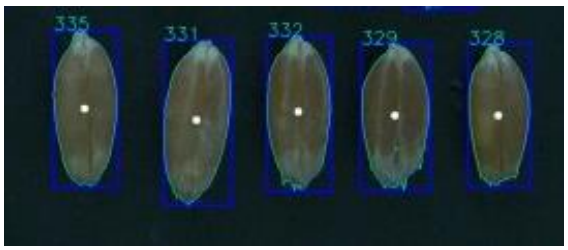
OpenCV'de *cv2.findContours()* komutu kullanılarak eşik değerlerine göre tespit edilmiş beyaz bölgelerin sınırları çizilmiştir. Bulunan bu sınırlar buğdayın görüntü içerisindeki her bir sınır piksel değerinin x ve y cinsinden konumunu vermektedir. Bu sınırların piksellerinin x ve y koordinat değerleri görüntü işleme yazılımında bir veri dizisinde saklanmış ve bu veri dizisi bir döngüye sokularak her buğday tanesi bulunmuştur. Buğdayların kapladıkları alan kadar yer kaplamayan fotoğraftaki çeşitli nesne, toz vb. hatalar yazılım yardımıyla yok sayılmış ve görüntüden çıkarılmıştır. Şekil 6.20'da Buğday sınırlarının orijinal görüntü üzerinde gösterimi sağlanarak doğruluk test edilmiştir. Görüntüde sınır çizgileri yeşil renkte ince bir çizgi şeklinde gösterilmiştir. Nesnelerin hatalı tespiti söz konusu olduğunda eşik değerleri değiştirilerek program tekrar çalıştırılmış ve görüntüler tekrar işlenmiştir.



Şekil 6.20 : Buğday sınırlarının orijinal görüntü üzerinde gösterimi.

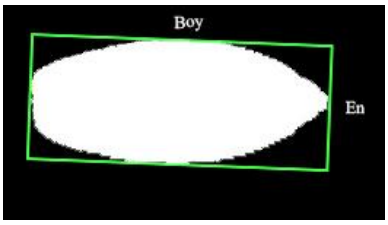
6.7.4 Buğday tanelerinin görüntüde belirlenmesi

Buğday görüntüsü üzerinden elde edilen sınır çizgileri her bir buğday tanesini temsil etmektedir. Görüntü işleme yazılımında bu dizi bir döngüye sokularak döngü içinde sayılmış, işaretlenmiş ve dikdörtgen içerisine alınmıştır. Şekil 6.21'de görüldüğü gibi buğday taneleri hangi açıyla dizilirse dizilsin çizdirilen dikdörtgenler buğday tanesini içine alacak şekilde yazılım içerisinde hesaplanarak çizdirilmiştir.



Şekil 6.21 : Buğdayların dışına çizilen dikdörtgenler.

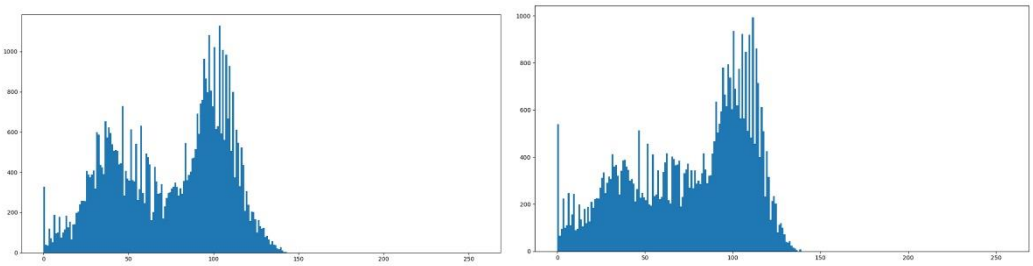
Çizilen dikdörtgenlerin en ve boyu buğdayların en ve boylarının hesaplanmasında kullanılmıştır. Şekil 6.22'de örnek bir dikdörtgen içinde buğday tanesi görülmektedir.



Şekil 6.22 : Buğdayın en ve boyunu ölçmek için kullanılan dikdörtgen.

6.7.5 Histogram

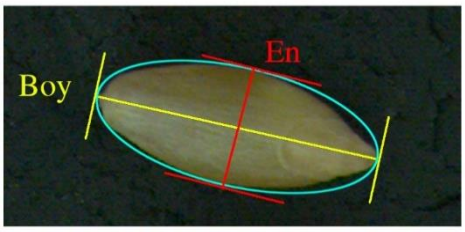
Buğday tanelerinin her birinin histogram grafiği çıkarılmıştır. Her bir buğday tanesinin 0-255 arası renk dağılımı Şekil 6.23'de görüldüğü gibi farklı çıkmaktadır. Çıkarılan histogramda buğday renkleri siyaha daha yakın çıkmakta ancak orta tonlarda yoğunlaşmaktadır. Bu durum buğday tanelerinden elde edilen renk örneklerinin doğruluğunu göstermektedir. Bu çalışmada histogram, sadece çalışmanın sağlıklı ilerleyip ilerlemediğini kontrol etmede kullanılmıştır (Zhu ve Zhang, 2010).



Şekil 6.23 : İki farklı buğday tanesine ait histogram grafiği.

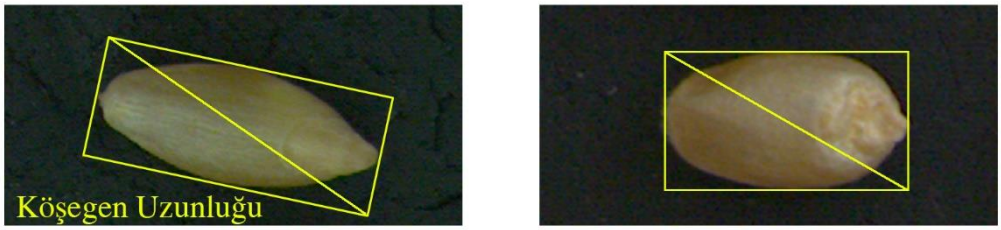
6.8 Şekil Özelliklerinin Çıkarılması

Görüntü işleme teknikleri kullanılarak her bir buğday tanesine ait 10 farklı şekil özelliği çıkarılmıştır. Buğday tanelerinin görüntüdeki duruş açısı ne olursa olsun çizilen dikdörtgenin buğday tanesini tam olarak içine alacak şekilde olması sağlanmıştır. Bu dikdörtgenin kısa kenarı buğdayın enini, uzun kenarı ise boyunu belirlemektedir. Şekil 6.24'deki gibi en ve boy değerleri tespit edilmiştir. En ve boy birbirine bölünerek bu oran bulunmuştur. En, boy ve en boy oranı özellikleri veri setine eklenmiştir.



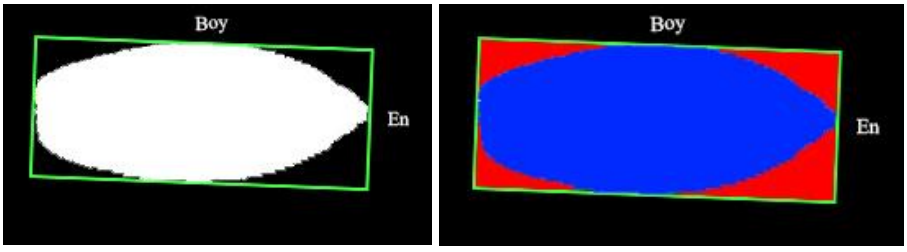
Şekil 6.24 : Buğdayın en ve boyunun hesaplanması.

Şekil 6.25'de görüldüğü gibi bir buğdayın etrafına çizilen bir dikdörgenin iki köşesi arasında çizilecek bir köşegen ile buğdayın uzun ya da kısa boylu olduğuna dair bilgi toplanabilmektedir. Bu köşegen değeri değeri en ve boy özelliklerinden hesaplanarak çıkarılmıştır.



Şekil 6.25 : Buğdaylardan alınan köşegen uzunluğu.

Buğday tanesinin çılız ya da dolgun olduğun tespit etmek için bu yöntem geliştirilmiştir. Bu değer, buğday tanesinin kapladığı alanın, buğday tanesinin dışına çizilen dikdörtgenin alanına oranlanması ile elde edilmiştir. Bu değer buğday tanesinin ne kadar şişman ya da cılız olduğunu anlamaya imkan vermektedir. Şekil 6.26'de görüldüğü üzere kırmızı bölgelerin fazla olması buğdayın cılız olduğunu göstermektedir.



Şekil 6.26 : Buğday tanelerinin dolgunluk hesaplanması.

Köşegen değeri, buğdayın ince uzun, ya da kısa tombul olduğunu temsil eden bir değerdir. Dolgunluk değeri ise buğdayın şişman oluşu ile alakalı bir değer olduğundan bu iki değerin Denklem 6.1'deki olduğu gibi birbirine oranlanması sonucu buğdaya ait

bir irilik değeri çıkarılmıştır. Bu oran irilik değeri olarak kabul edilmiş ve veri setine eklenmiştir.

$$irilik = \frac{\text{köşegen}}{\text{dolgunluk}} \tag{6.1}$$

Sınıfları tespit edilen buğday tanelerine ait görüntüde kapladıkları alan ve çevre değerleri OpenCV komutlarından *contourArea* ve *arcLength* kullanılarak elde edilmiştir. Elde edilen bu değerler alan ve çevre özellikleri olarak veri setine eklenmiştir.

OpenCV kütüphanesinin sağladığı şekil özelliklerini sayısallaştıran *HuMoment* komutu yardımıyla buğdaylardan şekilsel özellikleri alınmıştır. Görüntü Momentleri, görüntü piksel yoğunluğunun ağırlıklı bir ortalamasıdır. *HuMoments()* fonksiyonu yardımıyla buğdaya ait şekilsel bir sayısal ifade üretilmektedir. Bu sayısal ifadeler birbirine ne kadar yakınsa buğdayların benzerlikleri o kadar yüksek olacaktır. Yedi sonuç üreten HuMoment komutundan, her buğday tanesi için en belirleyici parametre olan *HuMoment[0]* ve *HuMoment[1]* parametreleri tercih edilmiş ve veri setine eklenmiştir.

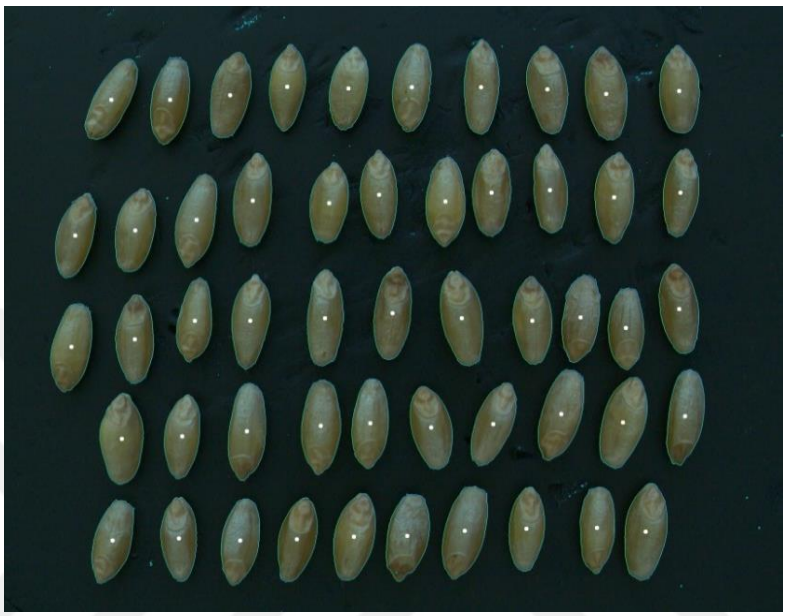
6.9 Renk Özelliklerinin Çıkarılması

Görüntü işleme teknikleri kullanılarak her bir buğday tanesinin merkezinden alınan RGB değerleri ve buğday tanesinin tamamının yüzeyinden alınan ortalama RGB değerleri çıkarılmıştır. OpenCV moment komutları yardımıyla her buğdayın merkez noktası belirlenmiştir. Moment komutunun döndürdüğü değerler ile, Formül 6.2'de hesaplanarak buğday tanesinin merkezinin x konumundaki karşılığı, Formül 6.3'de hesaplanarak y konumundaki karşılığı bulunmuştur.

$$cX = int(M["m10"] / M["m00"]) \tag{6.2}$$

$$cY = int(M["m01"] / M["m00"]) \tag{6.3}$$

Yazılımda ilk açılan orijinal resimden, bulunan bu merkez noktasına ait renk değerleri alınmış ve RGB cinsinden bir değer olarak veri setine eklenmiştir. Renk okunan resme herhangi bir renk ve görüntü işleme işlemi uygulanmamıştır. Şekil 6.27'de buğdayların merkezleri işaretlenmiş ve bu noktanın RGB değerleri merkez renk olarak alınmıştır.



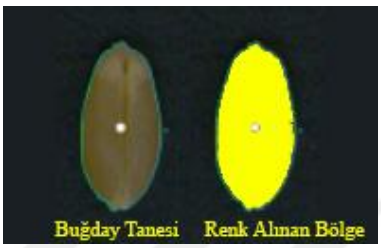
Şekil 6.27 : Merkezleri işaretlenmiş buğday taneleri.

Daha sonra bu merkeze 20 piksel uzaklıkta sağ, sol, alt ve üst köşesinden olmak üzere 4 renk, merkeze 40 piksel uzaklıkta sağ, sol, alt ve üst köşesinden olmak üzere 4 renk örneği daha alınmıştır. Buradan alınan renklerin ortalaması ve merkezden alınan renk değerleri ile birlikte ortalaması alınarak buğday merkez rengi elde edilmiş ve RGB değerleri veri setine eklenmiştir. Şekil 6.28'de renk değeri alınan noktalar gösterilmiştir.



