



Görüntü İşleme Tekniklerinden Faydalanarak Elma Çeşitlerinin Türlerine Göre Sınıflandırması

Sevim Adige^{1*}, Rifat Kurban², Ali Durmuş³, Ercan Karaköse⁴

¹Kayseri Üniversitesi, Lisansüstü Eğitim Enstitüsü, Elektrik-Elektronik Anabilim Dalı, Kayseri, Türkiye (ORCID: 0000-0002-8693-1126), sevim-adige@hotmail.com

²Kayseri Üniversitesi, Teknik Bilimler MYO, Bilgisayar Teknolojileri Bölümü, Kayseri, Türkiye (ORCID: 0000-0002-0277-2210), rifatkurban@kayseri.edu.tr

³Kayseri Üniversitesi, Teknik Bilimler MYO, Elektrik ve Enerji Bölümü, Kayseri, Türkiye (ORCID: 0000-0001-8283-8496), alidurmus@kayseri.edu.tr

⁴Kayseri Üniversitesi, Müh. Mim. Tasarım Fakültesi, Müh. Temel Bilimleri Bölümü, Kayseri, Türkiye (ORCID: 0000-0001-5586-3258), ekarakose@kayseri.edu.tr

(5th International Symposium on Innovative Approaches in Smart Technologies– 28-29 May 2022)

(DOI: 10.31590/ejosat.1136913)

ATIF/REFERENCE: Adige, S., Kurban, R., Durmuş, A. & Karaköse, E. (2022). Görüntü İşleme Tekniklerinden Faydalanarak Elma Çeşitlerinin Türlerine Göre Sınıflandırması. *Avrupa Bilim ve Teknoloji Dergisi*, (37). 131-138.

Öz

Gelişen teknoloji ile birlikte son dönemlerde sıkça duymaya başladığımız “Yapay Zekâ” ve “Derin Öğrenme” kavramlarının pek çok uygulama alanları mevcuttur. İnsan zekâsını taklit eden bu yöntemler çevresinden aldığı veri setlerini tıpkı insanlar gibi deneyim yoluyla öğrenir. Bu çalışmada Kayseri'nin Yahyalı ilçesinde yetişen elma çeşitlerinin cinslerine göre sınıflandırılması yapılmıştır. Elma meyvesi Eylül ayında toplandığı için elmaların ağaçtan koparıldığı hasat zamanında elde edilmiştir. Elma üretimi yapan çiftçilerin en büyük problemleri el izi olmadan ve en kısa sürede elmaların çeşitlerine göre sınıflandırılmasıdır. Bu çalışmada, 20 Golden, 20 Arjantin, 20 Buckeye Gala, 20 Galaval, 20 Superchief ve 20 Joremin elma türlerinden toplam 120 görüntü alınmıştır. Görüntüler sabit bir arka fonda aynı açı ve aynı büyüklükte Canon EOS 70D DSLR marka fotoğraf makinası ile çekilmiştir. Görüntü işlemek için MATLAB programının R2021a sürümünden faydalanılmıştır. Elma çeşitlerinin türlerine göre sınıflandırılması için derin öğrenme algoritmalarından yararlanılmıştır. Sınıflandırma problemlerinin çözümünde kullanılan en temel mimarilerinden olan AlexNet ve GoogleNet derin öğrenme algoritmaları kullanılmıştır. Çalışma AlexNet ve GoogleNet yöntemlerinin her ikisinde de 10 epoch değerinde ve sgd eğitim algoritmasında gerçekleştirilmiştir. Öğrenme oranları AlexNet ve GoogleNet için sırasıyla 0.0001 ve 0.0003 olarak ele alınmıştır. Görüntülerin %70'i eğitim %30'u test amacıyla kullanılmış olup toplam veri seti her çeşitte 20 adet olmak üzere 120 tane görselden oluşmaktadır. AlexNet mimarisi %83.33 başarı oranı, 1 dakika 52 saniyedir. GoogleNet mimarisinin sınıflandırma başarı oranı %91,67' dir, 2 dakika 14 saniye süre ile en başarılı sınıflandırma işlemini gerçekleştirmiştir.

Anahtar Kelimeler: Elma Sınıflandırma, AlexNet, GoogleNet, Derin Öğrenme.

