



**GÖRÜNTÜ İŞLEMENİN CONVOLUTIONAL
NEURAL NETWORK(CNN) MODELİ
KULLANILARAK TARIMSAL ALANDA
UYGULANMASI: HASTALIKLI YAPRAK TESPİTİ**

Betül KARAOĞLAN

**2022
YÜKSEK LİSANS TEZİ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ**

**Tez Danışmanları
Doç. Dr. Muhammet Tahir GÜNEŞER
Dr. Öğr. Üyesi İsa AVCI**

**GÖRÜNTÜ İŞLEMENİN CONVOLUTIONAL NEURAL NETWORK(CNN)
MODELİ KULLANILARAK TARIMSAL ALANDA UYGULANMASI:
HASTALIKLI YAPRAK TESPİTİ**

Betül KARAOĞLAN

**T.C.
Karabük Üniversitesi
Lisansüstü Eğitim Enstitüsü
Elektrik-Elektronik Mühendisliği Eğitimi Anabilim Dalında
Yüksek Lisans Tezi
Olarak Hazırlanmıştır**

**Tez Danışmanları
Doç. Dr. Muhammet Tahir GÜNEŞER
Dr. Öğr. Üyesi İsa AVCI**

**KARABÜK
Ağustos 2022**

Betül KARAOĞLAN tarafından hazırlanan “GÖRÜNTÜ İŞLEMENİN CONVOLUTIONAL NEURAL NETWORK(CNN) MODELİ KULLANILARAK TARIMSAL ALANDA UYGULANMASI: HASTALIKLI YAPRAK TESPİTİ” başlıklı bu tezin Yüksek Lisans Tezi olarak uygun olduğunu onaylarım.

Doç. Dr. Muhammet Tahir GÜNEŞER

Tez Danışmanı, Elektrik-Elektronik Mühendisliği Anabilim Dalı

Dr. Öğr. Üyesi İsa AVCI

Tez İkinci Danışmanı, Karabük Üniversitesi, Bilgisayar Mühendisliği Anabilim Dalı

Bu çalışma, jürimiz tarafından Oy Birliği ile Elektrik-Elektronik Mühendisliği Anabilim Dalında Yüksek Lisans tezi olarak kabul edilmiştir. 31/08/2022

Ünvanı, Adı SOYADI (Kurumu)

İmzası

Başkan : Dr. Öğr. Üyesi Abdulkadir TAŞDELEN (AYBÜ)

Üye : Doç. Dr. Muhammet Tahir GÜNEŞER (KBÜ)

Üye : Dr. Öğr. Üyesi İsa AVCI (KBÜ)

Üye : Dr. Öğr. Üyesi Tarık Adnan ALMOHAMAD (KBÜ)

Üye : Dr. Öğr. Üyesi Cihat ŞEKER (KBÜ)

KBÜ Lisansüstü Eğitim Enstitüsü Yönetim Kurulu, bu tez ile, Yüksek Lisans derecesini onamıştır.

Prof. Dr. Hasan SOLMAZ

Lisansüstü Eğitim Enstitüsü Müdürü

“Bu tezdeki tüm bilgilerin akademik kurallara ve etik ilkelere uygun olarak elde edildiğini ve sunulduğunu; ayrıca bu kuralların ve ilkelerin gerektirdiği şekilde, bu çalışmadan kaynaklanmayan bütün atıfları yaptığımı beyan ederim.”

Betül KARAOĞLAN

ÖZET

Yüksek Lisans Tezi

GÖRÜNTÜ İŞLEMENİN CONVOLUTIONAL NEURAL NETWORK(CNN) MODELİ KULLANILARAK TARIMSAL ALANDA UYGULANMASI: HASTALIKLI YAPRAK TESPİTİ

Betül KARAOĞLAN

Karabük Üniversitesi

Lisansüstü Eğitim Enstitüsü

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Tez Danışmanları:

Doç. Dr. Muhammet Tahir GÜNEŞER

Dr. Öğr. Üyesi İsa AVCI

Ağustos 2022, 31 sayfa

Son yıllarda yapay zekâ alanındaki çalışmaların artmasıyla beraber görüntü işlemeye dayalı sınıflandırma çözümlerine olan ilgi artmıştır. Görüntü işleme çözümleri: tıp, tarım, güvenlik sistemleri, uzay bilimleri, endüstriyel sistemler ve savunma sanayi gibi birçok alanda yenilikçi çözümler sunarak çeşitli kolaylıklar sağlamaktadır. Bu alanlardan biri olan tarım endüstrisinde, toprak işleme, dikim, sulama ve ürün bakımı süreçlerinde kullanılan yapay zekâ uygulamaları giderek yaygınlaşmaktadır. Bu uygulamalar özellikle tarımsal üretimde verimliliği ve sürdürülebilirliği artırma fırsatı sunarak ürün kalitesinin artmasında ve gıda güvenliğinin sağlanmasında önemli bir rol oynamaktadır. Ancak bitkilerdeki çeşitli hastalıklardan dolayı tarımda verim oranı ciddi anlamda düşüyor ve üretim kayıplarının önüne geçmek için bu hastalıkların tespitinde yapay zekâ çözümleri kullanılması hem maliyet hem de erken müdahale

açısından avantajlı bir çözüm önerisi olarak değerlendirilebilir. Bu çalışmada, tarımda ürün kaybını azaltmayı ve verimliliği artırmayı hedefleyerek Convolutional Neural Network (CNN) modeli kullanarak bitki hastalıklarının erken tespiti için bir çözüm önerdik. PlantVillage veri seti, “The Plant Pathology Challenge 2020”de kullanılmış olan veri seti ve DJI Phantom 3 Advanced insansız hava aracını ile elde ettiğimiz verilerden oluşturulan veri seti kullanıldı. Veri büyütme işlemi uygulanarak veri sayısı artırılmış, ardından geliştirilen CNN modeli ile görüntüler test edilmiştir. Veri setlerinde PlantVillage veri setinde %98.53, “The Plant Pathology Challenge 2020” veri setinde %83.2, tarafımızca hazırlanmış olan veri setinde %74.2 doğruluk oranları elde edilmiştir. Uygulama Anaconda 2020.11, Spyder 5 geliştirme ortamları kullanılarak Python programlama dilinde yapıldı.

Anahtar Sözcükler : CNN model, derin öğrenme, görüntü işleme, yapraklarda hastalık tespiti

Bilim Kodu : 90521

ABSTRACT

M. Sc. Thesis

APPLICATION OF IMAGE PROCESSING IN AGRICULTURE USING THE CONVOLUTIONAL NEURAL NETWORK(CNN) MODEL: LEAF DISEASE DETECTION

Betül KARAOĞLAN

Karabük University

Institute of Graduate Programs

Department of Electrical and Electronics Engineering

Thesis Advisors:

Assoc. Prof. Dr. Muhammet Tahir GÜNEŞER

Assist. Prof. Dr. İsa AVCI

August 2022, 31 pages

In recent years, with the acceleration of studies in the field of artificial intelligence (AI), deep learning-enabled systems aim to imitate a certain part of human intelligence. In the field of image processing, the interest of pattern recognition and classification has increased. In addition, the development in image processing has offered various conveniences by enabling innovative solutions in many fields such as medicine, agriculture, security systems, space sciences, and defence industry. For instance, agriculture applications adopt the involvement of artificial intelligence in the process of tillage, planting, irrigation and crop care. These AI-based applications contribute to product quality and food safety by offering the opportunity to increase efficiency and sustainability. In contrast, diseases in plants tremendously reduce the crop in agriculture. In order to prevent this problem, efficient methods can be utilised for early

detection of diseases to prevent crop losses. In this thesis, we propose a solution for early detection of plant diseases using the Convolutional Neural Network (CNN) model, aiming to reduce crop loss and increase productivity in agriculture. The PlantVillage dataset, the dataset used in "The Plant Pathology Challenge 2020", and the dataset created from the data we obtained with the DJI Phantom 3 Advanced unmanned aerial vehicle were used. The number of data was increased by applying the data augmentation process, and then the images were tested with the developed CNN model. In the datasets, PlantVillage dataset 98.53%, "The Plant Pathology Challenge 2020" 83.2%, created dataset by us 74.2% accuracy rates were obtained. The application was made using the Anaconda 2020.11, Spyder 5 development environments in the Python programming language.

Key Word : CNN model, deep learning, image processing, leaf disease detection

Science Code : 90521

TEŐEKKÜR

Bu tez alıőmasının planlanmasında, araştırılmasında, yürütülmesinde ve oluşumunda ilgi ve desteęini esirgemeyen, engin bilgi ve tecrübelerinden yararlandıęım, yönlendirme ve bilgilendirmeleriyle alıőmamı bilimsel temeller ışığında şekillendiren sayın hocam Do. Dr. Muhammet Tahir GÜNEŐER'e ve Dr. Öğr. Üyesi İsa AVCI'ya sonsuz teşekkürlerimi sunarım.

Sevgili aileme maddi, manevi hiçbir yardımı esirgemedi sevgi ve anlayıőla yanımda oldukları için tüm kalbimle teşekkür ederim. Deęerli arkadaşım Hatice Kübra KILIN'a tez sürecinde verdięi destek ve yardımlar için teşekkürlerimi sunarım.

