



**T.C.
YOZGAT BOZOK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ELEKTRİK – ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI**

**GIDADA TAĞŞIŞ TESPİTİ İÇİN GÖRÜNTÜ İŞLEME VE
YAPAY ZEKA YAKLAŞIMLARI: ANTEP FISTIĞI ÖRNEĞİ**

AYŞE TUNCEL ÇİFTÇİ

YÜKSEK LİSANS TEZİ

**Danışman: Dr. Öğr. Üyesi Tolga HAYIT
İkinci Danışman: Dr. Öğr. Üyesi Fatma HAYIT**

HAZİRAN – 2024

YOZGAT

T.C.
YOZGAT BOZOK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ELEKTRİK – ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

GIDADA TAĞŞIŞ TESPİTİ İÇİN GÖRÜNTÜ İŞLEME VE
YAPAY ZEKA YAKLAŞIMLARI: ANTEP FISTIĞI ÖRNEĞİ

AYŞE TUNCEL ÇİFTÇİ

YÜKSEK LİSANS TEZİ

Danışman: Dr. Öğr. Üyesi Tolga HAYIT

İkinci Danışman: Dr. Öğr. Üyesi Fatma HAYIT

HAZİRAN – 2024

YOZGAT



YOZGAT BOZOK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
LİSANSÜSTÜ TEZ ONAY FORMU

T.C.

YOZGAT BOZOK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

Enstitümüzün Elektrik – Elektronik Mühendisliği Anabilim Dalı Tezli Yüksek Lisans Programı öğrencisi Ayşe TUNCEL ÇİFTÇİ'nin hazırladığı “**Gıdada Tağşiş Tespiti için Görüntü İşleme ve Yapay Zeka Yaklaşımları: Antep Fıstığı Örneği**” başlıklı tezi ile ilgili tez savunma sınavı, Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliği'nin ilgili maddeleri gereğince 14/06/2024 Cuma günü saat 15:00'da yapılmış, tezin onayına oy birliği/oy çokluğu ile karar verilmiştir.

Başkan : Dr. Öğr. Üyesi Tolga HAYIT

(Danışman)

Jüri Üyesi : Doç. Dr. Mehmet BAKIR

Jüri Üyesi : Doç. Dr. Hakan KÖR

İkinci Danışman : Dr. Öğr. Üyesi Fatma HAYIT

ONAY:

Bu tezin kabulü, Enstitü Yönetim Kurulu'nun/...../..... tarih ve sayılı Enstitü Yönetim Kurulu Kararı ile onaylanmıştır.

...../...../.....

Prof. Dr. Ümit BUDAK

Lisansüstü Eğitim Enstitüsü Müdürü

TEZ BEYANI

Tez yazım kurallarına uygun olarak hazırlanan bu tezin yazılmasında bilimsel ahlak kurallarına uyulduğunu, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduğunu, tezin içerdığı yenilik ve sonuçların başka bir yerden alınmadığını, kullanılan verilerde herhangi bir tahrifat yapılmadığını, tezin herhangi bir kısmının bu üniversite veya başka bir üniversitedeki başka bir tez çalışması olarak sunulmadığını beyan eder, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğini beyan ederim.

Ayşe TUNCEL ÇİFTÇİ

...../...../.....

ÖN SÖZ

Yüksek lisans eğitimim süresince bilgi ve birikimiyle yol gösteren, desteğini esirgemeyen danışmanım Sayın Dr. Öğr. Üyesi Tolga HAYIT'a, uzman bilgisine başvurduğum çalışmamın gelişimine katkıda bulunan ikinci danışmanım Sayın Dr. Öğr. Üyesi Fatma HAYIT'a, yüksek lisans eğitimime başlamaya beni teşvik eden ve hiçbir zaman desteklerini esirgemeyen yol arkadaşım Canan AKÇA ERTÜRK'e, çalışma hayatımda lisans üstü eğitimimi destekleyen kıymetli mesai arkadaşlarıma, benim bugünlere kadar gelmemde emeği olan maddi ve manevi her daim destekleyen aileme ve eşimin ailesine, bu süreçte varlıklarıyla bana güç veren eşim Samed ÇİFTÇİ ve biricik oğlum Yiğit Serdar'a teşekkür ederim.

Ayşe TUNCEL ÇİFTÇİ

.../.../.....

ÖZET

YÜKSEK LİSANS TEZİ

GIDADA TAĞŞIŞ TESPİTİ İÇİN GÖRÜNTÜ İŞLEME VE YAPAY ZEKA YAKLAŞIMLARI: ANTEP FISTIĞI ÖRNEĞİ

AYŞE TUNCEL ÇİFTÇİ

YOZGAT BOZOK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

ELEKTRİK – ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

TEZ DANIŞMANI: Dr. Öğr. Üyesi Tolga HAYIT

İKİNCİ DANIŞMAN: Dr. Öğr. Üyesi Fatma HAYIT

Gıda güvenliği ve kalitesi, tüketici sağlığını korumak ve gıda endüstrisi açısından güvenilir bir ürün sunmak açısından kritik öneme sahiptir. Ancak, dünya genelinde gıda sahtekarlığı veya tağşiş sorunları, gıda endüstrisini tehdit eden bir sorun haline gelmiştir. Gıdalara kasıtlı olarak yabancı maddelerin eklenmesi veya düşük kaliteli malzemelerin kullanılması, tüketicileri yanıltarak sağlık riskleri ve güvenilirlik sorunlarına neden olmaktadır.

Geleneksel yöntemlerle gıda tağşişinin tespiti karmaşık ve zaman alıcı olabilir. Ancak, son yıllarda görüntü işleme ve yapay zekâ teknikleri, bu soruna daha hızlı ve etkili bir şekilde yaklaşım sunmaktadır. Gıda sahtekarlığının tespiti ve gıda kalitesinin denetimi için görüntü işleme algoritmaları ve yapay zeka modelleri kullanmak, üreticilerin ve düzenleyicilerin daha hızlı ve doğru kararlar almasına yardımcı olacaktır.

Bu tez çalışmasında, gıda endüstrisinde gıda tağşişinin tespit edilmesi için görüntü işleme ve yapay zeka tekniklerinin uygulanabilirliği Antep fıstığı örneği üzerinden tartışılmaktadır. Laboratuvar ortamında elde edilen Antep fıstığı ve tağşişli örnekleri fotoğraflanmış, görüntü işleme ve veri artırımı yapılarak veri seti oluşturulmuştur. Önerilen InceptionV3 modeli yoğun ağ yapısına sahip, hızlı bir derin öğrenme modelidir ve görüntü ile yapılacak çalışmalar için idealdir. InceptionV3 modeli eşsiz bir veri seti olan Antep fıstığı ve tağşişli örneklerini etkin bir şekilde sınıflandırmış ve %99.3'lük test doğruluğu ile yüksek başarı göstermiştir. Çalışmada yapılacak tağşiş sınıflandırma çalışmaları için temel oluşturmakta olup, gıda sektöründe tağşişin tespiti ve önlenmesi açısından umut verici niteliktedir.

2024, xiv + 86 Sayfa

Anahtar Kelimeler: Gıda güvenliği, tağşiş, Antep fıstığı, görüntü işleme, makine öğrenimi, CNN

ABSTRACT

MASTER THESIS

IMAGE PROCESSING AND ARTIFICIAL INTELLIGENCE APPROACHES FOR ADULTERATION DETECTION IN FOOD: THE CASE OF PISTACHIOS

AYSE TUNCEL CİFTÇİ

**YOZGAT BOZOK UNIVERSITY
SCHOOL of GRADUATE STUDIES
WRITE YOUR DEPARTMENT**

SUPERVISOR: Asst. Prof. Dr. Tolga HAYIT

CO-SUPERVISOR: Asst. Prof. Dr. Fatma HAYIT

Food safety and quality are critically important for protecting consumer health and ensuring the reliability of products within the food industry. However, food fraud or adulteration issues have become a global threat to the food industry. The intentional addition of foreign substances to food products or the use of low-quality ingredients misleads consumers, resulting in health risks and reliability issues.

