

(Araştırma Makalesi)

Doğada Yetişen Mantar Türlerinin Derin Öğrenme ile Tespiti**Merve AKIN*¹, Aycan DAĞDELEN², Rabia Nur EĞİNME³, Durmuş ÖZDEMİR⁴**¹Kütahya Dumlupınar Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 43100, Kütahya, ORCID No : <https://orcid.org/0009-0007-0542-0396>²Kütahya Dumlupınar Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 43100, Kütahya, ORCID No : <https://orcid.org/0009-0004-4603-4764>³Kütahya Dumlupınar Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 43100, Kütahya, ORCID No : <https://orcid.org/0009-0007-6504-2323>⁴Kütahya Dumlupınar Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 43100, Kütahya, ORCID No : <https://orcid.org/0000-0002-9543-4076>**Anahtar Kelimeler:***Derin Öğrenme,
Veri Seti,
Tensorflow,
Keras,
Mantar,
Zehirli Mantarlar,
Yenilebilen Mantarlar*

Özet: Mantarların Türk ve Dünya mutfaklarında kullanımı hızla artmakta, özellikle son yıllarda yabani mantar toplayıcılığı ve tüketiminde önemli artışlar yaşanmaktadır. Çevremizde sıkça gözlemediğimiz gıda zehirlenmelerinin birçoğunu mantar zehirlenmeleri oluşturmaktadır. Öyle ki bu oran erişkinlerde mantar zehirlenmeleri tüm akut zehirlenme vakalarının yaklaşık %7'sini oluşturmaktadır. Ülkemizin kırsal kesimleri başta olmak üzere pek çok yerinde halk mantarları toplayarak gıda olarak tüketmektedir. Ülkemizde yeterli bilgiye sahip olmayan kişiler tarafından toplanan mantarların besin olarak tüketilmesi ile zehirlenmeler ve ne yazık ki ölümler görülebilmektedir. Bu çalışmada doğada kolaylıkla yetişebilen mantarların insanlar üzerindeki olumsuz etkilerini azaltmak amacıyla, insanların mantar kullanımında bilgi sahibi olmalarını sağlayarak bilinç düzeylerini artırmak için derin öğrenme tabanlı mobil uygulama tasarlanmıştır. Çalışmada ayrıca açık kaynak kod olarak sunulan, Google ve bağımsız geliştiriciler tarafından geliştirilen Tensorflow ve Keras kütüphaneleri kullanılmıştır. Android Studio ve Java programlama dili kullanılarak tasarlanan mobil uygulamaya derin öğrenme metodlarından VGG16 entegre edilerek kameradan görüntüsü alınan mantar tespit edilerek kullanıcıya özellikleri sunulmaktadır. Araştırma bulgularına uygulanan istatistiksel analizler sonucunda doğruluk oranı %81.75 olarak hesaplanmıştır.

(Research Article)

Detection of Mushroom Species Growing in Nature with Deep Learning**Keywords:***Deep Learning,
Dataset,
Tensorflow,
Keras,
Mushroom,
Poisonous Mushrooms,
Edible Mushrooms*

Abstract: The use of mushrooms in Turkish and World cuisines is increasing rapidly, especially in recent years, there has been a significant increase in wild mushroom picking and consumption. Most food poisonings we frequently observe in our environment are caused by mushroom poisoning. This rate is such that mushroom poisoning in adults constitutes approximately 7% of all acute poisoning cases. In many parts of our country, especially in rural areas, people collect mushrooms and consume them as food. In our country, poisoning and, unfortunately, deaths can be seen due to the consumption of mushrooms collected by people who do not have sufficient knowledge of food. In this study, to reduce the harmful effects of mushrooms that can quickly grow in nature on humans, a deep learning-based mobile application was designed to increase people's awareness by providing information on mushroom use. Tensorflow and Keras libraries, which are offered as open-source code and developed by Google and independent developers, were also used in the study. VGG16, one of the deep learning methods, is integrated into the mobile application designed using Android Studio and Java programming language, and the mushroom image taken from the camera is detected, and

its features are presented to the user. As a result of the statistical analyses applied to the research findings, the accuracy rate was calculated as 81.75%.

1. GİRİŞ

Dünyada gelişen teknoloji ile birlikte yapay zekâ ve alt kümesi olan derin öğrenme teknolojileri birçok farklı alanda hayatımızı kolaylaştıran bir unsur haline gelmiştir. Derin öğrenme, beyindeki nöron ağını taklit eden bir bilgisayar yazılımıdır. Derin öğrenme ifadesi 2012 yılında Hinton tarafından çok katmanlı yapay sinir ağlarının verimli bir şekilde eğitilebileceği ortaya koyulduktan sonra literatürde kullanılmaya başlanmıştır [9].