İÇİNDEKİLER

	<u>Sayfa</u>
KABUL	ii
ÖZET	iv
ABSTRACT	vi
TEŞEKKÜR	viii
İÇİNDEKİLER.....	ix
ŞEKİLLER DİZİNİ	xi
ÇİZELGELER DİZİNİ	xii
SİMGELER VE KISALTMALAR DİZİNİ.....	xiii
BÖLÜM 1	1
GİRİŞ	1
BÖLÜM 2	3
LİTERATÜR TARAMASI.....	3
BÖLÜM 3	7
TEMEL KAVRAMLAR.....	7
3.1. YAPAY ZEKÂ.....	8
3.2. MAKİNE ÖĞRENMESİ	10
3.2.1. Denetimli Öğrenme.....	11
3.2.2. Denetimsiz Öğrenme.....	12
3.2.3. Yarı-Denetimli Öğrenme.....	12
3.2.4. Takviyeli-Pekiştirmeli (Reinforcement) Öğrenme	13
3.3. YAPAY SİNİR AĞLARI (YSA).....	14
3.3.1. İleri Beslemeli Sinir Ağları.....	14
3.3.2. Geri Beslemeli Sinir Ağları	15
3.3.3. Evrişimli Sinir Ağları.....	15
3.3.3.1 Convolutional Katmanı	16

	<u>Sayfa</u>
3.3.3.2 Pooling Katmanı.....	16
3.3.3.3 Fully-Connected Katmanı.....	16
3.4. DERİN ÖĞRENME.....	17
BÖLÜM 4.....	18
MATERYAL VE METOT.....	18
4.1. VERİSETİNİN HAZIRLANMASI.....	18
4.2. CNN PARAMETRELERİ.....	21
BÖLÜM 5.....	23
BULGULAR.....	23
BÖLÜM 6.....	25
SONUÇLAR.....	25
KAYNAKLAR.....	27
ÖZGEÇMİŞ.....	31

ŞEKİLLER DİZİNİ

	<u>Sayfa</u>
Şekil 3.1. Yapay zekâ-makine öğrenmesi-derin öğrenme şeması.	7
Şekil 3.2. Yapay zekânın temel alt alanları.	10
Şekil 3.3. Denetimli öğrenme.	11
Şekil 3.4. Denetimsiz öğrenme.	12
Şekil 3.5. Yarı denetimli öğrenme.	13
Şekil 3.6. Takviyeli-pekiştirmeli öğrenme.	13
Şekil 3.7. CNN mimarisi.	15
Şekil 4.1. Gürültü temizleme işlemi öncesi(a) ve sonrası(b).	19
Şekil 4.2. Veri çoğullama görüntü örnekleri.	20
Şekil 5.1. Confusion matrix.	23
Şekil 5.2. Eğitim ve test verileri accuracy grafiği.	24

ÇİZELGELER DİZİNİ

	<u>Sayfa</u>
Çizelge 4.1. Veri setleri başlangıç değerleri.....	18
Çizelge 4.2. Veri setlerinin veri çoğullama işleminden sonraki değerleri.	19
Çizelge 4.3. CNN Katman-Parametre Listesi.	21
Çizelge 5.1. Sonuçlar.	23

SİMGELER VE KISALTMALAR DİZİNİ

KISALTMALAR

- 3D : 3 Dimensional-3 Boyutlu
- ABD : Amerika Birleşik Devletleri
- AI : Artificial Intelligence – Yapay Zeka
- ANN : Artificial Neural Network
- BPNN : Back Propagation Neural Network-Geri Yayılımlı Yapay Sinir Ağı
- CART : Classification and Regression Tree-Sınıflandırma ve Regresyon Ağacı
- CBD : Coffee Berry Disease-Kahve Meyvesi Hastalığı
- CLR : Coffee Leaf Rust-Kahve Yaprağı Pası
- CNN : Convolutional Neural Network
- CWD : Coffee Wilt Disease-Kahve Solgunluğu Hastalığı
- DARPA: Defense Advanced Research Projects Agency-Savunma İleri Araştırma Projeleri Ajansı
- GA : Genetic Algorithm-Genetik Algoritma
- GPS : Global Positioning System-Küresel Konumlama Sistemi
- HSI : Hue Saturation Intensity
- IBM : International Business Machines Corporation
- KNN : K Nearest Neighbour-K en yakın komşu
- ML : Machine Learning - Makine Öğrenmesi
- PCA : Principal Component Analysis – Temel Bileşen Analizi
- RGB : Red Blue Green
- SVM : Support Vector Machines
- YSA : Yapay Sinir Ağı

BÖLÜM 1

GİRİŞ

Son yıllarda yapay zekâ alanındaki çalışmaların hızlanmasıyla beraber görüntü işleme dayalı nesne tanıma ve sınıflandırma uygulamalarına ilgi artmıştır. Görüntü işleme teknolojisi güvenlik, tıp, uzay bilimleri, savunma sanayi ve tarım gibi birçok alanda inovatif ve kolay entegre edilebilir çözümler sağlamaktadır. Bahsi geçen alanlardan birisi olan tarım endüstrisinde toprağın takibi, ekim, dikim, sulama ve ürün bakımı süreçlerinde yapay zekâ çözümleri kullanımı gittikçe yaygınlaşmaktadır [1-5]. Bu uygulamalar özellikle tarımsal üretimde verimliliği ve sürdürülebilirliği artırma fırsatı sunarak ürün kalitesinin yükselmesini desteklemektedir [1-5].

Ekonominin başlıca kaynaklarından biri olan tarım endüstrisi çevresel etkenlere aşırı derecede bağlı bir sektör olarak bilinmektedir. Tarım endüstrisinde çiftçileri etkileyen olumsuz etmenlerden en önemlilerinden birisi de tarım zararlıları olarak kabul edilmektedir. Bitki hastalıklarının tespiti ve önlenmesi ciddi bir endişe kaynağı olmakla beraber verimliliği arttırmak için zamanında tedavi büyük önem taşımaktadır [1-3]. Genel olarak, hastalıkların büyük çoğunluğu yapraklarda görülen belirtilerle tespit edilebilmektedir. Bu bağlamda görüntü işleme ile çiftçilerin işlerini kolaylaştıracak ve hastalıkların tespitinin daha erken yapılmasını sağlayacak yöntemlerin kolaylaştırıcı olacağı düşünülmektedir [1-5].

Yaprakların sağlık durumları, sadece tarım zararlılarının etkilerine değil aynı zamanda sıcaklık, ekim, hasat gibi çeşitli faktörlere de bağlıdır. Hastalıklar ise bulaşıcı ve bulaşıcı olmayan olmak üzere temelde iki kategoriye ayrılır. Bulaşıcı yaprak hastalıkları bakteri, mikoplazma, mantar, virüs gibi patojenik bir organizma tarafından başlatılır ve yayılır. Bulaşıcı olmayan bitki hastalıkları ise atmosferdeki bileşenlere, büyüme koşullarına, nem ve oksijen değerlerine, aşırı düşük sıcaklıklara veya mineral eksikliğe bağlı olabilir [2, 4-7].

Bitki hastalıklarının sebebi bakteri, virüs, parazit bitki veya yabancı otlar gibi canlı etmenler olabileceği gibi bitki için çok yüksek veya çok düşük sıcaklık, aşırı nem ve yağış, uygun olmayan toprak, az veya çok ışık alımı gibi cansız etmenler de olabilir. Belirtilen etmenlerin sonuçları bitkilerde sararma, çürüme, kuruma, belirli bölgelerde yanık oluşumu, renk değişimi gibi çeşitli şekillerde gözlemlenmektedir [2, 5].

Sürdürülebilir tarımın geliştirilmesinde insansız hava araçlarının potansiyelinin büyük olduğu daha önce yapılan çalışmalarla desteklenmektedir. Tohumların uygun zamanlarda ekilmesinde, geniş tarım arazilerinin izlenmesi ve yeniden ekim/dikim kararlarında insansız hava araçlarından faydalanılmaktadır [8, 9].

Bu çalışmanın amacı, farklı kaynaklardan elde edilen bitki yaprak resimlerinin benzeştirilip analiz edilerek bitkilerdeki hastalık tespitinin yapılması ve sonuçların karşılaştırılmasıdır. Tez kapsamında insansız hava araçlarından elde edilen görüntülerin veri analizinde kullanılmak üzere benzeştirilme işlemi yapılması, elde edilen görüntülerin işlenmesi için derin öğrenme yöntemi olan Convolutional Neural Network (CNN) – Evrimsel Sinir Ağları modelinin oluşturulması, görüntülerin işlenmesi ve sonuçların elde edilmesi işlemleri yapılmıştır.

Hazırlanan bu çalışma, genel itibarıyla literatür taraması ve deneysel çalışmalar olmak üzere iki kısımdan oluşmaktadır. Ancak, literatür taraması ve deneysel çalışmalar kendi içinde üç konu başlığı altında oluşturulmaya çalışılmıştır. Bunlardan birinci bölüm “Giriş” olup burada çalışmanın kısa özeti verilmiştir. İkinci bölümde, çalışmanın literatüre katkısının anlaşılabilmesi için bitki yapraklarında karşılaşılan ve görüntü işleme yöntemi ile tespit edilebilecek hastalıklar geniş bir literatür taramasıyla anlatılmıştır. Üçüncü bölümde bu çalışmanın deneysel çalışmalarında kullanılan yapay zekâ kavramı üzerinde durularak, konu ile ilgili temel kavramlar ve genel tanımlar detaylı bir biçimde tanıtılmıştır. Dördüncü bölümde ise deneysel çalışmada kullanılan materyal ve metotlar ayrıntılı bir şekilde açıklanmıştır.

Çalışmanın beşinci bölümünde, elde edilen veriler, kolay değerlendirilebilmesi için grafik olarak çizilmiş ve elde edilen grafikler değerlendirilmiştir.

Deneysel alıřmalar sonucu elde edilen bulgular, daha nceden yapılmıř benzer alıřmalarla sebep-sonu iliřkisi ile kıyaslanmıřtır.

