SİYAH ÇAYIN MAKİNE ÖĞRENİMİ İLE SINIFLANDIRILMASI

Sultan Aziz Kazdal
191402106

YÜKSEK LİSANS TEZİ
Bilgisayar Mühendisliği Anabilim Dalı
Bilgisayar Mühendisliği Yüksek Lisans Programı
Danışman: Prof. Dr. Emin Murat Esin

İstanbul
T.C. Maltepe Üniversitesi
Lisansüstü Eğitim Enstitüsü
Ağustos, 2020

SİYAH ÇAYIN MAKİNE ÖĞRENİMİ İLE SINIFLANDIRILMASI

Sultan Aziz Kazdal
191402106
Orcid: 0000-0001-8315-3798

YÜKSEK LİSANS TEZİ
Bilgisayar Mühendisliği Anabilim Dalı
Bilgisayar Mühendisliği Yüksek Lisans Programı
Danışman: Prof. Dr. Emin Murat Esin

İstanbul
T.C. Maltepe Üniversitesi
Lisansüstü Eğitim Enstitüsü
Ağustos, 2020



JÜRİ VE ENSTİTÜ ONAYI

ETİK İLKE VE KURALLARA UYUM BEYANI

TEŞEKKÜR

Bu çalışmanın gerçekleşmesine derin bilgi ve deneyimi Sayın Prof. Dr. Emin Murat Esin, tez danışmanı olarak çalışmanın planlanması ve yürütülmesini yönlendirmesi ile destek vermiştir. Sayın Dr. Öğr. Üyesi Ayşe Salman ve Dr. Öğr. Üyesi Hüseyin Fehmi Selim Bayraklı tez izleme komitesinde görev alarak değerli katkılarını sunmuşlardır.

Ayrıca değerli eşim Şennur Kazdal hayatımın ve akademik çalışmalarımın her aşamasından desteklerini esirgememiştir.

Desteklerlerinden dolayı yukarıda isimleri geçen kişilere içtenlikle teşekkürlerimi sunuyorum.

Sultan Aziz Kandal
Ağustos, 2020

ÖZ

SİYAH ÇAYIN MAKİNE ÖĞRENİMİ İLE SINIFLANDIRILMASI

Sultan Aziz Kazdal
Yüksek Lisans Tezi
Bilgisayar Mühendisliği Anabilim Dalı
Bilgisayar Mühendisliği Yüksek Lisans Programı
Danışman: Prof. Dr. Emin Murat Esin
Maltepe Üniversitesi Lisansüstü Eğitim Enstitüsü, 2020

Bu çalışma iki farklı kalitede olan siyah çayın sınıflandırılması için makine öğrenimi kullanılmıştır. SVM , Naive-Bayes gibi algoritmaların yanında görüntü sınıflandırma çokça kullanılan evrişimsel sinir ağı (CNN) ile de sınıflandırma çalışmaları yapılmıştır. SVM, Naive-Bayes sınıflandırıcılarına görüntülerin RGB,HSV, YCrCb renk uzaylarından elde edilen özniteliklerden oluşan veri setleri ile sınıflandırma çalışması yapılmıştır. SVM algoritması iki farklı kalitedeki siyah çayın YCrCb renk uzayından elde edilen öznitelikler ile testinde %99 gibi yüksek bir oranda doğruluk ortaya koymuştur. Bunun yanı sıra evrişimsel sinir ağı (CNN) herhangi bir yapısı gereği görseller üzerinde herhangi bir öznitelik çıkarımı sürecine ihtiyaç duymadan eğitim görsellerinde %98.52 ve doğrulama için kullanılan görseller için ise %98.56 oranında doğrulukla sınıflandırma yapmıştır. Elde edilen veriler dikkate alınarak farklı nesneleri de sınıflandırabilecek bir evrişimsel sinir ağının siyah çay görselleriyle de eğitilmesi sonucunda etkin bir sistem ortaya konulabileceği düşünülmektedir.

Anahtar Sözcükler: Siyah çay sınıflandırma, SVM , Naive-Bayes , Evrişimsel sinir ağı

ABSTRACT

CLASSIFICATION OF BLACK TEA BY MACHINE LEARNING

Sultan Aziz Kazdal
Master Thesis
Department of Computer Engineering
Computer Engineering Programme
Advisor: Prof. Dr. Emin Murat Esin
Maltepe University Graduate School, 2020

This study used machine learning to classify black tea of two different qualities. In addition to algorithms such as SVM and Naive-Bayes, classification studies have been carried out with convolutional neural network (CNN), which is widely used in image classification. Classification studies were carried out with data sets consisting of features obtained from RGB, HSV, YCrCb color spaces of the images to SVM, Naive-Bayes classifiers. SVM algorithm has demonstrated a high accuracy of 99% in the testing of two different qualities of black tea with features obtained from YCrCb color space. In addition, the convolutional neural network (CNN) classified the visuals with 98.52% accuracy and 98.56% accuracy for the visuals used for verification, without the need for any feature extraction process on the visuals due to any structure. Considering the obtained data, it is thought that an effective system can be created by training a convolutional neural network that can classify different objects with black tea images.

Keywords: Black tea classification, SVM, Naive-Bayes, Convolutional Neural Network

İÇİNDEKİLER

JÜRİ VE ENSTİTÜ ONAYI ii
ETİK İLKE VE KURALLARA UYUM BEYANI iii
TEŞEKKÜR iv
ÖZ v
ABSTRACT vi
İÇİNDEKİLER vii
TABLOLAR LİSTESİ viii
ŞEKİLLER LİSTESİ ix
KISALTMALAR x
ÖZGEÇMİŞ xi
BÖLÜM 1. GİRİŞ 1
BÖLÜM 2. LİTERATÜR ARAŞTIRMASI 4
BÖLÜM 3. ÇAY KALİTESİ SINIFLANDIRMA YÖNTEMLERİ 8
YEREL İKİLİ DESEN 8
HISTOGRAM 10
HU-MOMENTS 11
HARALICK 13
RENK KÜMELERİNİN BELİRLENMESİ 16
İSTENMEYEN PARTİKÜL TESPİTİ 17
EVRİŞİMSEL SİNİR AĞI 17
BÖLÜM 4. DENEYSEL ÇALIŞMA 22
VERİ ELDE ETME 22
VERİ ÇOĞALTMA 26
ÇALIŞMA ORTAMI 28
ÖZNİTELİK ÇIKARIMLARI 29
SINIFLANDIRMA 31
SVM SINIFLANDIRICISI 33
NAIVE-BAYES SINIFLANDIRICISI 34
EVRİŞİMLİ SİNİR AĞI SINIFLANDIRICISI 34
VERİ SETİ 1 ÇALIŞMASI 37
VERİ SETİ 2 ÇALIŞMASI 40
RGB ÖZNİTELİKLERİ TESTİ 40
HSV ÖZNİTELİKLERİ TESTİ 41
YCrCb ÖZNİTELİKLERİ TESTİ 42
VERİ SETİ 3 ÇALIŞMASI 44
BÖLÜM 5. TEST UYGULAMASI 48
BÖLÜM 6. SONUÇ 50
BÖLÜM 7. ÖNERİLER 53
KAYNAKÇA 54

TABLOLAR LİSTESİ

Tablo 1 : TSE KURU ÇAY GÖRÜNÜŞ ÖZELLİKLERİ 3
Tablo 2 : LBP OPERATÖRÜ ÖRNEK HESAPLAMASI 9
Tablo 3 : Örnek piksel değerleri 10
Tablo 4 : K-means RENK KÜMELEMESİ 17
Tablo 5 : EVRİŞİMSEL SİNİR AĞI YAPISI 17
Tablo 6 : EVRİŞİMSEL KATMAN HESAPLAMA ÖRNEĞİ 18
Tablo 7 : POOLING ÖRNEK HESAPLAMA 19
Tablo 8 : VERİ SETİ AÇIKLAMA TABLOSU 29
Tablo 9 : SINIFLANDIRMADA KULLANILACAK GÖRSEL ÖRNEKLERİ 31
Tablo 10 : SVM SINIFLANDIRMA FONKSİYONLARI – 1 33
Tablo 11 : SVM SINIFLANDIRMA FONKSİYONLARI – 2 34
Tablo 12 : SVM KARIŞIKLIK MATRİSİ (CONFUSION MATRIX) 37
Tablo 13 : SVM SINIFLANDIRMA RAPORU 38
TABLO 14 : NAIVE-BAYES KARIŞIKLIK MATRİSİ (CONFUSION MATRIX) 38
TABLO 15 : NAIVE-BAYES SINIFLANDIRMA RAPORU 39
Tablo 16 : SVM KARIŞIKLIK MATRİSİ (CONFUSION MATRIX) 40
Tablo 17 : SVM SINIFLANDIRMA RAPORU 41
Tablo 18 : SVM KARIŞIKLIK MATRİSİ (CONFUSION MATRIX) 41
Tablo 19 : SVM SINIFLANDIRMA RAPORU 42
Tablo 20 : SVM KARIŞIKLIK MATRİSİ (CONFUSION MATRIX) 43
Tablo 21 : SVM SINIFLANDIRMA RAPORU 43
Tablo 22 : 1 İSİMLİ ÇAYIN SINIFLANDIRMA TESTİ 49
Tablo 23 : 2 İSİMLİ ÇAYIN SINIFLANDIRMA TESTİ 49

ŞEKİLLER LİSTESİ

Şekil 1 : ÖRNEK HİSTOGRAM 10
Şekil 2 : YAPAY SİNİR AĞI KATMANI 19
Şekil 3 : YAPAY SİNİR AĞI MATEMATİKSEL MODEL GÖSTERİMİ 20
Şekil 4 : ÇOK KATMANLI BİR YAPAY SİNİR AĞI MODELİ [16] 21
Şekil 5 : ÇAY FOTOĞRALAMA DÜZENEĞİ 22
Şekil 6 : SİYAH ÇAYIN KONULDUĞU DÜZENEK 23
Şekil 7 : FOTOĞRAFLAMA DÜZENEĞİ ŞEMASI 24
Şekil 8 : ÖRNEK SİYAH ÇAY FOTOĞRAFI 24
Şekil 9 : ÖZNİTELİK ÇIKARILACAK SİYAH ÇAY GÖRSELİ 25
Şekil 10 : VERİ ÇOĞALTMA – 1 26
Şekil 11 : VERİ ÇOĞALTMA – 2 27
Şekil 12 : CNN GENEL YAPISI 35
Şekil 13 : CNN MODEL ÖZET BİLGİSİ 45
Şekil 14 : CNN DOĞRULAMA GRAFİĞİ 46
Şekil 15 : CNN MALİYET FONKSİYONU DEĞİŞİMİ 46
Şekil 16 : TEST UYGULAMASI ARAYÜZÜ 48

KISALTMALAR

MIAS : Mammographic Image Analysis Society – mamografik görüntü analiz topluluğu

SVM : Support Vector Machine (Destek vektör makinesi)

RGB : Red-Green-Blue, Genelde kullanlan renk uzayıdır.

HSV : Hue, Saturation, Value

CNN : Convolutional Neural Network (Evrişimsel Sinir Ağı)

LBP : Local Binary Pattern

ÖZGEÇMİŞ

Sultan Aziz KAZDAL

Bilgisayar Mühendisliği Anabilim Dalı

Eğitim

Derece	*Yıl*	*Üniversite, Enstitü, Anabilim/Anasanat Dalı*
Y.Ls.	2020	Maltepe Üniversitesi, Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Tezli Yüksek Lisans
Ls.	2005	Karadeniz Teknik Üniversitesi, Fen Edebiyat Fakültesi İstatistik ve Bilgisayar Bilimleri
Lise	2001	Rize Anadolu Öğretmen Lisesi

İş/İstihdam

Yıl	*Görev*
2006 -	Bilgi İşlem Müdürü. Karali Çay San Tic. A.ş.

Kişisel Bilgiler

Doğum yeri ve yılı : Rize, 1983 Cinsiyet: E
Yabancı diller : İngilizce (iyi)
E-posta : azizkazdal@gmail.com

BÖLÜM 1. GİRİŞ

Teknolojinin gelişmesi, güvenli gıdaya ulaşabilmeyi ve gıda sektörünün endüstriyel dönüşümünde önemli rol oynamıştır. Gıda sektöründe teknoloji; üretim, paketleme, lojistik, kalite kontrol gibi alanlarda etkin bir şekilde kullanılmakta olup bu çalışmanın konusu olan görüntü işleme ve yapay zeka teknolojisinin hangi alanlarda ve ne amaçla kullanıldığı incelenmektedir.

Görüntü işleme ile ışık altında nesnelerden elde edilen dijital görüntülerin belirli yöntem ve filtreler uygulanarak üretilen yeni görüntü ya da öznitelikler ile sistemlerin görüntü hakkında bir sonuca ulaşması sağlanmaktadır. Yapay zeka yöntemleri görüntü işleme ile elde edilen görüntü veya görüntülerden elde edilen öznitelikler kullanılarak ulaşılacak sonucun kararını veya sınıflandırmasını yapmamıza imkan sağlamaktadır. Bu iki yöntem günümüzde aktif olarak gıda ürünlerinin sınıflandırılması, kalitelerinin belirlenmesi, hastalıklı ya da bozuk yapıda olan ürünlerin ayıklanması, yer tespiti, rekolte hesaplanması gibi bir çok amaç için kullanılmaktadır.

Bu araştırmada gıda ürünlerinin sınıflandırılması ve kalitesinin belirlenmesi üzerine yapılmış çalışmalar ve ayrıca siyah çayın sınıflandırılmasına yönelik uygulanabilecek yöntemler üzerinde durulacaktır.

Türkiye'de çay üretimine yönelik ilk girişim II. Abdulhamit döneminde (1876-1909) Bursa kentinde gerçekleştirilmiş olup iklim koşulları sebebiyle bu girişim başarısız olmuştur. Ardından iklim koşulları daha iyi olmasından dolayı girişimler Doğu Karadeniz bölgesine yönlendirilmiştir. Üretim 1930 yılların sonunda başlamış fakat ikinci dünya savaşı sebebiyle ilk fabrikanın açılması savaş sonrası zamana kalmıştır. [1]

Çay üretiminin %60-65'inin üzerinde bir kısmı Rize olmak üzere, Trabzon, Artvin, Ordu ve Giresun illeriden 200.000 den fazla çiftçi bulunmaktadır ve bunlar her sene 250.000 tondan fazla siyah çay üretimi yapmaktadır. Çay bitkisi 1000 metreye çıkan rakımlarda da yetişmekte olup bu plantasyonlarda yetişen çaylarda böcek ilacı bulunmamaktadır. Çaydaki kimyasallar söz konusu olduğunda Türkiye'nin kendisine has bir avantajı, çay bitkisinin üzerine kar düşmesiyle çaylarda böcek ilaçları, mantar ilaçları

gibi kimyasallar kullanılmamasıdır. Hava koşullarına bağlı olarak, çay hasadı her sene üç-dört kez yapılmaktadır. [1]

Türkiye Dünya'da en fazla çay üreten [1, p. 42] ülkelerden biridir ve bu üretim büyük oranda iç pazarta tüketilmektedir. Türk çayının ihracatına yönelik çalışmalar olsada ihracatın artmamasında ki bazı etkenler bulunmaktadır. [1, p. 39]. Çay üretimi özel ve kamu (ÇAYKUR) olmak üzere toplamda 280'den fazla [1, p. 39] çay işleme birimi tarafından yapılmaktadır.