Detecting food adulteration using traditional methods can be complex and time-consuming. In recent years, however, image processing and artificial intelligence techniques have offered a more rapid and effective approach to this problem. Employing image processing algorithms and AI models for the detection of food fraud and monitoring food quality can assist producers and regulators in making faster and more accurate decisions.

In this thesis, the applicability of image processing and artificial intelligence techniques for detecting food adulteration in the food industry is discussed using the example of pistachios. Pistachio and adulterated samples were obtained and photographed in a laboratory setting, and the images were enhanced through image processing and augmented to create a dataset. The proposed InceptionV3 model, characterized by a dense network structure, is a fast deep learning model ideal for image-based studies. The InceptionV3 model effectively classified the novel dataset of pistachios and adulterated samples, achieving a high test accuracy of 99.3%. The methods proposed in this study provide a foundation for future adulteration classification studies and are promising for the detection and prevention of adulteration in the food industry.

2024, xv + 86 Pages

Keywords: Food safety, adulteration, pistachio, image processing, machine learning, CNN.

İÇİNDEKİLER

	<u>Sayfa</u>
TEZ ONAY FORMU.....	ii
TEZ BEYANI.....	iii
ÖN SÖZ.....	IV
ÖZET	V
ABSTRACT	VI
İÇİNDEKİLER.....	VII
TABLolar LİSTESİ.....	XII
ŞEKİLLER LİSTESİ	XII
SİMGELER VE KISALTMALAR LİSTESİ.....	XV
1. GİRİŞ	1
1.1. Gıda Güvenliği Taklit ve Tağşiş	2
1.1.1. Gıda Güvenliği.....	2
1.1.2. Gıdada Taklit ve Tağşiş.....	3
1.1.3. Gıdada Tağşiş Örnekleri.....	4
1.1.3.1. Et ve Et Ürünlerinde Tağşiş	4
1.1.3.2. Süt ve Süt Ürünlerinde Tağşiş	4
1.1.3.3. Bitkisel Yağlarda Tağşiş	5
1.1.3.4. Balda Tağşiş	5
1.1.3.5. Baharatlarda Tağşiş.....	5
1.1.3.6. Çay ve Kahve Ürünlerinde Tağşiş.....	6
1.1.4. Antep Fıstığı	6
1.1.5. Antep Fıstığı Tağşişi	8
1.1.6. Gıda Tağşişlerinin Belirlenmesinde Kullanılan Yöntemler	8
1.1.6.1. Fiziksel Yöntemler.....	9

1.1.6.2. Yakın Kızılötesi Spektroskopisi	9
1.1.6.3. FT-IR (Fourier Transform Infrared) Spektroskopisi	9
1.1.6.4. Raman Spektroskopisi	10
1.1.6.5. Hiperspektral Görüntüleme	10
1.1.6.6. Moleküler Yöntemler (Poliemeraz Zincir Reaksiyonu, PCR)	10
1.1.6.7. Elektronik Teknikler	11
1.1.6.8. Bilgisayarlı Görüntüleme	11
1.2. Problemin Tanımı	11
1.3. Araştırma Soruları	12
1.4. Amaç	12
2. SAYISAL GÖRÜNTÜ İŞLEME.....	13
2.1. Görüntü İşleme Teknikleri	14
2.1.1. Parlaklık Dönüşümleri / Parlaklık Düzeltmeleri.....	14
2.1.1.1. Histogram Eşitleme.....	15
2.1.1.2. Gama Düzeltme	16
2.1.2. Görüntü Bölütleme (Segmentasyon)	16
2.1.3. Filtreleme	16
2.1.4. Geometrik Dönüşümler	17
2.1.5. Renk Dönüşümleri	17
3. MAKİNE ÖĞRENİMİ.....	18
3.1. Makine Öğrenimi Yaklaşımları.....	19
3.1.1. Denetimli Öğrenme	19
3.1.2. Denetimsiz Öğrenme	19
3.1.3. Yarı denetimli Öğrenme	19
3.1.4. Pekiştirmeli Öğrenme	20
3.2. Makine Öğreniminde Sınıflandırma	20

3.3. Sınıflandırma Algoritmaları	20
3.3.1. K-en Yakın Komşu Algoritması	20
3.3.2. Destek Vektör Makineleri	21
3.3.3. Karar Ağaçları.....	22
3.3.4. Yapay Sinir Ağları	24
3.3.4.1. Yapay Sinir Ağları Elemanları	25
3.3.4.2. Yapay Sinir Ağlarının Yapısı	27
3.3.4.3. Mimarilerine Göre Yapay Sinir Ağları	27
3.3.4.4. Öğrenme Yöntemlerine Göre Yapay Sinir Ağları	28
3.3.4.5. Katman Sayılarına Göre Yapay Sinir Ağları.....	29
3.3.4.6. Yapay Sinir Ağlarının Kullanım Alanları	30
3.3.4.7. Yapay Sinir Ağlarının Avantaj ve Dezavantajları	31
4. DERİN ÖĞRENME.....	33
4.1. Derin Öğrenme Yöntemleri.....	35
4.1.1. Derin Sinir Ağları.....	36
4.1.2. Derin Oto-Kodlayıcılar.....	36
4.1.3. Derin İnanç Ağları.....	37
4.1.4. Tekrarlayan Sinir Ağları.....	37
4.1.5. Evrimsel Sinir Ağları	38
4.1.5.1.CNN Katmanları.....	39
4.1.5.2. Aşırı Uyum (Overfitting) ve Yetersiz Uyum (Underfitting)	42
4.1.5.3. Başlıca CNN Modelleri.....	43
4.1.5.3.1. LeNet	43
4.1.5.3.2. AlexNet.....	43
4.1.5.3.3. VGGNet.....	44
4.1.5.3.4. GoogleNet (Inception)	45

4.1.5.3.5. ResNet	45
4.1.5.3.6. MobileNet	46
4.1.5.3.7. EfficientNet	47
4.1.5.3.8. DenseNet	48
5. LİTERATÜRDEKİ ÇALIŞMALAR	49
6. MATERYAL VE METOT	52
6.1. Kullanılan Araç ve Yazılımlar	52
6.2. Veri Setinin Oluşturulması	52
6.2.1. Antep Fıstığı ve Tağşişli Örneklerinin Hazırlanması	52
6.2.2. Görsellerin Elde Edilmesi	54
6.2.3. Görsellerin Etiketlenmesi	55
6.2.4. Görüntü İşleme Ön Aşamaları	56
6.2.4.1. Maskeleme	56
6.2.4.2. Kırpma	57
6.2.4.3. Veri Artırımı	59
6.3. Derin Öğrenmeye Dayalı Sınıflandırma Yöntemi	60
6.3.1. CNN	60
6.3.1.1. DenseNet-201	60
6.3.1.2. ResNet-18	61
6.3.1.3. InceptionV3	61
6.3.1.4. Transfer Öğrenimi	62
6.3.2. Önerilen Model	63
6.4. Performans Değerlendirme Ölçütleri	64
6.4.1. Karışıklık Matrisi (Confusion Matrix)	65
6.4.2. Doğruluk (Accuracy)	65
6.4.3. Kesinlik (Precision)	65

6.4.4. Duyarlılık (Recall-Sensitivity).....	66
6.4.5. F1 Skor (F1-Score).....	66
6.4.6. ROC Eğrisi (Receiver Operating Characteristic Curve)	66
7. ARAŞTIRMA BULGULARI.....	67
8. TARTIŞMA.....	71
9. SONUÇ VE ÖNERİLER	73
10. KAYNAKLAR	75