Şekil 6.28 : Merkez rengi olarak örnek alınan noktalar

Buğday merkez rengi alındıktan sonra buğday tanesinin tüm yüzeyindeki renklerin ortalaması alınmış ve ortalama renk değeri elde edilmiştir. Bu işlem için her buğday tanesinin sınırları çizildikten sonra buğdayın bulunduğu piksel dizisi bir döngüye sokulmuş ve bu döngüde üzerindeki renk pikselleri tek tek okunarak ortalamaya dahil edilmiş ve ortalama RGB değeri elde edilmiştir. Şekil 6.29'da görülen yeşil sınır çizgisi ile belirtilen alan içindeki sarı bölgeden alınan renklerin ortalaması hesaplanmış ve RGB değeri olarak veri setine eklenmiştir.

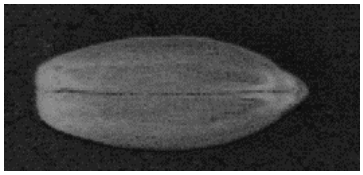


Şekil 6.29 : Buğday üzerinden ortalama renk örneği alınan bölge.

6.10 Doku Özelliklerinin Çıkarılması

Görüntü işleme teknikleri kullanılarak her bir buğday tanesine ait beş farklı doku özelliği çıkarılmıştır.

Bu çalışmada GLCM (Gri seviyeli eş oluşum matrisleri) kullanılarak buğdayların doku özellikleri çıkarılmıştır. GLCM fonksiyonlarının kullanılabilmesi için yazılıma *scikit-image* kütüphanesi eklenmiştir. Sınırları tespit edilmiş gri seviyeli renkte buğday taneleri görüntüden kırpılmıştır. Kırpılan bu taneler üzerinde GLCM doku matrisi komutu *greycomatrix* çalıştırılarak buğday doku değerleri alınmıştır. Komuttan elde edilen *Contrast, Correlation, Energy* ve *Homogeneity* özellikleri çıkarılarak yuvarlanmış ve veri setine olarak eklenmiştir. Şekil 6.30'da kırpılmış doku özellikleri alınmak üzere hazırlanmış tek bir buğday tanesi verilmiştir.



Şekil 6.30 : Doku özelliklerini almak için kırpılmış bir buğday tanesi.

LBP doku analiz yöntemi kullanılarak buğdayların kırpılmış görüntüleri üzerinden örüntüler çıkartılarak bir matris elde edilmiştir. Bu fonksiyon; en genel özellikleri (açı, yön) barındıran *UNIFORM* metodu ile çalıştırılmıştır. Buğday dokusu üzerindeki örüntüler bu komut ile sayısallaştırılarak bir matriste toplanmıştır. Bu çalışmada buğdaylardan elde edilen her bir buğday tanesine ait LBP matrisinin ortalaması alınmış ve ortalama veri setine eklenmiştir.

6.11 Buğdaylara Ait Elde Edilen Veri Seti

Görüntü işleme teknikleri kullanılarak her bir buğday tanesine ait elde edilen 10 şekil, altı renk ve beş doku özelliği elde edilmiş ve bu özellikler Çizelge 6.3'de verilmiştir. Çıkarılan özelliklerin istatistiksel değerleri Çizelge 6.4'de verilmiştir.

Çizelge 6.3 : Buğdaylardan çıkarılan özellikler tablosu.

ÖZELLİK GRUBU	ÖZELLİK NUMARASI	ÖZELLİK	AÇIKLAMA
Şekil özellikleri	1	Alan	Buğday tanesinin fotoğraftaki kapladığı alan
	2	Çevre	Buğday tanesinin fotoğraftaki sınıf çevre uzunluğu
	3	Humoment-0	Hu Moment 0 değeri
	4	Humoment-1	Hu Moment 1 değeri
	5	Boy	Buğday tanesinin boyu
	6	En	Buğday tanesinin eni
	7	Dolgunluk	Buğday tanesinin kapladığı alanın dışındaki dikdörtgene oranı
	8	En boy oranı	En boy oranı
	9	Köşegen	Dış Dikdötgen köşegeni
	10	İrilik	Köşegen değerinin dolgunluk değerine oranı
Renk özelikleri	11	Merkez_r	Merkez kırmızı renk
	12	Merkez_g	Merkez yeşil renk
	13	Merkez_b	Merkez mavi renk
	14	Ortalama_r	Ortalama kırmızı renk
	15	Ortalama_g	Ortalama yeşil renk
	16	Ortalama_b	Ortalama mavi renk
Doku özellikleri	17	Contrast	GLCM – Kontrast
	18	Correlation	GLCM – Korelasyon
	19	Homogeneity	GLCM – Homojenlik
	20	Energy	GLCM – Enerji yoğunluk
	21	Lbp	LBP – Patern matris ortalaması

Çizelge 6.4 : Çıkarılan özelliklerin istatistiksel değerleri.

No	Özellik	Minimum	Maksimum	Ortalama	Standart Sapma
1	Alan	2008,000	23256,500	12665,258	2339,655
2	Çevre	321,220	2177,939	510,740	137,596
3	Humoment-0	0,178	0,546	0,217	0,024
4	Humoment-1	0,001	0,251	0,022	0,010
5	Boy	74,250	373,209	193,486	21,142
6	En	33,287	172,957	86,978	10,610
7	Dolgunluk	21,965	337,019	34,464	16,629
8	En boy oranı	0,235	0,977	0,453	0,061
9	Köşegen	70,167	365,818	94,289	15,859
10	İrilik	1,034	4,733	2,847	0,417
11	Merkez_r	29,000	190,000	124,835	26,333
12	Merkez_g	36,000	186,000	118,120	24,047
13	Merkez_b	31,000	188,000	106,084	29,018
14	Ortalama_r	21,000	138,000	57,598	17,965
15	Ortalama_g	50,000	134,000	62,858	11,040
16	Ortalama_b	50,000	162,000	72,068	18,878
17	Contrast	10,497	1111,764	395,658	190,307
18	Correlation	0,000	0,969	0,853	0,084
19	Homogeneity	0,077	0,311	0,137	0,033
20	Energy	0,014	0,122	0,023	0,008
21	Lbp	9,616	11,988	10,483	0,301

6.12 WEKA Programı İle Buğday Veri Setinin Sınıflandırılması

Buğday görüntülerinin işlemesi sonucu elde edilen veri seti ile buğday taneleri kNN, SVM ve MLP algoritmaları kullanılarak sınıflandırılmıştır.

Öncelikle görüntü işleme yazılımının üretmiş olduğu Microsoft Excel dosyasındaki veriler Weka programının girdi dosyası olan arff dosyasına dönüştürülmüştür. Bu işlem bir metin editör programı olan Notepad++ kullanılmıştır.

Weka programın ön dosyası olan arff dosyaları oluşturulurken iki farklı sınıflandırma sistematiğine göre dosyalar oluşturulmuştur. Birinci sınıflandırma şekli buğdayların ekmeklik ya da makarnalık olup olmadıklarını belirlemek için hazırlanmıştır. İkinci sınıflandırma şekli de buğdayların çeşitlerine göre sınıflandırılması üzerine hazırlanmıştır.

6.12.1 Weka programında buğdayların sınıflandırılma aşamaları

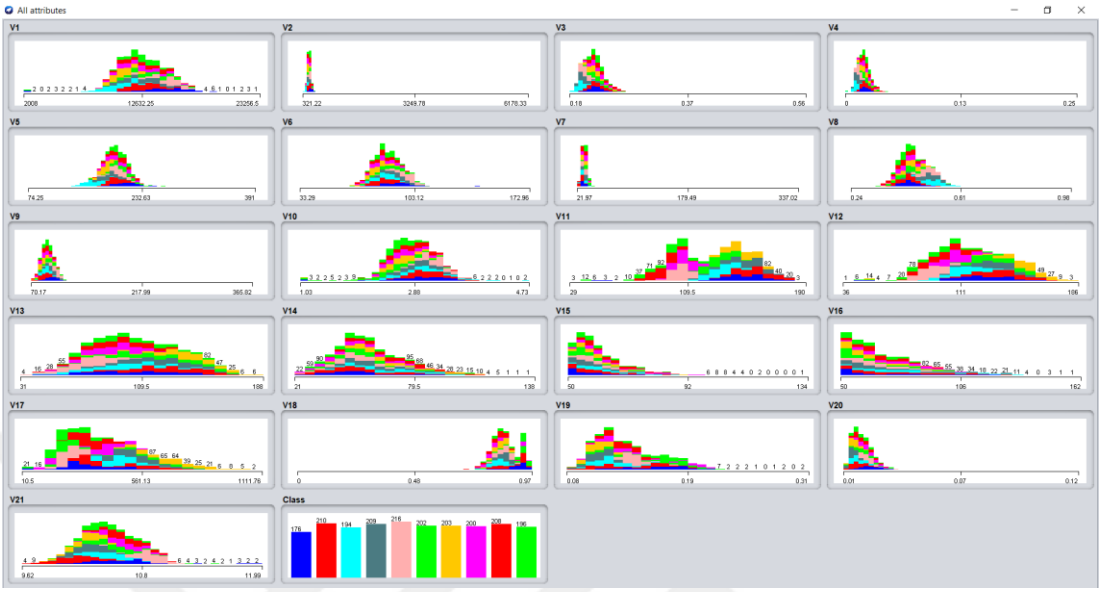
Weka programında oluşturulmuş olan arff dosyaları tek tek açılarak sınıflandırma algoritmaları çalıştırılarak sonuçlar elde edilmiştir. İlk olarak buğdayların tüketim türlerine (Ekmeklik, Makarnalık) göre sınıflandırılması için Şekil 6.31'de görüldüğü gibi bir arff dosyası hazırlanmıştır. Bu arff dosyasında "1" değeri makarnalık, "2" değeri ekmeklik buğdayı temsil etmektedir.

```
1  @relation EB
2  @attribute V1 REAL
3  @attribute V2 REAL
4  @attribute V3 REAL
5  @attribute V4 REAL
6  @attribute V5 REAL
7  @attribute V6 REAL
8  @attribute V7 REAL
9  @attribute V8 REAL
10 @attribute V9 REAL
11 @attribute V10 REAL
12 @attribute V11 REAL
13 @attribute V12 REAL
14 @attribute V13 REAL
15 @attribute V14 REAL
16 @attribute V15 REAL
17 @attribute V16 REAL
18 @attribute V17 REAL
19 @attribute V18 REAL
20 @attribute V19 REAL
21 @attribute V20 REAL
22 @attribute V21 REAL
23
24 @attribute Class {1,2}
25 @data
26 2248,960.3717051,0.325093662,0.012053913,99.282,69.318,206.140
27 2058,788.7493418,0.417170823,0.06835523,110.168,59.093,216.334
```

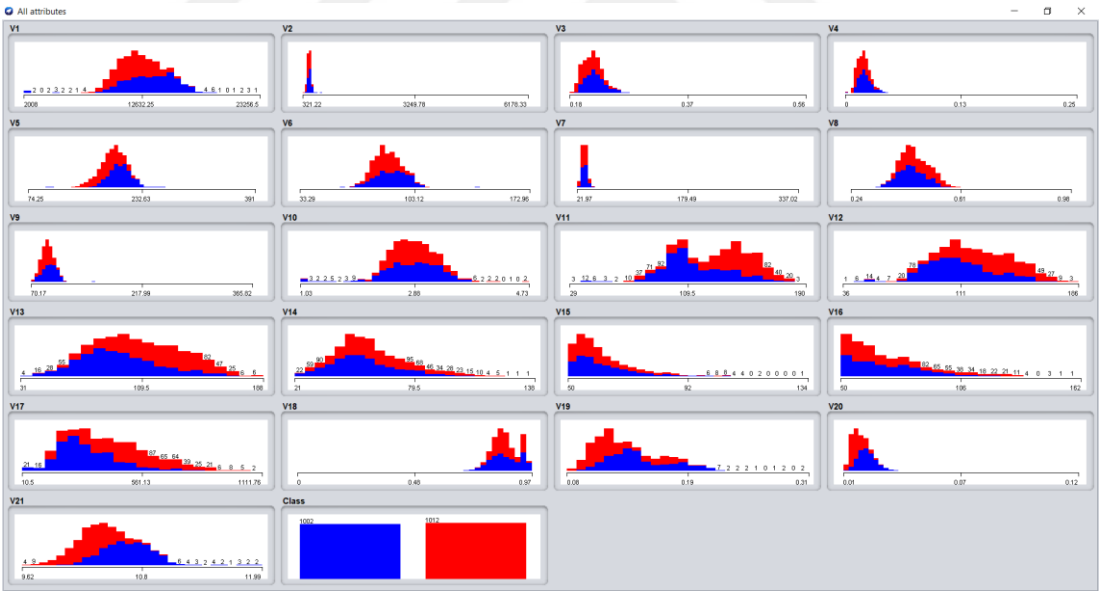
Şekil 6.31 : Weka programı veri seti dosyası yapısı.

Oluşturulan bu arff dosyası sınıflandırmada kullanılmak üzere 2014 buğday tanesinden için 21 farklı özellik içermektedir.