Classification of Apple Varieties by Types Using Image Processing Techniques

Abstract

With the developing technology, the concepts of "Artificial Intelligence" and "Deep Learning", which we have been hearing frequently in recent years, have many application areas. These methods, which imitate human intelligence, learn the data sets they receive from their environment through experience, just like humans. In this study, apple varieties grown in Yahyalı district of Kayseri were classified according to their type variables. Since the apple fruit is picked in September, it was obtained at the harvest time when the apples were plucked from the tree. The biggest problem of the farmers producing apples is the classification of apples according to their varieties without a handprint and as soon as possible. In this study, a total of 120 images were taken from 20 Golden, 20 Argentina, 20 Buckeye Gala, 20 Galaval, 20 Superchief and 20 Joremin apple varieties. The images were taken with a Canon EOS 70D DSLR camera at the same angle and the same size, on a fixed background. R2021a version of MATLAB program was used for image processing. Deep learning algorithms were used to classify apple varieties according to their types. AlexNet and GoogleNet deep learning algorithms, which are among the most basic architectures used in solving classification problems, are used. The study was carried out in both

* Sorumlu Yazar: Kayseri Üniversitesi, Lisansüstü Eğitim Enstitüsü, Elektrik-Elektronik Anabilim Dalı, Kayseri, Türkiye, ORCID: 0000-0002-8693-1126, sevim-adige@hotmail.com

AlexNet and GoogleNet methods at 10 epochs and sgd training algorithm. Learning rates are taken as 0.0001 and 0.0003 for AlexNet and GoogleNet, respectively. 70% of the images were used for training and 30% for testing, and the total data set consists of 120 images, 20 of each type. AlexNet architecture has 83.33% success rate, 1 minute 52 seconds. The classification success rate of the GoogleNet architecture is 91.67%, and it performed the most successful classification process for 2 minutes and 14 seconds.

Keywords: Apple Classification, AlexNet, GoogleNet, Deep Learning.

1. Giriş

Türkiye, verimli ve çevresel olarak çeşitlendirilmiş tarım alanları ile kaliteli tarım ürünleri üreten ülkeler arasında yer almaktadır. Tarımsal üretimin önemli kollarından biri de yaş meyve yetiştiriciliğidir. Türkiye, bazı meyve türleri bakımından dünyanın önde gelen üreticisidir. Elma (*Malus domestica*), gül (*Rosaceae*) familyasından bir meyve türüdür. Elma, içerdiği antioksidanlar, vitaminler, lif ve birçok farklı mineral ile sağlıklı ve yaygın olarak tüketilen bir meyvedir. Elma, yüksek miktarda C vitamini eşdeğer fenolik bileşikler, kanser ve DNA hasarı riskini azaltan değerli antioksidanlar içerir [1]. 2019-2020 sezonunda Türkiye dünya elma üretiminde 4. sırada yer almaktadır [2]. Son yıllarda elma üretiminin artmasıyla birlikte, yetiştiriciler için en önemli endişelerden biri, elmaları kısa sürede temassız olarak farklı türlere ayırmaktır. Elmaların türlerine göre sınıflandırması sırasında el değmeden sınıflandırılması ihracatta kayıpları azaltır ve elma kabuğunun daha steril olmasını sağlar. Bu sorunu çözmek için modern tarımda teknolojiyi en üst düzeyde kullanmak ve otomasyondan yararlanmak üreticiler için bir çözüm yöntemidir. Kamera, video kamera, tarayıcı gibi cihazlardan elde edilen sayısallaştırılmış görüntülerin bilgisayar ortamında yazılımlar vasıtasıyla işlenmesi veya analiz edilmesi görüntü işleme olarak tanımlanmaktadır. Bir karar vermek için bilgisayarla görme görevleri, dijital görüntüleri toplama, işleme, değerlendirme ve anlama yöntemlerini içerir.

Gelişen teknoloji ile birlikte son dönemlerde sıkça duymaya başladığımız “Yapay Zekâ” ve “Derin Öğrenme” kavramlarının pek çok uygulama alanları mevcuttur. İnsan zekâsını taklit eden bu yöntemler çevresinden aldığı veri setlerini tıpkı insanlar gibi deneyim yoluyla öğrenir.

Yapay zekâ çalışmaları genel olarak insanın düşünme yöntemlerini taklit eden yapay yöntemler geliştirmeye yönelik çalışmalara önem veren bir disiplindir. Ancak yapay zekânın yetenekleri bununla sınırlı değildir. Öğrenebilen, kendini geliştirebilen ve aynı zamanda gelecekte insan zekâsından bağımsız gelişebilecek bir kavrama doğru yeni yönelimler oluşmaktadır. Bu yönelim, insanın evreni ve doğayı anlama çabasında kendisine yardımcı olabilecek belki de kendisinden daha zeki, insan ötesi makineler oluşturmanın bir ürünüdür.