TABLÖLAR LİSTESİ

<u>Tablo</u>	<u>Sayfa</u>
Tablo 3.1. Biyolojik sinir sistemi elemanları ve yapay sinir sisteminde karşılıkları	25
Tablo 4.1. Derin Öğrenme Yöntemleri ve Kullanıldığı Alanlar (Küçük vd., 2018).....	36
Tablo 6.1. Elde edilen ham veri seti istatistikleri.....	56
Tablo 6.2. Elde edilen veri setinin eğitim (öğrenme süreci sırasında kullanılan örnek veri kümesi) ve doğrulama (modelde ince ayar yapmak için kullanılan örnek veri kümesi) ve test (eğitim ve doğrulama veri kümelerinden bağımsız veri kümesi) grupları.	59
Tablo 6.3. Önerilen InceptionV3 modeline ait parametre değerleri	63
Tablo 7.1. CNN modellerinin eğitim süresince elde edilen sınıflandırma doğruluk oranları	67
Tablo 7.2. InceptionV3'ün diğer ölçütler açısından performans sonuçları	70
Tablo 8.1. Literatürdeki benzer çalışmalar	71

ŞEKİLLER LİSTESİ

<u>Sekil</u>	<u>Sayfa</u>
Şekil 2.1. Sayısallaştırılmış renkli görüntü.	13
Şekil 2.2. Görüntü işlemenin kullanıldığı alanlar.....	14
Şekil 2.3. Histogram eşitleme yönteminin bir görüntüye uygulanması ve sonucu; (a) orijinal görüntü, (b) histogram eşitleme uygulanmış görüntü, (c) orijinal görüntünün histogramı, (d) histogram eşitleme uygulanmış görüntünün histogramı.	15
Şekil 3.1. Yapay zekâ şeması.	18
Şekil 3.2. $k=5$ için KNN sınıflandırıcısı	21
Şekil 3.3. SVM hiper düzlemi ve maksimum marjini.	22
Şekil 3.4. Dört boyutlu özellik uzayına sahip üç sınıftan oluşan bir karar ağacı	23
Şekil 3.5. Biyolojik Sinir Hücresi ve Yapay Sinir Ağı.....	24
Şekil 3.6. Yapay sinir ağlarında kullanılan başlıca aktivasyon fonksiyonları	26
Şekil 3.7. İleri Beslemeli Sinir Ağı Yapısı.	27
Şekil 3.8. Geri Beslemeli Sinir Ağı Yapısı.	28
Şekil 3.9. Tek Katmanlı Algılayıcı Modeli	30
Şekil 3.10. Çok Katmanlı Algılayıcı Modeli	30
Şekil 4.1. Eğitilen ve bilinen ilk derin ağ mimarisi.	33
Şekil 4.2. Derin Öğrenme çalışma basamakları.	35
Şekil 4.3. Bir CNN mimarisinin Genel Yapısı.....	39
Şekil 4.4. Evrişim operatörünün uygulanması.	40
Şekil 4.5. 4x4 boyutunda görüntüye 2x2 boyutunda maksimum ve ortalama havuzlama operatörünün uygulanması.....	41
Şekil 4.6. Dropout katmanının uygulanması.	42
Şekil 4.7. LeNet ağıının mimarisi.....	43
Şekil 4.8. AlexNet Mimarisi.	44
Şekil 4.9. VGG16 Mimarisi.	44
Şekil 4.10. VGG19 Mimarisi.	45
Şekil 4.11. GoogLeNet ağ mimarisi.	45
Şekil 4.12. ResNet mimarisinin şematik görünümü.	46
Şekil 4.13. MobileNet Mimarisi.....	47
Şekil 4.14. DenseNet Mimarisi	48
Şekil 6.1. Antep Fıstığı örneği.....	53
Şekil 6.2. Yer Fıstığı örneği	53
Şekil 6.3. Bezelyelerin WMF KITCHEN kurutucuda kurutulması	53
Şekil 6.4. Bezelye örneği	54
Şekil 6.5. Ispanak örneği.....	54
Şekil 6.6. Çekim kabini dış görüntüsü (a), Çekim kabini iç görüntüsü (b), Çekim kabini ve fotoğraf makinesi mekanizması görüntüsü (c).....	55
Şekil 6.7. Laboratuvar ortamında çekilmiş ürün fotoğrafları; (a) Antep fıstığı, (b) bezelye, (c) ıspanak, (d) yer fıstığı	55
Şekil 6.8. Maskeleme; (a) orijinal Antep fıstığı görüntüsü, (b) gri seviye görüntüsü, (c) maske ile kırpılmış görüntü	57
Şekil 6.9. Kırpma; Maskelenmiş Orijinal Antep fıstığı görüntüsü(a) ve sınırlarından kırpılmış görüntü(b)	58
Şekil 6.10. Maskelenmiş ve kırpılmış Antep fıstığı görüntüsünün, 10'ar derece döndürülmesiyle elde edilen görüntüler	59

Şekil 6.11. DenseNet-201 Mimarisi	60
Şekil 6.12. ResNet-18 Mimarisi	61
Şekil 6.13. InceptionV3 Mimarisi	622
Şekil 6.14. Transfer öğrenme çalışma prensibi.	63
Şekil 6.15. Önerilen derin öğrenme modeli iş akışı	64
Şekil 7.1. InceptionV3 ve DenseNet-201 eğitim ve doğrulama doğruluk grafikleri.....	68
Şekil 7.2. InceptionV3 ve DenseNet-201 eğitim ve doğrulama kayıp grafikleri.....	68
Şekil 7.3. InceptionV3 ve DenseNet-201 modelleri için test veri kümesine ait hata matrisleri. Sınıfların isimlendirmeleri pistachio: Antep fıstığı, pea: bezelye, spinach: ıspanak, peanut: yer fıstığı.....	69
Şekil 7.4. InceptionV3 ve DenseNet-201 modelleri için test veri kümesine ait hata matrisleri. Sınıfların isimlendirmeleri pistachio: Antep fıstığı, pea: bezelye, spinach: ıspanak, peanut: yer fıstığı.....	70



SİMGELER VE KISALTMALAR LİSTESİ

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile aşağıda sunulmuştur.

Simgeler	Açıklamalar
-----------------	--------------------

gr	: Gram
-----------	--------

dk	: Dakika
-----------	----------

hz	: Hertz
-----------	---------

Kısaltmalar	Açıklamalar
--------------------	--------------------

ANN	: Yapay Sinir Ağları
------------	----------------------

CNN	: Evrişimli Sinir Ağları
------------	--------------------------

DL	: Derin Öğrenme
-----------	-----------------

DT	: Karar Ağaçları
-----------	------------------

DSA	: Derin Sinir Ağları
------------	----------------------

HSI	: Hiperspektral Görüntüleme
------------	-----------------------------

LR	: Doğrusal Regresyon
-----------	----------------------

ML	: Makine öğrenimi
-----------	-------------------

NB	: Naive Bayes
-----------	---------------

NIR	: İletim spektral ölçüm yöntemi
------------	---------------------------------

PCR	: Polimeraz zincir reaksiyonu
------------	-------------------------------

SBM	: Derin inanç ağları
------------	----------------------

SVM	: Destek Vektör Makineleri
------------	----------------------------

KNN	: K-en yakın komşu
------------	--------------------

PIL	: Python Imaging Library
------------	--------------------------

RNN	: Tekrarlayan Sinir Ağı
------------	-------------------------

1. GİRİŞ

Gıda, insan yaşamının temel unsurlarından biridir. Gıda, insan vücudunun büyüme, gelişme, enerji sağlama ve sağlığı koruma süreçlerinde kritik bir rol oynar (Doğan, 2020). Teknolojinin gelişmesiyle gıda üretimi ve gıdaya ulaşma konusunda büyük yol kat edilmiş ve bu alanda oldukça önemli gelişmeler kaydedilmiştir. Ancak, bu kolaylıkların yanı sıra günümüzde gıda güvenliği ve kalitesi konusundaki endişeler giderek artmaktadır.