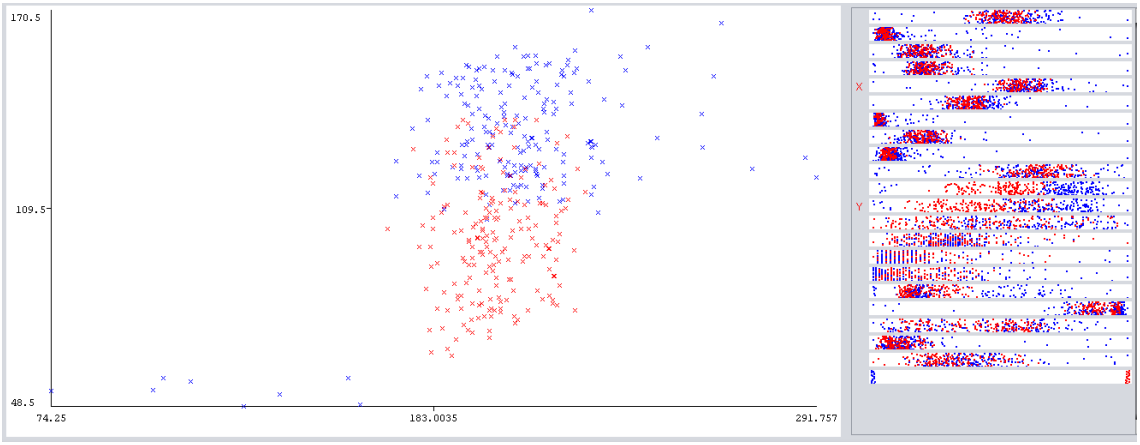
Tüm özellikler Şekil 6.32'de ve Şekil 6.33'de özelliklerin çeşit ve türe göre görsel dağılımları görülmektedir. Şekil 6.34'te bir özelliğe göre tüm buğdayların tür sınıflandırılmasının koordinat düzleminden gösterimi verilmiştir.



Şekil 6.32 : Weka programında özelliklerin çeşit bazında görsel gösterimi.



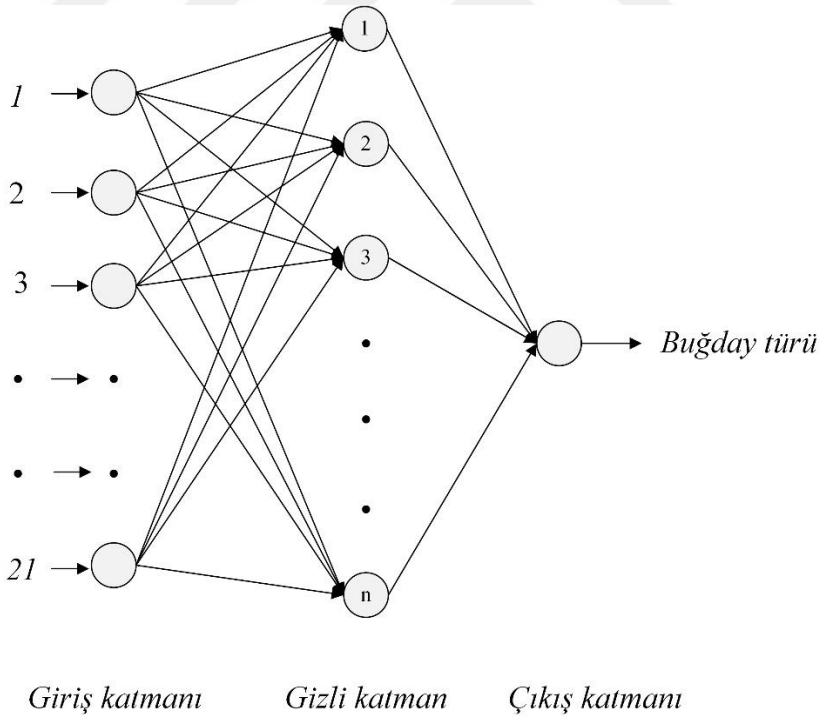
Şekil 6.33 : Weka programında özelliklerin tür bazında görsel gösterimi.



Şekil 6.34 : Bir özelliğin koordinat düzlemi üzerindeki görünümü.

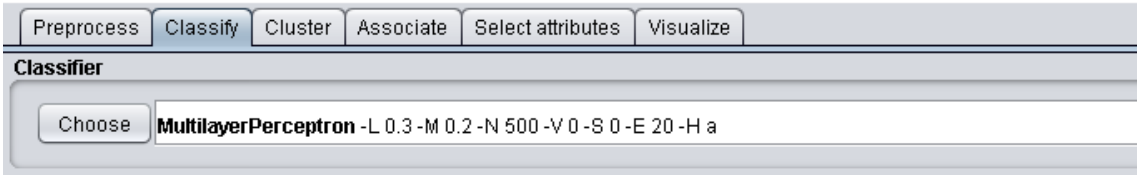
6.12.2 MLP algoritması ile sınıflandırma

Weka programında veriler açıldıktan sonra Classify ekranından Şekil 6.36'deki Multilayer Perceptron sınıflandırıcısı seçilmiştir. MLP algoritmasında gizli katmanlardaki farklı nöron sayıları için sınıflandırma başarısı test edilmiştir. Şekil 6.35'de tek gizli katmanlı MLP'nin modeli verilmiştir.

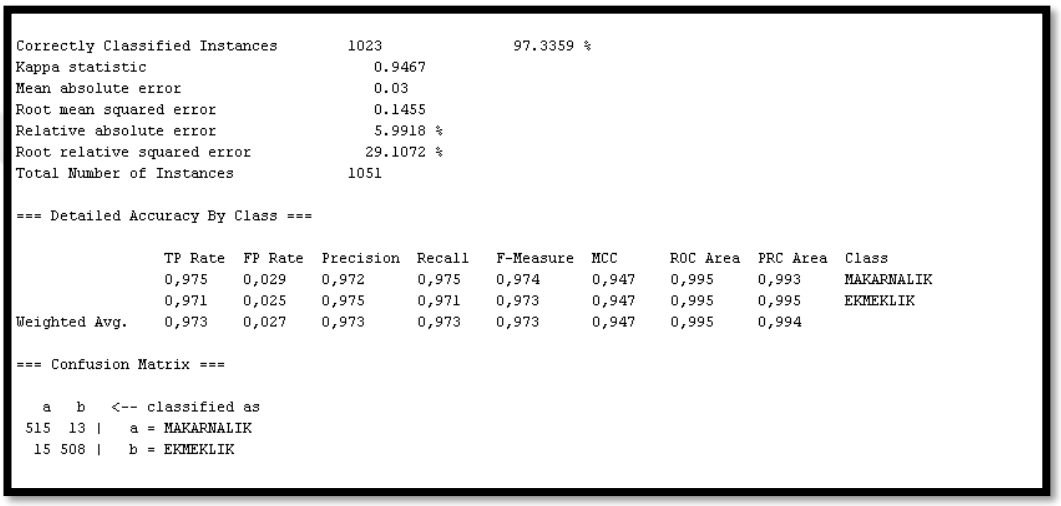


Şekil 6.35 : Tek gizli katmanlı MLP modeli.

Şekil 6.37'de bir MLP algoritması çalıştırılması sonrası elde edilen sonuçlardan bir tanesi gösterilmiştir. Sınıflandırma sonuçları Weka sonuç ekranından alınarak tez sonuçlarına işlenmiştir.



Şekil 6.36 : Weka programında MLP sınıflandırma fonksiyonunun seçimi.



```
Correctly Classified Instances        1023               97.3359 %
Kappa statistic                          0.9467
Mean absolute error                      0.03
Root mean squared error                  0.1455
Relative absolute error                  5.9918 %
Root relative squared error             29.1072 %
Total Number of Instances             1051

=== Detailed Accuracy By Class ===

                 TP Rate  FP Rate  Precision  Recall   F-Measure  MCC      ROC Area  PRC Area  Class
                 0,975    0,029    0,972      0,975    0,974      0,947    0,995     0,993     MAKARNALIK
                 0,971    0,025    0,975      0,971    0,973      0,947    0,995     0,995     EKMEKLIK
Weighted Avg.    0,973    0,027    0,973      0,973    0,973      0,947    0,995     0,994

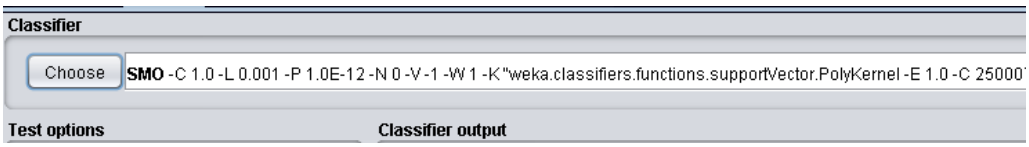
=== Confusion Matrix ===

   a   b   <-- classified as
 515  13 |   a = MAKARNALIK
  15 508 |   b = EKMEKLIK
```

Şekil 6.37 : Weka sonuç çıktısı ekranı.

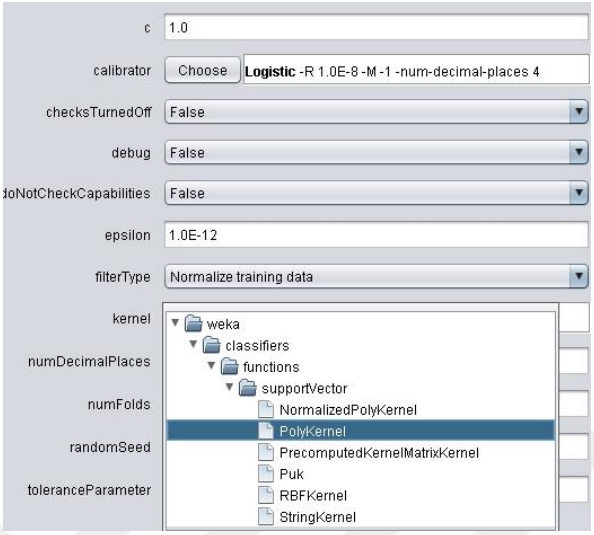
6.12.3 SVM algoritması ile sınıflandırma

Yaygın sınıflandırma yöntemlerinden biri olan SVM algoritması ile buğday verileri hem tür hem de çeşitlerine göre sınıflandırılmıştır. Bu sınıflandırmayı Şekil 6.38'de gösterildiği gibi Weka programında SVM algoritmasının karşılığı olan SMO fonksiyonu seçilerek gerçekleştirilmiştir.



Şekil 6.38 : Weka programında SMO sınıflandırma fonksiyonunun seçimi.

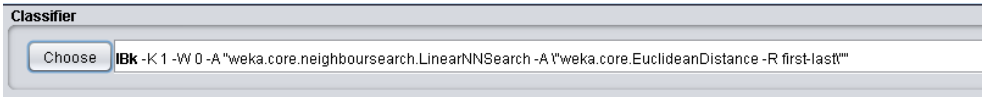
SVM algoritması şekil 6.39'da görüldüğü gibi çekirdek fonksiyonlar kullanarak sınıflandırma yapmaktadır. Bu tez çalışmasında çalışmada Poly Kernel ve Pearson VII function based Universal Kernel (PUK) çekirdek fonksiyonu kullanılmıştır.



Şekil 6.39 : Çekirdek fonksiyonun seçim ekranı.

6.12.4 kNN algoritması ile sınıflandırma

Bu tez çalışmasında kullanılan son algoritma kNN algoritmasıdır. Verilerin koordinat düzlemi üzerindeki kendisine en yakın komşuluk ilişkisine bakarak çalışan bu algoritmada verilen farklı komşuluk değerlerindeki sınıflandırma başarıları test edilmiştir. Şekil 6.40'daki ekran görüntüsünde görüldüğü gibi Weka programında IBk fonksiyonu kNN algoritmasını temsil etmektedir.



Şekil 6.40 : kNN Sınıflandırma fonksiyonunun seçimi.

7. BULGULAR VE TARTIŞMA

Bu çalışmada; on farklı buğday çeşidi sırt üstü ve karın üstü olacak şekilde dizilerek fotoğraflanmış ve görüntüler işlenerek her bir buğday tanesine ait 21 özellik çıkarılmıştır. Buğdayların ekmeklik ya da makarnalık olma durumuna (tür) ve buğday çeşidine göre yapay zeka algoritmaları kullanılarak iki farklı sınıflandırma çalışması yapılmış ve aşağıdaki modeller üzerinde detaylandırılmıştır.

- Bir ekmeklik ve bir makarnalık çeşit buğdayın türüne göre sınıflandırılması
- Beş ekmeklik ve beş makarnalık çeşit buğdayın türüne göre sınıflandırılması
- Beş çeşit makarnalık buğdayın kendi içinde çeşidine göre sınıflandırılması
- Beş çeşit ekmeklik buğdayın kendi içinde çeşidine göre sınıflandırılması
- 10 Çeşit buğdayın çeşidine göre sınıflandırılması

Tüm çalışma boyunca veri seti seçiminde çapraz doğrulama (Cross Validation) yöntemi kullanılmıştır. Test edilen buğday çeşitleri ve türleri Çizelge 7.1'de verilmiştir.

Çizelge 7.1 : Çalışmada kullanılan buğday çeşitleri ve tür özellikleri.

ÇEŞİT NO	BUĞDAY ADI	TÜR	TÜR KODU	MİKTAR
1	Eminbey	Makarnalık	1	176
2	Cumhuriyet-75	Ekmeklik	2	210
3	Nevzatbey	Ekmeklik	2	194
4	Alpu 2001	Ekmeklik	2	209
5	Cesare	Makarnalık	1	216
6	Çesit-1252	Makarnalık	1	202
7	Bayraktar 2000	Ekmeklik	2	203
8	Kunduru-1149	Makarnalık	1	200
9	Kızıltan-91	Makarnalık	1	208
10	Esperya	Ekmeklik	2	196

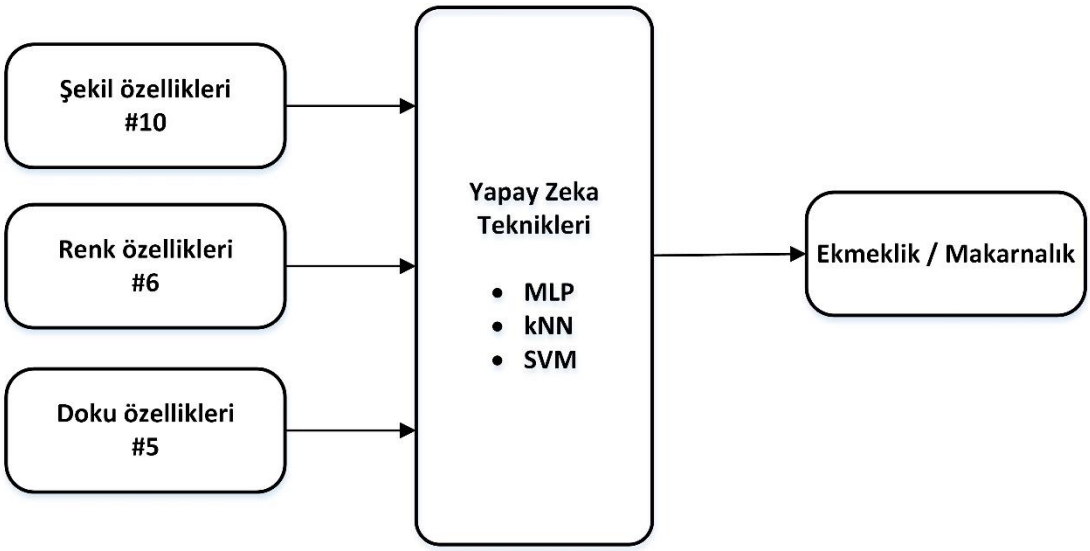
Çizelge 7.1'de bulunan buğdayların her çeşidinden 2014 adet buğday tanesi kullanılmıştır. Sınıflandırılma çalışması için görüntü işleme teknikleri ile her bir buğday tanesinden elde edilmiş ait 21 özellik kullanılmıştır. Bu özellikler ve özellik grupları Çizelge 7.2'de verilmiştir.