Deneysel alıřmaların nihai sonularının aıklandığı altıncı ve son blmde, deneysel alıřmalar sonucu elde edilen bulgular, deneysel alıřmanın amacına uygun bir biimde yorumlanarak sonulandırılmıřtır.

BÖLÜM 2

LİTERATÜR TARAMASI

Son dönemlerde yapılan çalışmalarda hastalık tespiti için otomatik tekniklerin geliştirilmesine odaklanılmış durumda. Domates yapraklarında, ayçiçeği bitkisinde, çeltik yapraklarında, patates hastalıklarının tespiti, elma yapraklarından hastalık tespiti üzerine yapılan çalışmalar [11-21] tercih edilen yeni yöntemlerin verimli ve kullanılabilir olduğunu gösteriyor.

Gulhane ve arkadaşının [21] pamuk yapraklarındaki hastalıkları tespit etmek için temel bileşen analizi (PCA) ve KNN yöntemlerini kullandıkları çalışmada, yanık, gri küf, alternaria ve magnezyum eksikliği gibi hastalıkların doğru tespit edilmesi %95 olarak belirtiliyor.

Khirade ve arkadaşları [22]. Belirli hastalıklara odaklanarak bir yöntem önerilmiş. Önerdikleri çözümde, bir yaprağın enfekte olmuş kısımlarını tanımlamak için sınır ve nokta tespiti. Görüntü segmentasyonu için K-means kullanılmış, geri yayılım öğrenmeli yapay sinir ağı (YSA) ile sınıflandırma uygulanmıştır. Görüntülerdeki gürültünün kaldırılması için ön işleme yapılmış-yöntemleri ekle.

Arakeri ve arkadaşlarının yaptığı çalışmada [23] dört adım var; İlk olarak RGB yaprak görüntüsü için ön işleme yapılıyor ve K-means kullanılarak kümelere ayrılıyor. İkinci aşamada, yaprak içindeki gereksiz kısımlar (yeşil alan)-ortak olanlar çıkarılıyor. Üçüncü aşamada, bölümlere ayrılmış virüslü nesne için doku özelliklerini hesaplanıyor. Son aşamada, çıkarılan öznitelikler önceden eğitilmiş bir sinir ağından geçirilerek sonuca ulaşıyor. K-means yöntemi kullanılarak yapılan çalışmanın test edilmiş olan veri setinde başarılı sonuçlar verdiği belirtiliyor.

Tigadi ve arkadaşları [24] hastalık tespiti için ANN sınıflandırma tekniklerini kullandıkları çalışmada RGB görüntüsü için ön işleme yapılıyor, ardından eşik değeri kullanılarak gereksiz kısım kaldırılarak görüntü bağlantılı bileşen etiketlemesi ile segmentlere ayrılıyor ve en son kullanılan ANN sınıflandırmasında faydalı segmentler çıkarılıyor.

Sladojevic ve arkadaşları [25] bitki yapraklarını çevrelerinden ayırt etme problemini inceledikleri çalışmalarını CNN ile yaprak görüntüsü sınıflandırmasına dayanmaktadır. Model on üç farklı bitki hastalığını tanıyor. Modelin doğruluk oranı %96,3 olarak belirtilmiştir.

Megha ve arkadaşları [26] yaprakların renk, şekil ve doku özellikleri kullanılarak, yaprak hastalıkları için içerik tabanlı görüntü alımının analizi işlemini gerçekleştiren bir uygulama önermişler. Çalışmada, soya fasulyesinin hastalıklı yapraklarının alınması için geliştirilmiş uygulamanın yüksek başarı oranına sahip olduğu belirtiliyor.

Sing ve arkadaşlarının önerdiği çalışmada [27] yakalanan görüntü üzüm yaprağı, yeniden boyutlandırmak için önce ön işleme yapılıyor ve ardından segmentasyon kullanılarak Hue-Saturation-Intensity(HSI) formatına dönüştürme işlemi yapılıyor. Temelde 2 prensip var: Süreksizlik ve benzerlik. Süreksizlik, yaprakların doku, renk, yoğunluk vb. gibi farklı özelliklere sahip bölgeleri çıkarıyor; benzerlik, görüntü piksellerini önceden tanımlanmış filtreyle gruplara ayırıyor. Çam ağacı örnekleri üzerinde yapılan çalışmada, görüntü segmentasyonu için genetik algoritma (GA) kullanmışlar ve K-means ve destek vektör makinesi (SVM) kullanılan çalışmada genetik algoritmanın diğerlerine oranla daha düşük performans verdiği gözlemlenmiştir. Çalışmada kullanılan veri setinin bu sonuçta etkili olduğu belirtilmiştir.

Patil ve arkadaşları [28] hastalığın tanımlanması için önerdikleri çalışmada; görüntü elde etme, ön işleme, görüntü segmentasyonu, özellik çıkarma, tespit ve sınıflandırma işlemlerini uygulamışlardır. Pamuk yaprağı üzerinde yapılan çalışmada K-means kümeleme algoritması ve SVM kullanılmıştır. Elde edilen sonuçların başarı oranının yüksek olduğu belirtilmiştir.

Öztürk ve arkadaşları [29] yaprak görüntülerinin segmentasyonu için hibrit bir sinir ağı önerdikleri çalışmalarında, dört renk bileşeni kullanılarak otomatik segmentasyon işlemi gerçekleştiriyorlar. RGB görüntü HSV, XYZ ve YIQ renk katmanlarına dönüştürülüyor ve öznitelik matrisi için. B, S, Z ve I bileşenleri kullanılıyor. Yapay sinir ağı gri kurt algoritması optimize edildiği çalışmada duyarlılık, özgüllük ve doğruluk açısından başarılı sonuçlar elde edilmiştir.

Salgadoe ve arkadaşları [30] çalışmalarında avokado ağaçlarının köklerini çürüten “phytophthora” hastalığını görüntü işleme ile analiz ettikleri çalışmada, ağaçların yakınında bulunan çalılar üzerinden görüntü işleme yapılıyor. Canny kenar tespiti ve Otsu yöntemlerinin kullanıldığı çalışmada toplam 80 çalı var ve RGB görüntüler için akıllı telefon kullanılmıştır.

Abrham ve arkadaşları [31] kahve bitkisi üzerinde yaptıkları çalışmada, “kahve yaprağı pası (CLR), kahve meyvesi hastalığı (CBD) ve kahve solgunluğu hastalığı (CWD)” bu üç hastalığa odaklanılmış. Hastalıkları tanıma tekniği olarak geri yayımlı yapay sinir ağı (BPNN) kullanılmış, görüntü segmentasyonu için K-means tercih edilmiş. İlk aşamada kahve bitkisi hastalıkları sisteme girdi olarak verildikten sonra, gürültüyü azaltmak için medyan filtreleme ile ön işleme yapılan çalışmanın doğruluk oranı %94,5.

Sivakamasundari ve arkadaşı [32] elma yapraklarındaki hastalıkların sınıflandırılması için ucuz ve hızlı bir çözüm önerisi olarak SVM ve K-means kullanımını önerdikleri çalışmalarında, alternaria, elma kabuğu, sedir pası hastalıklarının tespitinde doğruluğun yüksek olduğu sonucuna ulaşmışlardır. Bu nedenle gelecekte aynı sistem diğer bitki türlerini test etmek için kullanılabilir.

Sun ve arkadaşları [33] çoklu doğrusal regresyona dayalı görüntü tanıma sistemi sunmuşlardır. Görüntü segmentasyonu için, eşik değerini otomatik olarak hesaplayan geliştirilmiş bir histogram segmentasyon yöntemi önerilmiştir. Doğruluğu artırmak için renkli görüntü işleme bu sistemle birleştirilip, tanımda çoklu doğrusal regresyon ve görüntü öznitelik çıkarımı kullanılmıştır.

Ubbens ve arkadaşları [34] CNN ile yaprak sayma performansını artırmak için bilgisayar tarafından oluşturulan arabidopsis sukulent modelini kullanarak bilgisayar ortamında bu bitkiinin fenotipi çıkarılmıştır. Sadece bilgisayar ortamında üretilmiş olan bitki görüntüleri ile eğitilmiş olan CNN, gerçek bitki görüntülerindeki yaprakları saymada başarılı olmuştur. Bu çalışma 3D modellerin sinir ağı eğitimde başarılı sonuçlar verdiğini göstermektedir.

Sunny ve arkadaşları [35] narenciyeler üzerine yaptıkları çalışmada histogram eşitleme ve SVM kullanarak narenciye kanseri hastalığına odaklanmışlar. Görüntüler yüksek çözünürlüklü dijital kamera ile alınmış ve 100 örnek kullanılmıştır. Kullanılan yöntemin kanser hastalığını ayırt etmek için iyi tahmin oranı var.

Krishnan ve arkadaşları [36] bitki yaprak hastalıklarının otomatik tespiti ve sınıflandırılması için genetik algoritmanın kullanıldığı bir yöntem önermişlerdir. Önerilen algoritma muz, fasulye, jackfruit, limon, mango, patates, domates ve sapota yapraklarında test edilmiş. Çalışma sonucunda elde edilen bulgular bu çalışmanın kullanımını öneriyor.

Hari ve arkadaşlarının yaptığı çalışmada [37] sağlıklı ve hastalıklı bitki yapraklarını analiz etmek CNN kullanılmıştır. Mısır, üzüm, elma ve domates yaprakları kullanılan çalışmada önerilen yöntemin, bazı sınırlamalarla birlikte bitki yaprak hastalıklarını tespit etme yeteneği ile iyi bir potansiyel olduğu belirtilmektedir.