Çay üretiminin son aşaması olan tasnifleme de çaylar partikül boyutlarına göre elenerek sınıflandırılır ve depolanmak üzere ambalajlanırlar. Tasnifleme birimlerinde sınıflandırılan çaylar eleme sonrasında ayrıca ürün kalitesi de belirlenmektedir.

Üretim yılın belirli dönemlerinde olduğundan çuvallanarak depolanan çaylar yılın geri kalan dönemlerinde paketleme tesislerinde paketlenirler. Farklı kalitelerde ki çayları üretmek için paketleme öncesinde fabrikalarda üretilen çuvallanmış çaylarından üretilmek istenen kalitede ki ürünün reçetesine uygun olarak harman yapılır. Elde edilmek istenen ürün kalitesine bağlı olarak, harmanlama yılın farklı dönemlerinde (sürgünlerinde) ve farklı elek numaralarında ki (tasnifleme biriminden siyah çayın partiküllerine göre ayrılmış çaylar) çaylardan oluşmaktadır. Ayrıca paketleme tesisleri hem kendi fabrikalarında üretilen hem de dışardan temin ettikleri çayları da paketleme sırasında kullanmaktadırlar.

Harmanda kullanılacak çayların seçimi (ürün reçetesine bağlı olarak) sürgün ve elek numarası üzerinden yapılır. Seçilen çaylardan alınan numuneler hem gözle hem de laboratuvar da incelenir. Gözle yapılan değerlendirme oldukça önemlidir ve uzun zaman ve emek harcanarak elde edilen bu sınıflandırma becerisi insana bağımlı olduğundan maliyetli ve hataya açık olabilmektedir. Türk Standartları Enstitüsü tarafından ortaya konan siyah çayın görünüşüne ait kriterler [2] belirlenmiş olup gözle yapılan muayenede bu kriterler ve deneyimler önemli rol oynar.

Türk Standartlar Enstitüsüne göre çayın görünüşü [2] aşağıdaki gibi olmalıdır.

Kuru çayın görünüşü	Düzgün görünüşlü, siyah veya koyu bakır renkli olmalı, lif ve çöp ihtiva etmemeli

Tablo 1 : TSE KURU ÇAY GÖRÜNÜŞ ÖZELLİKLERİ

Düzgün görünüşlü; incelenen numunede ki yaprakların boyutlarının birbirine yakın olması, parçalanmış toz haline gelmemiş olmasını ifade etmektedir. Rengine yönelik siyah veya koyu bakır renginde olmasına dikkat edilmelidir. Parlak siyah veya kahvenrengi yaprakların olduğu çay kalitesinde bozukluk olduğu anlamı taşır. Ayrıca çay içinde yapancı madde ve lif (ince uzun kahverenkli parçalar) oranının fazla olması yine çayın kalitesinin düşük olduğu anlamını taşımaktadır.

Üretimde kalite standardının sürdürülebirliği açısından teknolojiden faydalanılarak, gözle yapılan sınıflandırılmanın taklit edilebilmesi bir çok gıda ürününde mümkün olduğu literatür [3] [4] [5]çalışmaları ile ortaya konmuştur. Siyah çay özelinde ise de benzer sınıflandırma çalışmaları literatüre [6] geçmiştir. Görüntü işleme ile elde edilecek görüntüye has öznitelikler, yapay zeka yöntemlerine veri olarak giriş yapılması ile etkin bir sınıflandırma yapılabileceği düşünülmektedir.

Sınınflandırma elde edilen ham görüntüden, görüntü işleme tekniklerini kullanarak çıkarılacak yeni görüntü veya görüntü değerlerinin (piksel karşılığı sayılardan) hesaplamalar sonrasında ortaya çıkacak ham görüntüyü temsil ettiği düşünülen değerler dizisi ile yapılacaktır. Elde edilen piksel karşılığı sayılar Bölüm 3'de (evrişimli sinir ağı hariç) öznitelik çıkarım yöntemleri olan yerel ikili desen, histogram, hu-moments, haralick, renk kümelerinin belirlenmesi ve istenmeyen partikül tespiti yöntemleridir.

Bu çalışmada; ham görüntüyü temsilen elde edilen öznitelikler (nümerik değerlerden oluşan matrisler) ve ham görüntünün kendisi (evrişimli sinir ağında) kullanılarak siyah çayın makine öğrenimi ile sınıflandırılması hedeflenmiştir.

BÖLÜM 2. LİTERATÜR ARAŞTIRMASI

Sağlık, gıda, güvenlik gibi pek çok alanda insanların karar verme süreçlerine makine öğrenimi kullanılarak destek olabilecek yöntemler geliştirilmektedir. Bu çalışmanın konusu olan siyah çay ve gıda alanında yapılan çalışmalarından başlıcaları irdenlenmiştir. Yapılan çalışmalarda, çalışmaya konu olan ürünlerin görsellerine ait renk değerleri ve ürünlerin doku özellikleri görüntüyü temsil eder ve makine öğrenimi için sınıflandırma verileri olarak kullanılır. Doku özellikleri, görüntü üzerindeki piksellerin birbirleri ile ilişkisi ile elde edilen sayılardan oluşan matrisler, çalışma yapılan ürünün türüne göre belirlenmiş renk aralıklarından oluşan yeni görüntü matrisleri gibi nümerik sayılardan oluşur. Görüntünün kendisi bilgisayarda nümerik sayılardan oluştuğundan doku özellikleri de sayılarlardan oluşmaktadır.

2010 yılında yapılan renk ve doku özellikleri kullanarak meyve tanıma (Fruit Recognition using Color and Texture Features) çalışması [4] 15 farklı meyve türünden toplamda 2635 meyve imgesi kullanılarak imgelerin renk ve doku özelliklerini çıkarılmıştır. Sınıflandırma işlemi istatistiksel öznitelik çıkarım yöntemlerini kullanarak yapılmıştır.

Önerilen meyve tanıma sistemi eğitim görsellerinin öznitelikleri çıkarılıp bir veritabanı oluşturulmuştur ve sonrasında test için kullanılan meyve görsellerinin öznitelikleri çıkarılıp sınıflandırma algoritması kullanılarak hangi sınıfa ait olduğu tahmin edilmektedir. Sistem elde edilen görüntüleri HSV renk uzayına dönüştürerek imge özniteliklerini çıkartarak çalışmaktadır. HSV renk uzayına dönüştürülme sebebi parlaklık ve krominans bilgilerinin elde edilmek istenmesidir.

2013 yılında yapılan elmaların görüntü işleme yöntemi ile sınıflandırılması ve leke tespiti çalışması [5] ile elma üzerindeki (doğal leke, çürük, pas) tespiti, renk, boyut olarak elmaların sınıflandırma amacıyla yapılmıştır. Bu çalışmada özel bir deney düzeneği yapılmıştır. Düzenek dairesel bant, görüntü işleme ünitesi, kontrol ünitesinden oluşmuş ve dairesel olarak tasarlanmıştır. Dairesel tasarlanmasının amacı elma için ikinci bir görüntü elde etme ve sapmaların hesaplanması için yapılmıştır.

Elmalardan elde edilen görüntülerin sınıflandırılması için hem TSE'nin TS 100-2007 standartı hem de Isparta bölgesindeki elma yetiştiricilerinden bilgiler toplanarak bir veritabanı oluşturulmuş ve sınıflandırma bu veriler çerçevesinde yapılmıştır.

2014 yılında Tıp Teknolojileri Ulusal Kongresi'ndeki gri seviyeli eş-oluşum matrisleri kullanılarak sayısal mamogram görüntüsünden doku öznitelikleri çıkarılmıştır. Mamogramdan elde edilen bu öznitelikler yapay sinir ağı ile kitle tespiti çalışması [7] (meme kanserinin tespiti) için kullanılmıştır. Çalışmada MIAS (Mammographic Image Analysis Society – mamografik görüntü analiz topluluğu, açık erişimi olan mamografik görüntü veri tabanı) veri tabanından alınan 218 adet görüntü kullanılmıştır. Görüntü üzerinde ön işleme, görüntü iyileştirme, öznitelik çıkarma, gibi işlemler yapılarak elde edilen öznitelikler yapay sinir ağı ile kitle tespiti yapılmak istenmiştir.

Çalışmada 10 teste ait sonuçların ortalaması alınarak başarı değerleri hesaplanmıştır. Buna göre duyarlılık için % 96, özgüllük için % 96 olarak bulunmuştur.

2015 yılında yapılan akciğer anomalilerinin ayrımı için Haralick (gri sevi eş oluşum matrisinden elde edilen, gri sevi pikselleri arasındaki farklılıklar) [8] doku özelliklerinin istatistiksel analizi çalışmasında [9] elde edilen görüntülerin gürültü azaltılması, görüntü iyileştirme, görüntü segmentasyonu ve sonucunda görüntülere ait Haralick öznitelikleri çıkarılmış ve akciğer anomalilerinin tespiti yapılmaya çalışılmıştır.

Materyal olarak DICOM (medikal görüntüleme birimlerinin genelde kullandığı dosyalama formatı) akciger CT (computed tomography) görüntüleri kullanılmıştır. Önerilen sistem dört aşamadan oluşmakta olup, görüntü işleme, akciğer görüntü segmentasyonu, öznitelik çıkarımı ve sınıflandırmadan oluşmaktadır. İstatistiksel analiz sağlıklı akciger dokusu ile anamoli olan dokular arasındaki ayrımı yapmakta kullanılmışıtr.

2015 yılında 4. Uluslarası Bilgi Bilimi ve Endüstri Uygulamaları Konferansında yayımlanan çalışmada yapay sinir ağları ve Haralick [8] öznitelikleri kullanılarak ahşap yüzey sınıflandırma çalışması, [10] her bir ahşap yüzeyinin kendine ait benzersiz dokusundan Haralick özniteliklerini çıkarılıp ileri beslemeli sinir ağı ile sınıflandırma yapılmıştır.

Çalışma 3 ana metod, doku analizi, Haralick öznitelik çıkarımı ve yapay sinir ağı ile sınıflandırma üzerine kurgulanmış ve sonucunda ortaya konulan sistem ahşap ve ahşap olmayan yüzeyler arasındaki sınıflandırmada % 94.10 doğrulukla sonuç vermiştir.

Tarım alanında diğer çalışmalardan biri de 2015 yılında yapılan ve tarımda doku tanımlama algoritmalarının kullanım alanlarına yönelik incelemede [11] yapraklar üzerindeki hastalıkların tanımlanması, ot algılanması, renklerine göre meyvelerin sınıflandırılması, rekolte tahmini, üretim planlaması, yeraltı sularında ki nitrat oranının tahmin edilmesi gibi bir çok alandan elde edilen veriler; K-means, derin öğrenme, Naive-Bayes, çok katmanlı sinir ağları, SVM (support vector machine), karar ağacı gibi makine öğrenme teknikleri ile sınıflandırma için kullanılmıştır.

Türkiye'de 2016 yılında yayımlanan bir başka araştırmada [3] görüntü işleme teknikleri kullanılarak Napolyon tipi kirazın sınıflandırılması yapılmıştır. Çalışmada kirazlara ait görüntüler matlab programının görüntü işleme modülü ile işlenmiş ve her bir kirazın çapının kaç mm olduğu ölçülerek daha doğru bir sınıflandırma yapılması hedeflenmiştir.

Yaprak tanımlama amacıyla 2017 yılında bir sempozyumda sunulan [12] Hu Moment ve yerel ikili desen (Hu Moments and Local Binary Patterns) değerleri öznitelik olarak yaprak görüntüsünden elde edilmiş ve destek vektör makinesi (Support Vector Machine) kullanarak yaprak tanımlama çalışması yapılmıştır. Çalışmanın önerdiği sistem Flavia (çeşitli yaprak görsellerinin bulunduğu açık kaynak bir yaprak görselleri. http://flavia.sourceforge.net/ adresinden incelenebilir) veri setini kullanarak yapılmıştır. Çalışmada yedi Hu Moment [13] (görüntünün geometrik şekillerinden elde edilen değişmezler) değişmezi ve yerel iki desen öznitelikleri destek vektör makinesi makine öğrenimi algoritması ile sınıflandırılmıştır. Sonuç olarak %94.13 oranında doğruluk ile sonuç verecek bir metod ortaya konmuştur.

Bu araştırmanın konusu olan çayın sınıflandırılması için farklı teknikler ve öznitelik çıkarım yöntemleri kullanılmaktadır. Literatüre geçmiş bazı siyah çay sınıflandırma çalışmaları aşağıda incelenmiştir.

2013 uluslarası ileri elektronik sistemler konferasında sunulan bir çalışmada, elektronik burun kullanılarak [14] siyah çaya ait öznitelikler sensör değerlerinden elde edilmiştir. 4 farklı kalite ve 40 çay örneğinden 10 tekrarlı olarak ve her bir sensörden 66 veri alınarak toplamda 26400 adetlik bir veri seti oluşturularak genetik ve genetik olmayan algoritmaların çayın kalite tahmini için performansları gözlenmiştir.

Çay üzerinde yapılan diğer bir çalışma Jaya alogritması ve Novel Fractional Fourier Entropy kullaranarak çayın kategorisini belirlenmesi çalışmasında [6] CCD kameralar ile elde edilen 300 çay görseli veri seti olarak kullanılmıştır. Bu görsellerin her birinden 64 adet renkli histogram özniteliği ayrıca yine her bir görselden 25 adet Fourier entpory özniteliği çıkarılmıştır. Toplamda her bir görsel için 89 öznitelik kullanılarak sınıflandırma ileri beslemeli yapay sinir ağı modeline giriş verisi olarak verilmiş ve ortalamada çayın sınıflandırılmasında % 97,9 oranında bir başarı sağlanmıştır.

Görsel sınıflandırmada oldukça etkili sonuçlar veren evrişimsel sinir ağı ile 2017 yılında yapılan çay sınıflandırma çalışmasında [6] 3 farklı tipte toplam 900 çay görseli veri seti olarak kullanılmıştır. 900 çay görseli veri çoğaltma teknikleri kullanılarak arttırılmış ve toplamda 54.000 görsel yapay sinir ağında eğitim ve test için kullanılmıştır. Evrişimsel sinir ağı görsellerde ki öznitelikleri uygulanan filtre (evrişimsel katmanda uygulanır) ve ara katmanlarında ki fonksiyonlar ile otomatik çıkarmaktadır. Çalışmanın sonucunda oolong çayı sınıf tahminleme başarı oranı % 99,5 yeşil çay sınıf tahminlemesi başarı oranı % 97.5 ve siyah çayın sınıf tahminlemesi başarı oranı da % 98,0 olarak elde edilmiştir.

BÖLÜM 3. ÇAY KALİTESİ SINIFLANDIRMA YÖNTEMLERİ

Çay üretiminde son aşama olan tasnif sonrasında sınıflandırılan kuru çaylar, paketleme tesislerine gitmeden önce mutlaka uzmanlar tarafından hem gözle hem de laboratuvar ortamında analizleri yapılmaktadır. Uzmanlar tarafından gözle yapılan inceleme TSE'nin [2] belirlediği görsel özellikleri içermesinin yanında incelemeyi yapan kişinin tecrübesi ile de karar verilebilmektedir.