Çizelge 7.2 : Elde edilen buğday özellikleri.

NO	ÖZELLİK GRUBU	ÖZELLİK ADI
1	Şekil özellikleri	Alan
2		Çevre
3		Humoment-0
4		Humoment-1
5		Boy
6		En
7		Dolgunluk
8		En boy oranı
9		Köşegen
10		İrilik
11	Renk özelikleri	Merkez_r
12		Merkez_g
13		Merkez_b
14		Ortalama_r
15		Ortalama_g
16		Ortalama_b
17	Doku özellikleri	Contrast
18		Correlation
19		Homogeneity
20		Energy
21		Lbp

7.1 Buğdayların Ekmeklik ya da Makarnalık Olarak Sınıflandırılması

Rastgele seçilen bir çeşit ekmeklik buğday (Esperya) ile bir çeşit makarnalık buğday (Çeşit-1252) kendi aralarında, beş Çeşit ekmeklik (Cumhuriyet-75, Nevzatbey, Alpu 2001, Bayraktar 2000, Esperya) ve beş çeşit makarnalık (Eminbey, Cesare, Çeşit-1252, Kunduru-1149, Kızıltan-91) olmak üzere toplam 10 çeşit buğday kendi aralarında MLP, SVM ve kNN algoritmalarını kullanarak ekmeklik ya da makarnalık olma durumlarına göre sınıflandırılmıştır. Buğdayların türlerine göre sınıflandırılmasına ilişkin blok diyagram Şekil 7.1'de verilmiştir.



Şekil 7.1 : Türlerine göre sınıflandırma işlemine ait blok diyagram.

7.1.1 Seçilen bir ekmeklik ve bir makarnalık buğdayın türüne göre sınıflandırılması

İlk olarak ekmeklik ve makarnalık olarak seçilen birer çeşit buğday üzerinde sınıflandırma yapılmıştır. Ekmeklik çeşit olarak Esperya buğdayından 196 adet, makarnalık çeşit olarak Çeşit-1252 buğdayından 199 adet buğday olmak üzere toplam 395 buğday tanesi kullanılmıştır. Bu türler MLP, SVM ve kNN algoritmalarını kullanılarak sınıflandırılmıştır.

7.1.1.1 MLP algoritması ile yapılan sınıflandırma

MLP ile yapılan sınıflandırma işleminde, öğrenme oranı, momentum ve çevrim değerleri sırasıyla 0,3, 0,2 ve 500 olarak alınmıştır. Bu değerler sabit tutularak gizli katmandaki farklı nöron sayılarında sınıflandırma başarısı test edilmiştir. Elde edilen sonuçlar Çizelge 7.3' de verilmiştir. Çizelge 7.3'e göre gizli katmandaki nöron sayısı 4 iken en yüksek sınıflandırma doğruluğu %99,2405 olarak elde edilmiştir. Ayrıca hassasiyet, hatırlama, F1 puanı, MCC ve Kappa katsayı değerleri sırasıyla 0,993, 0, 992, 0,992, 0,985 ve 0,9848 olarak hesaplanmıştır.

Çizelge 7.3 : MLP algoritmasında farklı nöronlarda sınıflandırma başarısı.

Nöron Sayısı	Doğruluk (%)	DPO	YPO	Hassasiyet	Hatırlama	F1 Puanı	MCC
1	97,4684	0,975	0,025	0,976	0,975	0,975	0,951
2	98,481	0,985	0,015	0,985	0,985	0,985	0,970
3	98,7342	0,987	0,012	0,988	0,987	0,987	0,975
4	99,2405	0,992	0,007	0,993	0, 992	0,992	0,985
5	98,9873	0,990	0,010	0,990	0,990	0,990	0,980
6	98,9873	0,990	0,010	0,990	0,990	0,990	0,980
15	98,9873	0,990	0,010	0,990	0,990	0,990	0,980
21	98,7342	0,987	0,012	0,988	0,987	0,987	0,975
25	98,481	0,985	0,015	0,985	0,985	0,985	0,970

Sınıflandırmaya ait karışıklık matrisi Çizelge 7.4'de verilmiştir. Karışıklık matrisi sonuçlarına bakıldığında, 199 adet makarnalık buğdayın 196 adeti makarnalık sınıfında, 3 adeti ise ekmeklik buğday olarak sınıflandırıldığı görülmektedir. 196 ekmeklik buğdayın tamamının kendi sınıfında doğru sınıflandırıldığı görülmektedir.

Çizelge 7.4 : MLP algoritması karışıklık matrisi.

		Tahmini Sınıf	
		Makarnalık	Ekmeklik
Gerçek Sınıf	Makarnalık	196	3
	Ekmeklik	0	196

7.1.1.2 SVM algoritması ile yapılan sınıflandırma sonuçları

SVM algoritması ile yapılan sınıflandırmada Poly Kernel ve Pearson VII function based Universal Kernel (PUK) çekirdek fonksiyonları kullanılmıştır.

Poly Kernel fonksiyonu kullanılarak yapılan sınıflandırma işleminde farklı c (karmaşıklık değeri) değerlerinde elde edilen sınıflandırma başarıları test edilmiştir. Elde edilen sınıflandırma performans değerleri Çizelge 7.5' te verilmiştir. Çizelge 7.5'e göre c değeri 1.8 iken en yüksek sınıflandırma doğruluğu %99,2405 olarak bulunmuştur. Ayrıca hassasiyet, hatırlama, F1 puanı, MCC ve Kappa katsayı değerleri sırasıyla 0,993, 0,992, 0,992, 0,985 ve 0,9797 olarak hesaplanmıştır.

Çizelge 7.5 : SVM (Poly Kernel) ile yapılan sınıflandırma sonuçları.

C	Doğruluk (%)	DPO	YPO	Hassasiyet	Hatırlama	F1 Puanı	MCC
0,6	98,2278	0,982	0,017	0,983	0,982	0,982	0,965
0,8	97,9747	0,980	0,020	0,981	0,980	0,980	0,960
1,0	98,2278	0,982	0,017	0,983	0,982	0,982	0,965
1,2	98,4810	0,985	0,015	0,985	0,985	0,985	0,970
1,4	98,4810	0,985	0,015	0,985	0,985	0,985	0,970
1,6	98,7342	0,987	0,012	0,988	0,987	0,987	0,975
1,8	99,2405	0,992	0,007	0,993	0,992	0,992	0,985
2,8	98,9873	0,990	0,010	0,990	0,990	0,990	0,980
3,2	98,7342	0,987	0,012	0,988	0,987	0,987	0,975

Çizelge 7.6'da karışıklık matrisi verilmiştir. Karışıklık matrisi sonuçlarına bakıldığında, 395 adet buğday içerisinden 195 makarnalık buğday kendi sınıfında 4 makarnalık buğday ekmeklik sınıfında görülmektedir. 196 ekmeklik buğdayın tamamının kendi sınıfında doğru sınıflandırıldığı görülmektedir.

Çizelge 7.6 : SVM (Poly Kernel) algoritması karışıklık matrisi.

		Tahmini Sınıf	
		Makarnalık	Ekmeklik
Gerçek Sınıf	Makarnalık	195	4
	Ekmeklik	0	196

PUK Çekirdek fonksiyonu ile yapılan çalışmada Omega ve Sigma değerleri sabit tutularak farklı c (karmaşıklık değeri) değerlerinde sınıflandırma başarıları test edilmiştir. Elde edilen sınıflandırma başarı performans değerleri Çizelge 7.7' de verilmiştir. 0,8 Karmaşıklık değeri ile en yüksek sınıflandırma doğruluğu %99,7468 olarak bulunmuştur. Ayrıca hassasiyet, hatırlama, F1 puanı, MCC ve Kappa katsayı değerleri sırasıyla 0,997, 0,997, 0,997, ve 0,9949 olarak hesaplanmıştır.

Çizelge 7.7 : SVM (PUK) ile yapılan sınıflandırma sonuçları.

C	Doğruluk (%)	DPO	YPO	Hassasiyet	Hatırlama	F1 Puanı	MCC
0,6	99,2405	0,992	0,007	0,993	0,992	0,992	0,985
0,7	99,4937	0,995	0,005	0,995	0,995	0,995	0,990
0,8	99,7468	0,997	0,002	0,997	0,997	0,997	0,995
0,9	99,4937	0,995	0,005	0,995	0,995	0,995	0,990
1,0	99,4937	0,995	0,005	0,995	0,995	0,995	0,990

Çizelge 7.8'de verilen karışıklık matrisi sonuçlarına bakıldığında, 395 adet buğday içerisinden 198 makarnalık buğday kendi sınıfında 1 makarnalık buğday ekmeklik sınıfında görülmektedir. 196 ekmeklik buğdayın tamamının kendi sınıfında doğru sınıflandırıldığı görülmektedir.

Çizelge 7.8 : SVM (PUK) algoritması karışıklık matrisi.

		Tahmini Sınıf	
		Makarnalık	Ekmeklik
Gerçek Sınıf	Makarnalık	198	1
	Ekmeklik	0	196

SVM algoritması fonksiyonları içinde Poly Kernel ve Pearson VII function based Universal Kernel fonksiyonunun başarısı diğer fonksiyonlara göre daha başarılı bulunmuştur. Bu çekirdek fonksiyonlarından ise bu çalışmada başarısı en yüksek Pearson VII function based Universal Kernel (PUK) fonksiyonu olmuştur.

7.1.1.3 kNN algoritmasına göre sınıflandırılması

kNN algoritması ile yapılan sınıflandırmada farklı k komşuluk değerlerinde buğdaylar ekmeklik ya da makarnalık olma durumlarına göre sınıflandırılmış ve elde edilen sonuçlar Çizelge 7.9'da verilmiştir. Bu sonuçlara göre komşuluk parametresi 3 iken en yüksek doğruluk değeri %98,2278 olarak hesaplanmıştır.

Ayrıca hassasiyet, hatırlama, F1 puanı, MCC ve Kappa katsayı değerleri sırasıyla 0,983, 0,982, 0,982, 0,965 ve 0,9946 olarak elde hesaplanmıştır.

Çizelge 7.9 : kNN algoritması farklı K değerleri ile sınıflandırma başarısı.

Komşuluk (K)	Doğruluk (%)	DPO	YPO	Hassasiyet	Hatırlama	F1 Puanı	MCC
1	97,7215	0,977	0,023	0,978	0,977	0,977	0,955
3	98,2278	0,982	0,018	0,983	0,982	0,982	0,965
5	97,9747	0,980	0,020	0,981	0,980	0,980	0,960
7	97,2152	0,972	0,027	0,974	0,972	0,972	0,946
9	96,7089	0,967	0,032	0,969	0,967	0,967	0,936

Çizelge 7.10'da kNN algoritması karışıklık matrisi verilmiştir. Bu matrise göre gerçek sınıfı makarnalık olan altı buğday ekmeklik olarak, gerçek sınıfı ekmeklik olan bir buğday da makarnalık olarak sınıflandırılmıştır.

Ekmeklik ya da makarnalık olma durumlarına göre yapılan sınıflandırmada, kNN algoritmasının diğer algoritmalara göre başarısının daha düşük olduğu görülmüştür.

Çizelge 7.10 : kNN algoritması karışıklık matrisi.

		Tahmini Sınıf	
		Makarnalık	Ekmeklik
Gerçek Sınıf	Makarnalık	193	6
	Ekmeklik	1	195

7.1.1.4 Algoritma başarılarının karşılaştırılması

Bir ekmeklik ve bir makarnalık buğday çeşidi önceki sınıflandırma çalışmasındaki gibi MLP, SVM ve kNN algoritmaları ile sınıflandırmaya tabi tutulmuş ve elde edilen sonuçlar Çizelge 7.11'de verilmiştir. Bu sonuçlara göre en yüksek sınıflandırma doğruluğu SVM algoritması ile elde edilmiştir. Algoritmaların en başarılı parametreleri Çizelge 7.12'de verilmiştir.

Çizelge 7.11 : MLP, SVM ve kNN algoritmalarının kıyaslanması.

Algoritma	Doğruluk (%)	DPO	YPO	Hassasiyet	Hatırlama	F1 Puanı	MCC
MLP	99,2405	0,992	0,007	0,993	0,992	0,992	0,985
SVM	99,7468	0,997	0,002	0,997	0,997	0,997	0,995
kNN	98,2278	0,982	0,018	0,983	0,982	0,982	0,965

Çizelge 7.12 : Algoritmalar için en başarılı parametre değerleri.