Halder ve arkadaşlarının yaptığı çalışmada [38] yaprak hastalıklarının tanımlanması ve sınıflandırılması için klasik sinir ağı algoritmasını kullanılmış. Öznitelik çıkarma işlemi için ortak özelliklere sahip tohum noktalarının aranması ve gruplandırılmasıyla ağın verimliliği ölçülmüştür. Önerilen yöntem yaprak hastalıklarının tanımlanması ve sınıflandırılmasında yüksek doğruluk sağlayarak tarım sektörüne yardımcı olmaktadır.

BÖLÜM 3

TEMEL KAVRAMLAR

Teknolojinin ilerlemesi ve gelişmesi ile birlikte yapay zekâ kavramı gittikçe önem kazanmıştır. Her alanda kullanımı yaygınlaşan bu yeni teknoloji, insanların çok uzun süre zarflarında yapabildikleri işleri daha kısa sürelerde daha güvenilir sonuçlarla başarabilmektedir. Önceki bölümde de bahsedildiği üzere tarım alanındaki çalışmalarda kullanılan yapay zekâ destekli çözümlerin, zaman tasarrufu sağlamak ile birlikte toprağın verimini arttığı, işleri büyük ölçüde kolaylaştırdığı da görülmektedir. Bu bölümde çalışmada kullanılan yöntemin daha kolay anlaşılması için yapay zekaya dair temel kavramlar hakkında genel bilgiler verilmiştir. Şekil 3.1’de belirtilen genelden özele doğru bir sıralama ile sırasıyla yapay zekâ, makine öğrenmesi ve derin öğrenme başlıkları detaylı bir şekilde açıklanmıştır. İlk olarak yapay zekanın ortaya çıkışı, yaygınlaşması, genel kullanım alanları ve kullanılan yöntemler hakkında bilgiler verilmiştir. Daha sonrasında makine öğrenmesinin tanımı, yöntemleri, algoritmaları açıklanmıştır. Sonrasında yapay sinir ağları hakkında ayrıntılı bilgiler verilmiş, bu bağlamda kullanılan algoritmalar hakkında detaylı bilgiler verilmiştir. Çalışmada kullanılmış olan CNN yöntemi bu kısımda ayrıntılı bir şekilde belirtilmiştir. Son olarak derin öğrenme kavramı üzerinde durularak kullanılan teknikler hakkında bilgi verilmiştir.



Şekil 3.1. Yapay zekâ-makine öğrenmesi-derin öğrenme şeması.

3.1. YAPAY ZEKÂ

Yapay zekâ, insan zekasını taklit eden bilgisayar programlarını kullanarak akıllı makineler oluşturulan bir bilim dalıdır. Temelde insanın yapabileceği işleri taklit ederek sonuca ulaşan bir sistem olan yapay zekâ, verilen görevlerin en ideal performansta çalışması için büyük verileri girdi olarak alabilen bir sistemdir.

1940’larda dijital bilgisayarların geliştirilmesiyle makinelerle satranç oynamak, matematiksel modelleri kanıtlamak gibi karmaşık görevlerin üzerinden gelebildiği görülmüştür. Yapay zekâ terimi isim olarak ilk önce 1956 yılında Dartmouth Konferansında McCarthy, Minsky, Shannon ve Rochester tarafından bahsedilmiş olsa da Turing 1950 yılında yayınladığı makalesinde dijital bilgisayar kavramından ve Turing Machine ve makinelerin bir insanın yapabildiği tüm işleri yapabileceği olasılığı ile adı konulmamış bir şekilde yapay zekâ kavramından ve üzerinde çalışılması gereken bir konu olduğundan bahsetmiştir [39]. McCarthy ve arkadaşları konferans sonucunda yayınladıkları bildiride yapay zekâ ve parametreleri üzerinde 2 ay boyunca çalışacak 10 kişilik ekip kurulmasını teklif etmişlerdir [40]. Bu proje hem alanın genel kavramları üzerinde kabul görmüş bir uygulama, terim olmamasından hem de katılımcıların kendi projelerine yoğunlaşması sebebiyle beklentilerin altında kalsa da yeni ortaya atılan kavram üzerinde çeşitli hükümetlerin de desteği ile çalışmalar yapılmaya başlandı. Ancak yapay zekâ ve bu kavram üzerindeki çalışmalarını eleştiren birkaç rapor sonucunda “AI Winter- Yapay zekâ kışı” olarak bilinen dönem başladı [41, 42].

1950’li yıllardaki ilk çalışmalar daha çok matematiksel problem çözme gibi sembolik yöntemler üzerindedir. 1960’larda ABD savunma bakanlığı bu yeni teknoloji üzerinde çeşitli çalışmalar yaparak olası durumlarda insan hareketlerini tahmin edebilecek sistemler üzerinde çalışmaya başladı. Defense Advanced Research Projects Agency (DARPA) 1970’li yıllarda sokak haritalama projesi ile Global Positioning System-GPS sisteminin temellerini atmış 2003 yılında akıllı kişisel asistanlar üreterek alanında bir ilke atmıştır. 1997 yılında IBM’in Deep Blue isimli bilgisayarı Garry Kasparov’u yenerek bir satranç şampiyonunu yenen ilk bilgisayar olarak tarihe geçti.

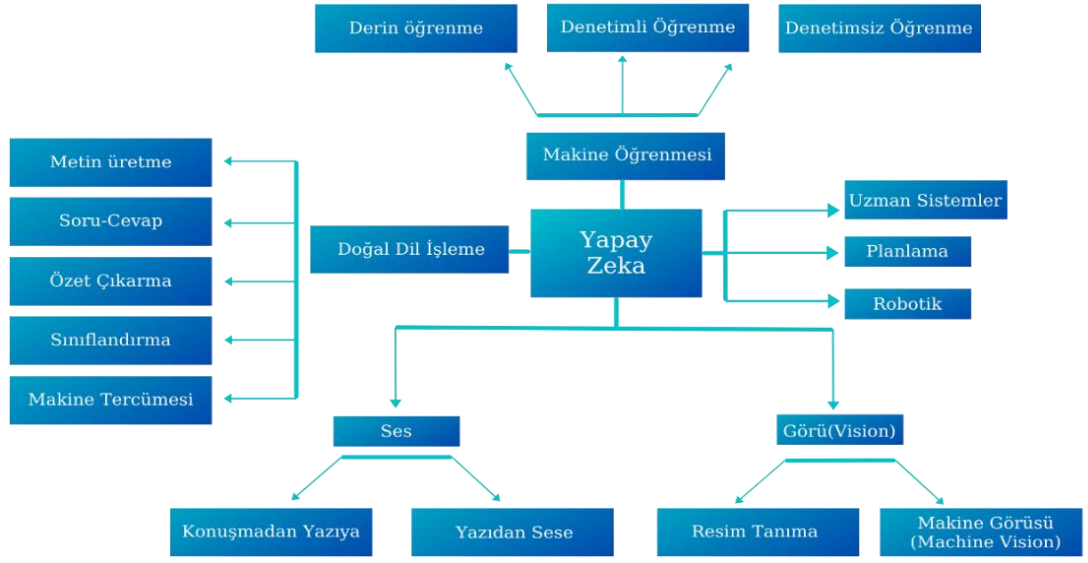
Yapılan bu ilk çalışmalar, şu an her bilgisayar bulunan akıllı arama, sesli komut özelliği gibi birçok uygulamaya öncü olmuştur [41, 42].

Teknoloji çağında verilerin gitgide artması analiz sürecinde yapay zekâ teknolojilerinin kullanılmasını bir gereklilik haline getirdi. Yapay zekanın normal bir insanın kısıtlı sürede tamamlayamadığı işleri daha kısa sürelerde daha doğru sonuçlarla tamamladığı birçok uygulamada performans, üretkenlik ve verimin yükseldiği de gözlemlenmiştir.

Tarım, sağlık, finans gibi birçok sektör ve endüstriye uyarlanabilen çözümler sunması yapay zekâ teknolojisinin uygulama alanı yelpazesini ciddi derecede genişletmiştir. Sağlık sektöründe ilaç dozajı ayarlanması, ameliyathanelerdeki cerrahi prosedürlerin test edilmesi gibi uygulamalarda yapay zekâ çözümlerinden yararlanılmaktadır.

Otomotiv sektöründe kendi kendine gidebilen – otonom araçlarda çeşitli sensör verilerinin anlamlandırılmasında yine yapay zekâ çözümleri karşımıza çıkmaktadır. Bankacılık sektöründe olağan dışı hesap hareketlerinin saptanarak olası dolandırıcılık işlemlerinin önlenmesinde yapay zekadan faydalanılmaktadır [41].

Görüntü işleme, doğal dil işleme, optimizasyon gibi çeşitli alanlarda özelleştirilmiş yapay zekâ metotları kullanılmaktadır. Şekil 3.2’de yapay zekânın temel alt alanları ve kullanım örnekleri verilmiştir [41, 43].



Şekil 3.2. Yapay zekânın temel alt alanları.

3.2. MAKİNE ÖĞRENMESİ

Makine öğrenmesi (Machine Learning-ML), makinenin zekasını-anlama yeteneğini geliştirmek için matematiksel modellere dayanan yapay zekanın alt dalıdır. Makine öğrenmesi kümeleme, sınıflandırma, regresyon gibi belirli görevler için klasik algoritmalar içerir. Temel anlamda bu makine öğrenmesi 3 aşamadan oluşur: karar aşaması, hata fonksiyonu ve modelin optimizasyon süreci [41].