Gıda endüstrisi, ürünlerin üretiminden tüketiciye ulaşmasına kadar geniş bir yelpazede faaliyet gösteren karmaşık bir sektördür (Elma vd., 2023). Bu süreçte, gıda ürünlerinin doğru bir şekilde işlenmesi, depolanması, taşınması ve pazarlanması önemlidir. Ancak, bu süreçlerde çeşitli sorunlar ortaya çıkabilir ve gıda ürünlerinin taşıması (sahtecilik) gibi istenmeyen maddelerle kirlenmesi veya kalite kaybı gibi problemler yaşanabilir (Siriken vd., 2021).

Dünya nüfusundaki hızlı artış, küreselleşen ürün ve hizmet ticareti, iklim değişikliklerine bağlı gıda kaynaklarının azalması ve enerji kullanımındaki artış gibi etkenlerin yanı sıra; yabancı yatırımlardaki artış, tüketici güvenliğinin sağlanması, çevrenin korunması ve sosyal sorumluluklar, yeni buluşlar ve teknolojik gelişmeler, gıda sektöründe uluslararası standartlara olan talebi sürekli olarak artırmaktadır (Yayla vd.,2020).

Dünya genelinde nüfusun artışı ve gıdaya olan ihtiyacın artması ile gıdada taşıması ciddi oranda artmış ve insan sağlığını tehdit eder hale gelmiştir. Özellikle, bazı değerli gıda ürünleri, ticari değerlerinden dolayı sahtecilik riskiyle karşı karşıyadır (Elma vd., 2020). Bu ürünlerin taşıması edilmesi, tüketicilerin sağlığını tehlikeye atmakta ve güvenilir gıda tedarik zincirinin bütünlüğünü zedelemektedir. Bu bağlamda, gıda endüstrisi ve araştırmacılar, gıda ürünlerinin taşımasını tespit etmek ve kalitesini korumak için çeşitli yöntemler geliştirmeye çalışmaktadır. Görüntü işleme ve yapay zekâ gibi ileri teknolojiler, bu amaçla kullanılabilecek potansiyel araçlar arasındadır (Sezer vd., 2019).

Bu çalışmada, gıda endüstrisindeki taşıması problemi ele alacak ve özellikle Antep fıstığı örneği üzerinden görüntü işleme ve yapay zeka yaklaşımlarını inceleyeceğiz. Bu çalışma, güvenilir gıda tedarik zinciri oluşturmak ve tüketicilerin sağlığını korumak için önemli bir adım olabilir.

1.1. Gıda Güvenliđi, Taklit ve Tađıřıř

Gıda güvenliđi, taklit ve tađıřıř g n m zde gıda alanında en b y k sorunlar arasında yer alır.

1.1.1. Gıda Güvenliđi

Gıda güvenliđi, sađlıklı gıda  retimini temin etmek amacıyla gıdaların  retim, iřleme, depolama, tařıma ve dađıtım s re lerinde uyulması gereken kuralları ve alınması gereken  nlemleri i erir ve sađlıklı, besleyici ve hijyenik bir gıda tedarikini kapsar (Giray vd., 2007).

Gıda güvenliđi, gıdanın kullanım amacına g re hazırlandığında ve t ketildiğinde t keticilere zarar vermemesi anlamına da gelmektedir. Gıda güvenliđi gıdadaki kasıtlı ve kasıtsız kirlenmeyi i erir ve kirlenmelerin oluřturabileceđi tehlike ve insan sađlıđı  zerindeki tehditleri de kapsar (Manning & Soon, 2016).

Eriřilen gıdaların sađlıklı ve besleyici olmalarını ama layan gıda güvenliđi yaklařımı, k resel hedefin zorunlu bir kořulunu oluřturur. Sađlıklı beslenmenin temelinde iyi ve temiz gıdanın bulunması  nemlidir. İyi ve temiz gıda, bir gıda  r n n n besleyici  zelliklerini koruması, b t nl đ n  s rd rmesi ve hastalıklara neden olabilecek canlı organizmalarla veya cansız maddelerle kontamine olmaması (Giray vd., 2007) yani güvenli olması anlamına gelir. T keticiler i in satın aldıkları ve t kettikleri gıda  r nlerinin besleyici ve sađlıklı olması, temel bir insan hakkıdır. Gıda güvenliđi, bu hakkın tesisini ve g vence altına alınmasını sađlayan bilimsel y ntemleri, hukuki altyapıyı ve politikaları i eren kurumsal bir yaklařımdır. Bu yaklařım, gıda  r nlerinin  retiminden t ketime kadar olan s re te güvenliđini sađlamak amacıyla oluřturulan bir sistemdir. Bu sayede t keticilere g venilir ve sađlıklı gıda sunularak genel halk sađlıđı korunmuř olur (Dođan, 2020).

1996 D nya Gıda Zirvesinde ise gıda güvenliđi "t m insanların sađlıklı ve aktif bir yařam s rd rmek i in her zaman yeterli, güvenli, besleyici gıdaya eriřiminin olması" olarak tanımlanmıřtır (Ko  & Uzmay, 2015).

1.1.2. Gıdada Taklit ve Tağşiş

Gıda sektöründe taklit ve tağşiş, son yıllarda ciddi bir endişe kaynağı haline gelmiş, bu durum, sağlık ve güvenlik risklerine yol açabilecek yanıltıcı uygulamaların artmasına neden olmuştur (Türkmen & Ataseven, 2020).

Gıdada taklit, gıda maddelerinin gerçek niteliklerinden farklı bir şekilde sunularak aynıysıymış gibi gösterilmeye çalışılmasıdır (Boran vd., 2023). Örneğin glikoz şurubunu bal olarak satmak, bitkisel yağlardan yapılan katı yağları tereyağı olarak satmak taklit örneklerindendir. Taklit ürünler, orijinal ürünlerin ambalaj, marka veya içeriği gibi unsurlarını kopyalayarak tüketicileri aldatma eğilimindedir (Koç & Uzmay, 2015).

Tağşiş kelime anlamı olarak bir şeyin içine başka bir madde karıştırma, saflığını bozma anlamına gelmektedir (Gündoğdu, 2019).

T.C Tarım ve Orman Bakanlığı tarafından 27009 sayılı Resmî Gazete 'de yayımlanan Gıda Güvenliği ve Kalitesinin Denetimi ve Kontrolüne Dair Yönetmeliğin 4. maddesi kapsamında, tağşiş terimi; 'Gıda maddelerinin ve gıda ile temasta bulunan madde ve malzemelerin, mevzuata veya izin verilen özelliklerine aykırı olarak üretilmesi hali.' şeklinde tanımlanmıştır (Temiz, 2019).

Tağşiş, gıda ürünlerinin üretim aşamalarında, mevzuata veya izin verilen standartlara aykırı şekilde işlenmesi sonucunda ortaya çıkan bir durumu ifade eder. Gıdada tağşiş, ürünlere özgü temel özellikleri oluşturan maddelerin veya besin içeriğinin, belirlenen kurallara uymayan bir şekilde çıkarılması, miktarının değiştirilmesi ya da aynı değeri taşımayan başka bir madde ile yer değiştirmesidir (Ay, 2022).

Gıda alanında taklit ve tağşiş, ticaret ilişkileri bağlamında "adil" rekabeti bozan ve haksız ticari kazanca sebep olur. Tağşiş, ticari bir dolandırıcılık faaliyeti olmasının yanında gıda güvenliği açısından risk oluşturarak halk sağlığı sorunlarına yol açabilmesi, gıda zehirlenmelerine veya hastalıklara neden olabilmesi açısından da oldukça riskli ve tehlikelidir (Türkmen & Ataseven, 2020).

Bazı gıda ürünlerinin işlenme süreçlerinde, tatlandırma, renklendirme, aroma katma, raf ömrünü uzatma gibi amaçlarla, mevzuatta belirtilmeyen veya kullanılması yasaklanan kimyasal maddelerin kullanılması sağlık açısından olumsuz sonuçlara neden olabilir (Ayper vd., 2010). Kısacası, taklit ve tağşiş hem halk sağlığı açısından bir tehdit hem de ticari bir sahtekârlık olarak değerlendirilebilir. Bu iki düzlemin kesiştiği ve farklılaştığı

alanların netleşmesi açısından, her tağşişli ürünün insan sağlığını bozmayabileceği, ancak her durumda bilgi sahibi olmayan tüketicinin kandırılmış ve dolandırılmış olduğu bir hile olduğu unutulmamalıdır (Doğan, 2020). Ayrıca, taklit ve tağşiş ürünlerin piyasaya sürülmesi, orijinal üreticilerin marka değerini olumsuz yönde etkileyebilir ve haksız rekabete yol açabilir (Ay, 2022).