Derin öğrenme, oluşturulan veri setleri ile sonuçlar hakkında tahminde bulunan birden çok katmandan meydana gelen makine öğrenme yöntemidir. Derin öğrenme, yapay zekâ yöntemlerinden biridir. Derin öğrenme yöntemi birden çok katmanda işlem yapabilmektedir. Genel olarak literatürde görüntü işleme, tıp, endüstri, nesne tespiti, gelecek tahmini gibi pek çok alanda çözüm üretmektedirler. Raikar ve arkadaşları [3] tarafından, bamyaların uzunluğuna göre küçük, orta, büyük ve ekstra büyük olmak üzere dört sınıflandırma yapılmıştır. Bamyaların uzunluğuna göre derecelendirmek için yapay görme teknolojisi ile araştırma yapılmıştır. Bamyanın derecelendirilmesinde üç derin öğrenme modeli kullanılmıştır: AlexNet, GoogLeNet ve ResNet50. Elde

edilen doğruluklar AlexNet için %63,45, GoogLeNet modeli için %68,99 ve ResNet50 için %99’ dur. Liu ve arkadaşları [4] tarafından CNNs modelinin kömür görüntü tanıma ve sınıflandırmadaki operasyonel süreçleri ortaya konmuş, sınıflandırma ağırlıklarının etkileyen özellikler analiz edilmiştir. En yüksek sınıflandırma doğruluğu ResNet50 modelinde tespit edilmiş, karışık kömür numunesi görüntü veri setindeki sınıflandırma doğruluğu %83,42 olarak belirlenmiştir. Antrasit renkli kömür numunelerinde doğruluk oranı ise %90,19’dur. GoogleNet sinir ağları kullanılarak tıbbi görüntüler incelenmektedir, tıbbi veri tabanından bir sorgu görüntüsüne benzer görüntüler sağlayarak hastalık teşhisine yönelik oldukça başarılı sonuçlar elde edilmektedir [5]. Yabancı ot tohumlarının tespitinde de GoogLeNet ve AlexNet sinir ağları kullanılarak sınıflandırma işlemi gerçekleştirilmektedir [6]. Dünya’da en çok ekimi gerçekleştirilen mısır mahsulünün yaprakları üzerinde hastalık tespiti için de evrişimli sinir ağlarıyla sınıflandırma yapılmaktadır [7]. AlexNet evrişimli sinir ağları sınıflandırma için sağlık alanında oldukça ciddi problemler için verimli bir sinir ağı olmuştur. Alzheimer hastalığını MCI düzeyinde teşhis etmek için MRI (Manyetik Rezonans Görüntüleme) tıbbi görüntülerinden önemli özellikleri etkili bir şekilde almak amacıyla AlexNet sinir ağlarının kullanıldığı bir sınıflandırma modeli önerilmektedir [8]. Meyveler üzerinde birçok sınıflandırma çeşidinde derin öğrenmenin kullanıldığı literatürde sık rastlanan bir durumdur. Papaya meyvelerinin olgunluk sınıflandırması için aralarında GoogleNet ve AlexNet’in de bulunduğu 7 farklı önceden eğitilmiş evrişimli sinir ağı kullanılmıştır [9]. Erken olgunlaşmış ve olgun çilek örneklerini sınıflandırmak için de önceden eğitilmiş AlexNet evrişimsel sinir ağı kullanılmıştır [10]. Derin öğrenme teknikleri aracılığıyla türlerini sınıflandırmak için iki bitki tohumu veri setini incelemiş; mahsulde hastalıkların erken tespiti ve mahsul verimini artırmak için çok önemli sonuçlar elde edilmiştir [11-12]. Bitkilerdeki hastalıkların sınıflandırılması evrişimli sinir ağlarının kullanımı yine bazı çalışmalarda gerçekleştirilmiş ve iyi sonuçlar elde edilmiştir [13].

Görüntü işleme fotoğraf makinası, video kamera ve tarayıcı gibi cihazlardan elde edilerek sayısallaştırılan görüntülerin bilgisayar ortamında gerçekleşen yazılımlar yardımıyla işlenmesi veya analizi olarak tanımlanmaktadır. Bu çalışmada kullanılan derin öğrenme yapılarından AlexNet, görüntü sınıflandırmasında kullanılan derin konvolüsyonel bir sinir ağıdır. İlk beş tanesi konvolüsyonel olmak üzere, son üç tanesi ise tam bağlı sekiz adet katmandan oluşmaktadır. Bu katmanlar arasında “pooling-ortaklama” ve “aktivasyon” katmanları da bulunmaktadır. Ayrıca giriş ve çıkış katmanları da birçok yapay zekâ alanlarında olduğu gibi yer almaktadır. AlexNet mimarisi, 1000 nesneyi sınıflandıracak şekilde tasarlanmış ve aynı zamanda nesne tanımlamada hata oranı %15,3 olarak belirlenmiştir. Bu çalışmada analizleri gerçekleştirilen bir diğer derin öğrenme yapısı ise GoogleNet’tir. GoogLeNet [14] yapısındaki Inception modüllerinden dolayı AlexNet mimarisine göre karmaşık bir mimaridir ve 22 katmanlı bir yapıya sahiptir. Bu yapının nesne tanımlamada hata oranı %5,7 olarak tespit edilmiştir. GoogleNet mimaris, ardışık bir şekilde konvolüsyon ve havuzlama yapısı oluşturmaktan uzak CNN mimarilerinden birisidir. GoogleNet

bellek ve güç kullanımı üzerinde günümüz teknolojisinde de önemli bir yere sahiptir.