Derin öğrenme (aynı zamanda derin yapılandırılmış öğrenme, hiyerarşik öğrenme ya da derin makine öğrenmesi) bir veya daha fazla gizli katman içeren yapay sinir ağları ve benzeri makine öğrenme algoritmalarını kapsayan çalışma alanıdır. Klasik Makine öğrenme teknikleri ile bir model tanımlama veya makine öğrenimi sistemi kurmak için öncelikle özellik vektörünün çıkarılması gerekmektedir. Özellik vektörünün çıkarılması için alanında uzman kişilere ihtiyaç duyulmaktadır. Bu işlemler hem çok zaman almakta hem de uzmanı çok meşgul etmektedir. Bu sebeple bu teknikler, ham bir veriyi ön işlem yapmadan ve uzman yardımı olmadan işleyemezler. Derin Öğrenme makine öğrenimi alanında çalışanların uzun yıllar boyunca uğraştığı bu sorunu ortadan kaldırarak büyük ilerleme sağlamıştır. Çünkü derin ağlar geleneksel makine öğrenmesi ve görüntü işleme tekniklerinin aksine öğrenme işlemini ham veri üzerinde yapmaktadır. Ham veriyi işlerken gerekli bilgiyi farklı katmanlarda oluşturmuş olduğu temsillerle elde etmektedir. Derin Öğrenme ilk defa 2012 yılında nesne sınıflandırma için yapılan, büyük ölçekli görsel tanıma (ImageNet) yarışmasında elde ettiği başarı ile dikkatleri üzerine çekmiştir. Derin Öğrenmenin temelleri geçmişe dayansa da özellikle son yıllarda popüler olmasının en önemli sebeplerinden ilki eğitim için yeteri kadar verinin olması ve ikinci olarak bu veriyi işleyecek donanımsal alt yapının olmasıdır [5].

Derin öğrenme (Deep Learning-DL), birçok alanda önemli başarılar elde etmiş güçlü bir makine öğrenmesi yöntemidir. Özellikle son on yılda, bilgisayarlı görü, nesne tanıma, konuşma tanıma, doğal dil işleme gibi birçok araştırma alanında başarılı sonuçlar elde ederek, yapay zekanın derin uykudan uyanmasına yol açmıştır. Günümüzde, çeşitli alanlardaki birçok araştırmacı, DL yöntemlerini kullanarak alanlarında en iyi sonucu almaya çalışmaktadır [8].

Sayısal veriler incelendiğinde yeryüzünde yaklaşık 1,5 milyon mantar türü vardır. Günümüzde ise sadece 69.000 kadar mantar türü tanımlanmıştır. Mantarların kullanım alanları ve insan hayatına çok fazla yararları olsa da

neden oldukları hastalıklar ve zehirlenmeler de oldukça fazladır. Mantar zehirlenmeleri, ülkemizde zehirlenmelerin çok büyük bir kısmını oluşturmaya da insan hayatını tehlikeye atma konusunda önemli bir riske sahiptir. Ülkemizde mantar zehirlenmesinden kaynaklanan ağır karaciğer yetmezliği gibi bazı hastalıklara sebebiyet vermektedir. İnsanların bilinçsizce mantar tüketiminden kaynaklanan sağlık sorunları ortaya çıkmaktadır [23]. Doğal alanlarda yetişen ve yapısında zehirli madde bulunan şapkalı mantarların taze, kurutulmuş veya konserve olarak yenmesi sonucunda gelişen ve ölümlerle de sonuçlanabilen ciddi tehlikeleri vardır. Bir haber kaynağına göre Karaman’da yaşayan bir aileden üç kişi bahçedeki mantarlardan zehirlenerek hastaneye kaldırıldı. Aileden iki kişi hastanede tedavi altına alınırken zehirlenmeye bağlı organ yetmezliği gelişen diğer aile üyesine kardeşinden karaciğer nakledildi. Bu olay bilinçsizce mantar tüketimine bağlı olumsuz sonuçlara sadece bir örnektir [11].

Bu çalışma ile amacımız toplumun mantarlar hakkında bilgi sahibi olmalarını sağlamak ve toplumu bilinçlendirerek bu gibi durumların ortaya çıkmasını en aza indirmektir. Bu amaç doğrultusunda mantarların türlerini belirterek zehirli olup olmadıkları bilgisini insanlara gösteren derin öğrenme tabanlı bir mobil uygulama tasarlandı. Bu uygulamayla birlikte; mantar toplayıcılığının hala yaygın olduğu yörelerde insan sağlığına zararlı olan mantarların eksik bilgi sebebi ile tüketilmesinin önüne geçilmesi hedeflenmiştir. Çalışmanın tasarımında Android Studio ve Java programlama dili ile derin öğrenme kütüphaneleri kullanılmaya karar verilmiştir.