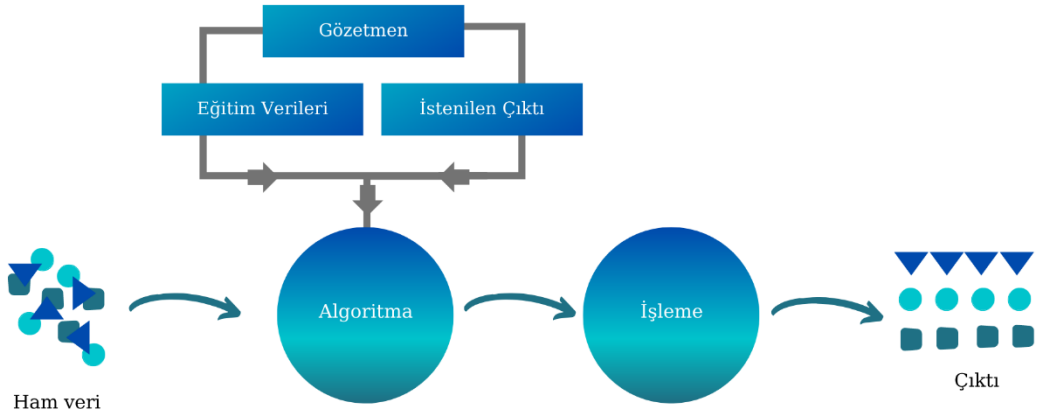
ML varlıkları, bu varlıkların birbirleriyle ilişkilerini anlamak için eğitim verilerinden oluşan girdileri alır. Makine öğrenimi süreci test sonuçlarından, örneklerden, doğrudan deneyimlerden veya talimatlardan oluşan veriler ile başlar. Daha sonra verilen girdiler arasında ortak kalıpları arayarak çıkarımda bulunmaya çalışır. Burada öncelikli hedef herhangi bir dış müdahale olmadan bilgisayarın veriyi öğrenmesini ve anlamlandırmasını sağlamaktır. Bu işlem makine öğrenmesinin “eğitim” sürecidir.

ML metodunun tahmin ettiği sonuç ile gerçek sonuç-temel doğruluk değeri arasındaki farkın minimum düzeyde olması istenir. Bu sebeple kayıp veya amaç fonksiyonu olarak adlandırılan bir “hata fonksiyonu” tanımlanır. Bu fonksiyon modelin tahminini değerlendirerek modelin doğruluğunu hesaplamak için bir karşılaştırma yapar.

Eğer modelin eğitim setinde daha iyi uyduğu veri noktaları-eşik değerleri varsa algoritma bu eşik değerlerine ulaşana kadar kendi kendisine güncelleme yaparak optimizasyon sürecini tamamlayacaktır. Bu sebeple makine öğreniminin başarısında tercih edilen algoritmalar ve kullanılacak olan eğitim verileri kritik öneme sahiptir. Eğitim metotları 4 ana başlıkta değerlendirilir: denetimli öğrenme, denetimsiz öğrenme, yarı-denetimli öğrenme ve takviyeli/pekiştirmeli öğrenme [41].

3.2.1. Denetimli Öğrenme

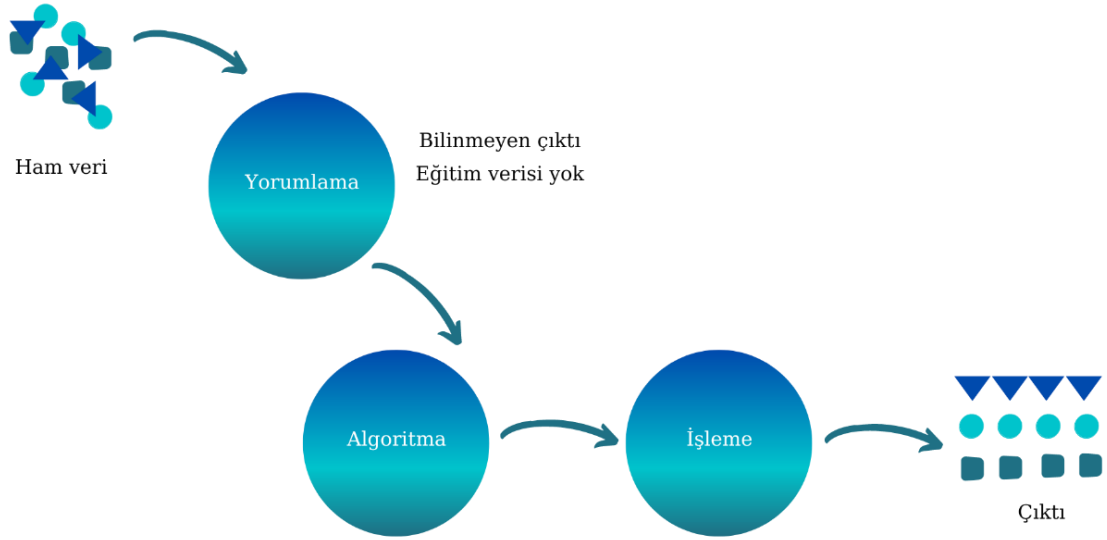
Çalışma mantığı Şekil 3.3'te belirtilen, denetimli öğrenme algoritmaları, daha öncesinde etiketlenmiş veya sınıflandırılmış eğitim veri setini analiz ederek sonuç değerini tahmin etmeye çalışır. Algoritma yeterli eğitimden sonra yeni girdi için anlamlı sonuçlar üretebilir. Regresyon ve sınıflandırma algoritmaları bu bağlamda değerlendirilebilir. Doğrusal regresyon, lojistik regresyon, CART, naive bayes, KNN, K-means, minimum spanning tree denetimli öğrenme algoritma örnekleridir [41].



Şekil 3.3. Denetimli öğrenme.

3.2.2. Denetimsiz Öğrenme

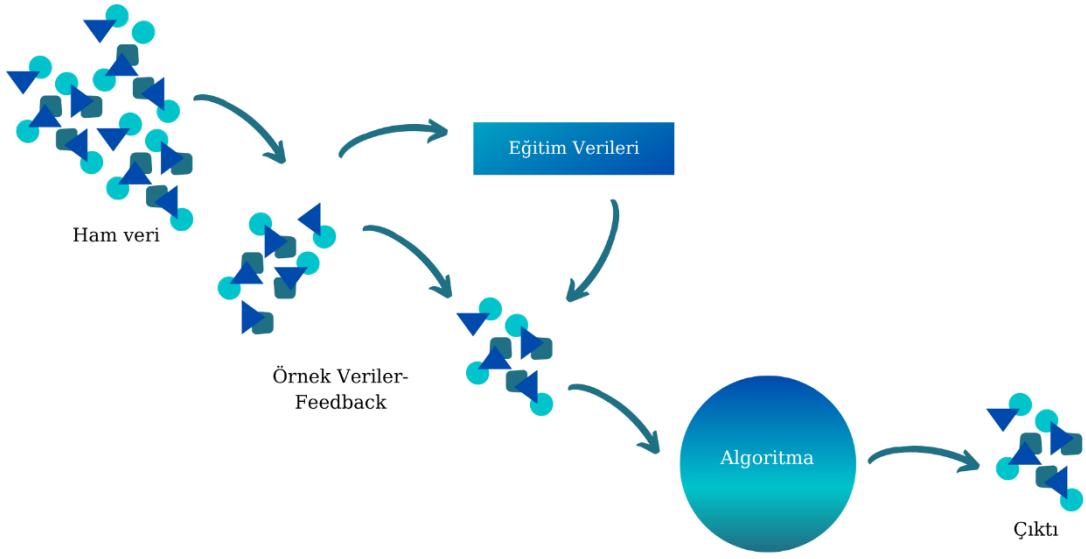
Çalışma mantığı Şekil 3.4'te gösterilen denetimsiz öğrenme algoritmaları etiketlenmemiş ham veri setlerindeki bağlantıları anlamak için kullanılır. Algoritma hiçbir zaman doğru çıktıyı kesin olarak vermez, çıktının ne olması gerektiğine dair veri setinden tahminde bulunur [41].



Şekil 3.4. Denetimsiz öğrenme.

3.2.3. Yarı-Denetimli Öğrenme

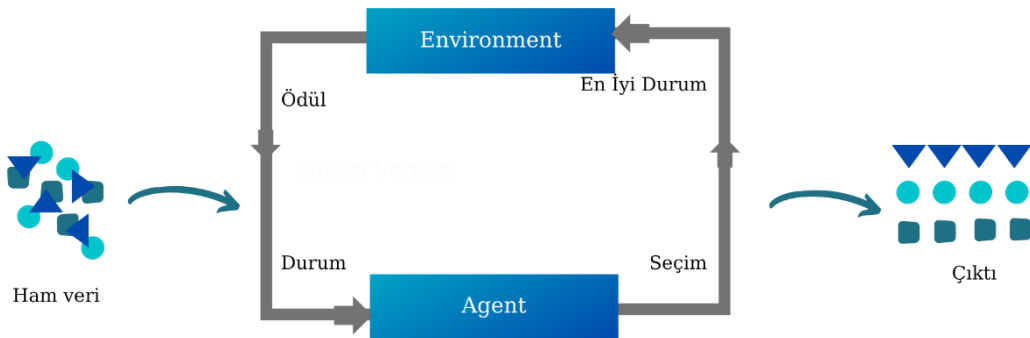
Çalışma mantığı Şekil 3.5'te gösterilen yarı denetimli öğrenme algoritmaları, denetimli ve denetimsiz öğrenmeyi birleştirerek etiketlenmemiş veri setlerinden sonuç çıkartmak için eğitim veri seti olarak daha küçük ama etiketli veri setlerini kullanır [41].



Şekil 3.5. Yarı denetimli öğrenme.

3.2.4. Takviyeli-Pekiştirmeli (Reinforcement) Öğrenme

Çalışma mantığı Şekil 3.6’da gösterilen takviyeli-Pekiştirmeli öğrenme algoritmaları ceza-ödül yöntemi kullanarak öğrenmeye dayanır. Algoritma doğru karar verdiğiğinde ödül verilir bu yöntem algoritmanın performansını üst düzeyde tutmak için ideal davranışın otomatik olarak belirlenmesine yardımcı olur [41].