1.1.3. Gıdada Tağşiş Örnekleri

Gıdada en çok tağşişe uğrayan ürünler; et ve et ürünleri, süt ve süt ürünleri, bitkisel yağlar, bal, baharatlar, çay ve kahve ürünleri ve kuruyemişler olarak kategorize edilmiştir.

1.1.3.1. Et ve Et Ürünlerinde Tağşiş

Et ve et ürünlerinde tağşiş genellikle ekonomik sebeplerden yapılırsa da insan sağlığı ve dini inançlar açısından oldukça zararlı ve hassastır. Etin tağşişi ile ortaya çıkan toksinler, patojenler ve diğer zararlı maddeler nedeniyle halk sağlığı üzerinde büyük risk oluşturur. Ayrıca ete karıştırılan diğer maddeler ve etler helal olmayan içeriğe sahip olabileceği için de dini olgu olarak da kabul edilemez (Li vd., 2020).

Et ve et ürünlerinde tağşiş, birkaç farklı yöntemle gerçekleştirilebilir. Bu yöntemler arasında, düşük popülerlik nedeniyle daha ucuz olan bir et türünün, daha pahalı olan bir başka et türüyle kısmen veya tamamen yer değiştirmesi (kırmızı et ve ürünlerine domuz, tavuk , ördek vb. etlerin karıştırılması), aynı hayvan türünden farklı dokuların kullanılması (ete sakatat vb. ürünlerin karıştırılması), hayvanlara hormon veya antibiyotik gibi maddeler verilerek etin ağırlığının ve görünümünün artırılması, renklendirici ve katkı maddelerinin kullanılması gibi teknikler yer almaktadır. Bu yöntemlerin her biri, tüketicileri aldatma amacıyla et ve et ürünlerinde tağşiş yapılmasına olanak tanır. Bu da gıda güvenliği ve tüketici hakları açısından önemli bir sorun olarak karşımıza çıkar (Fengou vd., 2021).

1.1.3.2. Süt ve Süt Ürünlerinde Tağşiş

Süt ve süt ürünleri içerdiği yüksek besin değerlerinden dolayı halk arasındaki yaygın olarak kullanıldığından tağşişe yaygın olarak uğrayan ürünlerdir (Elma vd., 2023). Tereyağına süt harici yağ katma, yoğurt ve peynir ürünlerine nişasta, pektin ilave etme (Siriken vd., 2021) sütü artırmak için su katma, seyreltilmiş süte melamin ve bitkisel yağ ilavesi, raf ömrünü uzatmak için bikarbonat vb. maddelerin katılması, uygun olmayan koşullarda saklanan sütlerin asitlik artışını önlemek için asitlik düzenleyiciler karıştırma, son tüketim tarihi geçmiş peynirleri yüksek ısıda eritip nitrat vb. ilavesi ile yeniden

kullanıma sunma, son kullanma tarihini deęiřtirme ve yanlış etiketleme (Elma vd., 2023) gibi birçok yöntemle süt ve süt ürünlerinde taęşıř yapılmaktadır. Süt mikroorganizma üretmeye ve bozulmaya oldukça yatkın bir ürün olduğundan tüm bu uygulamalar halk saęlığı üzerinde büyük risk oluşturmaktadır (Özay, İ., 2016).

1.1.3.3. Bitkisel Yaęlarda Taęşıř

Bitkisel yaę taęşıřı, yaęın asıl nitelięini ve kalitesini etkileyebilecek řekilde, daha düşük kaliteli, ucuz, zararlı veya gereksiz maddelerin bilinçli bir řekilde eklenmesi ile yapılmaktadır. Bu tür eklemeler, yaęın saęlığa zararlı olabilecek özellikler kazanmasına veya tüketiciye yanlış bir algı sunulmasına yol açabilir (Abbas & Baeten, 2016).

Bitkisel yaęlarda taęşıř genellikle yüksek maliyetli ve kaliteli yaęlara daha düşük maliyetli yaęların karıřtırılmasıyla yapılmaktadır. Özellikle hem tüketimi yaygın olan hem de saęlığa oldukça faydalı olan zeytinyaęında taęşıř, ülkemizde ve dünyada sıklıkla karřılařılan bir durumdur. Sızma zeytinyaęına ayçiçek yaęı, soya fasulyesi yaęı ve mısır yaęı, pamuk yaęı, fındık yaęı, rafine soya yaęı ve rafine prina yaęı gibi yaęlar belli oranlarda karıřtırılarak taęşıřı yapılmaktadır (Karacan vd., 2023).

1.1.3.4. Balda Taęşıř

Bal, sadece tatlandırıcı ya da besin maddesi olarak deęil aynı zamanda tedavi edici bir etkiye sahip olduğundan balın katkısız ve doęal olması oldukça önemlidir (Fakhlaei vd., 2020).

Bal bileřenleri aęısından yüksek kaliteli bir gıda olmasına raęmen taęşıře karřı açık ve hassas bir üründür. Üretimin azalması, küresel iklim deęiřikliklerinden kaynaklı sorunlar ve arzın artması ile balda yüksek oranda taęşıř yapıldığı bilinmektedir. Genellikle yüksek fruktozlu mısır řurubu ve ters řurup gibi ucuz řeker řuruplarının bala eklenmesiyle taęşıř yapılmakta (Ruiz-Matute vd., 2007) ve sonu olarak balın bileřenleri bozularak besinsel deęerinin azalmasına ya da balın renginin bozulmasına sebep olmaktadır.

1.1.3.5. Baharatlarda Taęşıř

Baharatlar biyoaktif bileřenler ve antioksidan içerdiklerinden (Özata, vd., 2019) taze ve katkısız olmaları büyük önem tařır. Bazı baharatlar özellikle ticari aıdan yüksek deęere sahip olduğu için taęşıře açıktır. Özellikle kırmızı ve toz bibere bařka maddeler ekleyerek boya karıřtırma (Siriken vd.,2021), bazı baharatlara niřasta ilave etme (Elma vd.,2023),

dünyanın en pahalı baharatlarından biri olan safranda ise aspir, mısır püskülü, nergis, enginar stigma ve stilusları gibi bitkileri ilave etme ve mum, yağ gibi maddeler ile emdirilerek ağırlığını artırma (Özoğul vd., 2023) gibi tağşiş yöntemleri görülmektedir.

1.1.3.6. Çay ve Kahve Ürünlerinde Tağşiş

Çay ve kahve ürünlerinde genellikle içerisine yabancı madde katarak ve boya maddeleri kullanarak tağşiş yapılmaktadır. Çay ve kahve posalarını kimyasal maddeler ile boyayıp içerisine nohut unu, kum, hindiba gibi ürünler katarak (Elma vd., 2023); bitki çayları, kahve ve çözünebilir kahvede ilaç etken maddesi olan sildenafil veya sibutramin, siyah çayda ise boya/gıda boyası eklenerek (Siriken vd.,2021) yapılan tağşiş örnekleri bulunmaktadır.