Bu çalışmada elma çeşitlerini türlerine göre sınıflandırmak için AlexNet ve GoogLeNet derin öğrenme yöntemleri kullanılmıştır. Kayseri'nin Yahyalı bölgesine ait 6 farklı türden elde edilen elma görüntüleri eğitim ve test veri setlerine ayrılmış; AlexNet ve GoogLeNet yöntemleriyle elde edilen sonuçlar birbirleriyle karşılaştırılmıştır.

2. Materyal ve Metot

2.1. Araştırma Modülü

Tarım, insanlık tarihi için her dönemde önemli olmuştur. En temel üretim dallarından biri olan tarım sektörü ülke nüfusunun devam edebilmesi, milli gelire ve iş alanlarınınardaki çalışılabilirliğe katkısı önemlidir. Aynı zamanda diğer sektörlerle hammadde ve sermaye sağlaması ve biyolojik çeşitlilik ile ekolojik dengeye olan katkısı nedeniyle dünya genelinde vazgeçilmez bir sektör olmuştur. Bundan dolayı bu sektör, ekonomik ve sosyal boyutlarıyla, toplumun bütün kesimlerini oldukça yakından ilgilendirmektedir [15]. Tarımsal alanın en önemli dallarından biri de meyve yetiştiriciliğidir. Bu çalışmada kullanılan elmalar Kayseri ilinde üretilmiştir. Ülkemiz elma üretiminde Kayseri'yi önemli kılan ilçelerden biri de Yahyalı ilçesidir. Yahyalı ilçesinde iklim ve toprak özellikleri bakımından elma yetiştirilmenin uygun olması alan başına yetiştirilen elmanın çokluğu, kalitesi ve doğallığını da olumlu yönde etkilemektedir. Yahyalı elması kendi içerisinde görüntü ve tat açısından "Golden, Arjantin, Joremini, Süper Chief Buckeye Gala, Starking Red Chief, Starkrimson, Scarlet Spur, Fuji, Gala, Beraburn, Rainders


Golden, Gold Chief, Pink Lady" gibi birçok çeşidi barındırmaktadır.

Bu çeşitler arası ayrımı yapabilmek makineleşmenin de insan gücünün yerini almasıyla daha ekonomik, hızlı ve sistemli hale gelmiştir. Hata payının az olduğu, teknoloji çağının aktif kullanıldığı, seri üretimin fazla olduğu bu çağda elmalar arası kalite ve cins ayrımının analizinin yapılabilmesi için çoğu alanda kullanılan otomasyon bu alanda da gerekliliğini göstermektedir. Tarımsal ürünlerin özelliklerinden olan renk, uzunluk, yüzey alanı ve iz düşüm alanı gibi fiziksel özelliklerinin bilinmesi mühendislik çalışmaları açısından oldukça önem taşımaktadır.

Bu çalışmada Yahyalı Bölgesine ait elmalarla ilgili görüntü işleme analizleri AlexNet ve GoogleNet sinir ağlarıyla gerçekleştirilmiştir.

2.1.1. AlexNet

Bu çalışmada incelenen yaygın önceden eğitilmiş CNN modeli, 2012'de ILSVRC'yi kazanan AlexNet'tir [16]. AlexNet, daha derin bir mimariyle tasarlandığı geleneksel CNN mimarisine kıyasla, kümelenmiş evrişim katmanları içeren daha fazla filtre katmanına sahiptir. 5 evrişim katmanını ve 3 tam bağlantılı katmandan oluşur. İlk iki evrişim katmanının her biri, bir alt katmandan ve bir yanıt normalleştirme katmanından oluşmaktadır. Her katmanı bir ReLU işlemi takip eder. Birinci, ikinci ve beşinci evrişim katmanının her birini bir maksimum havuzlama katmanı izler. AlexNet, yerel yanıt normalleştirmesini kullanmak gibi etkinleştirme işlevinin uygunluğunu önlemek için bazı avantajlara sahiptir. Bu araştırma için, veri kümesi 6 farklı meyveden oluştuğundan, tam bağlantılı katmanlar 6 farklı kategoriyi sınıflandırmak için ayarlanmıştır. AlexNet sinir ağlarının genel mimarisi Şekil 1'de gösterilmektedir.