Farklı sektörlerde de bu çalışmada kullanılan teknikler kullanılarak farklı problemlere çözüm getiren çalışmalar yapılmıştır. Yapılan literatür taramalarında karşılaşılan çalışmalarda, bu çalışmada da kullanılan tekniklerle benzerlik gösteren çalışmalar vardır. Eryılmaz, Şahin ve Kılıç; yaptıkları çalışmada derin öğrenme, yapay zeka ve makine öğrenmesi tekniklerini kullanarak istenmeyen e-postaların tespitini gerçekleştiren bir çalışma gerçekleştirmiştir. Çalışmada aynı veri kümesinde yapılan diğer çalışmalara göre, daha fazla öznelik seçim yöntemi ve daha fazla makine öğrenmesi algoritması test edilmiştir. Bu sayede veri kümesinin boyutunu artırarak geniş kapsamlı denemelerin yapılması hedeflenmiştir [7].

Alimovski ve Erdemir; çalışmalarında derin öğrenme, evrimsel sinir ağları ve makine öğrenmesi kullanmıştır. Orijinal veri seti ve çoğaltılmış veri setlerini kullanarak derin öğrenmeye dayalı yüz tanıma sistemindeki etkisi araştırılmıştır. Elde edilen sonuçlar, uygulanan veri artırma tekniğinin, yüz doğrulama işlemi için %1.8 oranında, yüz sınıflandırma işlemi için %2.2 ve %2.5 oranında artış sergilediği gözlemlenmiştir [1].

Muradlı; çalışmalarında VGG16, Resnet50 ile “MPI İnsan Duruşu” veri seti ve Evrişimsel Sinir Ağı kullanılarak insan duruş tespiti gerçekleştirmişlerdir. Çalışmanın amacı, Keras modeli adı verilen bir derin öğrenme modelinde son teknoloji bir ağ uygulayarak insan vücudunun duruşunu tahmin etmek için derin bir CNN yapısının nasıl kullanılabilirliğini keşfetmektir [15].

Bu çalışmada Android platformunda uygulamayı çıkarmak için Android Studio ve Java programlama dili kullanılmak üzere seçilmiştir. Toplanan veriler ile eğitilen modelimiz TensorFlow Lite biçiminde Android Studio ortamında kullanıldı. Ayrıca kullanıcı kayıt/giriş bilgilerinin kaydı tutmak adına veri tabanı bağlantısı kuruldu. Bu bağlamda veri tabanı olarak Firebase seçildi.

2. MATERYAL VE METOT

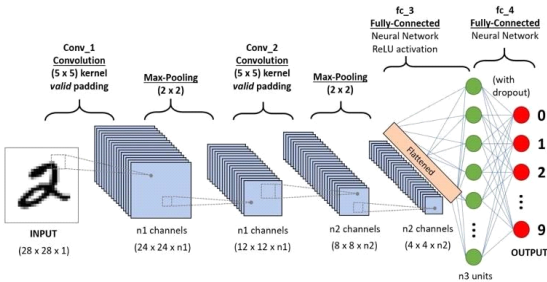
2.1. Kullanılan Yöntemler

Bu çalışmada mantar türlerinin tespiti için derin öğrenme sınıflandırıcı model olarak önceden eğitilmiş bir CNN modeli olan VGG16 kullanılmıştır.

2.1.1. CNN Model

Bilgisayar görmesi alanında, öznelik çıkarımı ve sınıflandırma her zaman önemli bir çalışma alanı olmuştur. ESA, görüntülerin analiz edilmesine başarıyla uygulanmış derin ileri beslemeli yapay sinir ağıdır. Genellikle görüntü işleme problemlerinde kullanılmaktadır. Giriş katmanı, evrişim katmanı, havuzlama katmanı, tam bağlantı katmanı ve çıkış katmanı adı verilen katmanlardan oluşur. ESA, görüntü tanıma uygulamalarında kullanılmaktadır. Her bir evrişim katmanında özellik haritaları bulunabilir. Bu özellik haritaları sayesinde ağ, farklı özellikleri öğrenebilmektedir [3].

ESA, sayılan bu avantajlarının dışında önemli bir dezavantaja sahiptir. Bu dezavantaj ise, modelin eğitim ve test aşamasında başarı ile çalışabilmesi için ihtiyaç duyulan yüksek bellekli güçlü GPU (Graphics Processing Unit) kartlarıdır. Son günlerde üreticilerin geliştirmiş oldukları yüksek bellekli kartları sayesinde bu sorunun önüne geçilmesine çalışılmaktadır [23].



Şekil 1. CNN Mimarisi [4].