1.1.4. Antep Fıstığı

“Yeşil altın”, “Meyvelerin kralı”, “Altın ağaç” ve “Kral meyvesi” gibi isimlerle de adlandırılan (Çağlar vd., 2017) sakız ağacıgiller familyasından olan Antep Fıstığı, kendine has tadı ve aroması olan (Ay, 2022) ; protein, yağ ve yağ asitleri, vitamin, mineral ve antioksidan bakımından oldukça zengin (Çağlar vd., 2017) sert kabuklu bir yemiştir. Kültür olarak ilk defa Hitit Uyarlığının Güney Doğu Anadolu bölgesindeki yerleşimlerde görülmüş (Elbistanlı vd., 2020) ve saraylarda önemli misafirlere ikram edilmiştir (Erdal vd., 2015). Yakın Doğu Gen Merkezi (Anadolu, İran, Kafkasya ve Türkmenistan) ve Orta Asya Gen Merkezi (Hindistan'ın kuzeyi, Pakistan, Afganistan ve Tacikistan) olmak üzere 2 gen merkezi bulunan (Elbistanlı vd., 2020) Antep Fıstığı, günümüzde daha çok kuzey yarım kürede 30-45 güney-kuzey paralelleri arasında mikroklima iklimlerde yetişmektedir (Gezginç & Duman, 2004). Dünyada en çok Antep fıstığı yetiştirilen ülkeler arasında 1. Sırada ABD, 2. Sırada İran ve 3. Sırada ise Türkiye bulunmaktadır. Şanlı Urfa ve Gaziantep (Kalkancı vd., 2023) başta olmak üzere toplam 56 ilde (Kaplan & Çat, 2023) Antep fıstığı yetiştiriciliği yapılmaktadır. Ülkemizde uzun, kırmızı, Siirt, halebi, Ohadi, keten gömleği, beyaz ben, değirmi, çakmak, sultani, vahidi, mümtaz, sefidi ve hacı şerifi gibi türleri (Elbistanlı vd., 2020) bulunmakla beraber en çok uzun, kırmızı, Siirt, Ohadi ve halebi gibi çeşitlerinin yetiştiriciliği yapılmaktadır (Mutlu, 2007).

Toprak olarak seçici olmayan aksine birçok ürünün yetişmediği kıraç, kayalık, kireçli ve eğimli arazilerde (Erdal vd., 2015) ve çoğu zaman sulama yapılmadan (Öztep & Işın, 2023) kurak şartlarda yetiştirilmektedir. Son yıllarda ülkemizde verimliliği artırmak için

birçok çalışma yapılmış ve çalışmalar sonucunda topraktaki eksik minerallerin tamamlanması ve sulama ile verimin artırılacağı kanaatine varılmıştır.

Kısa dönem kış soğuğu ve 30⁰ C'nin üstünde yaz sıcaklığına gereksinim duymaktadır (Kahraman, 2015) ve toprak olarak seçici olmamasına rağmen iklim olarak seçicidir.

Antep fıstığında bir yıl ürün verip 2. yıl daha az ve verimsiz ürün vermek ya da hiç ürün vermemek anlamına gelen periyodisite (Gezginç & Duman, 2004) görülmektedir. Gerek iklim ve toprak koşullarından kaynaklı gerekse periyodisiteden kaynaklı Antep fıstığındaki verim yıldan yıla değişmekte bu da piyasadaki istikrarı etkilemekte ve üretimde standardizasyonun sağlanmasını zorlaştırmaktadır (Erdal vd., 2015).

Ayrıca Antep fıstığı diotik bir türdür yani dişisi ve erkeği olan bir bitki türüdür. Dişi ve erkek cinsinin aynı bahçede bulunması verimi ve kaliteyi artırmaktadır (Kahraman, 2015). Sonuç olarak Antep fıstığının diotik bir tür olması da yetiştirilmesinde zorluklarla karşılaşılmasına sebep olmaktadır.

Antep fıstığı ceviz, fındık, badem ve çam fıstığı gibi kabuklu meyvelere kıyasla daha düşük yağ ve enerji içeriğine sahip olmakla birlikte daha zengin lif, fitosteroller, gamatokoferol ve ksantofil karotenoidler içerir (Çağlar vd., 2017). Kalsiyum, fosfor, B1, B2, C ve E vitaminleri bakımından zengindir ve yüksek miktarda protein ve mineral içermektedir. Antep fıstığının doymamış yağ oranı yüksek olduğundan kandaki kötü kolesterolü düşürüp iyi kolesterolü yükselterek vücudun yağ dengesini düzenlediği (Çınar & Okay, 2014) ve böylece koroner kalp hastalığı riskini azalttığı saptanmıştır. Ayrıca kan şekerinin yükselmesini önlediği (Ay, 2022) ve insan vücuduna olumlu etkilerinin olduğu bilinmektedir.

Ülkemizde ve dünyada en çok kuruyemiş olarak tüketilen Antep fıstığı; tatlı, pasta, dondurma, şekerleme ürünleri, et ürünleri ve yemeklerin içerisinde kullanılabilmektedir.

İnsan beslenmesi açısından temel gıdalar arasında yer almamasına rağmen yüksek besin değerleri, geniş kullanım alanı ve lezzetinden dolayı yurt içi ve yurt dışı pazarında oldukça talep gören Antep Fıstığı; sadece belirli iklimlerde yetişmesi, üretimin zorlu, kısıtlı (Erdal vd., 2015) olması ve üretim standardının olmamasından (Gezginç & Duman, 2004) dolayı oldukça yüksek fiyatlara satılmaktadır.

1.1.5. Antep Fıstığı Tağşışı

Antep fıstığının yerli yabancı pazarda oldukça kıymetli olması ve kullanım alanlarının çokluğu sebebiyle kuruyemiş ve çerezler içerisinde en çok tağşışe uğrayan ürün (Özata vd., 2019) olma eğilimindedir. Şeker ve diğer maddelerin kompleks bileşenlerin birbirine karışmasıyla karakteristik lezzetin bastırılması ve renginin sarı-koyu yeşil aralığında farklılık göstermesi nedeniyle, öğütülmüş Antep fıstığındaki tağşış, genellikle tat veya dokuda tespit edilemez (Sezer vd., 2019).

Antep fıstığının genellikle öğütülmüş veya doğranmış olarak şekerleme ve pastacılık sektörüne pazarlanması, Antep fıstığıyla üretilen bazı ürünlerin de orijinalliği konusunda endişeler oluşturmaktadır. Örneğin, Türk Mutfağının tescilli tatlılarından olan yurt içi ve yurt dışında rağbet gören fıstıklı baklavada Türk Standartları Enstitüsünün “Türk baklavası (TS 13645)” standardına göre en az %10 Antep fıstığı bulunmak zorundadır ve kurutulmuş bezelye tozu veya diğer bitkisel katkıların kullanımı yasaktır (Kahraman, 2015). Özellikle Ramazan, bayram gibi belirli dönemlerde yurt içinde talepte artış olması sebebiyle bu dönemlerde taklit ve tağşışli ürünlerde artış görülmektedir.

Bezelye renk ve doku bakımından Antep fıstığına en çok benzeyen ürün olduğundan Antep fıstığı tağşışinde sıklıkla kullanılan maddedir (Ay, 2022). Hem fiyat hem de erişilebilirlik yönünden oldukça uygun olan bezelye kurutulup öğütülerek ya da kurutulmadan öğütülerek Antep fıstığı içerisine karıştırılmakta bazen de hiç Antep fıstığı içermeden direk taklit ürün olarak tüketiciye doğrudan ya da ürünlerin içerisine eklenerek sunulmaktadır.

Yer fıstığının öğütülerek boyanması (Siriken vd., 2021) Antep fıstığında görülen tağşış yöntemlerindendir ve içerisinde kimyasal bulunması sebebiyle sağlık açısından da sakıncalıdır. Özellikle Antep fıstığı ezmesi ve baklava gibi ürünlerde kullanılan boyanmış yer fıstığı da tüketiciyi aldatan ve kaliteyi düşüren tağşışli ürünler arasındadır.

Antep fıstığında bir diğer tağşış yöntemi, ıspanak ve formlarının fıstık ile öğütülerek karıştırılmasıyla (Sezer vd., 2019) yapılan tağşıştir.

1.1.6. Gıda Tağşışlerinin Belirlenmesinde Kullanılan Yöntemler

Gıdada tağşışin belirlenmesinde literatürde birçok çalışma bulunmaktadır. Yapılan çalışmalarda bazen tek yöntem kullanılırken bazen de hibrit yöntemler kullanılmıştır.