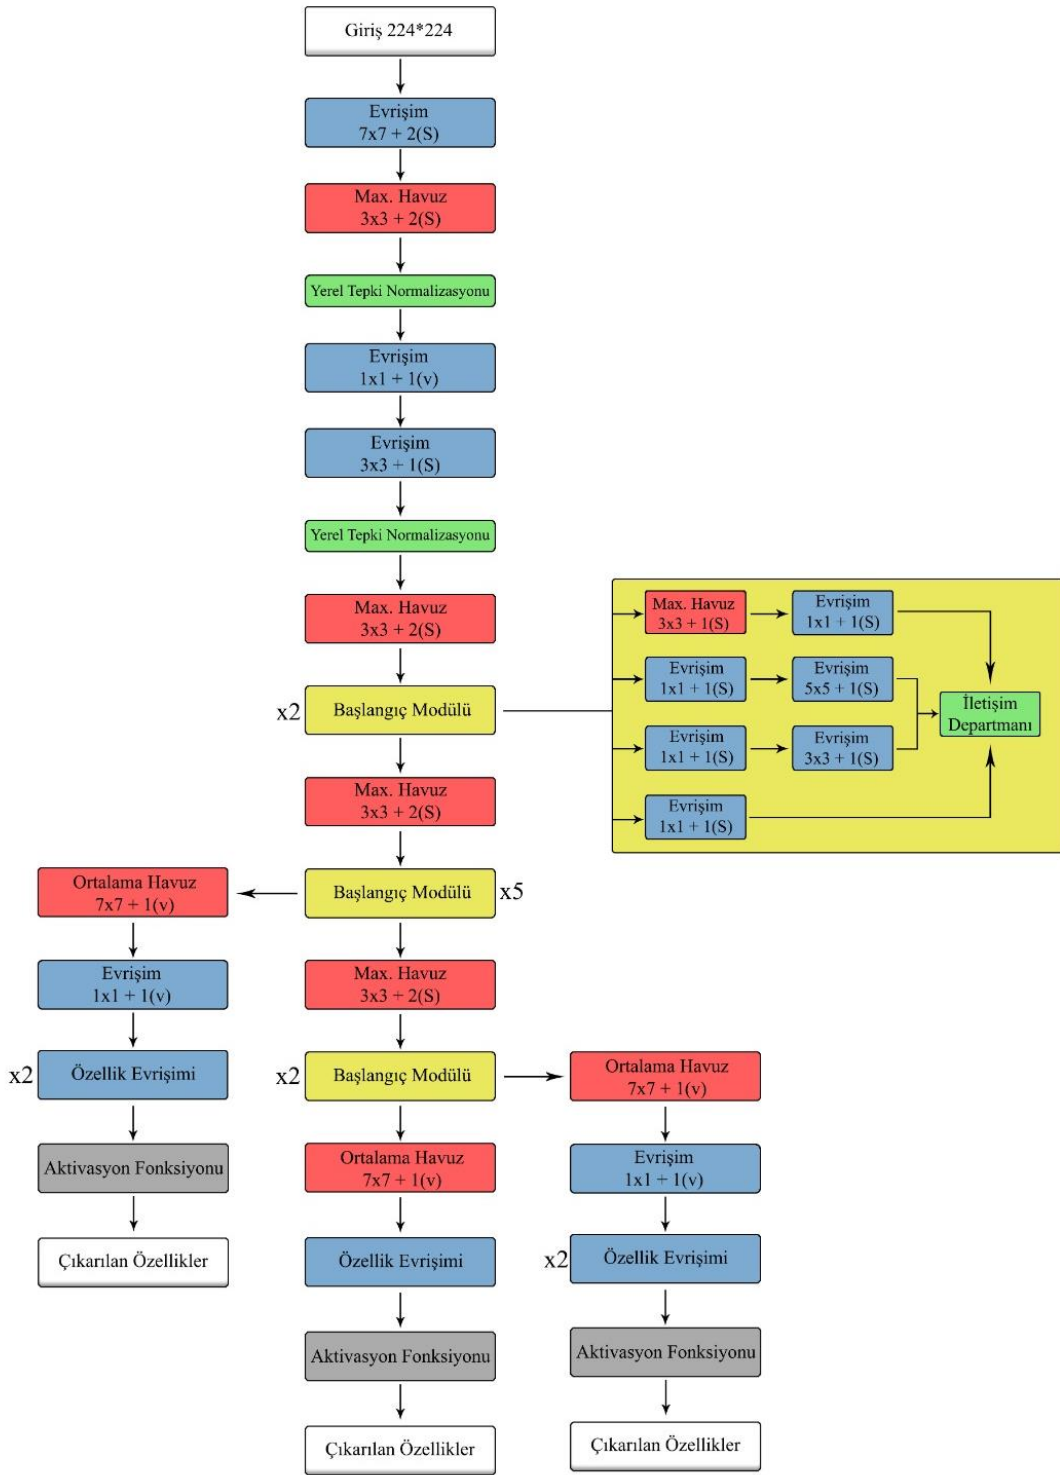


Şekil 1. AlexNet sinir ağının mimarisi

Şekil 1'de verilen AlexNet, 5 evrişim katmanı ve 3 tam bağlantılı katman dahil olmak üzere 8 ağırlık katmanından oluşur ve birinci, ikinci ve beşinci evrişim katmanlarını takiben üç maksimum havuzlama katmanı kullanılır. İlk evrişim katmanı, 4 piksel adım ve 2 piksel dolgu 11 × 11 boyutunda 96 filtreye sahiptir. Diğer evrişimli katmanların adımı ve dolgusu 1 piksel olarak ayarlanmıştır. İkinci evrişim katmanı 5 × 5 boyutunda 256 filtreye sahiptir. Üçüncü, dördüncü ve beşinci evrişim katmanları sırasıyla 3 × 3 boyutunda 384, 384 ve 256 filtreye sahiptir.