Literatür çalışmaları göstermiştir ki gıda alanında ve bu çalışmanın da konusu olan çay alanında makine öğrenimi sınflandırma için kullanılabilmektedir. Bir insan tarafından ancak deneyim ve bilgi ile elde edilen sınıflandırma becerisi, doğru şekilde elde edilen kuru çay imgeleri ve bunlardan elde edilen istatistiksel ve yapısal öznitelikler kullanılarak makine öğrenimi ile taklit edilebilmektedir. Makine öğrenimi algoritmaları sınıflandırma için hızlı ve objektif karar vermeyi sağlayacaktır.

Sınıflandırma da kullanılacak veriler elde edilme yöntemleri ve hesaplama şekillerince yedi farklı grupta kategorize edilmiştir [15]. Kategorize edilmiş bu yöntemler arasından bazıları bu araştırma içerisinde kullanılacak olup, bu yöntemlerin haricinde de teknikler kullanılarak öznitelikler çıkarılacaktır. Elde edilen öznitelikler veri seti grupları halinde sınıflandırma algoritmaları ile testleri yapılacaktır.

YEREL İKİLİ DESEN

Yerel ikili desen (Local Binary Pattern - LBP) operatörü ilk olarak Timo Ojala tarafından 1996 yılında ortaya konmuştur [16]. LBP operatörü gri seviye görüntü üzerinde ve görüntü üzerindeki pikselin 3x3 komşuluklarına bakarak seçili piksel değerini eşik değeri olarak kullanarak, komuşu piksellerini eşik değerinden büyük ve ya küçük olması durumuna göre işaretler. İşaretlenen bu komşu pikselleri ağırlıklandırılarak LBP oparatörünün hesaplandığı pikselin yeni değeri Tablo 2 deki örnek hesaplama yönetimi ile elde edilir.

LBP operatörünün gezdirildiği (x_c, y_c) x ve y koordinatlarındaki C pikselindeki değer eğer operatörün bulunduğu piksel değerinden büyük ise 1 küçük ise 0 olarak işaretlendir. İşaretlenen (1 ve 0 olarak) yeni komşuluk piksellerindeki değerler saat

yönüne doğru 2^p katsayısı ile çarpılarak toplanır. Elde edilen yeni değer LBP operatörü ve operatörün bulunduğu pikselin yeni değeri olur.

$$LBP_{P,R} = \sum_{p=0}^{P-1} s(g_p - g_c)x2^p \ , \ s(x) = \begin{cases} 1, eğer\ x \geq 0 \\ 0, diğer \end{cases}$$

P : Toplam komşuluk piksel sayısı

R : Komşuluk yarıçapı

Gp : Komşuluk gri seviye piksel değeri

Gc: Merkez gri seviye piksel değeri

$\begin{matrix} 6 & 5 & 2 \\ 7 & 6 & 1 \\ 9 & 8 & 7 \end{matrix}$	$\begin{matrix} 1 & 0 & 0 \\ 1 & - & 0 \\ 1 & 1 & 1 \end{matrix}$	$\begin{matrix} 1 & 2 & 4 \\ 128 & - & 8 \\ 64 & 32 & 16 \end{matrix}$
Örnek görüntü piksel değerleri	Eşikleme sonucu	Ağırlıklar
Şablon = 11110001 LBP = $1 + 16 + 32 + 64 + 128 = 241$ C (zıtlık değeri) = $\frac{(6+7+8+9+7)}{5} - \frac{(5+2+1)}{3} = 4.7$		

Tablo 2 : LBP OPERATÖRÜ ÖRNEK HESAPLAMASI

Örneğin Tablo 2 $Piksel(x_1, y_1) = 6$ değerine uygulanan LBP operatörü eşikleme sonucunu ve ağırlıkları gösterir.

Gri seviye görüntü üzerindeki her bir pikselde dolaştırılan LBP operatörü ile hesaplanan yeni piksel değerlerinin histogramı çıkarılır. Bu histogram değerleri görüntü için yerel ikili desen öznitelikleri olur.

HISTOGRAM

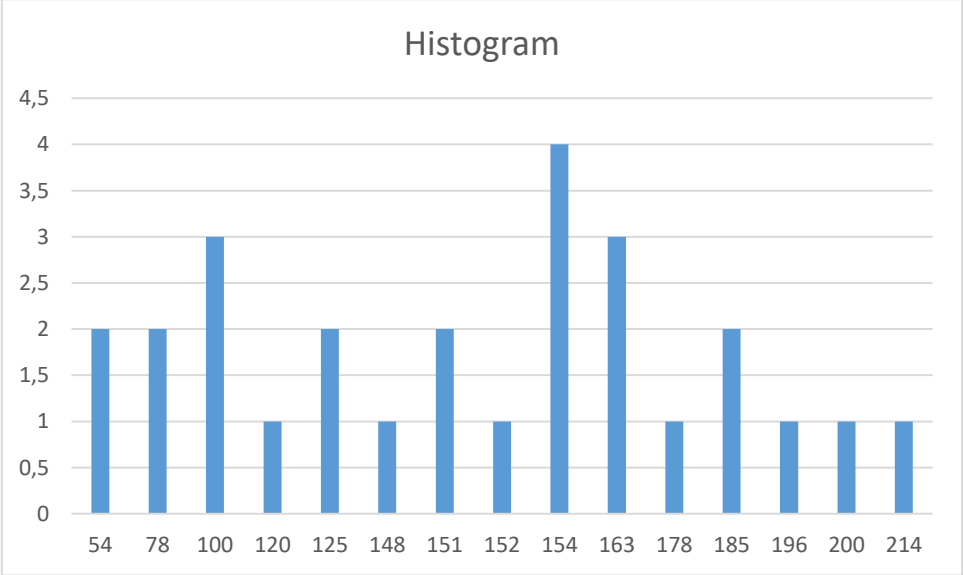
Bir görüntü üzerinde ki piksel değerlerinin (0-255 arası piksel değerleri) frekansları tablosu o görüntünün histogramıdır.

Örnek piksel değerleri ve piksel değerlerinin histogram gösterimi Tablo 3 ve Şekil 1'de gösterilmiştir.

154	178	185	152	163
125	154	120	125	163
185	100	78	54	151
163	100	54	151	78
100	148	196	200	214

Tablo 3 : Örnek piksel değerleri

$5x5$ boyutunda ki örnek bir görselin piksel değerleri Tablo 3'de verilmiştir.



Şekil 1 : ÖRNEK HİSTOGRAM

Tablo 3'deki örnek piksel değerleri ile elde edilen Şekil 1 histogram grafiği bize her bir piksel değerinin kaç defa görüntü içinde bulunduğunu gösterir. Örneğin 54 piksel değeri Tablo 3'de 2 defa bulunmaktadır.

HU-MOMENTS

Görsel doku tanımlama sistemlerinde kullanılan momentler Hu tarafından 1962 yılında ortaya konulmuş ve görselin ölçeklenmesi, döndürülmesi ya da dönüşüm işlemlerinden etkilenmeyecek şekilde görsele ait yedi değişmezden oluşmaktadır [13].

Hu ‘nun geliştirdiği bu yöntem karakter tanımlama, nesne tanımlama gibi bir çok alanda kullanılmakta ve kullanım yerlerinde başarı oldukça yüksektir.

Hu moment değişmezlerinin hesaplanma yöntemi aşağıda özetlenmiştir.

$f(x,y)$ iki boyutlu bir imge ve MxN bu iki boyutlu imgenin boyutları olmak üzere;

$$m_{p,q} = \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x,y) x^p y^q$$

p x in sırası ve q y sırasıdır.

Merkezi moment yukardaki denkleme benzer şekilde

$$\mu_{p,q} = \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x,y)(x - x_{ort})^p (y - y_{ort})^q$$

$x_{ort} = \frac{m_{10}}{m_{00}}$ ve $y_{ort} = \frac{m_{01}}{m_{00}}$ olarak hesaplanır.

Normalize edilmiş moment merkezi, merkezi moment değerinin uygun m_{00} kuvvetine bölünerek elde edilir.

$$\eta_{p,q} = \frac{\mu_{p,q}}{m_{00}^{\frac{p+q}{2}+1}}$$

Yedi Hu moment değişmezinin hesaplanması aşağıda gösterilmiştir.

$$h_1 = \eta_{20} + \eta_{02}$$

$$h_2 = (\eta_{20} - \eta_{02})^2 + 4\eta_{11}^2$$

$$h_3 = (\eta_{30} - 3\eta_{12})^2 + (3\eta_{21} - \eta_{03})^2$$

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

$$h_5 = (\eta_{30} - 3\eta_{12})(\eta_{30} + \eta_{12})((\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2) + (3\eta_{21} - \eta_{03})(\eta_{21} + \eta_{03})(3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2)$$

$$h_6 = (\eta_{20} - \eta_{02})((\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2) + 4\eta_{11}(\eta_{30} + \eta_{12})(\eta_{21} + \eta_{03})$$

$$h_7 = (3\eta_{21} - \eta_{03})(\eta_{21} + \eta_{03})(3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2) - (\eta_{30} - 3\eta_{12})(\eta_{21} + \eta_{03})(3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2)$$

Hesaplanan bu değişmezler görüntülerin geometrik desenlerine ait öznitelik olarak görüntü tanımlama ve sınıflandırmada kullanılabilmektedir.

HARALICK

Haralick istatistiksel bir doku analiz yöntemidir [8].Görüntünün doku özniteliklerinin çıkarılabilmesi için öncelikle gri seviye eş oluşum matrisinin (Gray-Level Co-Occurrence Matrix - GLCM) hesaplanması gerekir. GLCM matrisi her bir gri seviye pikselin komşu pikselleri arasındaki gri seviye farklılıklarını karşılaştırır. Gri seviye eş oluşum matrisisinden elde edilecek Haralick imge özniteliklerinin elde edilme yöntemleri aşağıda gösterilmiştir [8].

N_g toplam gri seviye renk sayısı, p_d normalize edilmiş $N_g \; x \; N_g \; GLCM$ matrisinin boyutu ve $p_d(i,j)$ GLCM matrisinin (i,j) ninci elemanıdır.

Kontrast referans piksel ve komşusunun gri seviye değişiminin değeridir.

$$\sum_i \sum_j (i,j)^2 \, p_d(i,j)$$

Homojenlik GLCM matrisindeki bir elemanın köşegenlerine göre dağılımını ölçer. Homojenlik artarsa kontras düşer.

$$\sum_i \sum_j \frac{1}{1+(i-j)^2} p_d(i,j)$$

Entropi rasgelelik veya imge içerisindeki bozukluk derecesini gösterir. Entropi değeri eş ölçüm matrisindeki tüm elemanlar aynı ise en yüksektir. Entropinin düşük olması eş ölçüm matrisindeki elemanların eşit olmamasıdır.

$$-\sum_i \sum_j p_d(i,j) \log p_d\,(i,j)$$

Enerji açısal ikinci momentden elde edilir. Açısal ikinci moment gri seviyelerin bütünlüğünü ölçer. Pikseller birbirine çok benzer ise açısal ikinci moment yüksek olacaktır.

Enerji = $\sqrt{ASM}$

ASM (Açısal ikinci moment - Angular second moments) = $\sum_i \sum_j {p_d}^2(i,j)$

Korelasyon gri seyive değerlerin GLCM matrisindeki lineer bağımlılıklarını gösterir.

$$\sum_i \sum_j P_d(i,j) \frac{(i-\mu_x)(j-\mu_y)}{\sigma_x \sigma_y}$$

$$\mu_x \; ve \; \mu_y \; ortalama \; , \sigma_x \; ve \; \sigma_y \; ise \; standart \; sapmadır.$$

$$\mu_x = \sum_i \sum_j i P_d(i,j)$$

$$\mu_y = \sum_i \sum_j i P_d(i,j)$$

$$\sigma_x = \sqrt{\sum_i \sum_j (i-\mu_x)^2 \, P_d(i,j)}$$

$$\sigma_y = \sqrt{\sum_i \sum_j \left(i-\mu_y\right)^2 P_d(i,j)}$$

Momentler rasgele bir değişkenin belirli güç fonksiyonlarının istatistiksel beklentisidir ve aşağıdaki gibi hesaplanırlar.

Moment 1 görüntüdeki ortalama piksel değerlerinin ortalamasıdır ve aşağıdaki gibi tanımlanır

$$m_1 = \sum_i \sum_j (i-j) \, p_d(i,j)$$

Moment 2 standart sapmadır ve aşağıdaki gibi tanımlanır

$$m_2 = \sum_i \sum_j (i-j)^2 \, p_d(i,j)$$

Moment 3 dağılımın asimetric derecesini ölçer ve aşağıdaki gibi tanımlanır

$$m_3 = \sum_i \sum_j (i-j)^3 \, p_d(i,j)$$

Son olarak moment 4 dağılımın nispi zirve ve düzlüğünü ölçer ve aşağıdaki gibi tanımlanır

$$m_4 = \sum_i \sum_j (i-j)^4 \, p_d(i,j)$$

Ayrıca eş oluşum matrisinin alt kümesi olan fark istatistikleri de kullanılmaktadır. Bu öznitelikler dağılımın olasıklarıdır ve aşağıdaki gibi tanımlanır

$$P_{x-y}(k) = \sum \sum C_d(i,j) \;, k = 0,1,2, \dots, N_g - 1$$

$$C_d(i,j)\ GLCM\ matrisinin\ (i,j)\ ninci\ elemanıdır$$

En basit fark istatistikleri açısal ikinci moment (ASM – Angular Second Moment), ortalama ve entropidir.

$$ASM = \sum_k \left(P_{x-y}(k)\right)^2$$

Eğer $P_{x-y}(k)$ çok yakın veya kapalı ise açısal ikinci moment küçük olur.

$$Ortalama = \sum_k k P_{x-y}(k)$$

$$Entropi = -\sum_k P_{x-y}(k)\, log P_{x-y}(k)$$

RENK KÜMELERİNİN BELİRLENMESİ

Doku tanımlama ve sınıflandırmada kullanılan yerel ikili desen, histogram, hu-moments,haralick gibi özniteliklere ek olarak siyah çay sınıflandırmasında kullanılanılan bir diğer öznitelik, K-means (yapay zeka, gözetimsiz öğrenme algoritması) algoritması ile görüntü üzerindeki renk kümeleri belirlenip elde edilen 5 renk grubu (k sayısı kümelenmek istenen renk küme sayısıdır bu örnekte 5 olarak alınmıştır) 1x 20 boyutunda bir matrise dönüştürülmüştür. Bu matrisin yapısı Tablo 4'de gösterilmiştir.

index 0	1. renk grubunun sayısı
index 1,2,3 1. renk grubu	RGB piksel değerleri
index 4	2. renk grubunun sayısı
index 5,6,7 2. renk grubu	RGB piksel değerleri
index 8	3. renk grubunun sayısı
index 9,10,11 3. renk grubu	RGB piksel değerleri
index 12	4. renk grubunun sayısı
index 13,14,15 4. renk grubu	RGB piksel değerleri
index 16	5. renk grubunun sayısı
index 17,18,19 5. renk grubu	RGB piksel değerleri

Tablo 4 : K-means RENK KÜMELEMESİ

Elde edilen 5 farklı renk ve bu renklerin görüntü içindeki sayıları düz bir matris haline ($1x20$ boyutlu) dönüştürülmüştür. Elde edilen bu matris her bir görüntü için özniteliklerden bir tanesi olarak değerlendirilecektir.

İSTENMEYEN PARTİKÜL TESPİTİ

Siyah çayda TSE görünüş standardına [2] uymayan maddeleri tespiti için siyah çay görüntüsünün, alt ve üst banta 2 RGB renk aralığı verilerek, siyah çay kalitesini etkileyen maddelerin görüntü içerisindeki yerleri ve görüntü içindeki piksel sayısı ve oranları elde edilmiştir. Elde edilen bu oransal değer görüntüye ait bir diğer öznitelik olarak veri seti içine dahil edilecek ve sınıflandırma da kullanılacaktır.