Şekil 3.6. Takviyeli-pekiştirmeli öğrenme.

3.3. YAPAY SİNİR AĞLARI (YSA)

Makine öğrenmesinin alt dallarından olan yapay sinir ağları derin öğrenme algoritmalarının temelini oluşturur. İnsan beynindeki nöronların birbirine sinyal gönderme şekline esinlenilerek ortaya çıkmış bir yapıdır. Özellikle doğrusal olmayan ilişkileri modellemek için uygun olan YSA tipik olarak konuşma, görme ve kontrol sistemlerindeki nesnelere veya sinyalleri sınıflandırmada ve örüntü tanıma işlemlerinde kullanılırlar [43].

Yapay sinir ağları, bir girdi katmanı, bir veya daha fazla gizli katman ve bir çıktı katmanı içeren katmandan oluşur. Her düğüm diğer bir deyişle yapay nöron belirli bir ağırlık değeriyle diğerine bağlanır. Herhangi bir düğümün çıktısı belirtilen eşik değerinin üzerindeyse, o düğüm etkinleştirilir ve ağın bir sonraki katmanına veri gönderilir. Aksi takdirde, ağın bir sonraki katmanına veri iletilmez [43].

İlk ve en basit sinir ağı, 1958'de Frank Rosenblatt tarafından tanıtılan algılayıcıydı. Tek bir nöron ve esasen sigmoid aktivasyon fonksiyonuna sahip doğrusal bir regresyon modelinden oluşuyordu. O zamandan beri, giderek daha karmaşık sinir ağları keşfedildi ve yüzlerce katman içerebilen günümüzün derin ağlarına yol açtı [43].

Derin öğrenme, birçok katmana sahip sinir ağlarını ifade ederken, yalnızca iki veya üç katmanlı bağlı nöronlara sahip sinir ağları, sığ-shallow sinir ağları olarak da bilinir.

Yaygın olarak kullanılan yapay sinir ağları: İleri beslemeli sinir ağı (feedforward neural network), geri beslemeli sinir ağı (feedback neural network), evrişimli sinir ağı (CNN) başlıkları altında ayrıntılı olarak açıklanacaktır.

3.3.1. İleri Beslemeli Sinir Ağları

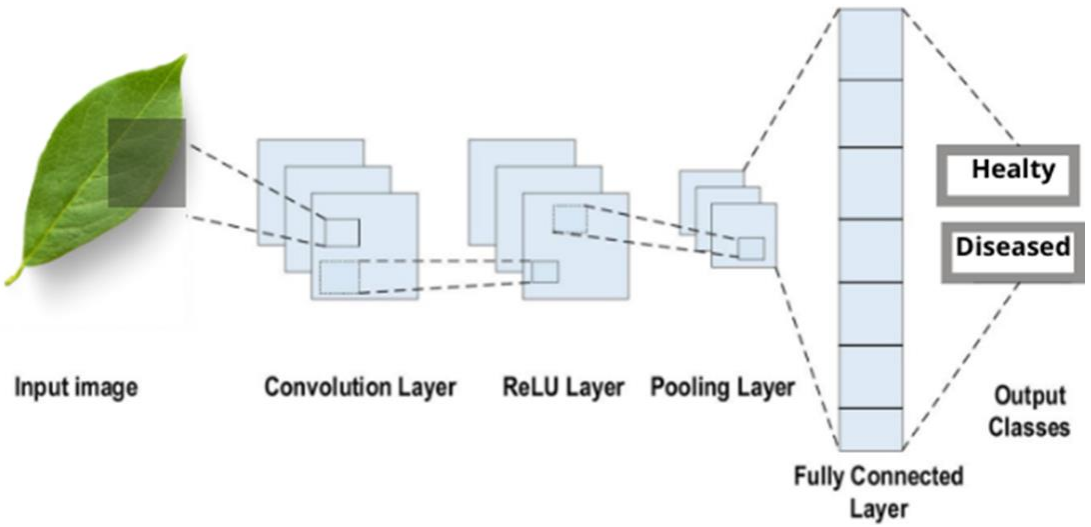
Bir giriş katmanından, bir veya birkaç gizli katmandan ve bir çıkış katmanından (tipik bir sığ sinir ağı) oluşur. Herhangi bir geri bildirim ya da döngü içermezler. Genellikle örüntü oluşturma, tanıma ve sınıflandırma problemlerinde kullanılırlar [43].

3.3.2. Geri Beslemeli Sinir Ağları

Bir giriş katmanından, bir veya birkaç gizli katmandan ve bir çıkış katmanından ve geri besleme döngülerinden oluşur. Bu sayede sinyaller her iki yöne de hareket edebilir, dinamik bir yapıya sahiptir. Bu ağlarda belirli bir denge noktasına ulaşıncaya kadar ağıın yapısı değişmeye devam eder. Bu değişimden dolayı etkileşimli veya tekrarlayan ağlar olarak da adlandırılırlar [43].

3.3.3. Evrişimli Sinir Ağları

Görüntü işlemede yaygın olarak uygulanan ve ağırlıkları paylaşan düğümlerle pencereleri giriş boyunca kaydırır ve özellik haritalarına girdiyi soyutlayan evrişimli katmanlarla karakterize edilen derin sinir ağı mimarisidir. Şekil 3.7’da belirtildiği gibi beş adet ana katmandan oluşur: input, convolutional, pooling, fully-connected ve output katmanları [43].



Şekil 3.7. CNN mimarisi.

3.3.3.1 Convolutional Katmanı

Bu katmanda girdi olarak gelen görüntü bir filtreden geçirilir. Filtrelemeden elde edilen değerlerle öznitelik matrisi oluşturur. Bu matris, kullanılacak olan filtreyi girdi olarak gelen tüm matris üzerinde hareket ettirerek oluşturulur.

Modele renkli bir girdi verilirse her bir renk katmanı için (Kırmızı-Yeşil-Mavi, RGB vb.) belirtilen işlemler ayrı ayrı yapılır.

Konvolüsyon katmanı kullanılmadan görüntülerdeki her piksel için modele bir girdi katmanı eklenebilir ve her giriş için gerekli bağlantılar sağlanabilir. Ancak çok fazla bağlantı ve işlem gücü gerekeceğinden dolayı bu işlemi doğrudan yapmak yerine öznitelik matrisi çıkarılarak daha az bağlantı ile gerçekleştirilebilir. Convolutional katman ile sadece görüntülerdeki gerekli ve önemli özellikler belirlenir. Aynı arka plan veya aynı özellikler gibi fark yaratmayan nitelikler sürece dahil edilmez [41] [43].

3.3.3.2 Pooling Katmanı

Pooling katmanı genellikle oluşturulan öznitelik matrislerine uygulanır. Öznitelik matrisinde pooling için belirlenen boyutlarda matrisler oluşturularak, o matristeki en büyük değer alınarak maksimum veya en düşük değer alınarak minimum pooling uygulanır. Bu katmanda, ağıdaki parametreler ve hesaplama sayısı azaltılarak ağıdaki uyumsuzluk kontrol edilir [41, 43].

3.3.3.3 Fully-Connected Katmanı

Fully-Connected Katmanı, yapay sinir ağına sahip olan kısımdır. Yapay sinir ağları ile öğrenmenin gerçekleştiği katmandır. Bu nedenle, bu katmanda ileriye doğru yayılma ve geriye doğru yayılma gerçekleşir [41, 43].

3.4. DERİN ÖĞRENME

Derin öğrenme, yapay sinir ağlarının büyük miktarda veriden öğrenim yaptığı karmaşık problemlerin çözümü için kullanılan makine öğrenimi alt kümesidir. Büyük miktarda veri ile eğitim, sinir ağındaki nöronları yapılandıran etkidir. Sonuç, bir kez eğitildikten sonra yeni verileri işleyen bir derin öğrenme modelidir. Bu işlemin bir sonucu olarak derin öğrenme modelleri kendi kendilerine yeni özellikler ekleyebilir veya kaldırabilirler. Bu modeller, birden fazla veri kaynağından bilgi alır ve bu verileri insan müdahalesine gerek kalmadan gerçek zamanlı olarak analiz eder [44].

Derin Sinir Ağları (DNN'ler), her katmanın görüntü, ses ve metinden anlam çıkaran temsil ve soyutlama gibi karmaşık işlemleri gerçekleştirebildiği ağ türleridir. Derin yapay sinir ağları gibi derin öğrenme yöntemleri, çok büyük veri kümelerindeki kalıpları ve yapıyı keşfetmek için birden çok işleme katmanı kullanır. Her katman, sonraki katmanların üzerine inşa ettiği verilerden bir kavram öğrenir; seviye ne kadar yüksekse, öğrenilen kavramlar o kadar soyut olur. Derin öğrenme, önceki veri işlemeye bağlı değildir ve özellikleri otomatik olarak çıkarır.

Basit bir örnek kullanmak gerekirse, şekilleri yorumlamakla görevli derin bir sinir ağı, ilk katmandaki basit kenarları tanımayı öğrenecek ve ardından sonraki katmanlarda bu kenarlardan oluşan daha karmaşık şekillerin tanınmasını ekleyecektir. Derin öğrenmeyi oluşturmak için kaç katman gerektiğine dair kesin ve hızlı bir kural yoktur, ancak çoğu çalışmada ikiden fazlasının gerekli olduğunu belirtilmektedir [44].