2.1.2. GoogLeNet

GoogLeNet, ağ modelinin derinliğini ve genişliğini artırarak oluşturulan derin evrişimli bir sinir ağı modelidir. Parametrelili 22 katman ve 100'den fazla ayrı katmandan oluşan GoogLeNet, RGB üç renkli kanal kullanır ve sensör piksel boyutu 224 × 224'tür. Gradyanın kaybolmasını önlemek için iki kaybı farklı bir derinlikte ayarlanır. Gradyanın geri dönüşünü sağlamak, fazla uydurmayı önlemek ve yakınsama hızını hızlandırmak için bir ReLU ile takip edilir [17]. GoogLeNet, başlangıç birimini kullanarak ağı genişliğini de artırır. Şekil 2'de GoogLeNet sinir ağlarının genel mimarisi verilmiştir.



Şekil 2. GoogleNet sinir ağının mimarisi

2.1.3. Verilerin Toplanması ve Çözümlemesi

Bu çalışmada Kayseri'nin Yahyalı ilçesinde yetişen elma çeşitlerinin cins değişkenlerine göre sınıflandırılması yapılmıştır. Elma meyvesi hasat zamanı Eylül ayında yapıldığı için en doğru verilere ulaşmak adına bu çalışmada elmaların ağaçtan koparıldığı hasat zamanında yapılmış olup 20 Golden, 20 Arjantin, 20 Joremini, 20 Süper Chief, 20 Buckeye Gala ve 20 Galaval elma türünden toplamda 120 görüntü alınmıştır.

Elma cinslerine göre yapılan sınıflandırmada 6 cinsten 1'er elmanın fotoğrafı alınmıştır. Görüntüler sabit bir arka fon ile aynı açı ve aynı büyüklükte hepsi ayrı ayrı fotoğraflanmıştır. Elmalara e-ISSN: 2148-2683

ait değerler görüntü işleme algoritmaları yardımıyla elde edilecektir. Ayrıca elmaların cinslerinin ayrıştırılması için renklerinden ve boyutlarından yararlanılıp bilgiler elde edilmiştir. Bu özellikler kullanılarak elmaların ayrıştırılmasında MATLAB'de bulunan ilgili sınıflandırma algoritmaları kullanılıp uygun olanları incelenip kullanılmıştır. Elde edilen 120 elma fotoğrafının farklı öğrenme seti oranlarında derin öğrenme modeli geliştirilmiştir. Öğrenme setinin haricinde kalan fotoğraflar ise test amacıyla kullanılmıştır.

Fotoğraflar Canon EOS 70D DSLR marka bir fotoğraf makinesi ile elde edilmiştir. Bu fotoğraf makinesinde CMOS tipi

bir sensör bulunmaktadır. Detaylı özellikler Tablo 1. aracılığıyla verilmiştir. Derin Öğrenmenin gerçekleştirildiği bilgisayar, Intel i5 3.4 GHz işlemcili ve 16 GB RAM özelliklerine sahiptir. Bu özelliklerde bir bilgisayar kullanılarak modelleme işlemleri

yapılmıştır. Modelleme işlemleri, çok paradigmatlı sayısal hesaplama yazılımı ve dördüncü nesil programlama dili olan MATLAB programının 2021b sürümünde gerçekleştirilmiştir.

Tablo 1. Çalışmada kullanılan kameranın teknik özellikleri

CANON EOS 70D DSLR	Teknik Özellikler
Sensör Tipi	CMOS
Kamera Tipi	DSLR
Maksimum Çözünürlük	5472X3648
Etkili Piksel	20 MP
Görüntü İşlemcisi	Digic 5+

2.1.4. Verilerin Analizi

Bölüm 2.1.1 ve 2.1.2 de bu çalışmada kullanılan veri setlerinin nasıl elde edildiği verilmiştir. Derin öğrenme uygulama alanının iki farklı yöntemi olan Alexnet ve GoogleNet ile belirlenen veri setlerinin görüntü işlemleri analiz edilmiştir. Bu analizler Matlab programı üzerinden ilgili yöntemlerin, özgün veri setleriyle birlikte incelenmesi sonucu elde edilmiştir. Her iki ağ yapısında hata oranlarını minimum değere çekmeye çalışarak 6 farklı elma türünü ayırt etmek için program koşuturulmuş olup sınıflandırma işlemi gerçekleştirilmiştir. Elma türlerini ayırt etmek amacıyla gerçekleştirilen analiz sonuçları bir sonraki bölümde verilecektir.