EVRİŞİMSEL SİNİR AĞI

Evrişimsel sinir ağları (convolutional neural network, CNN olarak anılacaktır) görüntü tanımlamada etkin bir yöntemdir. Sinir ağlarından farklı olarak görüntünün özelliklerini çıkaracak ekstra katmanlar kullanır. İnsan beyninde de bilinçsizce olan gördüğümüz nesnelere ait benzersiz özelliklerle nesneleri tanımlamıza benzer şekilde bu yöntem evrişimsel (convolutional) katmanında görüntülere ait benzersiz özellikleri çıkararak görüntü tanımlaması yapar.

Convolutional Layer	Görsel özelliklerin saptandığı katman
Pooling Layer	Ağ içinde parametreleri ve hesaplama sayısını azaltır
Flattening Layer	Klasik sinir ağı için özellikleri hazırlar
Fully-Connected Layer	Sınıflandırmada kullanılan sinir ağı

Tablo 5 : EVRİŞİMSEL SİNİR AĞI YAPISI

Evrişimsel bir sinir ağı genel olarak Tablo 5'deki yapılardan oluşur. CNN'in klasik bir sinir ağından en temel farkı olan evrişimsel katmanda görüntü öznitelikleri çıkarılır.

Bir CNN'de birden fazla evrişimsel katman bulunur ve her bir katmanda görüntüye ait özellikler çıkarmak için kullanılır. Giriş değeri olarak ağa verilen bir görselin evrişimsel katmanda hesaplanan özellik haritası bir sonraki evrişim katmanına giriş değer olarak verilir ve bu görüntüden de farklı bir özellik hesaplaması yapılır. Evrişimsel katmanlarda görüntü üzerinde filtre gezdirilir ve görüntü ve filtrenin denk gelen değerleri çarpılıp toplanır. Örnek hesaplama Tablo 6'da gösterilmiştir. Basit olması için görüntü olarak değerlendirilen örnek matrisin boyutları $5x5$ olarak seçilmiştir.

Örnek görüntü	Filtre	Özellik haritası
1 1 1 0 0 0 1 1 1 0 0 0 1 1 1 0 0 1 1 0 0 1 1 0 0	1 0 1 0 1 0 1 0 1	4 3 4 2 4 3 2 3 4

Tablo 6 : EVRİŞİMSEL KATMAN HESAPLAMA ÖRNEĞİ

Örnek görüntü $(1,1)$ koordinatlarına konulan filtre görüntü üzerinde denk geldiği koordinatlardaki değerler ile çarpılır ve toplanır elde edilen değer özellik hesaplama katmanından çıkacak matrisin ilk değer olacaktır. Bu örnekte ki hesaplama aşağıdaki şekilde olacaktır. İlk değer hesaplandıktan sonra filtre görüntünün sonuna kadar gezdirilir ve evrişimsel katmandaki özellik haritası hesaplanmış olur.

$$(1x1) + (1x0) + (1x1) + (0x0) + (1x1) + (1x0) + (0x1) + (0x1) + (1x1) = 4$$

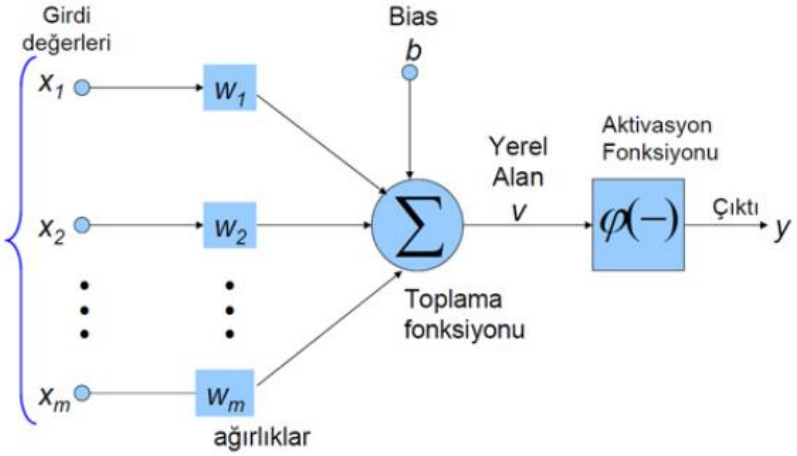
Pooling katmanı CNN modelindeki parametre ve hesaplama sayısı azaltmak ve ağ içindeki uyumsuzlukların kontrol edilmesi için kullanılır. Genellikle her bir evrişimsel katmandan sonra pooling katmanı konulur.Max pooling, avarage pooling ve L2-norm pooling işlemleri arasında en çok tercih edileni max pooling işlemindir. Tablo 7'de örnek görüntü üzerinde max-pooling işleminin uygulaması bulunmaktadır.

Örnek görüntü	2x2 boyutunda filte uygulaması sonrası (max-pooling)
1 0 2 3 4 6 2 3 3 1 1 0 1 2 2 4	6 8 3 4

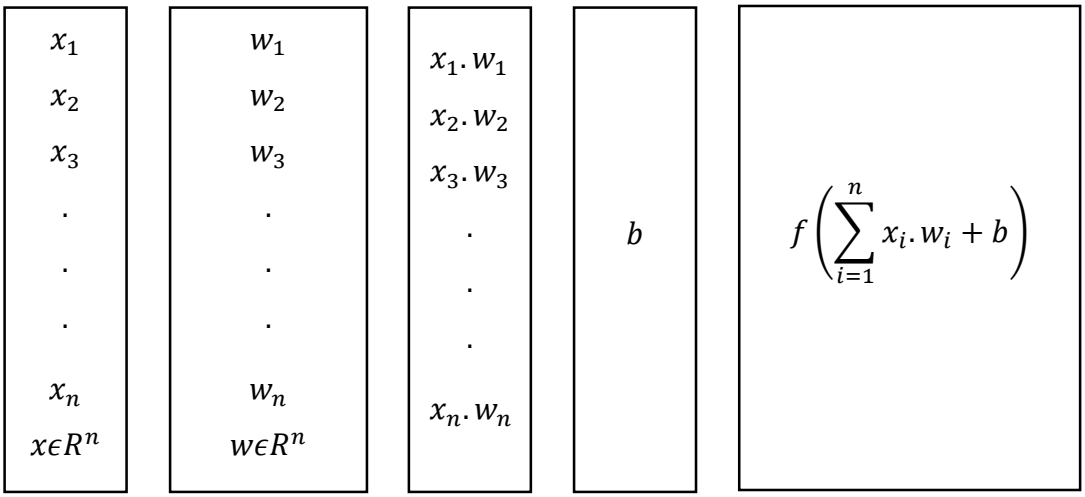
Tablo 7 : POOLING ÖRNEK HESAPLAMA

Klasir sinir ağına hazırlık için kullanılan düzleştirme katmanında görüntü özellik matrisi sinir ağı girişine uygun hale getirilir. nxm boyutunda matris halinde olan görüntü özelliği $1x(nxm)$ boyutuna indirgenerek/düzleştirilerek sınıflandırmada kullanılacak sinir ağına verilir.

Bundan sonraki süreç sinir ağı içinde her bir katmanda görüntü özellikleri kullanlarak hesaplamalar yapılır ve sınıflandırma sonucuna ulaşılır. Şekil 2'de bir sinir ağını katmanı ve Şekil 3'de sinir ağının matematiksel gösterimi ifade edilmiştir.



Şekil 2 : YAPAY SİNİR AĞI KATMANI

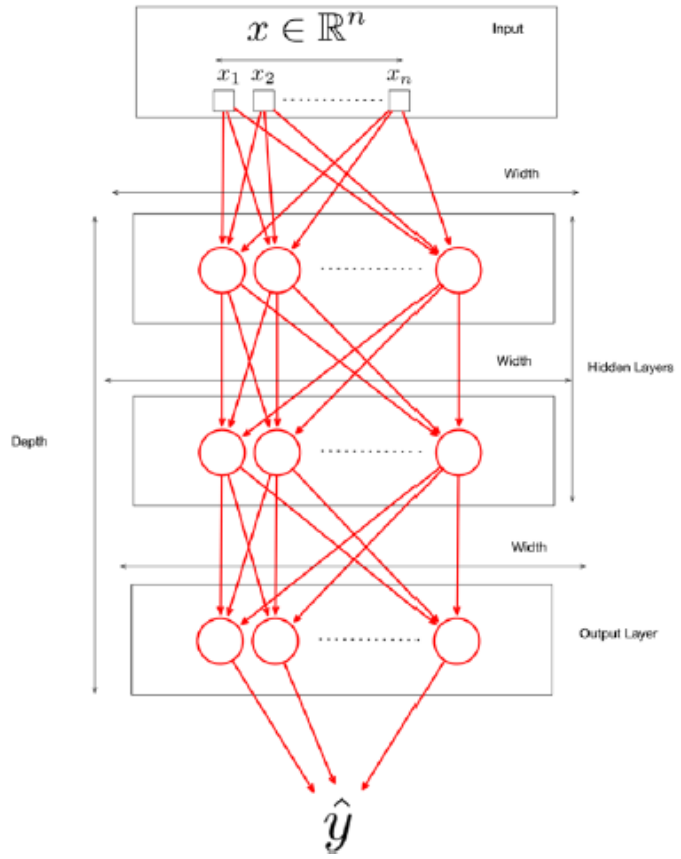


Şekil 3 : YAPAY SİNİR AĞI MATEMATİKSEL MODEL GÖSTERİMİ

Bir yapay sinir ağının matematiksel olarak ifadesi $f_0: x \rightarrow y$, $x \in R^n$ değerleri alan ve $y \in R^n$ çıkış değerini üreten bir fonksiyondur ve bu fonksiyon $\theta \in R^n$ değeri ile parameritize edildiğinde $y = f_\theta(x) = \theta.x$ olarak basitleştirilebilir. [17]

Yapay sinir ağı reel sayılar kümesinden giriş değerleri olan ve bu giriş değerleri değişken ağırlıklarla ağırlıklandırılıp sabit bir sayı ile toplanmasıyla işlem yapılan katmanda ki sonuç elde edilir. Elde edilen bu sonuç değeri bir sonraki katmana giriş değeri olarak gönderilir.Ağırlıklar ve sabitler ulaşılacak aktivasyon fonksiyonuna göre sinir ağı tarafından her bir döngüde iyileştirmeler yapılarak tekrar hesaplanmaktadır.

Şekil 2 deki yapay sinir ağı modeli tek katmanda ki bir birimi göstermektedir. Yapay sinir ağları birden fazla katman ve her bir katmanda birden fazla birimden oluşmaktadır. Çok katmanlı bir sinir ağı Şekil 4 de gösterilmiştir.



Şekil 4 : ÇOK KATMANLI BİR YAPAY SİNİR AĞI MODELİ [16]

Giriş katmanı (input layer) sınıflandırılacak verinin (convolutional ağdan elde edilen görüntü özellik matrisinin düzleştirilmiş hali) modele giriş yapıldığı katmandır. Ara katmanlar (hidden layer) ise toplama fonksiyonlar ve aktivasyon fonksiyonları ile giriş değerlerinin katsayıları ve sabit değişkenlerinin hesaplandığı katmanlardır. Çıkış katmanı (output layer) sınıflandırma neticesinin belirlendiği katmandır.

Sınıflandırmada CNN tercih edilmesi görüntü üzerinde herhangi bir ön işleme ya da görüntü özelliklerini çıkarma işlemlerine gerek kalmadan CNN kendisi evrişimsel katmanlarında bu işlemleri filtre gezdirerek ve seçilen aktivasyon fonksiyonları ile kendi yapmakdır. Klasik bir sinir ağında görüntü ön işleme ve özellik çıkarımları ayrıca yapılmalıdır. Ayrıca CNN klasik bir sinir ağına göre görüntü sınıflandırmada etkinliğini yapılan literatür çalışmaları ile ortaya konmuştur.

BÖLÜM 4. DENEYSEL ÇALIŞMA

VERİ ELDE ETME

Sınıflandırma yapılacak siyah çaylar 1 markaya ait 2 farklı kalitede (iyi kalite ve orta kalite) ürünler bir perakende noktasından satın alınmış ve tüketicilerin kullandığı paketlerden (dökme çay olarak) tercih edilmiştir. Her bir ürün için 1.5 kg temin edilmiştir.

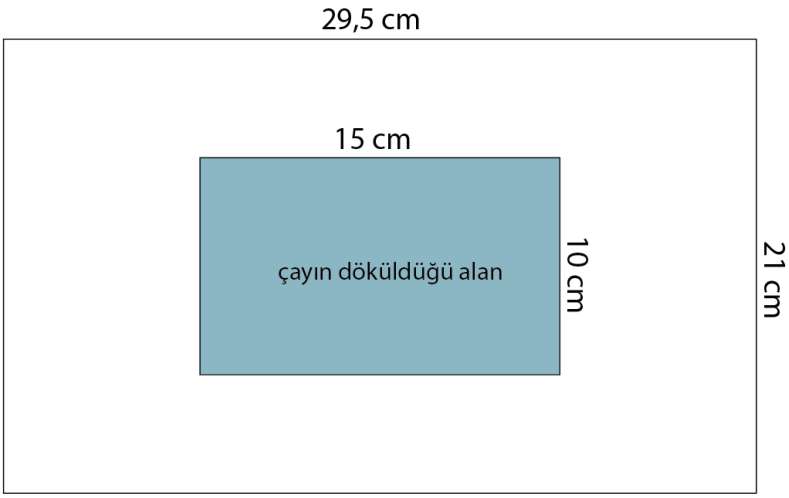
Çayın fotoğraflanması için düzenek çayın döküleceği alan ve fotoğraflanacağı alan olmak üzere 2 parça olarak hazırlanmıştır.



Şekil 5 : ÇAY FOTOĞRALAMA DÜZENEĞİ

Şekil 5 düzeneğin genel görünümüdür. Üstten led aydınlatmalı ve yukardan kamera ile çekim sağlanmıştır.

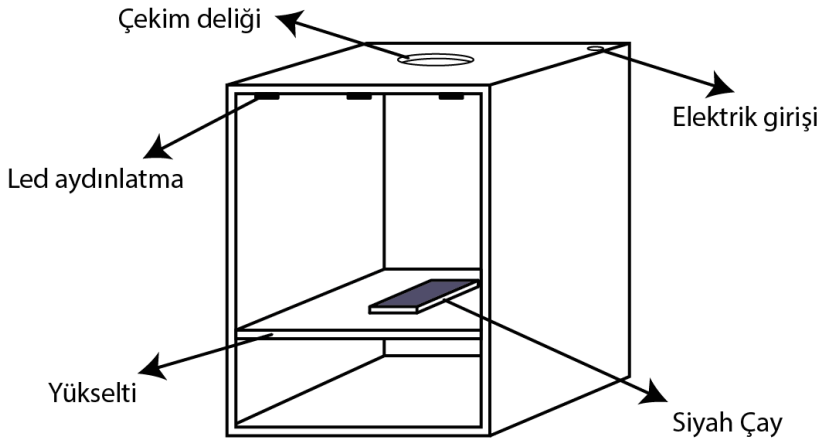
Çayın döküleceği alan kuş bakışı olarak Şekil 6'da ki gibi tasarlanmıştır.