2.1.2. Keras

Keras, Python için derin bir öğrenme kütüphanesidir ve derin öğrenme modellerinin oluşturulması ve eğitimi için çok uygun bir ortam sağlar [5]. Keras başlangıçta araştırmacıların daha hızlı denemeler yapabilmeleri için geliştirilmiştir. Keras'ın öne çıkan özellikleri aşağıdaki gibidir;

- Kodu değiştirmeden hem CPU'da (Central Processing Unit) hem de GPU'da çalışmasını sağlar.
- Derin öğrenme modellerinin prototiplemesinin hızlıca yapılmasına imkân sağlayan kullanıcı dostu API'ye (Application Programming Interface) sahiptir.
- Evrişimsel ağlar (bilgisayarlı görü için), yinelenmeli ağlar (zaman serisi işlemek için) ve her ikisinin beraber kullanımını için önceden tanımlı desteğe sahiptir. Keras'da pek çok değişik ağ yapısının, çoklu girdi ya da çoklu çıktının, katman paylaşımının, model paylaşımının vb. uygulanabilmesi mümkündür. Bu da Keras'ı, çeşitli üretici ağlardan sinirsel Turing makinesine kadar her türlü derin öğrenme modelinin oluşturulması için uygun hale getirmektedir. Keras, MIT lisansı (Massachusetts Institute of Technology) ile dağıtılmaktadır. Yani ticari projeler dahil her yerde serbest olarak kullanılabilir.

Önerilen modeli kurulumak için gerekli çalışmalar, Python 3.8 programlama dilinde yazılmış derin öğrenme kütüphanesi Keras kullanılarak yapılmıştır [14, 18, 10]. Modeli kurulumak ve derin öğrenme mimarisini inşa etmek için ihtiyaç duyulan kütüphaneler Anaconda yazılımı aracılığıyla yüklenmiştir [2]. Keras, Python ile yazılmış ve TensorFlow, CNTK (The Microsoft Cognitive Toolkit), Theano'nun üzerinde çalışabilen üst düzey bir sinir ağları uygulama derin öğrenme kütüphanesidir. Keras, Python için 250.000'den fazla kullanıcısı ve 700'den fazla açık kaynaklı katılımcısı ile (2018'in ortalarından itibaren) önde gelen bir derin öğrenme kütüphanesidir. Çabuk sonuç sağlamaya odaklanarak geliştirilmiştir. Kullanıcı dostu, modülerlik ve genişletilebilir olması özellikleriyle kolay ve hızlı prototipleme sağlar. Konvolüsyon ağları, yinelenen ağlar ve her ikisinin kombinasyonlarını destekler. CPU ve GPU'da sorunsuz çalışır. Keras, önemli sayıda girişimde, araştırma laboratuvarlarında (CERN, Microsoft Research ve NASA dahil) ve Netflix, Yelp, Square, Uber, Google gibi büyük şirketlerde kullanılmaktadır. Keras varsayılan olarak, TensorFlow'u tensör manipülasyon kütüphanesi olarak kullanır [14, 12].

Keras, Google mühendisi François Chollet tarafından, dört temel ilkeyi dikkate alınarak geliştirilmiştir [13]:


- Modülerlik: Bir model sadece bir sekans veya grafik olarak okunup, anlaşılabilir. Derin bir öğrenme modelinin tüm özellikleri, keyfi bir şekilde birleştirilip ayrılabilir.
- Minimalizm: Kütüphane, bir sonuç elde etmek için yeterli seviyedir, gereksiz süsten uzak ve okunabilirliği en üst seviyeye çıkaracak biçimde tasarlanmıştır.
- Genişletilebilirlik: Araştırmacıların yeni fikirleri denemelerini ve keşfetmelerini sağlamaya yönelik olarak, kütüphane içine yeni bileşenler kolaylıkla eklenebilir, eklenen yeni bileşenler kolaylıkla kullanılabilir.

- Python: Özel dosya formatlarına sahip ayrı bir model dosyası yoktur. Her şey doğal Python'dır.

Derin öğrenme modeli Python programlama dili Keras kütüphanesi kullanılarak Spyder geliştirme ortamı ile geliştirilmiştir. Google Colaboratory ile de Tensorflow tabanlı Keras kütüphanesi kullanılmaktadır.

2.1.3. TensorFlow

TensorFlow makine öğrenmesi ve derin öğrenme projelerini baştan sona tasarlayıp sonuçları görebileğimiz bir ortam sunmaktadır [16]. Google Brain ekibi tarafından 2015 yılında açık kaynaklı bir proje olarak yayınlanan bu kütüphane birbirinden farklı ortamlarda çalışabileceği gibi farklı programlama dilleri ve farklı donanımlarda da çalışabilir. Bu kütüphanedeki yapı temel olarak bir dizi hesaplamalardan meydana gelen veri akış grafiklerinden oluşmaktadır. Bu akış grafikleri düğümlerin durumunu kaydetmek, güncellemek için dallanma ve döngü kontrolüne izin veren bir veri akışı hesaplaması sunar [19]. Her bir düğüm 0 veya daha fazla girişe ve 0 veya daha fazla çıkışa sahip olan işlem örneği gösterir. Şekil 2'de görülmektedir.