3. Araştırma Sonuçları

Çalışmanın bu bölümünde sınıflandırma için kullanılan her iki algoritmanın da sonuçları irdelenecektir. Bu araştırma için deneyler Bölüm 2.1.3.' de verilen özellikli bilgisayar ve program

ile yapılmıştır. Elma veri seti yukarıdaki bölümlerde verilen kamera özellikleriyle fotoğraflanarak bireysel ve profesyonel çekim sonucunda elde edilmiştir. Veri seti "Golden, Joremini, Buckeye Gala, Arjantin, Galaval, Super Chief" türlerine ait toplamda 120 elma çeşidinden oluşmaktadır. Her sınıf için görüntülerin boyutu 512 x 512 pikseldir, ancak bu deney için tüm görüntüler 224x224 olarak yeniden boyutlandırılmıştır.

3.1. AlexNet Sinir Ağları Simülasyon Sonuçları

Her iki algoritmada da tüm veri setinin %30 u kadar test verisi ayrılmıştır. Çalışmalarda 94 tane rastgele seçilmiş elmalar eğitim seti olarak kullanılmıştır. Şekil 3 AlexNet sinir ağlarıyla eğitimi gerçekleştirilmiş olan veri setinin test sonuçları göstermektedir. Bu sonuçlara göre ilgili sinir ağının sınıflandırma sonuçlarının oldukça başarılı olduğu tespit edilebilmektedir. Şekil 4' te verilen karmaşıklık matrisinin sonuçlarına göre de Galaval ve Buchkeygala cinsi elma türleri haricinde diğer türlerde %100 doğrulukta tahmin gerçekleştiği anlaşılmaktadır.



Şekil 3. AlexNet sınıflandırma sonuçları

Doğruluk Sınıfı	Arjantin	6					
	Buckeye Gala		5			1	
	Galaval		5	1			
	Golden				6		
	Joremin					6	
	Superchief						6
		Arjantin	Buckeye Gala	Galaval	Golden	Joremin	Superchief
		Tahmin Sınıfı					

Şekil 4. AlexNet Confusion matrix

Tablo 2’de AlexNet sinir ağlarıyla gerçekleştirilen sınıflandırma analizinin doğruluk sonucu ve çalışma süresi verilmiştir.

Ortalama 2 dakikalık bir çalışma süresi içerisinde yaklaşık 5 verinin 4’ünün doğru sınıflandırıldığı tespit edilmiştir.

Tablo 2. AlexNet sinir ağlarının doğruluk performansı

Girdi	Görsel Girdi Boyutu	Doğruluk	Toplam Süre	Öğrenme Oranı	Tekrar Sayısı
RGB Görsel	224x224x3	%83.33	1 dk 52 sn	0.0001	10

3.2. GoogleNet Sinir Ağları Simülasyon Sonuçları



Şekil 5. GoogleNet sınıflandırma sonuçları

Doğruluk Sınıfı	Arjantin	6					
	Buckeye Gala		6				
	Galaval		2	4			
	Golden				6		
	Joremin		1			5	
	Superchief						6
	Tahmin Sınıfı	Arjantin	Buckeye Gala	Galaval	Golden	Joremin	Superchief

Şekil 6. GoogleNet Confusion matrix

36 tane eğitim setinde kullanılmamış elmalar test seti olarak kullanılmıştır. Şekil 5 GoogleNet sinir ağlarıyla eğitimi gerçekleştirilmiş olan veri setinin test sonuçlarını göstermektedir. Bu sonuçlara göre ilgili sinir ağının sınıflandırma sonuçlarının

oldukça başarılı olduğu tespit edilebilmektedir. Şekil 6'da verilen karmaşıklık matrisinin sonuçlarına göre de Galaval ve Joremin cinsi elma türleri haricinde diğer türlerde oldukça yüksek doğruluk oranında tahmin gerçekleştiği tespit edilmiştir.

Tablo 3. GoogleNet sinir ağlarının doğruluk performansı

Girdi	Görsel Girdi Boyutu	Doğruluk	Toplam Süre	Öğrenme Oranı	Tekrar Sayısı
RGB Görsel	224x224x3	%91.67	2 dk 14 sn	0.0003	10

Tablo 3' te GoogleNet sinir ağlarıyla gerçekleştirilen sınıflandırma analizinin doğruluk sonucu verilmiştir. Bu sinir ağlarıyla gerçekleşen çalışma için gerekli çalışma süresi yine aynı tablo içerisinde verilmiştir. 2,14 dakikalık bir çalışma süresi içerisinde yaklaşık %92 oranında doğru sınıflandırma yapıldığı tespit edilmiştir.

4. Sonuç

Bu çalışmada AlexNet ve GoogleNet'in elma türlerini tanıma için elde edilen veri setlerine dayalı farklı doğruluk performansları araştırılmıştır. Özgün fotoğraflara dayalı olarak meyve tanıma performansları analiz edilmiştir. Deneylerin sonuçlarına dayanarak, AlexNet ve GoogleNet sinir ağlarının CNN temelli derin öğrenme olarak mükemmel sonuçlar verdiğini görebiliriz.