Şekil 6 : SİYAH ÇAYIN KONULDUĞU DÜZENEK

Çayın döküldüğü alan çevresi yaklış 5 mm yükseklikte plastikle çevrilidir. Çay çevrili alana döküldükten sonra yaprakların kırılmamasına dikkat edilerek yavaşça tüm alanı kaplayacak şekilde düzeneğin üzerine yayılmıştır. Yaprakların boyutu ve rengi kaliteyi etkilen faktör olduğundan bu aşamada azami dikkat gösterilmiştir.

Fotoğraflama işlemi için dört tarafı kapalı (Şekil 5'deki gibi görüntü) bir fotoğraflama kutusu hazırlanmıştır. Çayın konulduğu Şekil 6 daki düzenek Şekil 7 deki fotoğraflama kabini içine yerleştirilerek yukardan sabit uzaktıktan fotoğraflama işlemi gerçekleştirilmiştir.



Şekil 7 : FOTOĞRAFLAMA DÜZENEĞİ ŞEMASI



Şekil 8 : ÖRNEK SİYAH ÇAY FOTOĞRAFI

Kurulan düzenekten Şekil 8'de ki gibi görüntü elde edilmiştir. Daha sonra bu görüntüler merkezlenerek çayın haricindeki kısımlar kesilip Şekil 9'da ki gibi özniteliklerin çıkarılacağı görüntüye dönüştürülmüştür. Dönüşüm işlemi sadece kesme işleminden ibarettir. Görüntü üzerinde herhangi bir aydınlatma ya da filtre gezdirilmemiştir.



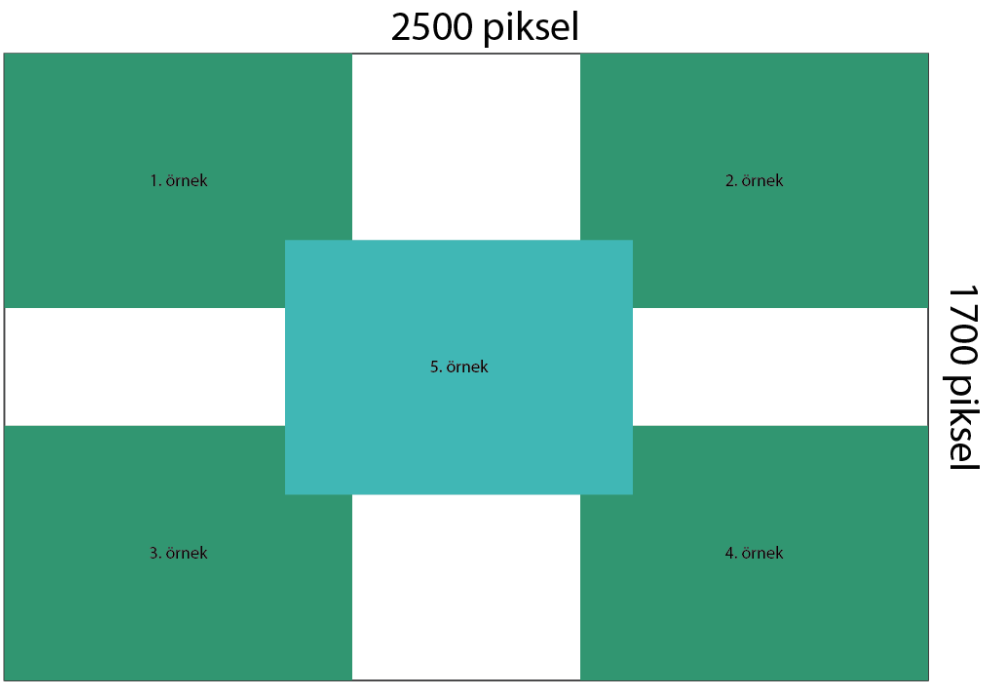
Şekil 9 : ÖZNİTELİK ÇIKARILACAK SİYAH ÇAY GÖRSELİ

İki farklı kalitedeki çaydan iyi kalitede olandan 129 adet ve orta kalitede olan çaydan ise 131 adet fotoğraf elde edilmiştir. İyi kalite çay 1 ve orta kalite çay 2 olarak isimlendirilmiştir. İyi ve orta kalite siyah çaylar herbir kalite için farklı 3 paketten alınan örnekler fotoğraflanmıştır.

VERİ ÇOĞALTMA

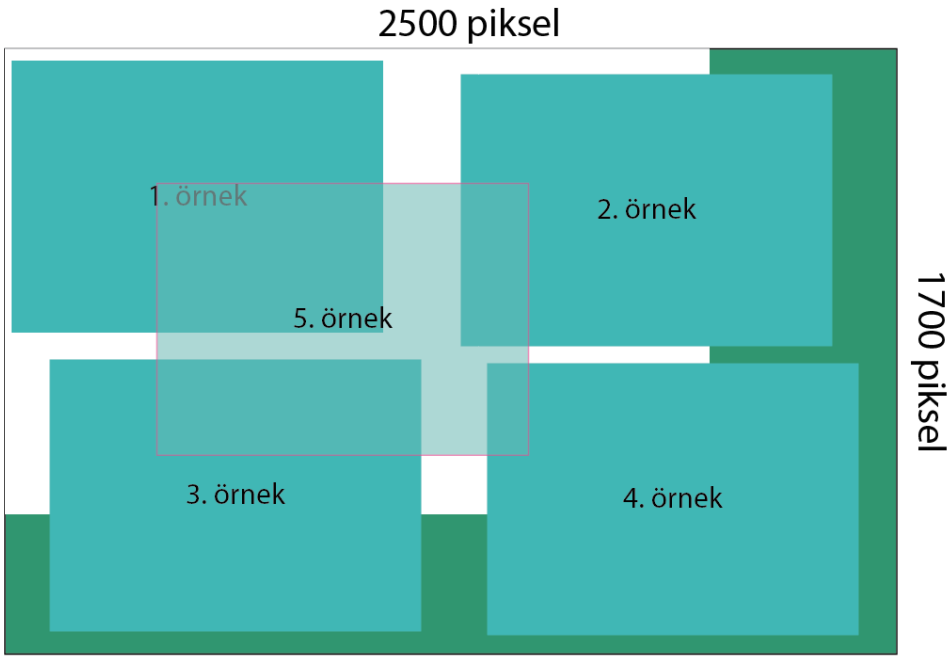
Görüntü işleme ve sınıflandırma için kullanılacak fotoğrafların çözünürlükleri yakşalık $2500\ x\ 1700\ piksel$ boyutundadır. Veri miktarı az olduğundan 2 farklı yöntem ile veri miktarı artırılmıştır.

Yöntemlerden birincisi Şekil 10'da da temsili olarak gösterilen ve öznitelik çıkarılacak siyah çayın dört köşesinden ve orta noktasından $1024x1024\ piksel$ boyutlarında parçalar alınmasıdır.



Şekil 10 : VERİ ÇOĞALTMA – 1

İkinci yöntem ise yine aynı siyah çay görselinden beş farklı rasgele nokta seçerek $1024x1024\ piksel$ boyutlarında parçalar alınmıştır. Şekil 11'de görüldüğü gibi parça alınacak boyutlar dikkate alınarak, sağdan ve alttan parça boyutu kadar örnek alınacak görüntünün başlangıç noktası kontrol edilerek ham görüntüden parça alınmıştır.



Şekil 11 : VERİ ÇOĞALTMA – 2

Şekil 11'deki görüntüde temsili olarak gösterilen koyu yeşil alanlar rasgele noktalardan alınacak parça boyutları gerçek görüntünün dışına taşmaması için piksel kontoü yapıldığı alandır.

Şekil 10 ve 11'de ki görüntü üzerinden parça alınarak bir görüntüden on farklı görüntü elde edilmiştir. Elde edilen on farklı siyah çay görseli, parçaların alındığı görselden farklı dokulara sahip olacağından kullanılan iki veri çoğaltma tekniği etkin olacağı düşünülmektedir.

Veri çoğaltma ile elde edilen her bir görsel orjinal formatında RGB olarak, HSV renk uzayı dönüşümü yapılarak, YCrCb renk uzayı dönüşümü yapılarak, Gri seviye dönüşümü yapılarak, istenmeyen partiküller görsel üzerinde ayrıştırılarak ve son olarak da özel renk katmanları ile renklendirilerek ayrı ayrı parça ölçüsünde sabit diske kaydedilmiştir. Farklı renk uzayı dönüşümlerinin yapılmasının sebebi sınıflandırma için oluşturulacak veri setini büyütmektir.

ÇALIŞMA ORTAMI

Deneysel çalışmalar geliştirme oramı PyCharm 2020.1 ve progralama dili olarak da Python (versiyon 3.8) kullanılarak gerçekleştirilmiştir. Yapay zeka algoritmaları eğitim ve test çalışmaları Intel Core i7-2600K işlemcide ve NVIDIA GeForce GTX 745 ekran kartı kullanılarak gerçekleştirilmiştir.

Evrişimsel sinir ağı haricinde kullanılan SVM ve Naive-Bayes yapay zeka algoritmaları işlemci üzerinde ve Python sklearn kütüphanesi kullanılarak çalışılmıştır. Evrişimsel sinir ağı hesaplamaları için Google tarafından geliştirilen TensorFlow kütüphanesi kullanılmıştır. Ayrıca sinir ağı modellemesi Keras ile yapılmıştır. Keras tensorflow kütüphanesi ile çalışabilen sinir ağı modellemelerini daha pratik hale getiren bir kütüphane olması sebebiyle tercih edilmiştir. Tensorflow gibi kütüphaneler ile üretilen yapay zeka modelleri grafik kartları ile daha performanslı çalıştığından, bu yapı ile geliştirilen ve test edilen veriler grafik kartı üzerinde işlenmiştir. Grafik kartı ile işlenen veriler işlemcilere kıyasla daha az maliyetli olmaktadır.

Ayrıca görüntüleri diskten okuma, kaydetme, renk uzayı değişimi, görüntülerden parçalar çıkarma gibi görüntü işleme işlemleri için OpenCV Python kütüphanesi, görüntülerki doku özniteliklerini çıkarmak için python mahotas kütüphanesi ve test uygulamasının ekranları içinde python PyQt5 kütüphanesinden faydalanılmıştır. PyQt5 kütüphanesi python içinde Qt kütüphanelerini kullanabilmek ve python ile masaüstü uygulama geliştirebilmek için tasarlanmış bir kütüphanedir. Bu kütüphane yardımıyla eğitilmiş modeller test uygulaması içinde sabit diskte kayıtlı bunulan yapay zeka algoritma modeli ve CNN modeli kullanılarak görsel bir sınıflandırıcı uygulaması yapılmıştır.

ÖZNİTELİK ÇIKARIMLARI

Veri çoğaltma teknikleri uygulanarak elde edilen görüntülerin her biri görüntü işleme metodları kullanılarak öznitelik çıkarımı yapılmıştır. Her bir görsel için renk kümelerinin belirlenmesi, istenmeyen partiküllerin tespiti, tüm renk kanallarının histogramlarının çıkarılması, doku ve nesne tanımlamada kullanılan haralick ve hu-moments sabitlerinin çıkarılması gibi ön işlem aşamasından geçirilip sınıflandırmada kullanılmak üzere CSV formatında sabit diske veri setleri kaydedilmiştir.

Her bir görsel için elde edilen veri seti 1x813 boyutunda bir matristir. Bu matris içinde veri setinin haricinde görsel ile ilgili yapısal bilgiler de mevcuttur. Sınıflandırmada yapılan bilgilerin bir kısmı kullanılmayacaktır. Tablo 8'de elde edilen veri setinin detayları bulunmaktadır

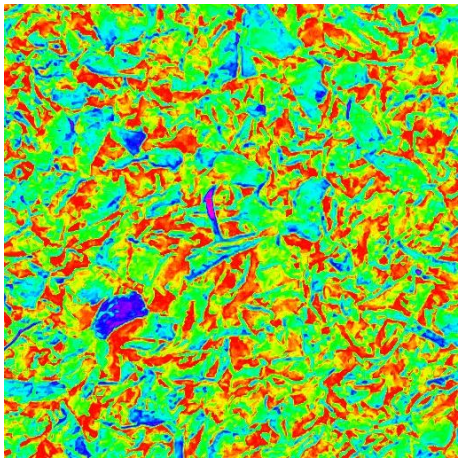
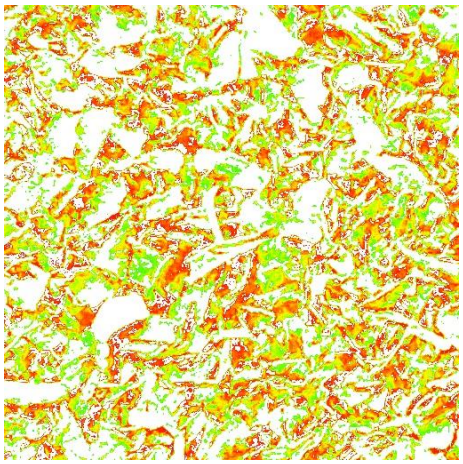
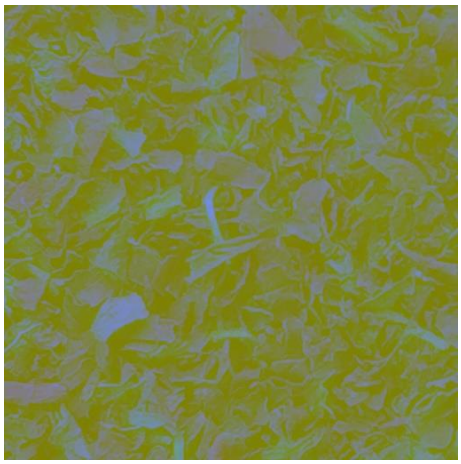
İndeks 0	test (0) ya da eğitim (1) (eğitim) datası belirtir
İndeks 1	1 (iyi kalitede ki çay) 2 (orta kalitede ki çay)
İndeks 2	görselin çözünürlüğüdür (1024 v.s.)
İndeks 3	dosya adıdır. 1000 dosya adı + 10 parça no
İndeks 4	0:rgb, 1: hsv, 2:YCrCb, 3:Gray , 4: mask, 5: color map
İndeks 5	5 küme 3 renk. Toplam 1x20 uzunluk
İndeks 25	3 kanalın histogram değerleri 256 * 3 = 768 toplam değer
İndeks 793	haralick öznitelikleri toplam uzunluk 13
İndeks 806	Hu-moment öznitelikleri toplam uzunluk 7

Tablo 8 : VERİ SETİ AÇIKLAMA TABLOSU

CNN yapay zeka modelinde Tablo 8’de çıkarılan öznitelikler kullanılmayacaktır. CNN modelleri ara katmanları arasında (evrişimsel katmanda) görüntüyü işleyerek görsellerin kendine özgü özniteliklerini çıkarmaktadır. CNN’in çıkış katmanında ki veriler görselin özniteliğini ifade etmektedir. CNN’e görseller sabit diskten okunarak direk verilecektir.

SINIFLANDIRMA

Veri çoğaltma teknikleri uygulanarak elde edilen siyah çay görüntülerine görüntü işleme uygulanarak renk uzayı dönüşümleri ve istenmeyen partikül oranı gösteren örnek görseller Tablo 9'de gösterilmiştir.