Algoritma	Parametre	Değer
MLP	Çevrim	500
	Öğrenme oranı	0,3
	Momentum	0,2
	Gizli katman	1
	Gizli katman nöron sayısı	4
SVM	Çekirdek fonksiyonu	Pearson VII (PUK)
	Karmaşıklık sabiti (c)	1,1
	Omega	1,0
	Sigma	1,0
kNN	Komşuluk	3
	Nn arama algoritması	LinearNNSearch

7.1.2 Tüm buğdayların ekmeklik ya da makarnalık durumuna göre sınıflandırılması

Çalışmada kullanılan 1002 adet makarnalık, 1012 adet ekmeklik olmak üzere toplam 2014 adetten oluşan 10 çeşit buğday deneme yanılma yöntemi ve MLP, SVM ve kNN algoritmaları kullanılarak ekmeklik ya da makarnalık olma durumlarına göre sınıflandırılmış ve elde edilen sonuçlar Çizelge 7.13'de verilmiştir. MLP, SVM ve kNN algoritmalarıyla Çizelge 7.15'deki parametreler kullanılarak yapılan sınıflandırmada sırasıyla %94,4389, %96,1271 ve %94,0914 doğruluk elde edilmiştir. En başarılı algoritma olan SVM algoritmasına ait hassasiyet, hatırlama, F1 puanı, MCC ve Kappa katsayı değerleri sırasıyla 0,962, 0,961, 0,961, 0,923 ve 0,9228 olarak hesaplanmıştır. Algoritmalara ait ön ayar parametreleri Çizelge 7.15'de verilmiştir.

Çizelge 7.13 : Türe göre yapılan sınıflandırma başarı durumu.

Algoritma	Doğruluk (%)	DPO	YPO	Hassasiyet	Hatırlama	F1 Puanı	MCC
MLP	94,4389	0,944	0,056	0,944	0,944	0,944	0,889
SVM	96,1271	0,961	0,039	0,962	0,961	0,961	0,923
kNN	94,0914	0,941	0,059	0,942	0,941	0,941	0,883

Sınıflandırma işlemine ait karışıklık matrisi Çizelge 7.14'de verilmiştir. Bu matrise göre gerçek sınıfı makarnalık olan 52 buğday ekmeklik olarak, gerçek sınıfı ekmeklik olan 26 buğday da makarnalık olarak bulunmuştur.

Bu matriste gerçekte makarnalık olan buğdayların ekmeklik sınıfına daha fazla kaydığı gözlemlenmiştir. Bu durum on çeşit arasında makarnalık olup da ekmeklik buğdaylara benzeyen bazı çeşitlerin olduğunu göstermektedir.

Çizelge 7.14 : SVM algoritması karışıklık matrisi.

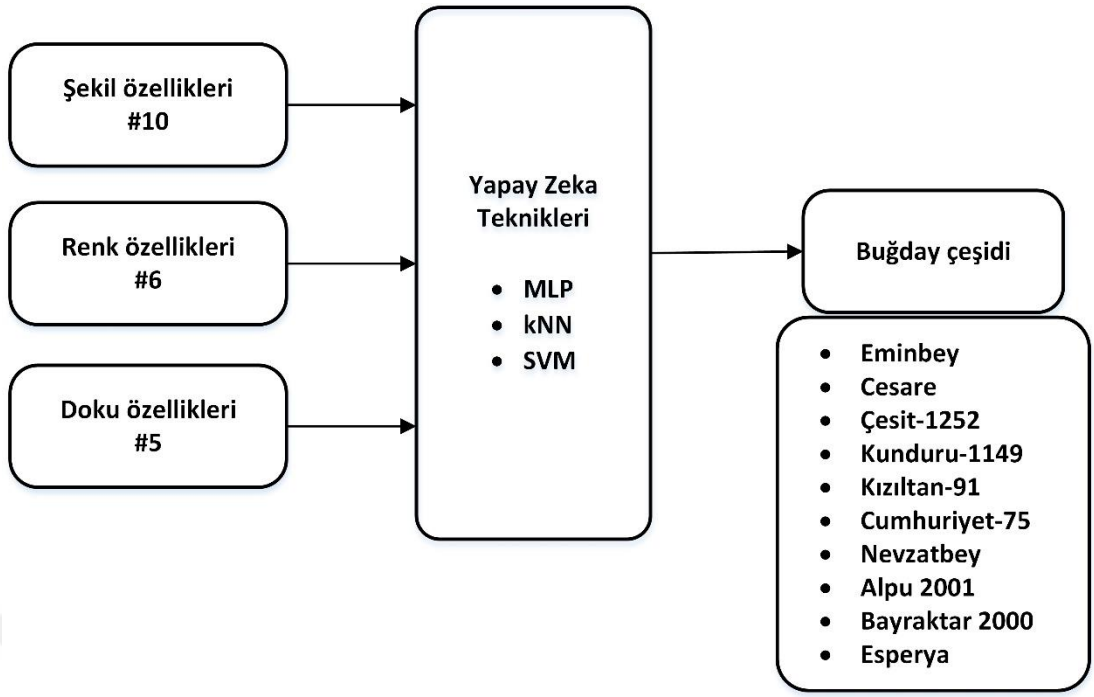
		Tahmini Sınıf	
		Makarnalık	Ekmeklik
Gerçek Sınıf	Makarnalık	950	52
	Ekmeklik	26	986

Çizelge 7.15 : Sınıflandırmada kullanılan algoritmalara ait parametre değerleri

Algoritma	Parametre	Değer
MLP	Çevrim	500
	Öğrenme oranı	0,3
	Momentum	0,2
	Gizli katman	1
	Gizli katman nöron sayısı	5
SVM	Çekirdek fonksiyonu	Pearson VII (PUK)
	Karmaşıklık sabiti (c)	3,8
	Omega	1,0
	Sigma	1,0
kNN	Komşuluk	7
	Nn arama algoritması	LinearNNSearch

7.2 Buğdayların Çeşitlerine Göre Sınıflandırılması

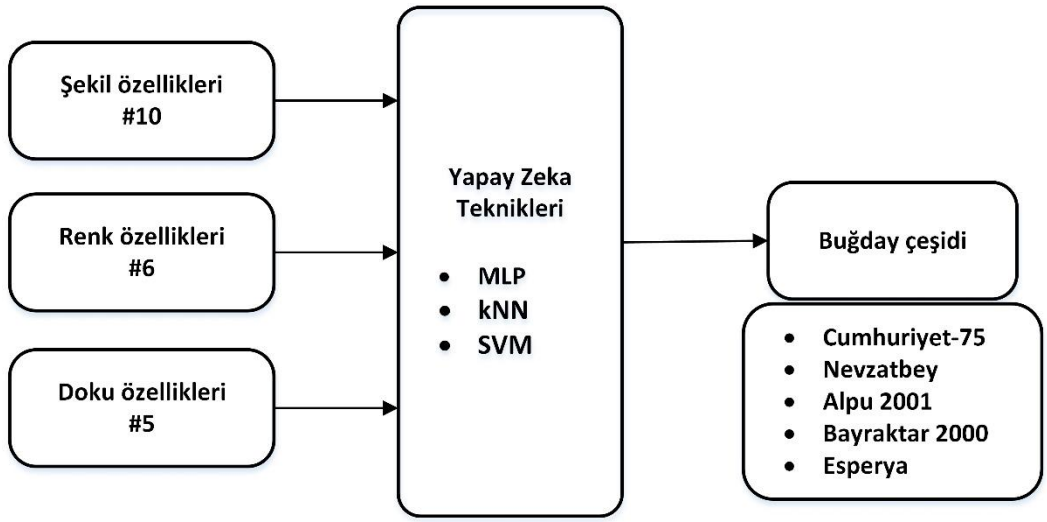
Bu bölümde ilk olarak beş çeşit makarnalık buğday (Eminbey, Kızıltan-91, Cesare, Çesit-1252, Kunduru-1149) ve beş çeşit ekmeklik buğday (Cumhuriyet-75, Nevzatbey, Alpu 2001, Bayraktar 2000, Esperya) kendi içinde çeşitlerine göre sınıflandırılmıştır. Daha sonra 10 çeşitten oluşan tüm buğdaylar çeşitlerine göre sınıflandırılmıştır. Bu çalışmada MLP, SVM ve kNN algoritmaları kullanılmış ve en yüksek doğruluk değerleri kaydedilmiştir. Buğdayların türlerine göre sınıflandırılmasına ait blok diyagram Şekil 7.2'de verilmiştir.



Şekil 7.2 : Buğdayların çeşitlerine göre sınıflandırılmasına ait blok diyagram.

7.2.1 Beş çeşit ekmeklik buğdayın kendi içinde sınıflandırılması

Toplam 1012 adet beş çeşit ekmeklik buğday deneme yanılma yöntemi ile MLP, SVM ve kNN algoritmaları kullanılarak çeşitlerine göre sınıflandırılmıştır. Sınıflandırmaya ait blok diyagram Şekil 7.3' de, sınıflandırma sonuçları ise Çizelge 7.16'da verilmiştir.



Şekil 7.3 : Beş çeşit ekmeklik buğdayın sınıflandırılmasına ait blok diyagram.

MLP, SVM ve kNN kullanılarak yapılan sınıflandırmada sırasıyla %92,2849, %93,3729 ve %88,3284 doğruluk değerleri elde edilmiştir. Sınıflandırma işleminde Çizelge 7.18'deki parametreler kullanılmıştır. En başarılı algoritma olan SVM algoritmasına ait hassasiyet, hatırlama, F1 puanı, MCC ve Kappa katsayı değerleri sırasıyla 0,934, 0,934, 0,934, 0,917 ve 0, 9171 olarak hesaplanmıştır.

Çizelge 7.16 : Beş çeşit ekmeklik buğdayın sınıflandırma sonuçları.

Algoritma	Doğruluk (%)	DPO	YPO	Hassasiyet	Hatırlama	F1 Puanı	MCC
MLP	92,2849	0,923	0,020	0,924	0,923	0,923	0,904
SVM	93,3729	0,934	0,017	0,934	0,934	0,934	0,917
kNN	88,3284	0,883	0,030	0,883	0,883	0,883	0,854

Çizelge 7.17'deki karışıklık matrisi incelendiğinde;

- Cumhuriyet-75 buğdayının 22 tanesi Alpu 2001,
- Nevzatbey buğdayının 7 tanesi Alpu 2001 ve 2 tanesi Bayraktar 2000,
- Alpu 2001 buğdayının 16 tanesi Cumhuriyet-75, 7 tanesi Nevzatbey ve 4 tanesi Bayraktar 2000,
- Bayraktar 2000 buğdayının 4 tanesi Nevzatbey, 4 tanesi Alpu 2001 ve 1 tanesi Esperya,
- Esperya buğdayının tamamı Esperya olarak sınıflandırılmıştır.

Bu matris değerlendirildiğinde Alpu 2001 buğdayı diğer buğdaylara benzerlik göstermektedir. Özellikle Cumhuriyet-75 ve Alpu 2001 beyaz renkli buğdaylar olduğundan birbirine çok benzemektedir. Bu benzerlik sınıflandırmada hata oranını yükseltmektedir. Ancak bu sınıflandırma ekmeklik olan çeşitler arasından yapıldığı için birbirlerine benzemeleri normal bir durum olarak kabul edilmekte ve elde edilen başarının yüksek seviyede olduğu değerlendirilmektedir.

Bu sınıflandırma çalışmasında en başarılı algoritma SVM algoritması ve PUK çekirdek fonksiyonu olmuştur.

Çizelge 7.17 : Beş çeşit ekmeklik buğdayın SVM algoritması karşıklık matrisi.

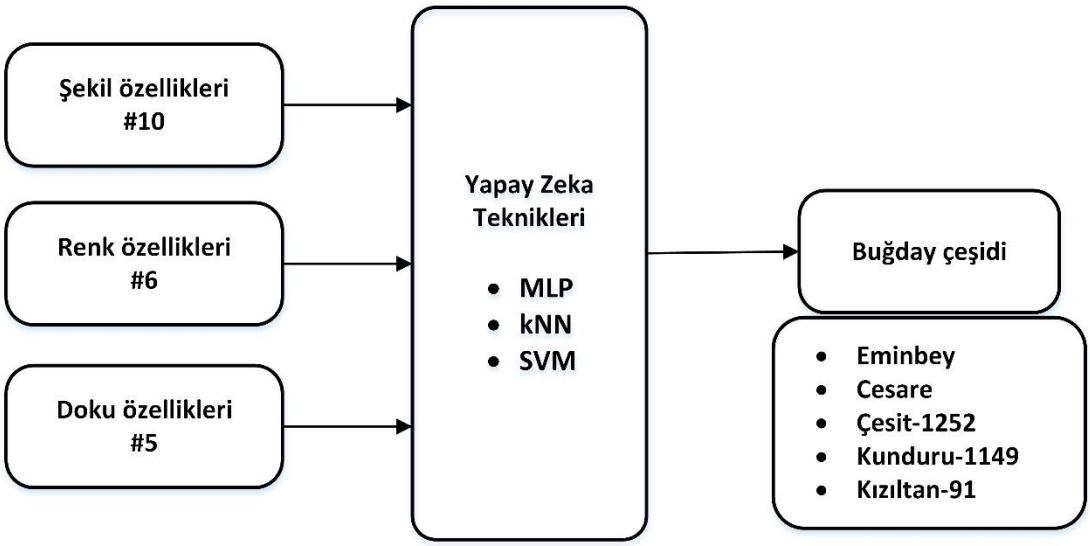
		Tahmini Sınıf				
		Cumhuriyet75	Nevzatbey	Alpu 2001	Bayraktar 2000	Esperya
Gerçek Sınıf	Cumhuriyet75	188	0	22	0	0
	Nevzatbey	0	185	7	2	0
	Alpu 2001	16	7	182	4	0
	Bayraktar 2000	0	4	4	193	1
	Esperya	0	0	0	0	196

Çizelge 7.18 : Sınıflandırmada kullanılan algoritmalara ait parametre değerleri.