GoogleNet sinir ağının genel eğitim ve test süresi, AlexNet sinir ağına kıyasla daha uzun olmasına rağmen, daha doğru sonuçlar verdiği gözlemlenmiştir. Farklı şekil, renk ve dokuya sahip elmaları tanımada GoogleNet'in daha iyi sonuçlar vereceği bu çalışmada gözlemlenmiştir. Gelecekteki çalışmalar için, diğer makine öğrenimi ve derin öğrenme teknikleriyle diğer veri kümeleri üzerinde daha fazla deney yapılarak sınıflandırma işlemleri gerçekleştirilecektir.

5. Teşekkür

Bu çalışma, Kayseri Üniversitesi Bilimsel Araştırma Projeleri (BAP) Koordinasyon Birimi tarafından FYL-2022-1059 proje numarasıyla desteklenmiştir.

Kaynakça

- [1] Kaur, C., & Kapoor, H. C. (2001). Antioxidants in fruits and vegetables—the millennium's health. *International journal of food science & technology*, 36(7), 703-725.
- [2] Ahmad, R., Hussain, B., & Ahmad, T. (2021). Fresh and dry fruit production in himalayan Kashmir, sub-Himalayan Jammu and trans-himalayan Ladakh, India. *Heliyon*, 7(1), e05835.
- [3] Raikar, M. M., Meena, S. M., Kuchanur, C., Girraddi, S., & Benagi, P. (2020). Classification and Grading of Okra-ladies finger using Deep Learning. *Procedia Computer Science*, 171, 2380-2389.
- [4] Liu, Y., Zhang, Z., Liu, X., Wang, L., & Xia, X. (2021). Deep learning-based image classification for online multi-coal and multi-class sorting. *Computers & Geosciences*, 157, 104922.
- [5] Deepak, S., & Ameer, P. M. (2020). Retrieval of brain MRI with tumor using contrastive loss based similarity on

GoogLeNet encodings. *Computers in Biology and Medicine*, 125, 103993.

- [6] Luo, T., Zhao, J., Gu, Y., Zhang, S., Qiao, X., Tian, W., & Han, Y. (2021). Classification of weed seeds based on visual images and deep learning. *Information Processing in Agriculture*.
- [7] PAN, S. Q., QIAO, J. F., Rui, W. A. N. G., YU, H. L., Cheng, W. A. N. G., TAYLOR, K., & PAN, H. Y. (2022). Intelligent diagnosis of northern corn leaf blight with deep learning model. *Journal of Integrative Agriculture*, 21(4), 1094-1105.
- [8] Kumar, L. S., Hariharasitaraman, S., Narayanasamy, K., Thinakaran, K., Mahalakshmi, J., & Pandimurugan, V. (2022). AlexNet approach for early stage Alzheimer's disease detection from MRI brain images. *Materials Today: Proceedings*, 51, 58-65.
- [9] Behera, S. K., Rath, A. K., & Sethy, P. K. (2021). Maturity status classification of papaya fruits based on machine learning and transfer learning approach. *Information Processing in Agriculture*, 8(2), 244-250.
- [10] Gao, Z., Shao, Y., Xuan, G., Wang, Y., Liu, Y., & Han, X. (2020). Real-time hyperspectral imaging for the in-field estimation of strawberry ripeness with deep learning. *Artificial Intelligence in Agriculture*, 4, 31-38.
- [11] Loddo, A., Loddo, M., & Di Ruberto, C. (2021). A novel deep learning based approach for seed image classification and retrieval. *Computers and Electronics in Agriculture*, 187, 106269.
- [12] Sachdeva, G., Singh, P., & Kaur, P. (2021). Plant leaf disease classification using deep Convolutional neural network with Bayesian learning. *Materials Today: Proceedings*, 45, 5584-5590.
- [13] Abade, A., Ferreira, P. A., & de Barros Vidal, F. (2021). Plant diseases recognition on images using convolutional neural networks: A systematic review. *Computers and Electronics in Agriculture*, 185, 106125.
- [14] Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., ... & Rabinovich, A. (2015). Going deeper with convolutions. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 1-9).
- [15] Adger, W. N., Huq, S., Brown, K., Conway, D., & Hulme, M. (2003). Adaptation to climate change in the developing world. *Progress in development studies*, 3(3), 179-195.
- [16] Muhammad, N. A., Nasir, A. A., Ibrahim, Z., & Sabri, N. (2018). Evaluation of CNN, Alexnet and GoogleNet for fruit recognition. *Indonesian Journal of Electrical Engineering and Computer Science*, 12(2), 468-475.
- [17] Bai, Y., Wan, H., & Bai, C. (2017). Study on human behavior classification in still images based on GoogLeNet. *Comput. Knowl. Technol*, 13(18), 186-188.