BÖLÜM 4

MATERYAL VE METOT

4.1. VERİSETİNİN HAZIRLANMASI

Çalışma 11. nesil i7 işlemci, NVIDIA RTX 3050ti sistemlerine sahip kişisel bilgisayar kullanılarak Anaconda 2020.11, Spyder 5 geliştirme ortamlarında Python programlama dili ile gerçekleştirilmiştir. Veri seti hazırlanırken DJI Phantom 3 Advanced insansız hava aracı kullanılmıştır.


Çalışmada üç farklı veri setindeki görüntülerden yararlanılmıştır. 2 veri seti hazır etiketli verilerden oluşurken son veri seti insansız hava aracı kullanılarak tarafımızca elde edilmiş görüntülerden oluşmaktadır. Kullanılan veri setleri ile ilgili ayrıntılı bilgi çizelge 4.1’de ayrıntılı olarak verilmiştir. Veri seti1 PlantVillage, Veri seti 2 “The Plant Pathology Challenge 2020” de kullanılmış olan elma resimlerinden, Veri seti 3 tarafımızca hazırlanmış olan görüntülerden oluşmaktadır.

Çizelge 4.1. Veri setleri başlangıç değerleri.

	Veri seti 1	Veri seti 2	Veri seti 3
Hastalıklı Yaprak Sayısı	17418	1299	5
Sağlıklı Yaprak Sayısı	3221	692	36

İnsansız hava aracından elde edilen görüntü sayısının az ve karışık olmasından dolayı öncesinde elde edilen görüntülere veri çoğullama işlemi uygulanmıştır. Sağa döndürme, sola döndürme, yakınlaştırma, arka plan doldurma, yatay ekseninde döndürme, dikey ekseninde döndürme, parlaklık değiştirme, kırpma yöntemleri kullanılarak veri çoğullama işlemi yapılmıştır. Bu işlemlerden sonra medyan filtresi kullanılarak verilerdeki gürültülerin temizlenmesi işlemi yapılmıştır.

Gürültü temizle işlemini için her veri RGB renk katmanlarına ayrılmış her katmanda gürültü işleme yapılarak sonrasında katmanlar birleştirilerek görüntü elde edilmiştir. Gürültü temizleme işleminin örneği Şekil 4.1’de verilmiştir.




Şekil 4.1. Gürültü temizleme işlemi öncesi(a) ve sonrası(b).

Veri çoğullama ve gürültü temizleme işleminden sonra elde edilen görüntü sayıları çizelge 4.2’de görüntü örnekleri Şekil 4.2’de verilmiştir. Veri setleri %80’e %20 oranında ayrılarak eğitim ve test verileri oluşturulmuştur. Eğitim için ayrılan veri setleri kendi içerisinde yine %80’e %20’ oranında ayrılarak işleme alınmıştır.

Çizelge 4.2. Veri setlerinin veri çoğullama işleminden sonraki değerleri.

	Veri seti 1	Veri seti 2	Veri seti 3
Hastalıklı Yaprak Sayısı	17418	15588	90
Sağlıklı Yaprak Sayısı	3221	8304	432



Şekil 4.2. Veri çoğullama görüntü örnekleri.

4.2. CNN PARAMETRELERİ

CNN modelinde kullanılan parametreler tablo 4.3'te ayrıntılı olarak verilmiştir. Parametrelerin belirlenmesinde kullanılan formüller 4.1 ve 4.2'de listelenmiştir.

$$\text{Convolutional Katmanı} = ((m * n * d) + 1) * k \quad (4.1)$$

$$\text{Fully Connected Katmanı} = ((c * p) + 1) * c \quad (4.2)$$

Çizelge 4.3. CNN Katman-Parametre Listesi.

No	Katman	Aktivasyon Fonksiyonu
L1	Convolutional	ReLu
	Max Pooling	
L2	Convolutional	ReLu
	Max Pooling	
L3	Convolutional	ReLu
	Max Pooling	
L4	Convolutional	ReLu
	Max Pooling	
L5	Fully Connection	ReLu
	Drop-Out	
L6	Fully Connection	
	Softmax	

Accuracy, elde edilen sonucun gerçek sonuca ne kadar yakın olduğu gösteren değerlendirme kriteridir. Doğru sınıflandırılmış olan görüntü sayısının (TP) toplam görüntü sayısına oranı ile hesaplanır. Precision, sonuca ne kadar yaklaşıldığını gösteren kriterdir. Doğru sınıflandırılmış pozitif görüntü sayısının (TP) doğru sınıflandırılmış pozitif ve doğru sınıflandırılmış negatif görüntü sayılarının (FP) toplamına oranı ile hesaplanır. Recall doğru sınıflandırılmış pozitif görüntülerin ne kadarının doğru olarak sınıflandırıldığını gösteren kriterdir. Doğru sınıflandırılmış pozitif görüntü sayısının (TP) doğru sınıflandırılmış pozitif ve yanlış sınıflandırılmış negatif görüntü sayılarının (FN) toplamına oranı ile hesaplanır. Fmeasure modelin doğruluğunu gösteren kriterlerdendir. Precision ve recall değerlerinin harmonik ortalaması hesaplanarak elde edilir.

Sonuçların elde edilmesinde kullanılan accuracy, precision, recall, fmeasure hesaplamalarında kullanılan formüller 4.3, 4.4, 4.5 4.6' da verilmiştir.

$$Accuracy = \frac{\text{Doğru sınıflandırılmış görüntülerin toplamı}(TP)}{\text{Toplam görüntü sayısı}} \quad (4.3)$$

$$Precision = \frac{TP}{TP+FP} \quad (4.4)$$

$$Recall = \frac{TP}{TP+FN} \quad (4.5)$$

$$Fmeasure = \frac{2*Precision*Recall}{Precision+Recall} \quad (4.6)$$

Model oluşturulduktan sonra eğitim için ayrılan veriler ile eğitilmiş ve sonrasında test verileri sisteme girdi olarak verilmiştir.


BÖLÜM 5

BULGULAR


Oluşturulan CNN modelinin 3 veri seti ile eğitilmesi ve sonrasında test verilerinin modele verilmesi ile Çizelge 5.1’de belirtilen sonuçlar elde edilmiştir. Şekil 5.1’de modelin performansını görselleştiren ve özetleyen confusion matrisi verilmiştir. Şekil 5.2’de modelin test ve eğitim verilerinin accuracy-epoch grafiği verilmiştir.

Çizelge 5.1. Sonuçlar.

	Veri seti 1	Veri seti 2	Veri seti 3
Accuracy (%)	98.53	83.2	74.2
Precision (%)	98.32	82.56	72
Recall (%)	98.35	82.6	72
F1-measure (%)	98.33	82.5	72



Şekil 5.1. Confusion matrix.



Şekil 5.2.Eğitim ve test verileri accuracy grafiği.

BÖLÜM 6

SONUÇLAR

Çalışma sonucunda elde edilen bulguların değerlendirilmesi bu bölümde verilmiştir. Tez kapsamında çalışmada hastalık tespitinde kullanılan fotoğrafların kaliteleri düşürülerek geliştirilen CNN modelinde test edildi. Elde edilen sonuçlara göre hastalık tespiti için kullanılmış olan bu yöntemin gerçek zamanlı uygulama olarak geliştirilebilmesi için modelin test edilmesi gerektiğine ancak sabit fotoğraflarda düşük kaliteli verilerde de modelin doğruluk oranının yüksek olduğu sonucuna ulaşıldı. Hazır kullanılan veri setlerinde elde edilen yüksek doğruluk oranları modelin sabit fotoğraflarda başarılı sonuç verdiğini göstermektedir. Tarafımızca hazırlanmış olan veri setinde nispeten düşük oranda başarı olması veri sayısının model için önemli bir kriter olduğunu göstermektedir.

Çalışmada 2 örnek veri seti ve bizim oluşturduğumuz veri seti kullanılmıştır. Bunlar sırasıyla: PlantVillage veri seti, “The Plant Pathology Challenge 2020”de kullanılmış olan veri seti ve DJI Phantom 3 Advanced insansız hava aracını ile elde ettiğimiz verilerden oluşturulan veri setidir. Veri büyütme işlemi uygulanarak veri sayısı artırılmış ve sonrasında verilere gürültü temizleme işlemi uygulanmıştır.

Veri setlerinde PlantVillage veri setinde %98.53, “The Plant Pathology Challenge 2020” veri setinde %83.2, tarafımızca hazırlanmış olan veri setinde %74.2 doğruluk oranları elde edilmiştir. Uygulama Anaconda 2020.11, Spyder 5 geliştirme ortamları kullanılarak Python programlama dilinde yapıldı. Elde edilen sonuçlar modelin hastalık tespiti için kullanılmasının verimli olacağını göstermektedir.

Çalışmadaki kısıtlarımız, insansız hava aracından görüntü elde edilmesi, kullanılan bilgisayar limitleri ve elde edilen veri örneklerindeki bozulmalardır. Bundan sonraki çalışmalarda veri örneklerinin artırılması başarı oranını arttıracaktır.

Verilerdeki bozulmaların önüne geçebilmek adına gerçek zamanlı uygulamalar geliştirilebilir. Tarımda verimliliği ve sürekliliği arttırmak için gerçek zamanlı olarak uygulanması için algoritma performansında iyileştirmeler yapılabilir.