1.1.6.1. Fiziksel Yöntemler

Gıdalardaki tağışışın tespiti için çeşitli fiziksel yöntemler geliştirilmiştir. Bu yöntemler arasında mikroskobik ve makroskobik görsel yapısal analizler, gıdanın morfolojisi, doku, çözünürlük, toplu yoğunluk gibi fiziksel parametrelerin analizi (Bansal vd., 2017) yer alır. Ancak, bu yöntemlerin niteliksel tağışış tespitini garanti yöntem olmadığı bilinmektedir. Örneğin, mikroskopi kullanarak üründeki yapısal değişiklikler veya lezzet, koku ve doku gibi duysal özellikler incelenebilir fakat tamamen güvenilir bir yöntem değildir.

1.1.6.2. Yakın Kızılötesi Spektroskopisi

İletim spektral ölçüm yöntemi, (Near infrared spectroscopy, NIR) gıda uygulamalarında geleneksel yöntemlere alternatif olarak sıkça kullanılan (Ertugay vd., 2010) kalite kriterlerinin belirlenmesinde tercih edilen bir yöntemdir. NIR spektroskopisi, 780-2500 nm dalga boyu aralığındaki elektromanyetik radyasyonun absorpsiyonuna dayanır (Büyükcın vd., 2018). Bu yöntemde, ürünün bir tarafından gönderilen ışık, diğer tarafındaki NIR spektrometre dedektörü tarafından algılanarak kat eden ışınlara dayalı olarak bir spektrum elde edilerek maksimum bilgi sağlanır (Büyükcın vd., 2008). NIR, geleneksel yöntemlere kıyasla bazı avantajlara sahiptir. Tahribatsız ve hızlı bir yöntem (Ertugay vd., 2008) olarak bilinmektedir. Analizler sırasında kimyasal madde kullanımına gerek olmaması (Büyükcın vd., 2008), düşük analiz maliyeti, birçok bileşenin eş zamanlı analizi, az miktarda ve tekrar kullanılabilir örnek ihtiyacının olması, çevrim içi olarak kullanılabilmesi (He vd., 2020) gibi avantajları vardır.

Ancak, bu yöntemin dezavantajları da mevcuttur. Özellikle, her ürüne uygulanamaması ve ışığın ürünün iç inden geçişinde yaşanan yoğunluk kayıpları önemli sorunlardır. Bu nedenlerle, iletim yöntemi genellikle küçük yapı ve ışığı geçirmeye meyilli ürünlerde kullanılmaktadır (Büyükcın vd., 2008).

1.1.6.3. FT-IR (Fourier Transform Infrared) Spektroskopisi

FT-IR Gıda tarım sektöründe analitik çözümler üretmek ve kalite-kontrol amacıyla kullanılan (Çağlar vd., 2019), matematiksel olarak Fourier dönüşümü kullanılarak kızılötesi ışığın dalga sayısına bağlı olarak yoğunluğunun ölçüldüğü (Yeşilören & Ekşi, 2014) analitik bir yöntemdir. FT-IR spektroskopisi ile orta kızılötesi bölgedeki moleküler bağların titreşimlerini içeren spektrumlar elde edilir ve spektrum bantları numunedeki moleküllerin kimyasal bağ yapısı ve mevcut fonksiyonel grupları ile ilişkilendirilir. Her

bileşenin kendine özgü bir parmak izi bölgesi olduğundan, farklı molekül bağlarına sahip numuneler farklı titreşim frekansları ile tespit edilebilir (İçyer vd., 2019). Kullanılan örneklerle zarar vermediğinden özellikle maddenin saf olup olmadığının tespitinde sıklıkla kullanılmaktadır (Bansal vd., 2017).

1.1.6.4. Raman Spektroskopisi

Raman tarafından 1928 yılında bulunan ve Nobel ödüllü bu spektroskopi (Yeşilören & Ekşi, 2014), Raman saçılmasına dayalı foton ile örnek molekül arasında enerji alışverişi ile gerçekleşen bir tekniktir (He vd., 2020). Güçlü bir lazer kaynağının örneğe uygulanmasıyla saçılan fotonun yoğunluk ölçümüne dayanır (Çağlar vd., 2019). Gıdaların kalite ve saflık ölçütlerini değerlendirmek için kullanılan bu analitik yöntem (Çağlar vd., 2019) genellikle yağ (Yeşilören & Ekşi, 2014), bal, süt ve içeceklerin (He vd., 2020) taşımasını belirlemede kullanılmaktadır. Diğer spektroskopi yöntemlerine göre suya toleransının olması sebebiyle daha avantajlı (Çağlar vd., 2019) fakat maliyeti sebebiyle de dezavantajlı (İçyer vd., 2019) konumdadır.

1.1.6.5. Hiperspektral Görüntüleme

Hiperspektral görüntüleme (Hyperspectral Imaging, HSI) tekniği, spektroskopi ve görüntüleme yöntemlerini birleştirerek bir numunenin hem spektral hem de uzaysal bilgisini eş zamanlı olarak elde etmeyi amaçlar. Bu yaklaşım, üç boyutlu bir veri küpü olan (x, y, k) şeklinde ifade edilen, iki boyutlu uzaysal bilgiyi ve spektral bilgiyi içeren bilgilerin birleşimini sağlar. Her piksel, hiperspektral görüntülerde her dalga boyunda gri tonlamalı bir spektruma sahiptir. Bu özellik, numunenin fiziksel ve kimyasal bileşimi hakkında detaylı bilgi sağlar ve spektral özelliklerin uzaysal dağılımını görselleştirmeye olanak tanır (He vd., 2020). Dataküp veya hiperküp olarak adlandırılan hiperspektral görüntü veri yapılarını oluşturmak için nokta tarama, çizgi tarama ve alan tarama metotları kullanılmaktadır. Meyve, sebze, et gibi gıdalarda rutubet, toplam kuru madde, pH, fiziksel yapı gibi özellikleri analiz etmede başarılı bir yöntemdir (Balkir vd., 2019).

1.1.6.6. Moleküler Yöntemler (Poliemeraz Zincir Reaksiyonu, PCR)

DNA temelli yaklaşımlar, özellikle et ve işlenmiş et ürünlerinde hayvan türlerini belirlemek için sıklıkla kullanılmıştır (Onay, 2010). Kullanılan örneklerin DNA'sının yüksek sıcaklıklarda bozulmaması (Kahraman, 2015) ve stabil olması bu yöntemin tercih edilmesine sebep olmuştur. Polimeraz zincir reaksiyonu olarak bilinen PCR, DNA'nın

kopyalanarak çoğaltılması olayıdır (Yeşilören & Ekşi, 2014). Et ve et ürünlerinde yabancı ve katkı maddelerinin ayırt edilmesinde, yağların saflığının ölçülmesinde güvenilir ve hassas bir yöntem olarak karşımıza çıkmaktadır (Gryzinska, 2019).

1.1.6.7. Elektronik Teknikler

Elektronik burun- elektronik dil sistemleri, biyolojik materyallerden yayılan uçucu bileşenlere dayalı olarak çalışır ve bu nedenle gıda sektörü, çevre kontrolü, insan sağlığı gibi çeşitli alanlarda kullanılmaktadır. Bu yöntem, beyindeki koku-tat algılama mekanizmasına benzer şekilde işler. Elektronik burun sistemi, farklı özelliklerin belirlenmesine yardımcı olan sensörlerden, sinyal toplama biriminden ve örnek tanımlama yazılımından oluşur (Yeşilören & Ekşi, 2014). Gıda analizlerinde kullanılan elektronik burun sistemi, örneklerin analiz için gruplandırılması ve her bir örneğin laboratuvar analizlerinin bir kısmının yapılması için ayrılmasını içerir (Adak, 2016). Yapay sinir ağları ile kullanılan modellerde yapay sinir ağı modeli ne kadar sağlıklı eğitilir ve örneklendirilirse uygulamadaki veri sonuçları o kadar sağlıklı olmaktadır (Yeşilören & Ekşi, 2014) Et ve süt ürünlerinin taşıyıcı tespitinde sıklıkla kullanılmaktadır (He vd., 2021).