Şekil 2. Veri Akış Grafığı

TensorFlow, otomatik farklılaştırma ve parametre paylaşma yetenekleri nedeniyle farklı mimari türlerini destekler. TensorFlow, paylaşılan parametreleri güncellemek için iş birliği yapan çoklu hesaplama kaynaklarını kullanarak veri akış grafiği modelinin paralel yürütülmesi yoluyla paralellik destekler. Paralel çalışma yeteneği ciddi performans artışlarına izin verir [25]. TensorFlow ayrıca mobil ve Nesnelerin İnterneti (IoT) cihazlar için optimize edilmiş çıkarım yapma sürümünü de sunmaktadır. Düşük donanım özelliklerinde etkin sonuçlar vermesi hedeflenmiştir [22]. TensorFlow ile Google ve Amazon gibi bulut ortamlarında model oluşturmak, eğitmek ve test etmek mümkündür. Şekil 3'de TensorFlow mimari katmanlarına yer verilmiştir.

2.1.3. VGG16 model

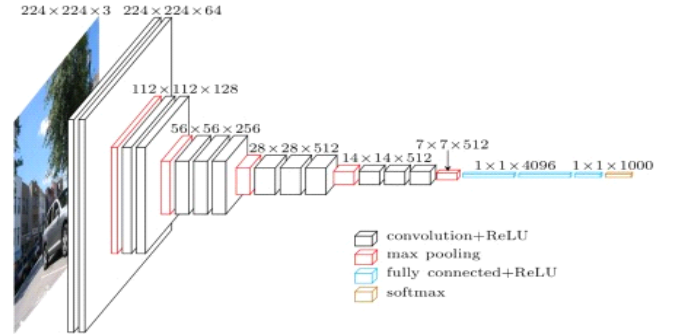
VGG-16 mimarisi; evrimsel, havuz ve tamamen bağlı katmanlardan oluşur. Toplam 21 ana katmandan oluşur. Bu mimari artan bir ağ yapısına sahiptir. Görüntü giriş çözünürlüğü 224×224 pikseldir. Evrimsel katmanındaki filtre boyutu 3×3 pikseldir. Bu mimaride

son katmanlar özellik çıkarımı için kullanılan tam bağlantılı katmanlardan oluşur [20].




Şekil 3. TensorFlow Mimari Katmanları [19]

VGG16 modeli Görsel Geometri Grubu (Visual Geometry Group) tarafından ILSVRC-2014 yarışmasında daha iyi sonuçlar elde etmek için geliştirilen bir ağ modelidir [6]. Giriş katmanında yer alacak görüntü $224 \times 224 \times 3$ boyutundadır. ImageNet veri seti ile %89 doğruluk yakalamış bir derin öğrenme ağ modelidir [21]. Şekil. 3'te sunulan VGG16 ağ mimarisinde, 13 evrişim katmanı ve 5 havuzlama katmanı ile toplamda 18 katman bulunmaktadır [6].



Şekil 4. VGG16 Mimarisi [24].



Şekil 5. VGG16 Mimarisi [4].

2.2. Kullanılan Veri Seti

Bu çalışmada kullanılan veri seti, internet üzerinden alınan fotoğraflarla 23 ayrı sınıf oluşturulacak şekilde hazırlandı. Yapay zekâ tarafından daha anlaşılabilir olabilmesi için her bir fotoğraf arka planından ayrıldı. Her bir hedef mantarı, yeterli çeşitlilik seviyesine sahip yeterli kaynak görüntü toplamak için mantarlardan çeşitli açılardan ve mesafelerden görüntüleri veri setine

eklemeye özen gösterildi. Veri setini hazırlarken tüm mantar fotoğrafları, arka planlarının sadeliği baz alınarak tek tek seçilip eğitim modeli için ayarlandı. Tek tek sınıflara ayrılan tüm fotoğraflar “eğitim”, “geçerleme” ve “test” olmak üzere 3 sınıfa ayrıldı. Eğitim sınıfında 130 fotoğraf, geçerleme sınıfında 40 fotoğraf, test sınıfında ise 50 fotoğraf bulunmaktadır. Bu üç sınıf altında da her biri kendi sınıfının mantar türüyle aynı kategoriye konuldu.

2.3. Veri Seti İçin Kullanılan Mantarlar

Bu çalışmada 23 farklı mantar türüne ait 5060 adet mantar fotoğrafı kullanıldı. Bu mantarlar; Ağulu Mantarı, Bal Mantarı, Biftek Mantarı, Borazan Mantarı, Çam Kabara Mantarı, Çörek Mantarı, İmparator Mantarı, İstiridye Mantarı, Kanlıca Mantarı, Kantarel Mantarı, Kamabakar Mantarı, Kış Mantarı, Köygöçüren Mantarı, Kuzugöbeği Mantarı, Kültür Mantarı, Maitake Mantarı, Panter Mantarı, Sığır Dili Mantarı, Sinek Mantarı, Şeytan Mantarı, Şimeji Mantarı, Şitake Mantarı ve Trüf Mantarıdır.