KAYNAKLAR

1. Kaur, I., Aggarwal, G., and Verma, A. "Detection and Classification of Disease Affected Region of Plant Leaves using Image Processing Technique", *Indian Journal of Science and Technology*, 9(48). (2016).
2. Dhingra, G., Kumar, V., and Joshi, H. D. "Study of digital image processing techniques for leaf disease detection and classification", *Multimedia Tools and Applications*, 77(15), 19951–20000. (2018).
3. Mishra, B., Nema, S., Lambert, M., and Nema, S. "Recent technologies of leaf disease detection using image processing approach-A review", *In Proceedings of 2017 International Conference on Innovations in Information, Embedded and Communication Systems, ICIIECS 2017 (Vol. 2018-January, pp. 1–5). Institute of Electrical and Electronics Engineers Inc.* (2018).
4. Singh, V. "Sunflower leaf diseases detection using image segmentation based on particle swarm optimization", *Artificial Intelligence in Agriculture*, 3, 62–68. (2019).
5. Patil, P. C., Patil, D. D., and Subramaniam, P. P. "Detection and Identification of Rice Leaf Diseases using Multiclass SVM", *International Research Journal of Engineering and Technology (IRJET)*, 6673–6677. (2020).
6. Yadav, R., Kumar Rana, Y., and Nagpal, S. "Plant leaf disease detection and classification using particle swarm optimization", *In Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)* (Vol. 11407 LNCS, pp. 294–306). Springer Verlag. (2019).
7. Ahmad, I., Hamid, M., Yousaf, S., Shah, S. T., and Ahmad, M. O. "Optimizing pretrained convolutional neural networks for tomato leaf disease detection", *Complexity*, (2020).
8. Kumar, S., Sharma, B., Sharma, V. K., Sharma, H., and Bansal, J. C. "Plant leaf disease identification using exponential spider monkey optimization", *Sustainable Computing: Informatics and Systems*, 28. (2020).
9. Tsouros, D. C., Bibi, S., and Sarigiannidis, P. G. "A review on UAV-based applications for precision agriculture", *Information*, 10(11), 349. (2019).

10. Radoglou-Grammatikis, P., Sarigiannidis, P., Lagkas, T., and Moscholios, I. "A compilation of UAV applications for precision agriculture.", *Computer Networks*, 172, 107148. (2020).
11. Wang, L., and Rajan, D. "An image similarity descriptor for classification tasks.", *Journal of Visual Communication and Image Representation*, 71. (2020).
12. Albayati, J. S. H., and Üstündağ, B. B." Evolutionary feature optimization for plant leaf disease detection by deep neural networks.", *International Journal of Computational Intelligence Systems*, 13(1), 12–23. (2020).
13. Andrushia, A. D., and Patricia, A. T. "Artificial bee colony optimization (ABC) for grape leaves disease detection.", *Evolving Systems*, 11(1), 105–117. (2020).
14. Yadhav, S. Y., Senthilkumar, T., Jayanthi, S., and Kovilpillai, J. J. A. "Plant Disease Detection and Classification using CNN Model with Optimized Activation Function.", *In Proceedings of the International Conference on Electronics and Sustainable Communication Systems*, ICESC 2020 (pp. 564–569). Institute of Electrical and Electronics Engineers Inc. (2020).
15. Kerkech, M., Hafiane, A., and Canals, R. "Vine disease detection in UAV multispectral images using optimized image registration and deep learning segmentation approach.", *Computers and Electronics in Agriculture*, 174. (2020).
16. Waheed, A., Goyal, M., Gupta, D., Khanna, A., Hassanien, A. E., and Pandey, H. M. "An optimized dense convolutional neural network model for disease recognition and classification in corn leaf.", *Computers and Electronics in Agriculture*, 175. (2020).
17. Nakshmi, J. V. N., Hemanth, K. S., and Bharath, J. "Optimizing Quality and Outputs by Improving Variable Rate Prescriptions in Agriculture using UAVs", *In Procedia Computer Science* (Vol. 167, pp. 1981–1990). Elsevier B.V. (2020).
18. Nandhini, S., and Ashokkumar, K. "Improved crossover based monarch butterfly optimization for tomato leaf disease classification using convolutional neural network.", *Multimedia Tools and Applications*, 80(12), 18583–18610. (2021).
19. Nalini, S., Krishnaraj, N., Jayasankar, T., Vinothkumar, K., Britto, A. S. F., Subramaniam, K., and Bharatiraja, C. "Paddy Leaf Disease Detection Using an Optimized Deep Neural Network.", *Computers, Materials and Continua*, 68(1), 1117–1128. (2021).
20. León-Rueda, W. A., León, C., Caro, S. G., and Ramírez-Gil, J. G. "Identification of diseases and physiological disorders in potato via

- multispectral drone imagery using machine learning tools.”, *Tropical Plant Pathology*. (2021).
21. Gulhane, V. A., and Kolekar, M. H. “Diagnosis of diseases on cotton leaves using principal component analysis classifier”, *Annual IEEE India Conference (INDICON)* (pp. 1-5). IEEE. (2014).
 22. Khirade, S. D., and Patil, A. B. “Plant disease detection using image processing”, *International conference on computing communication control and automation* (pp. 768-771). IEEE. (2015).
 23. Arakeri, M. P., Arun, M., and Padmini, R. K. “Analysis of late blight disease in tomato leaf using image processing techniques.”, *International Journal of Engineering and Manufacturing*, 4, 12-22. (2015).
 24. Tigadi, B., and Sharma, B. “Banana Plant Disease Detection and Grading Using Image Processing”, *International Journal of Engineering Science and Computing* (2016).
 25. Sladojevic, S., Arsenovic, M., Anderla, A., Culibrk, D., and Stefanovic, D. “Deep neural networks based recognition of plant diseases by leaf image classification.”, *Computational intelligence and neuroscience*, (2016).
 26. Megha, S.V., Niveditha, R., Sowmyashree, N., and Vidhya, K.A. “Image Processing System for Plant Disease Identification by Using FCM-Clustering Technique.”, *International Journal of Advance Research, Ideas and Innovations in Technology*. (2017).
 27. Singh, V., and Misra, A. K. “Detection of plant leaf diseases using image segmentation and soft computing techniques”, *Information processing in Agriculture*, 4(1), 41-49. (2017).
 28. Patil, J. K., and Kumar, R. “Analysis of content based image retrieval for plant leaf diseases using color, shape and texture features”, *Engineering in agriculture, environment and food*, 10(2), 69-78. (2017).
 29. Ozturk, S., and Akdemir, B. “Automatic leaf segmentation using grey wolf optimizer based neural network.”, *Electronics* (pp. 1-6). IEEE. (2017).
 30. Salgadoe, A. S. A., Robson, A. J., Lamb, D. W., Dann, E. K., and Searle, C. “Quantifying the severity of phytophthora root rot disease in avocado trees using image analysis”, *Remote Sensing*, 10(2), 226. (2018).
 31. Abrham Debasu Mengistu, Seffi Gebeyehu Mengistu, and Dagnachew Melesew. “An Automatic Coffee Plant Diseases Identification Using Hybrid Approaches of Image Processing and Decision Tree”, *Indonesian Journal of Electrical Engineering and Computer Science*, 9(3), 806–811. (2018).

32. Sivakamasundari, G., and Seenivasagam, V. "Classification of leaf diseases in apple using support vector machine", *International Journal of Advanced Research in Computer Science*, 9(1). (2018).
33. Sun, G., Jia, X., and Geng, T. "Plant diseases recognition based on image processing technology", *Journal of Electrical and Computer Engineering*, 2018. (2018).
34. Ubbens, J., Cieslak, M., Prusinkiewicz, P., and Stavness, I. "The use of plant models in deep learning: an application to leaf counting in rosette plants", *Plant methods*, 14(1), 1-10. (2018).
35. Sunny, S., and Gandhi, M. I. "An efficient citrus canker detection method based on contrast limited adaptive histogram equalization enhancement", *Int. J. Appl. Eng. Res*, 13(1), 809-815. (2018).
36. Krishnan, V.L., and Balaji, G. "Identification And Classification Of Plant Leaf Diseases Using Neural Networks", *International Journal Of Engineering Development And Research* (2019).
37. Hari, S. S., Sivakumar, M., Renuga, P., and Suriya, S. "Detection of plant disease by leaf image using convolutional neural network", *International Conference on Vision Towards Emerging Trends in Communication and Networking (ViTECoN)* (pp. 1-5). IEEE. (2019).
38. Halder, M., Sarkar, A., and Bahar, H. "Plant disease detection by image processing: a literature review", *image*", 1, 3. (2019).
39. Hoffmann, C. H. "Is AI intelligent? An assessment of artificial intelligence, 70 years after Turing", *Technology in Society*, 68, 101893. (2022).
40. Turing, A. M. "Mind", *Mind*, 59(236), 433-460. (1950).
41. McCarthy, J., Minsky, M., Rochester, N., and Shannon, C. L. "The dartmouth summer research project on artificial intelligence". *Artificial intelligence: past, present, and future*. (1956).
42. Yılmaz, D. Ö. Ü. A., Yayın, K. "Yapay Zekâ." *Kodlab Yayın Dağıtım Yazılım Ltd. Şti..* (2021).
43. McCarthy, J. Defense Advanced Research Projects Agency.
44. Öztemel, E. "Yapay sinir ağları". *PapatyaYayıncılık*, Istanbul. (2003).
45. Şeker, A., Diri, B., anved Balık, H. H. "Derin öğrenme yöntemleri ve uygulamaları hakkında bir inceleme", *Gazi Mühendislik Bilimleri Dergisi*, 3(3), 47-64. (2017).

ÖZGEÇMİŞ

Betül KARAOĞLAN ilk, orta ve lise öğrenimini Gaziantep'te tamamladı. 2014 yılında Dokuz Eylül Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği Bölümü'nde öğrenime başlayıp 2019 yılında mezun oldu. 2020 yılında Karabük Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik Elektronik Mühendisliği Anabilim Dalı'nda yüksek lisans eğitimine başladı. 2021 yılında Karabük Üniversitesi'nde araştırma görevlisi olarak göreve başladı ve halen aynı kurumda çalışmaya devam etmektedir.