Algoritma	Parametre	Değer
MLP	Çevrim	500
	Öğrenme oranı	0,3
	Momentum	1
	Gizli katman	0,2
	Gizli katman nöron sayısı	5
SVM	Çekirdek fonksiyonu	Pearson VII (PUK)
	Karmaşıklık sabiti (c)	4,5
	Omega	1,0
	Sigma	1,0
kNN	Komşuluk	5
	Nn arama algoritması	LinearNNSearch

7.2.2 Beş çeşit makarnalık buğdayın kendi içinde sınıflandırılması

Toplam 1002 adet beş çeşit makarnalık buğday deneme yanılma yöntemi ile MLP, SVM ve kNN algoritmaları kullanılarak çeşitlerine göre sınıflandırılmıştır. Sınıflandırmaya ait blok diyagram Şekil 7.4'da, sınıflandırma sonuçları ise Çizelge 7.19'da verilmiştir.



Şekil 7.4 : Beş çeşit makarnalık buğdayın sınıflandırılmasına ait blok diyagram.

MLP, SVM ve kNN algoritmaları kullanılarak yapılan sınıflandırma işleminde ve sırasıyla %93,2933, %95,3954, %87,3874 doğruluk değerleri elde edilmiştir. Sınıflandırma işleminde Çizelge 7.21'deki parametreler kullanılmıştır. En başarılı algoritma olan SVM algoritmasına ait hassasiyet, hatırlama, F1 puanı, MCC ve Kappa katsayı değerleri sırasıyla 0,954, 0,954, 0,954, 0,943 ve 0,9424 olarak hesaplanmıştır.

Çizelge 7.19 : Beş çeşit makarnalık buğdayın sınıflandırma sonuçları.

Algoritma	Doğruluk (%)	DPO	YPO	Hassasiyet	Hatırlama	F1 Puanı	MCC
MLP	93,2933	0,933	0,017	0,935	0,933	0,933	0,917
SVM	95,3954	0,954	0,011	0,954	0,954	0,954	0,943
kNN	87,3874	0,874	0,032	0,873	0,874	0,873	0,842

Çizelge 7.20'deki karışıklık matrisi incelendiğinde gerçek sınıfı;

- Eminbey olan 7 buğdayın Çeşit-1252,
- Cesare olan 2 buğdayın Kızıltan-91,
- Çeşit-1252 olan 8 buğdayın Eminbey ve 8 buğdayın Kunduru-1149;
- Kunduru-1149 olan 3 buğdayın Cesare, 1 buğdayın Çeşit-1252 ve altı buğdayın Kızıltan-91,
- Kızıltan-91 olan 11 buğdayın Kunduru-1149 olarak hatalı sınıflandırıldığı görülmüştür.

Makarnalık buğdayların genel olarak kendi içlerindeki sınıflandırma başarısı ekmeklik buğdaylara nazaran daha yüksektir. Kunduru-1149 buğdayı kısmen Kızıltan-91 buğdayına benzerlik göstermiştir. Gerçekte de fiziksel olarak gözle incelendiğinde birbirinden ayırt etmesi çok zor buğdaylardır. Makarnalık buğdaylar genel olarak birbirine daha çok benzeyen buğdaylar olmalarına rağmen sınıflandırma başarısı tatmin edici seviyededir.

Bu sınıflandırma çalışmasında en başarılı algoritma SVM algoritması ve PUK çekirdek fonksiyonu olmuştur.

Çizelge 7.20 : SVM algoritması ile elde edilen karışıklık matrisi.

		Tahmini Sınıf				
		Eminbey	Cesare	Çeşit-1252	Kunduru-1149	Kızıltan-91
Gerçek Sınıf	Eminbey	169	0	7	0	0
	Cesare	0	214	0	0	2
	Çeşit-1252	8	0	183	8	0
	Kunduru-1149	0	3	1	190	6
	Kızıltan-91	0	0	0	11	197

Çizelge 7.21 : Sınıflandırmada kullanılan algoritmalara ait parametre değerleri.

Algoritma	Parametre	Değer
MLP	Çevrim	500
	Öğrenme oranı	0,3
	Momentum	0,2
	Gizli katman	1
	Gizli katman nöron sayısı	5
SVM	Çekirdek fonksiyonu	Pearson VII (PUK)
	Karmaşıklık sabiti (c)	4
	Omega	1,0
	Sigma	1,0
kNN	Komşuluk	7
	Nn arama algoritması	LinearNNSearch

7.2.3 On farklı çeşitteki buğdayın sınıflandırılması

Makarnalık ve ekmeklik 10 farklı çeşit toplam 2014 adet buğday tanesi, Çizelge 7.1'de verilen miktarlarda deneme yanılma yöntemi ve MLP, SVM ve kNN algoritmaları kullanılarak çeşitlerine göre sınıflandırılmış ve elde edilen sonuçlar Çizelge 7.22'de

verilmiştir. MLP, SVM ve kNN kullanılarak yapılan sınıflandırma işleminde ve sırasıyla %87,7855, %91,3605, %82,3734 doğruluk değerileri elde edilmiştir. Sınıflandırma işleminde Çizelge 7.24'deki parametreler kullanılmıştır. En başarılı algoritma olan SVM algoritmasına ait hassasiyet, hatırlama, F1 puanı, MCC ve Kappa katsayı değerleri sırasıyla 0,914, 0,914, 0,914, 0,914 ve 0,904 olarak hesaplanmıştır.

Çizelge 7.22 : 10 farklı çeşit buğdayın sınıflandırma sonuçları.

Algoritma	Doğruluk (%)	DPO	YPO	Hassasiyet	Hatırlama	F1 Puanı	MCC
MLP	87,7855	0,878	0,014	0,879	0,878	0,878	0,865
SVM	91,3605	0,914	0,010	0,914	0,914	0,914	0,904
kNN	82,3734	0,824	0,020	0,823	0,824	0,822	0,803

Çizelge 7.23'deki karışıklık matrisi incelendiğinde Eminbey, Çeşit-1252 ve Cumhuriyet-75 buğdaylarının başarısının en düşük olduğu görülmektedir. Bu buğdaylar diğerlerine daha çok benzerlik göstermektedir.

10 farklı buğday çeşidi göz önünde bulundurulduğunda elde edilen başarı oldukça yüksektir.

Çizelge 7.23 : 10 farklı çeşitteki buğdayın SVM algoritması karışıklık matrisi.

		Tahmini Sınıf									
		Eminbey	Cumhuriyet-75	Nevzatbey	Alpu 2001	Cesare	Çesit-1252	Bayraktar 2000	Kunduru-1149	Kızıltan-91	Esperya
Gerçek Sınıf	Eminbey	149	17	0	4	0	5	1	0	0	0
	Cumhuriyet-75	9	178	1	22	0	0	0	0	0	0
	Nevzatbey	0	1	182	8	1	0	2	0	0	0
	Alpu 2001	1	16	9	180	0	1	2	0	0	0
	Cesare	0	0	0	0	212	0	0	2	2	0
	Çesit-1252	7	0	0	1	0	171	9	8	0	0
	Bayraktar 2000	2	1	2	2	0	6	190	0	0	0
	Kunduru-1149	1	0	0	0	2	1	0	187	7	2
	Kızıltan-91	0	0	0	0	0	0	0	6	196	6
	Esperya	0	0	0	0	0	0	0	1	6	189

Çizelge 7.24 : Sınıflandırmada kullanılan algoritmalara ait parametre değerleri.

Algoritma	Parametre	Değer
MLP	Çevrim	500
	Öğrenme oranı	0,3
	Momentum	0,2
	Gizli katman	1
	Gizli katman nöron sayısı	10
SVM	Çekirdek fonksiyonu	Pearson VII (PUK)
	Karmaşıklık sabiti (c)	4,5
	Omega	1,0
	Sigma	1,0
kNN	Komşuluk	5
	Nn arama algoritması	LinearNNSearch

7.3 En başarılı özellikler istatistiği

Beşi ekmeklik, beşi makarnalık toplam 10 faklı buğday çeşidi üzerinden hem ekmeklik ya da makarnalık durumlarını, hem de çeşitlerini belirten iki farklı veri seti ve 21 özellik çıkarılmıştır. Bu veri setlerindeki özellikler arasında sınıflandırmada katkısı en fazla olan özellikler Weka programındaki özellik seçim algoritmaları kullanılarak tespit edilmiştir. Bu özellikler korelasyon tabanlı özellik seçimi (Correlation-based Feature Selection - CFS) değerlendiricisi ve BestFirst metodu kullanılarak test edilmiştir. 10 çeşit türlerine göre listelendiği veri seti üzerinde 9 farklı özellik, 10 çeşit buğdayın çeşitlerine göre listelendiği veri seti üzerinde ise 10 özellik sınıflandırmaya en iyi katkıyı sağladığı görülmüştür. Bu özellikler Çizelge 7.25'de gösterilmiştir.

Bu tabloya göre buğday tanelerinden çıkarılan şekil özellikleri, renk özellikleri ve doku özelliklerinden en az bir alanın sınıflandırmaya katkı sağladığı ortaya çıkmaktadır. Bu durum yapılan çalışmanın çok boyutlu yapılmasın önemini ortaya çıkarmıştır.

Çizelge 7.25 : Seçilen en iyi özellikler tablosu.

No	Veri Seti	Seçilen Özellikler
1	Ekmeklik – makarnalık veri seti üzerinde (en başarılı 8 özellik seçilmiştir)	Humoment-0
2		Boy
3		Köşegen
4		Merkez_r
5		Merkez_b
6		Contrast
7		Energy
8		Lbp
1	10 çeşit buğday veri seti üzerinde (en başarılı 10 özellik seçilmiştir)	Boy
2		En boy oranı
3		Köşegen
4		İrilik
5		Merkez_r
6		Merkez_g
7		Ortalama_b
8		Contrast
9		Correlation
10		Lbp

Sadece bu özellikler seçilerek tekrar yapılan sınıflandırmada; tüm özelliklerin kullanıldığı en başarılı algoritma ve parametreler kullanılarak elde edilen sonuçlar Çizelge 7.26'da verilmiştir. Bu çizelgeye göre özellik seçim algoritmasının belirlediği özelliklerin sınıflandırma başarısı tüm özelliklerin kullanılarak elde edilen sınıflandırma başarısına çok yakın olduğu görülmüştür. Öte yandan tüm özellikler içerisinde de sınıflandırmaya düşük ağırlıkta da olsa katkı sağlayan özelliklerin olduğu da ortaya çıkmıştır.

Çizelge 7.26 : En başarılı özelliklerle tüm özellikler arasında başarı kıyaslaması.

Veri seti	Tüm özelikler	Seçilmiş özellikler
Tür veri seti üzerinde	96,1271	93,4955
Çeşit veri seti üzerinde	91,3605	89,7219

8. SONUÇ VE ÖNERİLER

Bu çalışmada beş çeşit ekmeklik (Cumhuriyet-75, Nevzatbey, Alpu 2001, Bayraktar 2000, Esperya) ve beş çeşit makarnalık (Eminbey, Cesare, Çeşit-1252, Kunduru-1149, Kızıltan-91) olmak üzere toplam 10 farklı buğday çeşidinden oluşan toplam 2014 adet buğday tanesinin Basler acA2500-14uc kamera ve Basler C125-0618-5M lens ile kurulan çekim düzeneği üzerinden görüntüsü alınmıştır.

Buğdaylardan elde edilen görüntüler Python dili ile OpenCV kütüphanesi kullanılarak yazılan bir programla bilgisayar ortamında işlenerek her bir buğday tanesine ait 10 adet şekil, altı adet renk ve beş adet doku olmak üzere 21 farklı özellik çıkarılmıştır. Çıkarılan bu özellikler üzerinden aşağıdaki sınıflandırmalar yapılmış ve en başarılı sonuçlar ve algoritmalar bulunmuştur.

İlk olarak, rastgele seçilen bir ekmeklik (Esperya) ve bir makarnalık (Çeşit-1252) buğdayların türlerine göre yapılan sınıflandırma işleminde, MLP, SVM ve kNN algoritmaları ile elde edilen sınıflandırma doğruluğu sırasıyla %99,2405, %99,7468 ve %98,2278 olarak bulunmuştur.

Daha sonra, beş ekmeklik ve beş makarnalık toplam 10 çeşit buğday, türlerine göre MLP, SVM ve kNN algoritmaları ile sınıflandırılmıştır. Sınıflandırma sonucunda sırayla %94,4389, %96,1271 ve %94,0914 doğruluk değerleri elde edilmiştir.

Daha sonra, makarnalık beş çeşit buğday ile ekmeklik beş çeşit buğday kendi aralarında çeşitlerine göre sınıflandırılmıştır. Beş çeşit ekmeklik buğday (Cumhuriyet-75, Nevzatbey, Alpu 2001, Bayraktar 2000, Esperya) kendi içinde çeşitlerine göre MLP, SVM ve kNN algoritmaları kullanılarak sınıflandırılmıştır. Sınıflandırma sonucunda sırayla %92,2849, %93,3729 ve %88,3284 doğruluk değerleri elde edilmiştir.

Daha sonra, beş çeşit makarnalık buğday (Eminbey, Kızıltan-91, Cesare, Çesit-1252, Kunduru-1149) kendi aralarında çeşitlerine göre MLP, SVM ve kNN algoritmaları kullanılarak sınıflandırılmıştır. Sınıflandırma sonucunda sırayla %93,2933, %95,3954, %87,3874 doğruluk değerleri elde edilmiştir.

Son olarak beş çeşit makarnalık ve beş çeşit ekmeklik toplam 10 buğday çeşidi, çeşitlerine göre MLP, SVM ve kNN algoritmaları kullanılarak sınıflandırılmıştır. Sınıflandırma sonucunda sırayla %87,7855, %91,3605, %82,3734 doğruluk değerleri elde edilmiştir.

Tüm buğday sınıflandırmalarında en yüksek doğruluk SVM algoritması ve PUK çekirdek fonksiyonu ile elde edilmiştir.