RGB renkler	HSV renklendirilmiş
	
İstenmeyen partiküller	YCrCb renkler
	

Tablo 9 : SINIFLANDIRMADA KULLANILACAK GÖRSEL ÖRNEKLERİ

Tablo 9'de ki her bir örnek görüntüden elde edilien renk kümeleri, histogram, hu-moments ve haralick öznitelikleri sınıflandırma tamamı ya da bir kısmı kullanılacaktır. RGB görüntü kamera ile çekilmiş görüntü, HSV ve YCrCb görüntüler RGB den elde

edilmiş görüntü ve istenmeyen partikül görseli ise HSV görüntüden belirli renk aralıkları çıkartılarak elde edilmiştir.

Deneyimli ve eğitimli insanlar tarafından yapılan gözle sınıflandırma insan gözünün görebileceği dalga boyutları ile oluşan RGB renk uzayı görseller ile yapılmaktadır. Uzman kişi RGB renklerden oluşan bir siyah çaya bakarak kalitesi ve sınıflandırması hakkında bilgi sahibi olabilmektedir. RGB görüntüden elde edilen diğer dönüşümler ancak bir bilgisayar sayesinde elde edilebilir ve insan kullanımına sunulabilir.

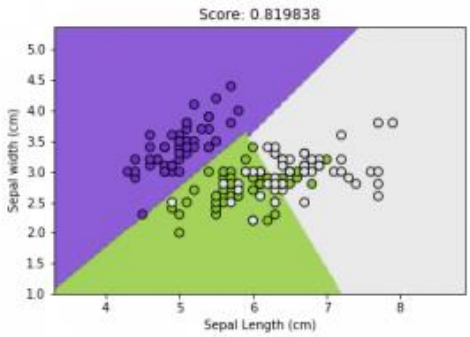
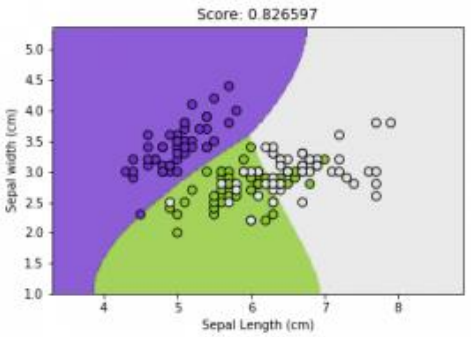
Makine öğrenimi algoritmaları ve yöntemleri için tek başına bu görseller anlamsızdır. Bir makine öğrenimi algoritmasının bu görselleri tanımlayabilmesi ve sınıflandırma yapabilmesi için öncesinde mutlaka bu görsellere ait özelliklerin sayılarla ifade edilebilecek hale dönüştürülmesi gerekir. Bu görsellerden elde edilen veri matrisi ve özelliklerin ne olduğu Tablo 8'de ifade edilmiştir.

Burada istisnai olan yapay zeka yöntemi evrişimsel sinir ağlarıdır. Evrişimsel sinir ağları etkin bir sınıflandırma yapan özelliklerden birisi olan görüntünün kendisini kullanabilmesi ve görüntüye ait benzersiz özellikleri evrişim aktmanında çıkarması, görüntü sınıflandırmada son yıllarda çokça kullanılmasını ortaya çıkarmıştır.

SVM SINIFLANDIRICISI

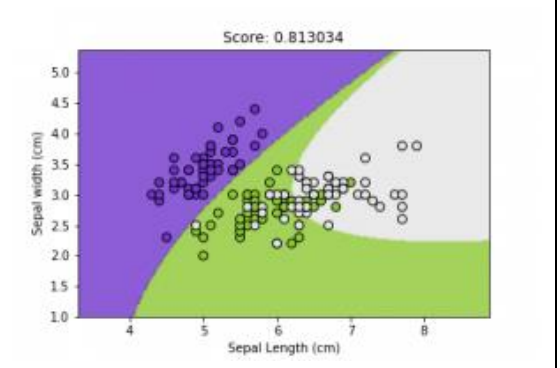
SVM sınıflandırısı bir denetimli öğrenme sınıflandırıcısıdır ve sınıflandırılacak veri kümelerinin aralarındaki sınır çizgilerini belirleyerek veri kümelerinin sınıflandırılmasını sağlar. Bu sınır çizgileri hiper düzlem ya da karar sınırları olarak adlandırılır. Verilerin oluşturduğu bu düzlemi ve boyutları verilere ait birer özellik olarak değerlendiririz. Hiper düzlemde bu verilerin sınırlarının belirlenmesi demek veri sınıflarınında sınıflandırılması anlamı taşır.

Düzlemde sınır çigizleri her zaman düz bir çizgi (lineer) ile belirlenemeyebilir. Sınır çizgileri polinom, radyal temelli ve sigmoid gibi fonksiyonlarla da belirlenebilmektedir. Tablo 10 ve 11'de seçilen çekirdek sınır belirleyicinin IRIS [18] veri seti (yaprakların taç ve çanak uzunluklarını içeren veri seti) üzerinde uygulanıp elde edilmiş sınırlarının görselleştirilmesi bulunmaktadır.

Lineer	Radyan Temelli Fonksiyon
	

Tablo 10 : SVM SINIFLANDIRMA FONKSİYONLARI – 1

Tablo 10 lineer ve radyan temelli fonksiyonlar ile IRIS veri seti sınıflandırmasının görsel ayrıştırılması gösterilmiştir. Lineer fonksiyon ile veri seti sınıflandırma sonucu düz çizgiler ile ayrılmış ve seçilen fonksiyon radyan temelli olduğunda ise veri seti sınıfları arası sınırlar girintili hale gelmiştir.

Polinom


Tablo 11 : SVM SINIFLANDIRMA FONKSİYONLARI – 2

Tablo 11 ise bize IRIS veri setinin SVM ile sınıflandırma sonucunu seçilen SVM çekirdek fonksiyonu polinom olması durumunda elde edilecek sınır çizgilerini göstermektedir.

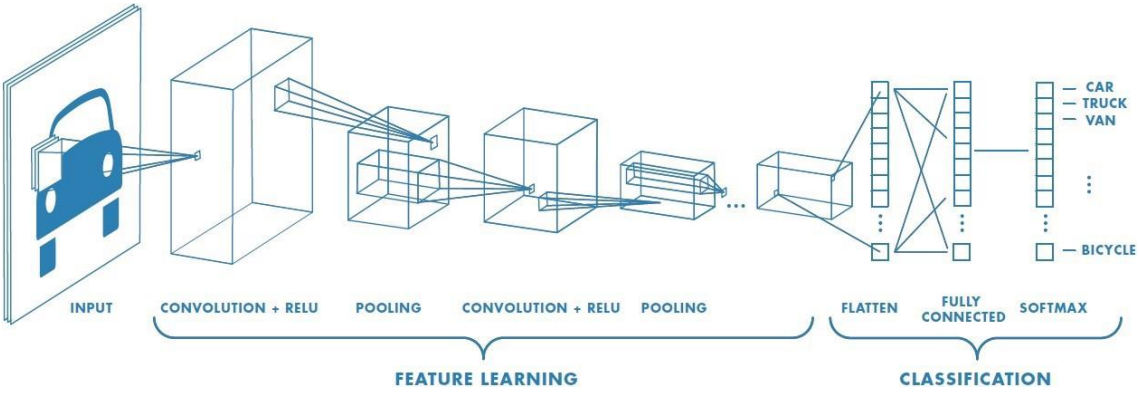
NAIVE-BAYES SINIFLANDIRICISI

Olasılık sınıflandırıcılardan biri olan Naive Bayes sınıflandırma algoritması Bayes teoremine dayarnır ve veri seti içinde her bir değerin olasılığını hesaplayarak en yüksek değere göre sınıflandırma yapar.

EVRİŞİMLİ SİNİR AĞI SINIFLANDIRICISI

Bir evrişimli yapay sinir ağının (CNN) yapısı Şekil 12'de [19] özetlenmiştir. Bu tip ağların yapay sinir ağlarında farkı sınıflandırılacak verilerin görüntü olması ve görüntüler öncesinde bir öznitelik çıkarım mühendisliği yapmaya gerek kalmadan görüntü renkli ya da renksiz (eldeki veri türüne göre ya da tercihe göre) yapay sinir ağına giriş verisi olarak verilebilmesidir. Giriş verisi olarak görüntüyü alan yapay sinir ağı giriş katmanından sonra görüntüye ait öznitelikleri convolutional (evrişimsel) katmanında hesaplamaktadır. Özniteliklerin çıkarıldığı katmanda herbir piksel üzerinde gezdirilen bir filtre ile hesaplama yapılır ve hesaplanan yeni piksel değerleri bir sonraki katmana aktarılır. Bu işlem evrişim (convolution) katmanı sayısınca devam eder. En son evrişim katmanında elde edilen değer artık görüntünün özniteliği olur. Bu değer matrisi

sınıflandırma öncesinde düzleştirilip tam bağlantılı katmana aktarılır. Son olarak aktivasyon fonksiyonunda geçirilip tahmin değeri elde edilir.



Şekil 12 : CNN GENEL YAPISI

Genel bir CNN yapısı Şekil 12 ile özetlenmiştir. Katmanlar arası görüntünün transferi ve son olarak sınıflandırma yapılacak klasik sinir ağı katmanı görünmektedir.

Sınıflandırma için üç farklı çalışma veri seti oluşturulmuş ve farklı veri setlerinin sınıflandırma performansları incelenmiştir.

Birinci veri setinde uzman bir kişinin referans aldığı bilgilerden olan renk yoğunluğu (veri kümemiz içinde görsellerden 5 farklı renk grubu elde edilmiştir) ve istenmeyen partiküllerin oranı bulunmaktadır. Bu veriler SVM ve Naive-Bayes algoritmaları ile test edilmiştir.

İkinci veri setinde ise siyah çaylar arasında ki kalite farklılıkları çayın görselliğinde ki doku (görünüş) farklılığı olarak da değerlendirilebileceğinden, doku tanımlama ve sınıflandırma da kullanılan özellikler siyah çay görsellerinden elde edilerek birinci veri setinde ki değerler ile birleştirilerek yine SVM ve Naive-Bayes algoritmaları ile sınıflandırma testleri yapılmıştır. Bu veri setinde görüntünün RGB, HSV ve YCrCb renk uzayları arasında ki sınıflandırma performansları da incelenmiştir.

Son olarak üçüncü veri seti olarak görüntülerden herhangi bir öznitelik çıkarımı yapılmadan evrişimsel sinir ağına $1024x1024\ piksel$ boyutunda parçalar alınarak elde edilen siyah çay görselleri $256x256\ piksel$ boyutuna indirgenerek CNN modeline sınıflandırma için gönderilmiştir. Boyut indirgenmesi CNN modeli içinde parametre

sayısını düşüreceğinden görseller $256x256\,piksel$ boyutuna indirgenmiştir. $1024x1024x3\,piksel$ giriş değerine sahip bir CNN modeli 252.162.754 hesaplanacak parametre içerirken $256x256x3\,piksel$ boyutuna sahip bir model 13.087.426 adet hesaplanacak parametre içermektedir.

VERİ SETİ 1 ÇALIŞMASI

Veri seti 1 RGB görüntüden elde edilen renk kümeleri, hsv renk uzayı dönüşümü yapılarak elde edilen renk kümeleri bilgisi ve Tablo 9'da örneklendirilen istenmeyen partikül oranını içermektedir. Veri seti 1 toplamda her bir görsel için 1x41 boyutunda bir matrisden oluşmaktadır. Veri seti 1 için SVM ve Naive-Bayes sınıflandırıcıları ile testler yapılmış olup SVM karışıklık matrisi Tablo 12'de, SVM sınıflandırma raporu Tablo 13'de, Naive-Bayes karışıklık matrisi Tablo 14'de ve Naive-Bayes sınıflandırma raporu Tablo 15'de gösterilmiştir. Veri seti 1 de veri çoğaltma teknikleri uygulanarak 2 farklı üründen eğitim için toplam 2020 adet ve test için 580 adet görsel elde edilmiştir. Veriler normalize edilmeden sınıflandırıcılarda kullanılmıştır.

Test için ayrılan 580 adet görselin SVM sınıflandırma sonucu karışıklık matrisi Tablo 8 ve sınıflandırma raporu Tablo 9'da incelenebilir. SVM sınıflandırıcı çekirdek fonksiyonu lineer olarak kullanılmıştır.

213	67
93	207

Tablo 12 : SVM KARIŞIKLIK MATRİSİ (CONFUSION MATRIX)

Tablo 12 karışıklık matrisi göstermiştir ki 1 olarak isimlendirilen (iyi kalite) toplam 280 adet görselin 213 tanesi doğru ve 67 taneside yanlış sınıflandırılmıştır. Benzer şekilde 2 (orta kalite) olarak isimlendirilen çay topalm 300 adet görselleden 207 tanesi doğru ve 93 taneside yanlış olarak SVM ile sınıflandırılmıştır. Bu sınıflandırmaya ait detay verileri Tablo 13'de hesaplanmıştır.

	Precision	Recall	f1-Score	Support
1	0.70	0.76	0.73	280
2	0.76	0.69	0.72	300
Accuracy			0.72	580
Macro avg	0.73	0.73	0.72	580
Weighted avg	0.73	0.72	0.72	580

Tablo 13 : SVM SINIFLANDIRMA RAPORU

SVM algoritmasında 2020 adet eğitim ve 580 adet test verisi ile sınıflandırma sonuç raporu Tablo 13'deki duruma göre 1 ve 2 nolu ürünler için %73 ve %72'lik değerler (f1 skoru) ve %72 gibi bir doğruluk ortaya koymuştur.

SVM ile kıyaslamak amacıyla bir başka sınıflandırıcı olan Naive-Bayes sınıflandırıcısına ait karışıklık matrisi ve sınıflandırma raporu Tablo 14 ve Tablo 15'de gösterilmiştir.

208	72
159	141

TABLO 14 : NAIVE-BAYES KARIŞIKLIK MATRİSİ (CONFUSION MATRIX)

Tablo 14 bize göstermiştir ki Naive-bayes alogritması toplam 280 adet 1 nolu üründen 208 tanesini doğru ve 72 tanesinide yanlış olarak ayrıca toplam 300 adet 2 nolu çayın 141 tanesini doğru ve 159 tanesini de yanlış olarak sınıflandırmıştır. Bu sınıflandırma sonuçları Tablo 15'de detaylandırılmıştır.

	Precision	Recall	f1-Score	Support
1	0.57	0.74	0.64	280
2	0.6	0.47	0.55	300
Accuracy			0.60	580
Macro avg	0.61	0.61	0.60	580
Weighted avg	0.62	0.60	0.59	580

TABLO 15 : NAIVE-BAYES SINIFLANDIRMA RAPORU

Tablo 15'de de görüldüğü üzere Naive-Bayes eldeki verilerin sınıflandırmasında vasat bir sonuç ortaya koymuştur. Toplam 2020 adet eğitim ve 580 adetlik test verisi içinden 1 ve 2 nolu ürünler için % 64 ve % 55 lık bir başarı ve %60'lık bir doğruluk ortaya koymuştur.

Veri seti 1 için yapılan sınıflandırmada SVM algoritması daha iyi bir sınıflandırma sonucu elde edilmiştir.

VERİ SETİ 2 ÇALIŞMASI

Sınıflandırma için kullanılacak bu veri seti her bir görsel için $1x808$ boyutunda bir matrisden oluşmaktadır. Bu veri setindeki görsele (RGB, HSV, ,YCrCb ve maskelenmiş görsel) ait öznitelikler yaklaşık 72 saatlik bir işlemci çalışması sonrasında elde edilmiştir. Görsele ait görüntü işleme ile edilmiş RGB, HSV, YCrCb, gri seviye ve maskelenmiş görüntülerin öznitelikleri ayrı ayrı çıkarılmıştır ve sınıflandırma performansları SVM ve Naive-Bayes sınıflandırıcı ile karşılaştırılmıştır.