Şekil 6. a) İmparator Mantarı b) Ağulu Mantarı c) Panter Mantarı

2.4. Model'in Eğitilmesi

Modelin eğitilmesi için TensorFlow'un Keras API'si kullanılarak bir VGG16 modelinin evrişim tabanı oluşturuldu ve ön eğitilmiş ağırlıkları yüklendi. Bu taban, özellik çıkarımı için kullanılacak bir derin öğrenme modelidir. VGG16 modeli kullanılarak yeni bir sinir ağı modelinin oluşturulması sağlandı. Model, eğitim veri seti üzerinde belirtilen sayıda epoch boyunca eğitildi ve

doğrulama veri seti üzerinde performansı izlendi. Bu işlemlerin ardından h5 uzantılı bir dosya elde edildi. Bu dosya, Android Studio ortamına uyarlanabilmesi için TensorFlow Lite uzantılı bir dosya haline getirildi.



Şekil 7. Akış Şeması

3. BULGULAR

Proje bir mobil uygulamaya entegre edilerek daha verimli ve kullanışlı hale getirildi. Mobil uygulama için Android Studio ortamı seçilmiştir.

3.1 Uygulamanın Kayıt Ol Sayfası


Uygulamayı kullanırken öncelikle kullanıcıların kaydolması gerekmektedir. Bu kayıt işlemi gerçekleştiğinde kullanıcının bilgileri veri tabanına kaydedilmektedir. Veri tabanı olarak Firebase kullanıldı. Uygulamanın kayıt ol sayfası Şekil 8’de gösterilmektedir.



Şekil 8. Kayıt Ol Sayfası.

3.2 Uygulamanın Giriş Yap Sayfası

Kaydılduktan sonra uygulamaya girmek için giriş yapılması gerekmektedir. Giriş yap butonuna tıklandıktan sonra kayıt bilgileri doğru bir şekilde girilip uygulamaya giriş yapılmaktadır. Uygulamadaki giriş yap sayfası Şekil 9'da bulunmaktadır.



Şekil 9. Giriş Yap Sayfası.

3.3 Uygulamanın Ana Sayfası

Uygulama açıldığında ana ekranda mantarlar ile ilgili bilgilendirici bir yazı bulunmaktadır. Ardından sol taraftaki menü butonundan seçenekler görüntülenmektedir.



Şekil 10. Uygulamanın Ana Sayfası.

3.4 Mantarları Tarama Sayfası

Ana ekrandaki menüden hemen tarayın kısmına tıklanılması durumunda kullanıcı, mantarları tarama sayfasına yönlendirilmektedir. Bu sayfada taratılmak istenen mantarın fotoğrafını yükleyerek mantar hakkında

bilgi sahibi olunmaktadır. Mantarın fotoğrafı, telefon kamerasından veya telefonun galerisinden seçilip veri setindeki en iyi eşleşme yapılarak hangi mantar olduğu kullanıcıya gösterilmektedir. Mantarın isminin olduğu kısma tıklanıldığında mantarın yenilebilir ya da zehirli olduğu bilgisi ile birlikte mantar hakkındaki bilgiler de kullanıcıya sunulmaktadır. Bu sayede kullanıcılar mantarı yemeden önce kolaylıkla mantarlar hakkında bilgi sahibi olmaktadır.



Şekil 11. Taratılan Mantar.



Şekil 12. Taratılan Mantarın Bilgileri.

3.5 Veri Setindeki Bulgular

Çalışmada TensorFlow, Python kullanarak bazı bulgular elde edilmiştir. Bu çalışmanın asıl amacı kullanıcıları

mantar zehirlenmelerine karşı en etkili biçimde bilinçlendirmektir.

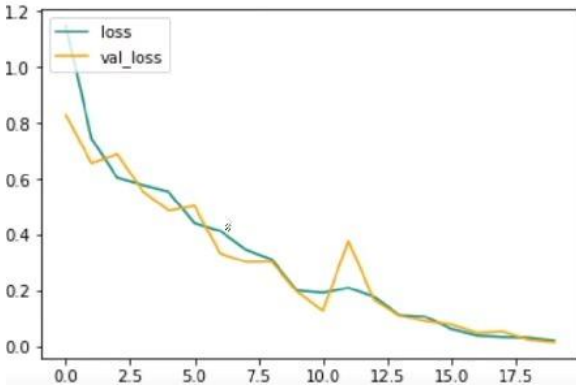
Bu çalışmada mantar veri seti oluşturuldu. Veri seti bir görüntü veri kümesini eğitim, doğrulama ve test veri kümelerine böldü. Bu işlem daha sonra modelin eğitimi, doğrulaması ve performansını değerlendirmesi için kullanıldı. Bir evrişimsel sinir ağı modeli oluşturuldu. Modelin eğitimi gerçekleştirilirken bu veriler TensorBoard'a kaydedildi. Tablo 1.'de 4 eğitim boyunca kaydedilen veriler gösterilmektedir.