Buğday görüntüleri bilgisayara bağlanan bir kamera yardımıyla alınmış bilgisayarda işlenerek sayısal hale getirilmiştir. Bu süreç uzun çekim, istifleme ve işleme süreçlerinin beraberinde getirmiştir. Bu çalışma bilgisayar ortamında Python programlama dili ve OpenCV kütüphanesi kullanılarak yapılmıştır. Günümüzde bu dil ve kütüphaneyi destekleyen gömülü sistemler bulunmaktadır. Bu alanda en çok tercih edilen gömülü mini bilgisayarlardan olan Raspberry Pi veya Nvidia Jetson gibi ürünler kullanılarak sınıflandırma için bir prototip cihaz elde edilebilir.

Bu prototip cihaz, buğday tanelerinin hızlıca işlenip sonuçların hızlıca ekrandan verilmesini sağlayarak buğday sınıflandırma konusunda daha hızlı ve pratik bir çözüm olacaktır. Geliştirilecek bu cihaz, buğday alım satımı yapan ticaret borsalarında, toprak mahsulleri ofislerinde ve gıda fabrikalarında çalışan uzmanların doğru ve hızlı karar verebilmesi için yardımcı olabilecektir.

Ayrıca derin öğrenme teknikleri kullanılarak sınıflandırma hızı ve başarısı arttırılabilir.

KAYNAKLAR

Abakar, K. A., & Yu, C. (2014). Performance of SVM based on PUK kernel in comparison to SVM based on RBF kernel in prediction of yarn tenacity.

Abdullah, N. A., & Quteishat, A. M. (2015). Wheat seeds classification using multi-layer perceptron artificial neural network.*International Journal of Electronics Communication and Computer Engineering*,*6*(2), 306-309.

Anchalia, P., Roy, K., 2014. *The k-Nearest Neighbor Algorithm Using MapReduce Paradigm*. Fifth International Conference on Intelligent Systems, Modelling and Simulation, 513-518.

Anonim, (2007). Modern Colour Theory For Traditional And Digital Painting, 2007.., http://www.huevaluechroma.com/076.php. (Erişim tarihi 17.12.2019)

Anonim, (2018). Basler acA2500-14uc Technical Manual, 2019. Basler AG, https://www.baslerweb.com/en/sales-support/downloads/document-downloads/basler-ace-usb-3-0-users-manual. (Erişim tarihi : 18.11.2019).

Anonim, (2019a). Kernel Functions & SVMs, https://kfrankc.com/posts/2019/06/21/kernel-functions-svm. (Erişim tarihi : 12 Mart 2020).

Anonim, (2019b). Understanding Camera Sensors for Machine Vision Applications https://www.edmundoptics.com/knowledge-center/application-notes/imaging/understanding-camera-sensors-for-machine-vision-applications/ (Erişim Tarihi: 25.11.2019).

Anonim, (2019c). Basic Thresholding Operations. https://docs.OpenCV.org/2.4/doc/tutorials/imgproc/threshold/threshold.html. (Erişim tarihi : 12 Şubat 2020).

Anonom, (2020). GLCM Texture Feature. https://support.echoview.com/WebHelp/Windows_and_Dialog_Boxes/Dialog_Boxes/Variable_properties_dialog_box/Operator_pages/GLCM_Texture_Features.htm#About_the_GLCM_and_textures (Erişim Tarihi: 2.05.2020)

Anonim, (2019d). Create a Gray-Level Co-Occurrence Matrix. https://www.mathworks.com/help/images/create-a-gray-level-co-occurrence-matrix.html. (Erişim tarihi : 18.01.2020).

Arefi, A., Motlagh, A. M., & Khoshroo, A. (2011). Recognition of weed seed species by image processing. *Journal of Food, Agriculture and Environment*, *9*(1), 379-383.

Aytekin, A., Çakır, F. S., Yücel, Y. B., & Kulaözü, İ. (2018). Geleceğe Yön Veren Kodlama Bilimi Ve Kodlama Öğrenmede Kullanılabilecek Bazı Yöntemler. *Avrasya Sosyal Ve Ekonomi Araştırmaları Dergisi*, *5*(5), 24-41.

Babalık, A. (2007). Yapay sinir ağları ile buğday tanelerinin kalite tespiti (Doctoral dissertation, Selçuk Üniversitesi Fen Bilimleri Enstitüsü).

Babalık, A. ve Botsalı, F.M. (2010). Yapay Sinir Ağı ve Görüntü İşleme Teknikleri Kullanarak Durum Buğdayının Camsılığının Belirlenmesi. *Journal of Technical-Online* 9, 2, 163-74.

Bagheri, A., & Nikparast, Y. (2017). Seed identification by artificial vision: a review. *Biological, Environmental and Agricultural Sciences*, *1*(1), 28-32.

Berman, M., Connor, P., Whitbourn, L., Coward, D., Osborne, B. and Southan, M. (2007). "Classification of sound and stained wheat grains using visible and near infrared hyperspectral image analysis*", J. Near Infrared Spectrosc.* 15, 351–358.

Blakeney A.B., Cracknell R.L., Crosbie G.B., Jefferies S.P., Miskelly D.M., O'Brien L., Panozzo J.F., Suter D.A.I., Solah V., Watts T., Westcott T., Williams R.M. (2009). Understanding Wheat Quality. p:8. GRDC, Kingston, Australia.

Bradski, G., & Kaehler, A. (2000). OpenCV. *Dr. Dobb's journal of software tools*, *3*

Bradski, G., & Kaehler, A. (2008). *Learning OpenCV: Computer vision with the OpenCV library*. " O'Reilly Media, Inc.".

Carrasco O. C. (2019). Support Vector Machines for Classification. https://towardsdatascience.com/support-vector-machines-for-classification-fc7c1565e3. (Erişim tarihi : 01.09.2019)

Clay D. (2019). Face Recognition using Python and OpenCV. https://morioh.com/p/e38983d2c4ec (Erişim Tarihi: 25.12.2019)

Cramir, H. (1946). Mathematical methods of statistics. *Princeton U. Press, Princeton*, 500.

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

Çınar, İ. (2019). *Yapay zeka teknikleri kullanılarak pirinç çeşitlerinin sınıflandırılması*. Yüksek lisans tezi, Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Konya.

Dawson-Howe, K. (2014). *A practical introduction to computer vision with opencv*. John Wiley & Sons.

Dener, M., Dörterler, M., & Orman, A. (2009). Açık kaynak kodlu veri madenciliği programları: WEKA'da örnek uygulama. *Akademik Bilişim*, *9*, 11-13.

Eleyan, A., ve Demirel, H. (2011). Co-occurrence matrix and its statistical features as a new approach for face recognition. *Turkish Journal of Electrical Engineering & Computer Sciences*, *19*(1), 97-107.

Erikçi, F. (2018). Kodek, Hd Ses Kalitesi Nedir. Telefon Görüşmelerinde Sesin İletimi, https://fatiherikci.com/tag/nyquist (Erişim tarihi : 18.02.2020)

García, G. B., Suarez, O. D., Aranda, J. L. E., Tercero, J. S., Gracia, I. S., & Enano, N. V. (2015). *Learning image processing with OpenCV*. Packt Publishing Ltd.

Gonzales, R. C., & Woods, R. E. (2002). Digital image processing.

Gonzalez R.C., Woods R.E., Eddins S.L. (2004). Digital Image Processing Using MATLAB, Pearson Education, p. 65-483.

Guzman, C., Peña, R. J., Singh, R., Autrique, E., Dreisigacker, S., Crossa, J., ... & Battenfield, S. (2016). Wheat quality improvement at CIMMYT and the use of genomic selection on it. *Applied & translational genomics*, *11*, 3-8.

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

Güleç, T. E., Sönmezoğlu, Ö. A., & Yıldırım, A. (2010). Makarnalık buğdaylarda kalite ve kaliteyi etkileyen faktörler. *GOÜ. Ziraat Fakültesi Dergisi*, *27*(1), 113-120

Haykin, S. S. (2009). Neural networks and learning machines/Simon Haykin.

Haralick, R. M., Shanmugam, K., & Dinstein, I. H. (1973). Textural features for image classification. *IEEE Transactions on systems, man, and cybernetics*, (6), 610-621.

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.

Kavzoglu, T., ve Colkesen, I., (2009). A kernel functions analysis for support vector machines for land cover classification. *International Journal of Applied Earth Observation and Geoinformation*, *11*(5), 352–359.

Khoshroo, A. L. I. R. E. Z. A., Arefi, A. R. M. A. N., Masoumiasl, A. S. A. D., & Jowkar, G. H. (2014). Classification of wheat cultivars using image processing and artificial neural networks. *Agricultural Communications*, *2*(1), 17-22.

Kızılkaya, M. (2007). EEM 740 Sayısal Görüntü İşleme. http://akizilkaya.pamukkale.edu.tr/Bölüm1_goruntu_isleme.pdf. (Erişim Tarihi: 5.3.2020)

Koçer, H. E. (2007). *İris deseninin yapay zeka yöntemleri ile tanınması* (Doctoral dissertation, Selçuk Üniversitesi Fen Bilimleri Enstitüsü).

Li, K., Meng, M. Q. H., & Chen, X. (2012, July). Robot aided object segmentation without prior knowledge. In *Proceedings of the 10th World Congress on Intelligent Control and Automation* (pp. 4797-4802). IEEE.

Küçük, Z. (2019). Cross-Validation Nedir. https://womaneng.com/cross-validation-nedir. (Erişim tarihi : 01.04.2020)

Madhura, C., & Dheeraj, D. (2013). Feature Extraction for Image Retrieval Using Color Spaces and GLCM. *International Journal of Innovative Technology and Exploring Engineering (IJITEE)*, *3*(2), 159-162.

Mallick, S., Bapat, K. (2018). Shape Matching using Hu Moments (C++/Python). https://www.learnOpenCV.com/shape-matching-using-hu-moments-c-python. (Erişim Tarihi: 25.09.2019)

Masoumi, A. (2013)," Görüntü İşleme Tekniği İle Ekmeklik Buğday Çeşidinde Kaliteye Esas Bazı Özelliklerin Belirlenmesi" Ege Üniversitesi Fen Bilimleri Enstitüsü Yüksek Lisans Tezi

Matthews, B. W. (1975). Comparison of the predicted and observed secondary structure of T4 phage lysozyme. *Biochimica et Biophysica Acta (BBA)-Protein Structure*, *405*(2), 442-451.

Mordvintsev, A., & Abid, K. (2014). Opencv-python tutorials documentation. *Obtenido de https://media. readthedocs. org/pdf/opencv-python-tutroals/latest/opencv-python-tutroals. pdf*. (Erişim Tarihi: 03.03.2020)

Ojala, T., Pietikainen, M., & Maenpaa, T. (2002). Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. *IEEE Transactions on pattern analysis and machine intelligence*, *24*(7), 971-987.

Oliphant, T. E. (2007). Python for scientific computing. *Computing in Science & Engineering*, *9*(3), 10-20.

Özkan, I. A., & Koklu, M. (2017). Skin Lesion Classification using Machine Learning Algorithms. *International Journal of Intelligent Systems and Applications in Engineering*, *5*(4), 285-289.

Öztemel, E. (2003). Yapay sinir ağlari. *PapatyaYayincilik, Istanbul*.

Pazoki, A. R., Farokhi, F., & 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.

Pisarevsky, V. (2010). Introduction to OpenCV. *Agenda*, *42*, 433-434.

Pişkin, M. (2016a). Renk Uzayları, http://mesutpiskin.com/blog/renk-uzaylari.html 20.11.2019 (Erişim Tarihi : 20.11.2019).

Pişkin, M. (2016b). OpenCV Thresholding (Eşikleme). http://mesutpiskin.com/blog/OpenCV-thresholding-esikleme.html. (Erişim Tarihi: 25.09.2019)

Punn, M., & Bhalla, N. (2013). Classification of wheat grains using machine algorithms. *International Journal of Science and Research (IJSR)*, *2*(8), 363-366.

Rosebrock, A. (2017). Deep Learning with OpenC. https://www.pyimagesearch.com/2017/08/21/deep-learning-with-OpenCV. (Erişim Tarihi: 01.02.2020)

Ross, L., & Russ, J. C. (2011). The image processing handbook. *Microscopy and Microanalysis*, *17*(5), 843.

Russ J.C., (2016). The Image Processing Handbook, *Sixth Edition, CRC Press*, p. 1-661.

Rossum, G. (1995). Python reference manual.

Sabancı, K., Ünlerşen, M. F., & Dilay, Y. (2016). Karaman Yöresinde Yetiştirilen Elma Çeşitlerinin Sınıflandırma Parametrelerini Görüntü İşleme Teknikleri Kullanarak Belirlenmesi. *Tarım Makinaları Bilimi Dergisi, 12*(2), 133-139.

Sabancı, K., Kayabaşı, A., & Toktaş, A. (2017). Computer vision-based method for classification of wheat grains using artificial neural network. *Journal of the Science of Food and Agriculture*, *97*(8), 2588-2593.

Sahoo, G. (2013). Study of parametric performance evaluation of machine learning and statistical classifiers. *International Journal of Information Technology and Computer Science (IJITCS)*, *5*(6), 57.

Shopa, P., Sumitha, N., & Patra, P. S. K. (2014, February). Traffic sign detection and recognition using OpenCV. In *International conference on information communication and embedded systems (ICICES2014)* (pp. 1-6). IEEE.

Sidra. (2020). RGB Image Histogram https://www.mathworks.com/matlabcentral/fileexchange/56662-rgb-image-histogram. (Erişim tarihi 20.10.2019).

Singh, C. B., Jayas, D. S., Paliwal, J., & White, N. D. (2010). Detection of midge-damaged wheat kernels using short-wave near-infrared hyperspectral and digital colour imaging. *Biosystems engineering*, *105*(3), 380-387.

Srivastava, S. (2014). Weka: a tool for data preprocessing, classification, ensemble, clustering and association rule mining. *International Journal of Computer Applications*, *88*(10).