Sınıflandırma veri setinin yapısı Tablo 8'de özetlenmiştir. Tablo 8'deki görüntüyü tanımlayıcı bilgilerin haricinde ki (indeks 5-813 arasındaki veriler) veriler görsele ait birer öznitelik olarak kabul edilmiştir. SVM çekirdek fonksiyonu lineer olarak seçilmiştir.

RGB ÖZNİTELİKLERİ TESTİ

RGB olarak diske kayıtlı olan görsellerden elde edilmiş öznitelikler kullanılarak SVM algoritması ile deneysel çalışmalar yapılmıştır.Her bir göselin $1x808$ boyutunda bir öznitelik matrisi kullanılmıştır. Karışıklık matrisi tablo 16 ve sınıflandırma sonuç raporu Tablo 17 'de sunulmuştur.

280	0
8	292

Tablo 16 : SVM KARIŞIKLIK MATRİSİ (CONFUSION MATRIX)

SVM sınıflandırma sonucunda elde edilen karışıklık matrisi sonucuna göre 280 adetlik 1 isimli çaydan tamamı doğru ve toplam 300 adetlik 2 isimli çaydan 292 adet doğru 8 adet yanlış ile oldukça iyi bir sınıflandırma elde edilmiştir. Sınıflandırma detay bilgileri Tablo 17'de sunulmuştur.

	Precision	Recall	f1-Score	Support
1	0.97	1.00	0.99	280
2	1.00	0.97	0.99	300
Accuracy			0.99	580
Macro avg	0.99	0.99	0.99	580
Weighted avg	0.99	0.99	0.99	580

Tablo 17 : SVM SINIFLANDIRMA RAPORU

RGB görüntüden elde edilen öznitelikler SVM sınınflandırma algoritması kullanılarak f1-skor %99 olarak oldukça yüksek bir sınıflandırma değeri elde edilmiştir. Ayrıca SVM sınıflandırma doğruluk oranı da %99 ile oldukça yüksek olmuştur.

HSV ÖZNİTELİKLERİ TESTİ

RGB görüntüden HSV renk uzayı dönüşümü elde edilerek sabit diske kaydedilen siyah çay görseline ait $1x808$ boyutundaki öznitelik matrisi SVM sınıflandırma algoritması ile deneysel çalışması yapılmıştır. Karışıklık matrisi Tablo 18 ve sonuç raporu Tablo 19'da sunulmuştur.

279	1
3	297

Tablo 18 : SVM KARIŞIKLIK MATRİSİ (CONFUSION MATRIX)

Tablo 18'de ki karışık matrisine göre 280 adetlik 1 isimli siyah çayın 279 tanesi doğru ve 1 tanesi yanlış ayrıca 300 adetlik 2 isimli siyah çayın 297 tanesi doğru ve 3

taneside yanlış olarak tahminlenmiştir. Karışıklık matrisinin detay raporu Tablo 19'da sunulmuştur.

	Precision	Recall	f1-Score	Support
1	0.99	1.00	0.99	280
2	1.00	0.99	0.99	300
Accuracy			0.99	580
Macro avg	0.99	0.99	0.99	580
Weighted avg	0.99	0.99	0.99	580

Tablo 19 : SVM SINIFLANDIRMA RAPORU

Tablo 19'da ki sonuçlara göre HSV renk uzayından elde edilen görsele ait özniteliklerin sınıflandırma performansı 1 ve 2 isimli ürünler için %99 ve SVM sınıflandırıcısının doğruluk oranı %99 olarak gerçekleşmiştir. Bu sonuçlar HSV renk uzayınından elde edilen özniteliklerin sınıflandırma için etkin olduğunu ortaya koymuştur.

YCrCb ÖZNİTELİKLERİ TESTİ

Renk uzaylarından bir başkasyı olan YCrCb renk uzayı dönüşümü HSV de olduğu gibi yine orjinal RGB görüntüden elde edilmiştir. Bu görseller içinde $1x808$ boyutunda bir öznitelik matrisi elde edilmiş ve SVM ile sınıflandırma çalışması yapılmıştır. SVM sınıflandırma karışıklık matrisi Tablo 20 ve sonuç raporu Tablo 21'de sunulmuştur.

278	2
2	298

Tablo 20 : SVM KARIŞIKLIK MATRİSİ (CONFUSION MATRIX)

Tablo 20'deki karışıklık matrisi sonuçlarına göre YCrCb renk uzayından elde edilen siyah çay görseline ait öznitelikler ile SVM algoritması 280 adetlik 1 isimli siyah çayın 278 tanesini doğru 2 tanesini yanlış ve 300 adetlik 2 isimli siyah çayın 298 tanesini doğru ve 2 tanesini yanlış olarak tahminlemiştir. Tablo 21'de SVM sonuç raporu sunulmuştur.

	Precision	Recall	f1-Score	Support
1	0.99	0.99	0.99	280
2	0.99	0.99	0.99	300
Accuracy			0.99	580
Macro avg	0.99	0.99	0.99	580
Weighted avg	0.99	0.99	0.99	580

Tablo 21 : SVM SINIFLANDIRMA RAPORU

Tablo 21'deki elde edilen sonuçlar ışında SVM algoritması YCrCB renk uzayından elde edilen öznitelikler ile sınıflandırma performansı %99 f1-skoru ve yine %99 doğrulukla sonuç vermiştir. Önceki HSV ve RGB renk uzayından elde edilen değerler YCrCb renk uzayından elde edilen değerlere de oldukça yakındır.

Gri seviye ve maskelenmiş görüntü sınıflandırma performansları RGB, HSV ve YCrCb görüntülerinden elde edilen öznitelikler kullanılarak elde edilen sınıflandırma performansından daha düşük çıkmış ve çalışma içerisinde sunulmamıştır. Ayrıca Naive-

Bayes sınıflandırıcısı SVM sınıflandırıcısı ile kıyaslanamayacak kadar da düşük doğrulukla sonuç ortaya çıkarmıştır.

1 ve 2 numaralı veri setleri ile yapılan çalışmalar SVM sınıflandırıcısının ürün 1 ve ürün 2 için çıkarılan özniteliklerini kullanarak başarılı bir sınıflandırma sonucu ortaya koymuştur. RGB, HSV ve YCrCb renk uzayları arasında YCrCb'den elde edilen başarı daha dengeli olmuştur. Bu dengeli sonuç YCrCb'nin kullanımını daha makul olmasını sağlamıştır.

VERİ SETİ 3 ÇALIŞMASI

Evrişimsel sinir ağı (convolutional neural network, CNN olarak anılacaktır) için hazırlanan bu veri seti, veri çoğaltma yöntemleri ile elde edilen görsellerden oluşmaktadır. Görseller üzerinde herhangi öznitelik mühendisliği yapmadan CNN giriş katmanına renkli olarak olarak verilmiştir.

Sabit diskte $1024x1024\ piksel$ çözünürlükte bulunan renkli görüntüler eğitim için 12.100 ve test için 3.480 adet görsel yapay sinir ağına $256x256\ piksel$ çözünürlüğe düşürülerek, bulundukları klasörlerden 20'şerli gruplar halinde alınıp eğitim için CNN'e gönderilmiş ve sinir ağı 30 devir (epoch) her bir devir de 200 (steps per epoch) adımda eğitim sürecini tamamlanmıştır. Sinir ağı doğrulama işlemi (validation step) için ise 90 adım olarak doğrulama işlemini yapılmıştır.

Maliyet fonksiyonu olarak "categorical_crossentropy", optimizasyon için RMSprop ve öğrenme katsayısı 1e-4 (0.0001) olarak ayarlanmıştır. Sinir ağının özet bilgisi Şekil 12'de gösterilmiştir. 13.086.913 parametre sinir ağının eğitimi süresinde hesaplanacak ve sinir ağı model oluşturulacaktır. Yapan sinir ağının eğitim ve test işlemleri ekran kartı ile yapılmış olup işlemciye göre maliyet etkin bir sonuç ortaya çıkmıştır.

```
Model: "sequential"
_________________________________________________________________
Layer (type)                 Output Shape              Param #
=================================================================
conv2d (Conv2D)              (None, 254, 254, 32)      896
_________________________________________________________________
max_pooling2d (MaxPooling2D) (None, 127, 127, 32)      0
_________________________________________________________________
conv2d_1 (Conv2D)            (None, 125, 125, 64)      18496
_________________________________________________________________
max_pooling2d_1 (MaxPooling2 (None, 62, 62, 64)        0
_________________________________________________________________
conv2d_2 (Conv2D)            (None, 60, 60, 128)       73856
_________________________________________________________________
max_pooling2d_2 (MaxPooling2 (None, 30, 30, 128)       0
_________________________________________________________________
conv2d_3 (Conv2D)            (None, 28, 28, 128)       147584
_________________________________________________________________
max_pooling2d_3 (MaxPooling2 (None, 14, 14, 128)       0
_________________________________________________________________
flatten (Flatten)            (None, 25088)             0
_________________________________________________________________
dense (Dense)                (None, 512)               12845568
_________________________________________________________________
dense_1 (Dense)              (None, 2)                 1026
=================================================================
Total params: 13,087,426
Trainable params: 13,087,426
Non-trainable params: 0
_________________________________________________________________
```

Şekil 13 : CNN MODEL ÖZET BİLGİSİ

Şekil 13’ de özetlenen CNN modeli dört evrişimsel katmandan ve 2 klasik sinir ağı katmanından oluşmaktadır. Her evrişimsel katmandan sonra pooling metodlarından max pooling uygulanmış ve klasik sinir ağına giriş için değerler matrisi düzlenştirilmiştir.



Şekil 14 : CNN DOĞRULAMA GRAFİĞİ

CNN ile yapılan 1 ve 2 isimli siyah çay görsellerinin eğitim için ayrılan 12.100 adet görsel ve test için ayrılan 3.480 adet görselin sınıflandırma sonuç grafiği Şekil 14'de sunulmuştur. Eğitim doğruluğu arttırkça eğitim veri seti içindeki doğrulama amacıyla kullanılan görsellerinde doğru sınıflandırma oranı arttmıştır.



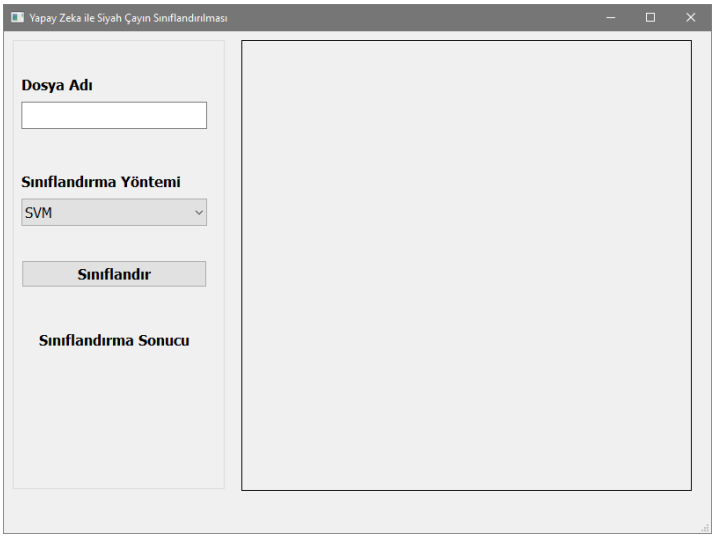
Şekil 15 : CNN MALİYET FONKSİYONU DEĞİŞİMİ

Kullanılan maliyet fonksiyonunun değişimi 12.100 adet eğitim ve 3.480 adet de doğrulama 1 ve 2 isimli siyah çay görselleri kullanılarak Şekil 15'de sunulmuştur. Eğitim görsellerinde ki hata payı düştükçe aynı şekilde doğrulama için ayrılan görsellerin hata payları da düşüş göstermiştir.

Özet bilgisi Şekil 13 de olan CNN modeli eğitimi grafik kartı ile yaklaşık 20 dakika sürmüş ve eğitim verileri %98.52 ve doğrulama verileri (test verileri) doğruluk oranı %98.56 olarak gerçekleşmiştir. Ayrıca eğitim maliyet fonksiyonu değeri 0.0563 ve test maliyet fonksiyonu değeri 0.0321 olmuştur. Bu sonuçlar ve RGB,HSV ve YCrCb gibi renk uzayı dönüşümlerinden elde edilen öznitelikleri SVM algoritması kullanılarak elde edilen sonuçlara oldukça yakındır. Bundan dolayı CNN gibi etkin bir sınıflandırma yönteminin başarısı siyah çay sınıflandırma çalışmasında da ortaya çıkmıştır.

BÖLÜM 5. TEST UYGULAMASI

Eğitim ve test görselleri arasında yer almayan 1 ve 2 isimli siyah çay görsellerinde ayrılan ikişer adetlik görsel yazılan test uygulaması ile test edilmiştir. Test uygulaması yapay zeka algoritmalarının eğitimleri sonucunda ortaya çıkan eğitim modellerini kullanmaktadır. Modeller sabit diskten okunup test uygulaması grafik arayüzü ile kullanılmaktadır.

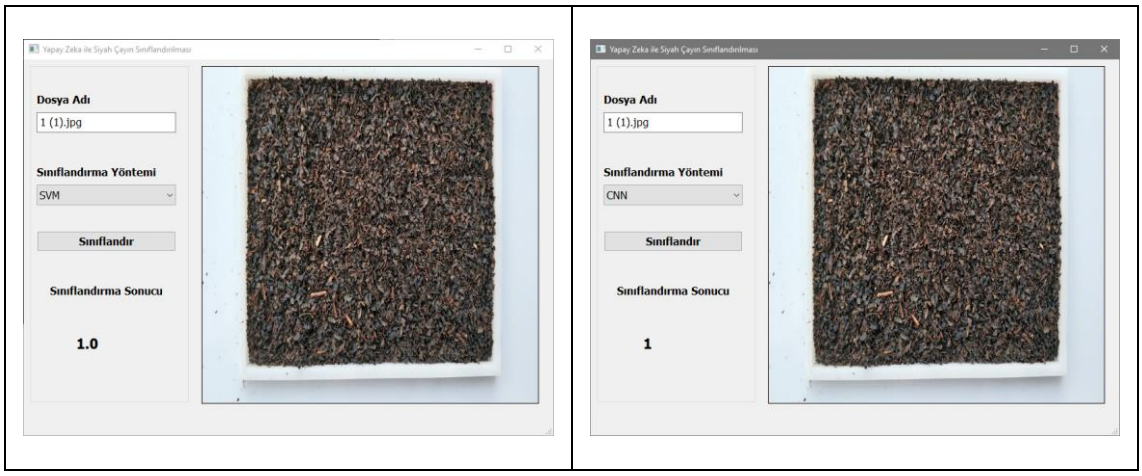


Şekil 16 : TEST UYGULAMASI ARAYÜZÜ

Test uygulaması arayüzü sınıflandırılacak siyah çay görselinin adı, sınıflandırma yöntemi seçimi, sınıflandırma sonucu ve seçilen görselin ekranda gösterileceği alanlardan oluşmaktadır.