Tablo 1. 4 Eğitim Boyunca TensorBoard Kaydedilen Veriler

Eğitim Sayısı	Kayıp	Kesinlik	Değer Kaybı	Değer Doğruluğu
1	0.0630	0.9162	0.2000	0.7375
2	0.0704	0.9262	0.1367	0.8250
3	0.0660	0.9036	0.1121	0.8750
4	0.0576	0.9174	0.1398	0.8500

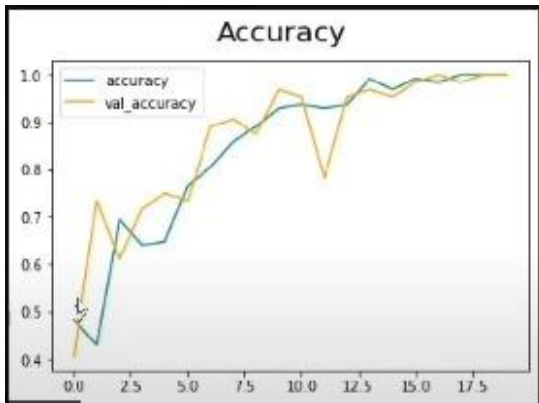
Tablo 1.'de görüldüğü üzere eğitim sayısı arttıkça kayıp değerlerinde bir azalma meydana gelmektedir. Ayrıca değer kaybı da azalmaktadır.

Modelin eğitimi sırasında kaydedilen kayıp ve değer kaybı değerlerini çizgi grafiği olarak Şekil 13'de görselleştirilmiştir.



Şekil 13. Kayıp ve Değer Kaybı Çizgi Grafiği.

Modelin eğitimi boyunca TensorBoard'a kaydedilen kesinlik ve değer doğruluğu metrikleri çizgi grafiği olarak Şekil 14' de gösterilmiştir.



Şekil 14. Kesinlik ve Değer Doğruluğu Çizgi Grafiği.

Grafikten de anlaşılacağı üzere kesinlik değerlerinde bir artma meydana gelmiştir.

4. TARTIŞMA VE SONUÇ

Çalışmada, bilinçsizce tüketilen mantarların insan yaşamını büyük risklerle karşı karşıya bırakabileceği bilindiği için riskleri en aza indirebilmek adına kullanıcıların bilinçlendirilmesi gerektiği vurgulanmaktadır. Kullanıcılar tükettiği mantarın özelliklerini bilirse hem zararlarını hem de faydalı özelliklerini öğrenmiş olacaktırlar. Bu sayede insan hayatının tehlikeye girebilecek durumları en aza indirgenmiş olacaktır.

Derin öğrenme ve yapay zekâ günümüz teknolojisinin vazgeçilmez bir parçası olmuştur. Birçok alanda kullanıldığı gibi sosyal inovasyon alanındaki uygulamalarında da başarılı sonuçlar üretmektedir. Yapay zekâ ve derin öğrenme doğru bir şekilde uygulandığında birçok alandaki uygulamalarda çok başarılı sonuçlar verebilir.

Bu çalışma, elde edilen bulgular doğrultusunda eğitilen veri setleriyle gerçekleştirilmektedir. Bulgularda meydana gelen kayıp değerlerindeki ve değer kaybındaki azalma açıkça görülmektedir. Tüm verilerin doğruluk değeri %81.75 olarak hesaplanmıştır. Ayrıca modelin eğitimi sırasındaki kesinlik ve doğruluk değerleri artmaktadır. Bu dört bulgu bu veri setinin eğitilmesindeki başarıyı açıkça göstermiştir.

Elde edilen sonuçlardan yola çıkarak, çoğaltılmış veri setinin mevcut görüntü sayısı artırıldığı takdirde mantar tespiti uygulamamızın performansında iyileşme olacağına kanaatlenmiştir.

Etik Hususlar

Etik kurallara uyum

Bu araştırmanın planlanmasından uygulanmasına, verilerin toplanmasından verinin analizine kadar olan tüm süreçte "Yükseköğretim Kurumları Bilimsel Araştırma ve Yayın Etiği Yönergesi" kapsamında uyulması belirtilen tüm kurallara uyulmuştur. Yönergenin ikinci bölümü olan "Bilimsel Araştırma ve Yayın Etiğine Aykırı Eylemler" başlığı altında belirtilen eylemlerden hiçbiri gerçekleştirilmemiştir. Çalışmanın yazım sürecinde bilimsel etik ve alıntı kurallarına uyulmuş, toplanan veriler üzerinde herhangi bir tahrifat yapılmamış ve bu çalışma herhangi başka bir akademik yayın ortamına değerlendirme için gönderilmemiştir.