Taner, A., Tekgüler, A., & Sauk, H. (2015). Classification of durum wheat varieties by artificial neural networks. *Anadolu Tarim Bilimleri Dergisi*, *30*(1), 51.

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

Wafy, M., Ibrahim, H., & Kamel, E. (2013, December). Identification of weed seeds species in mixed sample with wheat grains using SIFT algorithm. In 2013 9th *International Computer Engineering Conference (ICENCO)* (pp. 11-14). IEEE.

Williams, P., Haremein, F.J., Nakkaul, H., Rihawi, S. 1986, Crop Quality Evaluation Methods and Quidelines. *Technical Mansal*, No: 14.

Yaman, K. (2000). Görüntü işleme yönteminin Ankara hızlı raylı ulaşım sistemi güzergahında sefer aralıklarının optimizasyonuna yönelik olarak incelenmesi. Yayınlanmamış Yüksek Lisans Tezi, Gazi Üniversitesi. *Fen Bilimleri Enstitüsü*.

Yasar, A., Kaya, E., & Saritas, I. (2016). Classification of Wheat Types by Artificial Neural Network. *International Journal of Intelligent Systems and Applications in Engineering*, *4*(1), 12-15.

Yüksel, F., Koyuncu, M., & Sayaslan, A. (2011). Makarnalık buğday (Triticum durum) kalitesi. *Turkish Journal of Scientific Reviews*, *4*(2), 25-31.

Zak, S. H. (2003). *Systems and control* (Vol. 198). New York: Oxford University Press.

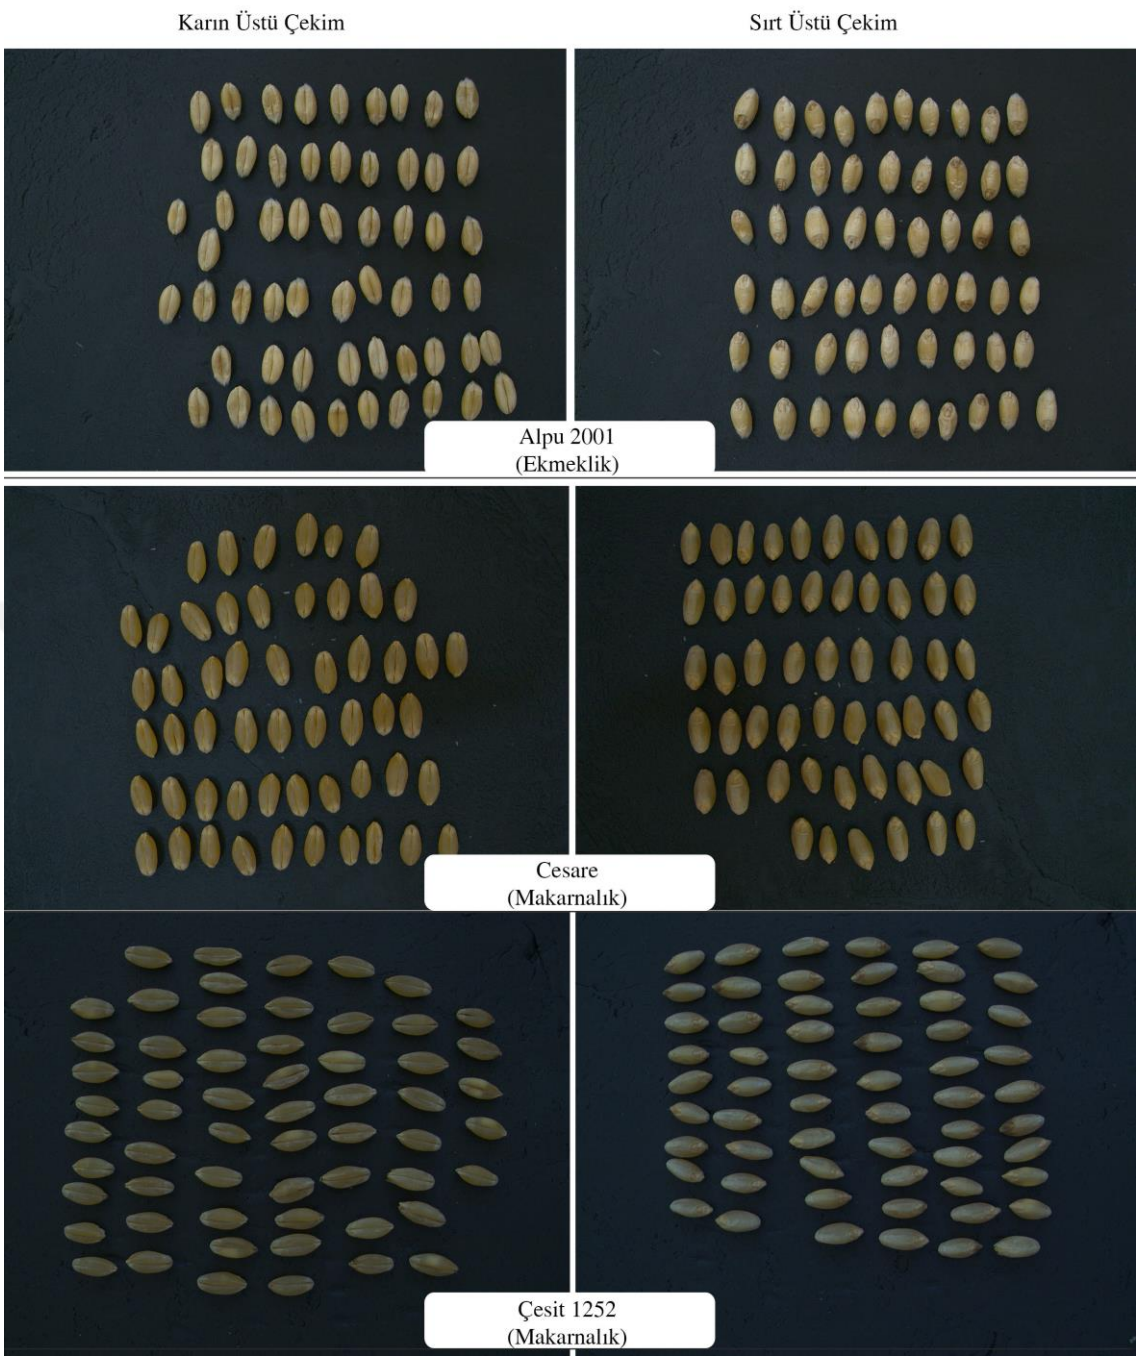
Zapotoczny, P. (2014). Discrimination of wheat grain varieties using image analysis and multidimensional analysis texture of grain mass. *International Journal of food properties*, *17*(1), 139-151.

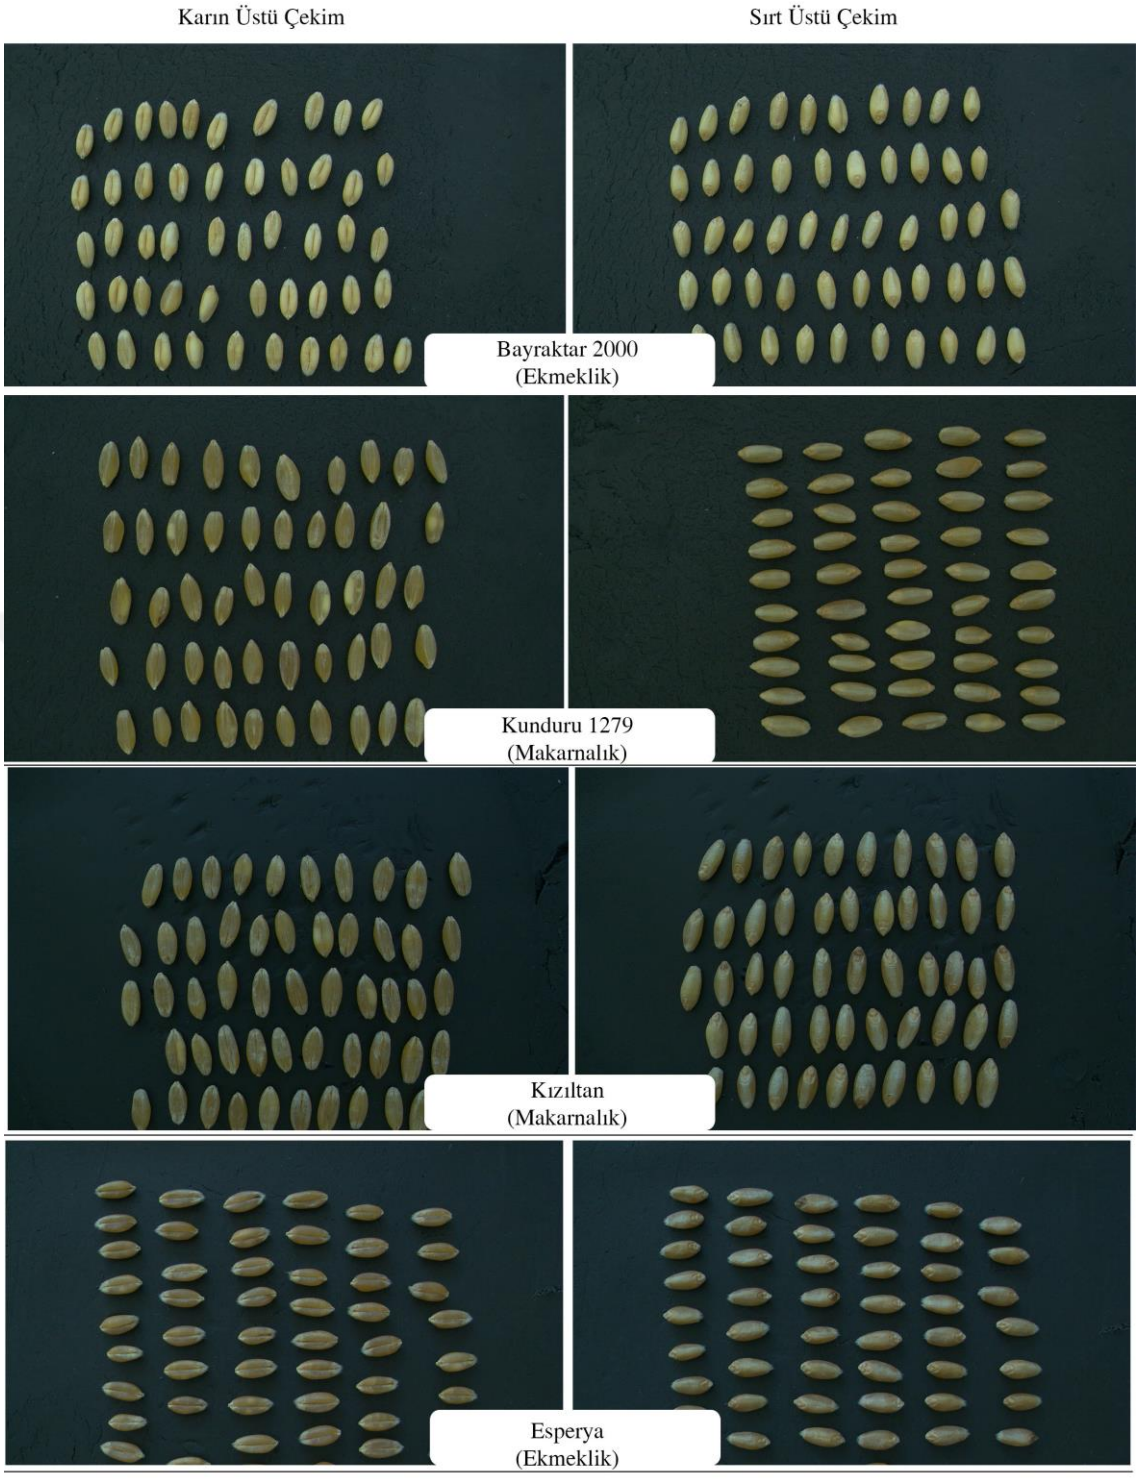
Zhu, L. Q., & Zhang, Z. (2010, August). Auto-classification of insect images based on color histogram and GLCM. In *2010 Seventh International Conference on Fuzzy Systems and Knowledge Discovery* (Vol. 6, pp. 2589-2593). IEEE.

EKLER

Çalışmada Kullanılan Buğday Görüntüleri




Karın Üstü Çekim
Sırt Üstü Çekim
Alpu 2001
(Ekmeklik)
Cesare
(Makarnalık)
Çesit 1252
(Makarnalık)


Karın Üstü Çekim
Sırt Üstü Çekim
Bayraktar 2000
(Ekmeklik)
Kunduru 1279
(Makarnalık)
Kızıltan
(Makarnalık)
Esperya
(Ekmeklik)

ÖZGEÇMİŞ



Kimlik Bilgileri:

Adı Soyadı : Hakan ATÇEKEN

E-posta : hakanatceken@gmail.com

Adresi : Sümer mah. 1333. Sk. No: 40 Mercan Konutları A Blok D:4 KARAMAN

Eğitim:

Lise : Ereğli Anadolu Ticaret Meslek Lisesi Ereğli / KONYA

Lisans : Süleyman Demirel Üniversitesi / Elektronik ve Bilgisayar Eğitimi Ana Bilim Dalı / Bilgisayar Sistemleri Öğretmenliği- ISPARTA

Yabancı Dil ve Düzeyi: Orta

İş Deneyimi: Milli Eğitim Bakanlığı / Öğretmen

Deneyim Alanları: Bilişim Teknolojileri Öğretmeni / 15 Yıl

Çalıştığı Kurumlar :

Baklan Ataköy İlköğretim Okulu - DENİZLİ

Ayrancı Yatılı Bölge Ortaokulu - KARAMAN

Karaman İl Milli Eğitim Müdürlüğü (Bilgi İşlem Yöneticisi)

Temizel Ünlü Mesleki ve Teknik Anadolu Lisesi - KARAMAN