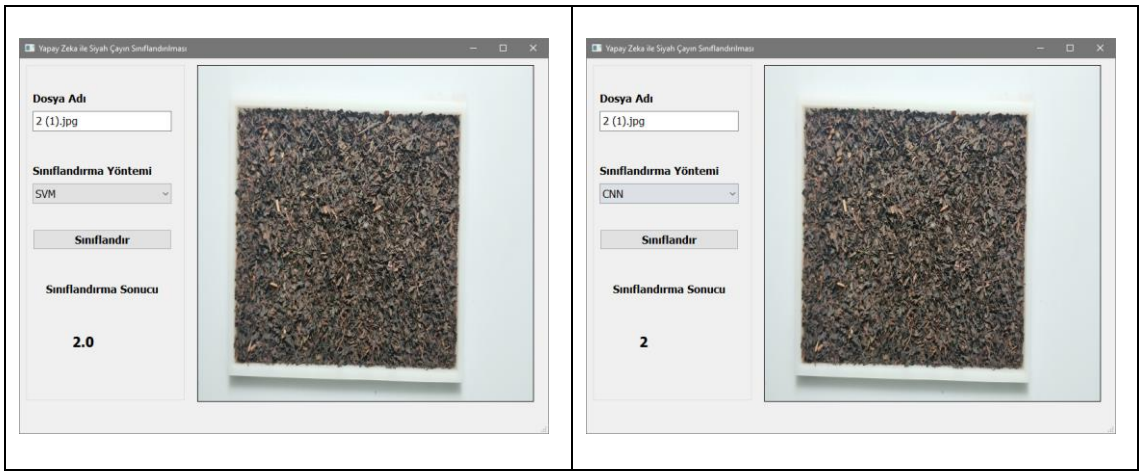
Kayıtlı modeller kullanılarak yapılan test çalışmalarında eğitim ve test sırasında kullanılmayan, fotoğrafı çekilen siyah çaylara ait görsellerin sınıflandırılmasında başarılı sonuç elde edilmiştir.

Test uygulamasında SVM sınıflandırma yöntemi kullanılarak yapılan sınıflandırma yaklaşık 30 saniye sürmekte ve CNN kullanılarak yapılan sınıflandırma yaklaşık 1.5 saniye sürmektedir. Bunun temel sebebi SVM yöntemi için öncesinde görsellere ait özniteliklerin hesaplanması gerekiyor. CNN sınıflandırma yöntemi ise direk görsellerinde sabit diskten okunup sinir ağına gönderildiğinden SVM'e göre çok daha kısa sürmektedir.



Tablo 22 : 1 İSİMLİ ÇAYIN SINIFLANDIRMA TESTİ

Tablo 22 bize yapılan test uygulaması ile 1 isimli siyah çayın kayıtlı SVM algoritması ile eğitimi yapılmış modelin ve CNN modeli kullanılarak 1 (1).jpg isimli siyah çay görselinin sınıflandırma sonucunu göstermektedir. Uygulama 1 isimli siyah çay görselini doğru olarak sınıflandırmıştır.



Tablo 23 : 2 İSİMLİ ÇAYIN SINIFLANDIRMA TESTİ

Tablo 23 ise test uygulamasını kullanarak 2 isimli siyah çayın kayıtlı SVM ve CNN modeli kullanılarak 2 (1).jpg isimli siyah çay görselinin sınıflandırma sonucu gösterilmektedir. Uygulama 2 isimli siyah çay görselini başarılı şekilde sınıflandırmıştır.

BÖLÜM 6. SONUÇ

Bu çalışmada siyah çay görüntüsünden elde edilen farklı veri setleri, makine öğrenimi sınıflandırma algoritmaları ve yöntemleri kullanılarak siyah çayın makine öğrenimi ile sınıflandırma sonuçları ortaya konmuştur. SVM gibi bir çok sınıflandırma probleminde başarılı sonuç veren sınıflandırıcı ve evrişimsel sinir ağı 2 farklı ürün kalitesinden elde edilen görüntülerin öznitelikleri ve görüntülerin kendileri kullanılarak yapılan sınıflandırmada da başarılı sonuç vermiştir. Bunun yanında Naive-Bayes sınıflandırma algoritması SVM'e kıyasla oldukça düşük sınıflandırma sonucu ortaya koymuştur.

Veri seti 1'de ki veriler olan renk kümeleri ve istenmeyen partiküllerin oranı (lif oranı ve belirli renk aralıklarının dışında olan kısım) ile yapılan sınıflandırma çalışması veri seti 2'de ki bütünleştirilmiş veriler ile yapılan sınıflandırmaya göre daha az doğruluk sonucu sunmuştur.

Veri seti 2'nin yüksek oranda sınıflandırma başarısı, veri seti muhteviyatının çok geniş olmasından kaynaklanmaktadır. Veri seti içinde doku tanımlama/sınıflandırmada kullanılan haralick ve hu-moments ayrıca görüntünün renkli histogram değerleri ile çayın renk kümelerinin değerleri bulunmaktadır. Sınıflandırılacak siyah çay görsellerine ait bu öznitelikler sınıflandırma performansını arttırmıştır.

Görüntü işlem ile elde edilen YCrCb görüntüsünden elde edilen öznitelikler kullanıma en uygun öznitelikler olarak karşımıza çıkmıştır. Ürün 1 ve 2'e ait %99 doğruluk oranı ile sınıflandırma sonucu oldukça tatmin edici olmuştur. Sınıflandırma tekli sınıflar ile (her bir görselin özniteliği karşında sadece görselin ait olduğu sınıf bilgisi) yapılmış olup çoklu sınıflar (görselin ait olduğu sınıf bilgisi, görselin niteliği gibi, çay olması) %99 başarı elde edilen SVM sınıflandırmasında kullanılmamıştır. Çoklu sınıflandırmanın en ideal uygulanma sınıflandırıcısı CNN olduğundan SVM ile denenmemiştir.

CNN ile yapılan temel bir yapay sinir ağı eğitim eğitim süreci SVM sınıflandırıcısına göre daha maliyetli olmasına karşın sunmuş çoklu sınıflandırma gibi avantajlar ile ön plana çıkmaktadır. CNN ile %98.52 eğitim verisi doğruluğu ve %98.56

test verisi doğrulu SVM ile kıyasla biraz daha düşük performanslı gibi gözüksede yapay sinir ağı iyileştirmesi ile doğruluk oranları arttırılma imkanı bulunmaktadır. Ayrıca Naive-Bayes ile yapılan sınıflandırma çalışmasında algoritma, elde edilen veri setleri ile sınıflandırma performansı SVM ve CNN ile karşılaştırılamayacak kadar (yaklaşık doğruluk %60 olarak çıkmıştır) düşük olmuştur. Naive-Bayes sınıflandırıcısı bu veri setleri ile çalışmaya uygun bir sınıflandırıcı olmaktan uzak kalmıştır.

Eğitim ve test veri setleri içinde olmayan yeni bir görselin SVM ya da CNN ile sınıflandırılabilmesi için SVM'de bir öznitelik çıkarımı işlemi yapılması şartken CNN'de sadece görsel sabit okunma işlemi yapılması yeterli olmaktadır. Bu yönüyle CNN SVM'e göre eğitim sonrasında modelin kullanımı sırasında daha hızlı sonuç verecektir.

Sınıflandırıcılarda kullanılmayan bir verinin sınıflandırıcılara verilmesi durumu tüm makine öğrenimi algoritmaları için temel bir problemdir. Siyah çay yerine modele bir masa görseline ait öznitelikler ya da CNN için masa görselinin kendisi sınıflandırma sonucu tahmin edilmesi istendiğinde, sınıflandırıcı sadece 2 ürüne ait öznitelik ile eğitildiği için, modele verilen yeni öznitelik/görsel içinde ürün 1 ya da ürün 2 şeklinde bir tahmin ortaya koyacaktır. Ortaya çıkan bu sonuç sınıflandırıcının yanlış veri ile beslenmesinin sonucudur. Çok farklı veri sınıfları ile eğitilmiş bir CNN modeli bu problem en aza indirmek mümkündür. Geniş veri sınıfları ile eğitilmiş CNN model alınıp, bu model tekrar siyah çay için (çoklu sınıf bilgileri ile yani görseller hem siyah çay hemde ürün bilgisi etiketlemesi verisi içermelidir) eğitildiğinde, model artık siyah çayı siyah çay olarak öğrenmiş olacaktır. Bu modele yeni bir veri girişi yapıldığında tahminlenen sonuç önce siyah çay olup olmadığına bakılır ve siyah çay tahminlemesi sonuç içerisinde yer alıyorsa tahmin sınıfı (bu çalışmada ürün 1 ve ürün 2) sonuç olarak gösterilir.

Bir çok veri sınıfı ile eğitilmiş CNN modelleri (ImageNet, ResNet, InceptionResNetV2 gibi) 150 milyona yaklaşan parametre sayıları ve 100'den fazla yapay sinir ağı katmanlarından oluşabilmektedir. Bu tür bir modeli alıp istenilen yeni veri seti ile tekrar eğitmek maliyetli de olabilmektedir.

CNN modellerinin eğitim maliyetleri (zaman en önemli maliyet kalemi olarak değerlendirilmektedir) eğer hazırda iyi bir grafik kartı varsa (NVIDIA ekran kartı ve

CUDA destekli olması) bu donanım üzerinde işlemciden daha az maliyetle model eğitimi tamamlanabilmektedir.

Eğer hazırda böyle bir imkan yoksa Google, Microsoft gibi bulut hizmet sağlayıcıları üzerinden yapay zeka modellerinin eğitimi için gerekli kaynak sağlanarak maliyetler minumum düzeyde tutulması tercih edilebilir.

BÖLÜM 7. ÖNERİLER

Bu çalışmada siyah çay görselleri tüketici elekroniği kategorisinde olan bir kamera ile çekilmiştir. Bu gibi kameralar elektromanyetik spektrumda ki insan gözünün görebildiği (380 – 740 nanometre) dalga boylarında ki ışık yansımalarından oluştuğundan elde edilecek öznitelikler sınırlı kalabilmektedir.

Spektrumda ki kızıl ötesi dalga boyundan görüntü elde edebilen yakın kızıl ötesi (NIR, Near Infrared, 780nm-2500nm arası) ekipmanlar kullanılarak endüstriyel alanda siyah çayın kalite strandartlarının imalat sırasında izlenebilmesi sağlanabilir.

Bu izleme işlemi çayın yaprak olarak fabrika gelmesinden siyah çay olarak tasniflerden çıkması arasında ki tüm imalat süreçlerini kapsayacak şekilde geliştirilme imkanı endüstriyel kameralar sağlanabilmektedir.

Bu izleme süreçlerinden elde edilen veriler dizayn edilecek bir CNN modeli kullanılarak eğitilip, izleme süreçlerinin kalite parametlerinin yüksek doğurlukla tahminlemesini sağlayabilecektir. Elde edilecek bu veriler ile imalat sırasında gerekli aksiyonlar alınıp ürünün kalite standartı korunması için destekleyici olabileceklerdir.

KAYNAKÇA

[1] Rize Çay Araştırma ve Uygulama Merkezi, «Sürdürülebilir Çay Üretimi Raporu,» Rize Çay Araştırma ve Uygulama Merkez, Rize, 2018.

[2] Türk Standardları Enstitüsü, «TS 4600 Siyah Çay Tebliği,» Türk Standardları Enstitüsü, Ankara, 1996.

[3] A. A. A. T. Mehmet BALCI, «GÖRÜNTÜ İŞLEME TEKNİKLERİ KULLANILARAK NAPOLYON TİPİ KİRAZLARIN SINIFLANDIRILMASI,» *Selçuk-Teknik Dergisi,* cilt 15, no. 3-2016, 2016.

[4] R. S. S. N. L. S.Arivazhagan, «Fruit Recognition using Color and Texture Features,» *Journal of Emerging Trends in Computing and Information Sciences,* cilt 1, no. 2, 2010.

[5] M. M. SOFU, O. ER, M. C. KAYACAN ve B. CETİŞLİ, «Elmaların Görüntü İşleme Yöntemi ile Sınıflandırılması ve Leke Tespiti,» *Gıda Teknolojileri Elektronik Dergisi,* cilt 8, no. 1, pp. 12-25, 2013.

[6] X. Y. ,. C. C. ,. R. V. R. ,. W. ,. P. P. Yudong Zhang, «Tea Category Identification Using a Novel Fractional Fourier Entropy and Jaya Algorithm,» *Entropy — Open Access Journal,* cilt 18, no. 77, 2016.

[7] V. GÖREKE, E. UZUNHİSARCIKLIOĞLU ve A. GÜVEN, «Gri Seviyeli Eş-oluşum Matrisleri Kullanılarak Sayısal Mamogram Görüntüsünden,» %1 içinde *Tıp Teknolojileri Ulusal Kongresi,* KAPADOKYA, 2014.

[8] K. S. a. I. D. R. M. Haralick, «Textural Features for Image Classification,» IEEE Transactions on Systems, Man and Cybernetics, vol. 3, no. 6, pp. 610–621, 1973.

[9] N. Z. a. H. A. Elnemr, «Statistical Analysis of Haralick Texture Features to Discriminate Lung Abnormalities,» Computer & Systems Department, Electronics Research Institute, Cairo 12611, Egypt, 2015.

[10] D. K. S. C. N. D. Sourav Samanta, «Fourth International Conference on Information Science and Industrial Applications,» %1 içinde *Fourth International Conference on Information Science and Industrial Applications,* Busan, South Korea, 2015.

[11] P. R. S. R. S. K. P. M. P. Raj, «Applications of Pattern Recognition Algorithms in Agriculture: A Review,» *Int. J. Advanced Networking and Applications,* cilt 6, no. 5, pp. 2495-2502, 2015.

[12] E. T. M. T. Marko Lukic, «Leaf Recognition Algorithm using Support Vector Machine with Hu Moments and Local Binary Patterns,» %1 içinde *IEEE 15th International Symposium on Applied Machine Intelligence and Informatics,* Herl'any, Slovakia, 2017.

[13] M.-K. HU, «Visual Pattern Recognition by Moment Invariants,» IRE TRANSACTIONS ON INFORMATION THEORY, 1962.

[14] R. BANERJEE, N. S. KHAN, S. MONDAL, B. TUDU ve R. BANDYOPADHYAY, «Feature Extraction from Electronic Nose Employing Genetic Algrotihm for Black Tea Quality Estimation,» %1 içinde *Internatioanl Conference on Advanced Electronic Systems*, Kolkata,India, 2013.

[15] A. HUMEAU-HEURTIER, «Texture Feature Extraction Methods: A Survey,» IEEE, 2018.

[16] «Scholarpedia - Local Binary Patterns,» Scholarpedia, 03 03 2010. [Çevrimiçi]. Available: http://www.scholarpedia.org/article/Local_Binary_Patterns. [Erişildi: 7 12 2019].

[17] N. Ketkar, Deep Learning with Python A Hands-on Introduction, Bangalore, Karnataka, India: APRESS, 2017.

[18] I. f. d. set-Wikipedia.org, «Iris flower data set,» Wikipedia.org, 30 05 2020. [Çevrimiçi]. Available: https://en.wikipedia.org/wiki/Iris_flower_data_set. [Erişildi: 10 6 2020].

[19] S. Saha, «Towards Data Science - A Comprehensive Guide to Convolutional Neural Networks — the ELI5 way,» Medium, 15 12 2018. [Çevrimiçi]. Available: https://towardsdatascience.com/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way-3bd2b1164a53. [Erişildi: 16 12 2019].