Finansman

Yazarlar kamu, ticari veya kâr amacı gütmeyen sektörlerdeki fon kuruluşlarından özel bir hibe alınmadığını beyan ederler.

Çıkar çatışması

Çalışma ile ilgili herhangi bir kişi veya kurumla çıkar çatışmasının bulunmadığını yazarlar olarak onaylıyoruz.

KAYNAKÇA

- [1] Alimovski, E., Erdemir, G. 2021. Veri Artırma Tekniklerinin Derin Öğrenmeye Dayalı Yüz Tanıma Sisteminde Etkisi . İstanbul Sabahattin Zaim Üniversitesi Fen Bilimleri Enstitüsü Dergisi , UAKK2020 , 76-80.
- [2] Anaconda3 (1.9.6) [Computer software].
- [3] Ari A., Hanbay D., 2018. Deep learning based brain tumor classification and detection system, Turkish J. Elect. Eng. Comput. Sci., 26: 2275–2286.
- [4] CNN mimarisi, Erişim Adresi: <https://towardsdatascience.com/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way-3bd2b1164a53>, Erişim: 19.10.2022.
- [5] Dandil, E., 2015. Mr görüntüleri ve mr spektroskopisi verileri ile yapay öğrenme tabanlı beyin tümörü tespit yöntemi ve uygulaması, pp. 4-7
- [6] Doğan, F., Türkoğlu İ. 2018. Comparison of Leaf Classification Performance of Deep Learning Algorithms. Sakarya University Journal of Computer and Information Sciences, 1: 10-21.
- [7] Eryılmaz, E., Şahin, D. Ö., Kılıç, E. 2020. Türkçe İstenmeyen E-postaların Farklı Öznitelik Seçim Yöntemleri Kullanılarak Makine Öğrenmesi Algoritmaları ile Tespit Edilmesi". Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi, c. 13, sayı. 2, ss. 57-77.
- [8] He, X. Zhang, S. Ren., J. Sun. 2016. Deep residual learning for image recognition. In CVPR.
- [9] Hinton, G. Deng, L. Yu, D. Dahl, G.E. Mohamed, A.-r. Jaitly, N. Senior, A. Vanhoucke, V. Nguyen, P., Sainath, T.N. 2012. Deep neural networks for acoustic modeling in speech recognition: The shared views of four research groups. IEEE Signal Processing Magazine, 29: 82-97.
- [10] JetBrains PyCharm (2018.3.2) [Computer software]
- [11] Karaaslan, Y.S. (2023,14 Haziran). Mantardan zehirlenen genç kız karaciğer nakliyle hayata döndü. aa.com.tr
- [12] Keras, <https://machinelearningmastery.com/introduction-python-deep-learning-library-keras/>, erişim tarihi sürekli.
- [13] Keras , <http://linkedin.com/in/fchollet>, erişim tarihi sürekli.
- [14] Keras , <http://keras.io> , erişim tarihi sürekli.
- [15] Muradli, F. 2021. Derin öğrenme kullanılarak görüntülerden insan duruş tespiti. acikerisim.sakarya.edu.tr
- [16] Neden TensorFlow. (accessed May 19, 2021). <https://www.tensorflow.org/about?hl=tr>
- [17] Pekşen, A. Mantar Zehirlenmeleri ve Başlıca Zehirli Mantarlar. ordu.tarimorman.gov.tr
- [18] Python (3.6) [Computer software]
- [19] Serbest, K., Aktürk, S. 2022. Nesne Tespiti İçin Derin Öğrenme Kütüphanelerinin İncelenmesi. Journal of Smart Systems Research 3(2), 97-119.
- [20] Simonyan, K., Zisserman, A. 2014. Very deep convolutional networks for large-scale image recognition. arXiv Prepr arXiv14091556.
- [21] Simonyan, K. ve Zisserman, A.(2015). Very Deep Convolutional Networks For Large-scale Image Recognition. ICLR.
- [22] TensorFlow Lite | Mobil ve Uç Cihazlar için Makine Öğrenimi. (accessed May 19, 2021). <https://www.tensorflow.org/lite/?hl=tr>
- [23] Türkoğlu, M., Hanbay, K., Saraç Sivrikaya, I., Hanbay, D. 2020. Derin Evrimsel Sinir Ağı Kullanılarak Kayısı Hastalıklarının Sınıflandırılması. Bitlis Eren Üniversitesi Fen Bilimleri Dergisi, 9: 334-345.
- [24] VGG16 mimarisi, Erişim Adresi: <http://www.cs.toronto.edu/~frossard/post/vgg16/>, Erişim: 19.10.2022.
- [25] Wahab, A., Elshawi, R., Barnawi, A., Sakr, S. 2021. DLBench: a comprehensive experimental evaluation of deep learning frameworks, Clust. Comput. J. Networks, Softw. Tools Appl., p. 1, doi: 10.1007/s10586-021-03240-4.