1.1.6.8. Bilgisayarlı Görüntüleme

Gıdaların işleme ve depolanma süreçlerinin izlenebilmesi ve güvenlik sağlanabilmesi için fiziksel, kimyasal, duyuşal, mikrobiyolojik ve toksikolojik özelliklerin takip edilebildiği analitik yöntemlerin tercih edilmesi, tüketiciler tarafından daha çok tercih edilen gıdaların oluşturulmasında önemli bir rol oynamaktadır. Bu nedenle, uygulanacak analitik yöntemlerin seçimi, söz konusu özellikleri belirleme açısından büyük önem taşımaktadır (Yeşilören & Ekşi, 2014). Bu bağlamda, hızlı ve güvenilir bir yöntem olan bilgisayarlı görüntüleme modern gıda endüstrisinde tahıllar, meyve ve sebzeler, süt, et ve deniz ürünleri gibi birçok işlenmiş ürünün kontrolünde geniş bir kullanım alanı bulmuştur (Balkir vd., 2019). Biyolojik görmenin bir simülasyonu olan bilgisayarlı görme numunelerin şekil, boyut, konum vb. özelliklerini hızlı ve güvenilir şekilde tahmin edebilir (He vd., 2021).

1.2. Problemin Tanımı

Gıda güvenliğinde taşıyıcı günümüzde küresel bir sorun (Li vd., 2020) olarak devam etmekte ve insanlığa maddi manevi zarar vermektedir. Her insanın güvenli gıdaya ulaşma

hakkı olduğunu düşündüğümüzde, taklit ve tağşişe uğramış ürünlerin, doğru ve güvenli yollarla tespit edilebilmesi önemli bir husus halini almaktadır.

Antep fıstığı ülkemizde ve dünyada sınırlı olarak yetişen, besin değerleri yüksek ve ihracatı ile ülkeye önemli oranda getirisi olan bir üründür. Güvenli gıda kapsamında Antep fıstığı ve öğütülmüş formlarının en doğal ve kaliteli haliyle tüketiciye sunulması önemlidir. Ancak ticari açıdan büyük öneme sahip olması sebebiyle piyasada önemli oranda sahte ve tağşişe uğramış birçok ürün bulunmaktadır. Bu sebeple ürünlerdeki tağşişin hızlı, nesnel ve otomatik olarak değerlendirilebilmesi ihtiyaç halini almıştır.

1.3. Araştırma Soruları

Soru1: Tağşiş edilmiş Antep fıstığı örnekleri nasıl elde edilir?

Soru2: Antep fıstığı görselleri üzerinden geleneksel yöntemle nasıl sınıflandırma yapılabilir?

Soru3: Geleneksel yöntem dışında modern sınıflandırma ile yüksek hız ve doğrulukla tağşiş tespiti yapılabilir mi?


1.4. Amaç

Bu tez çalışmasında gıda güvenliği açısından kritik öneme sahip tağşişin otomatik ve güvenli olarak tespiti amaçlanmaktadır. Literatürde tağşiş tespiti ile ilgili birçok yöntem bulunsa da bu çalışmada Antep fıstığı örneği üzerinden benzersiz bir veri seti oluşturularak, bu veri seti ile tağşişin ve oranlarının tespiti için güvenilir bir yöntem hedeflenmektedir.

2.SAYISAL GÖRÜNTÜ İŞLEME

Görüntü işleme, kaydedilmiş olan dijital görüntü verilerini bilgisayar algoritmaları ve matematiksel işlemler kullanarak veri analizi yapmak ve anlamlı sonuçlar elde etmek için amaca uygun şekilde değiştirmeye yarayan işlemler bütünüdür. Görüntü işlemenin temel amacı, görüntü üzerindeki istenmeyen bozulmaları azaltmak ve sonraki aşamalarda kullanılmak üzere görüntüyü hazırlamak, aynı zamanda görüntü özelliklerini iyileştirerek veri kalitesini artırmaktır (Hayıt, 2021).

Görüntüleri işleyebilmek için verilerin bilgisayar ortamına uygun hale getirilmesi yani sayısallaştırılması gerekmektedir (Karakoç, 2011). Sayısallaştırma, görüntünün her biri belirli bir konum ve değere sahip olan ve piksel adı verilen öğelerin sonlu sayısından oluşması işlemidir. Analog bir görüntü veya resim, genellikle $I(x, y)$ gibi bir fonksiyonla temsil edilir, burada I bir şiddet birimi (örneğin parlaklık) temsil ederken, x ve y değişkenleri ise görüntünün yatay ve dikey eksenindeki koordinatlarına karşılık gelen değerleri ifade eder. (Karakoç, 2011) Sayısal bir görüntü ise bu analog görüntünün örneklenerek her satır ve sütunun 0-255 arasında değer aldığı $m \times n$ boyutunda bir matrisle dönüşmesi ile oluşturulur. Görüntüler, pikselleri 0 ve 1'den oluşan siyah-beyaz, gri tonlardan oluşan ve parlaklık bilgisi içeren gri tonlamalı ve RGB (Red, Green, Blue) üç kanaldan oluşan renkli görüntüler olmak üzere 3 formatta olabilir (Perihanoğlu, 2015).



Şekil 2.1. Sayısallaştırılmış renkli görüntü (Kaynak: Kavuncu vd., 2018)

Görüntünün sayısallaştırılmasından sonra görüntü ön işleme ve özellik çıkarma işlemleri yapılabilir. Görüntü ön işleme, mevcut sayısal görüntüyü kullanırken daha iyi sonuç elde edebilmek için görüntünün iyileştirilmesi işlemlerini içermekte ve bu adımda kontrast ayarları, histogram eşitleme ve çeşitli morfolojik işlemler yapılmaktadır. Orijinal görüntü

üzerinde yapılan görüntü ön işleme sürecinden sonra artık veri özellik çıkarma işlemleri için uygun hale gelmektedir (Samtaş & Gülesin, 2011).

Sayısal görüntü işleme, yapay zekânın ilk adımı olarak kabul edilir. Bu nedenle görüntü işleme; yapay zekâ, makine öğrenmesi ve derin öğrenme yöntemleriyle sıkı bir şekilde ilişkilidir. Görüntü işleme ve yapay zekâ birlikte gelişen ve özellikle son yıllarda birçok alanda bir arada kullanılan teknolojilerdir. Bu teknolojiler tıp, biyomedikal, askeri endüstri, meteoroloji, coğrafya, radar, güvenlik, gıda, hayvancılık, robotik, uzaktan algılama (Başaran vd., 2023) gibi birçok alanda zamandan tasarruf ederek daha hızlı ve güvenilir çalışmalar yapılmasına olanak sağlamıştır. Şekil 2.2’de görüntü işlemenin ilişkili olduğu ve kullanıldığı alanlar gösterilmiştir.



Şekil 2.2. Görüntü işlemenin kullanıldığı alanlar (Kaynak: Görentaş vd., 2023)

2.1. Görüntü İşleme Teknikleri

Görüntü işleme teknikleri, dijital görüntüler üzerinde bilgisayar destekli analiz ve manipülasyon işlemlerini ifade eden önemli bir araştırma alanını oluşturmaktadır.


2.1.1. Parlaklık Dönüşümleri / Parlaklık Düzeltmeleri

Parlaklık dönüşümleri veya parlaklık düzeltmeleri, bir görüntünün genel parlaklık düzeyini ayarlamak veya belirli bölgelerdeki parlaklık farklılıklarını düzeltmek için kullanılır.

2.1.1.1. Histogram Eşitleme

Histogram eşitleme görüntü üzerinde düzgün dağılmamış olan parlaklık değerlerini eşitlemek için kullanılan ve görüntüyü iyileştirmeye yönelik yapılan bir kontrast düzeltme işlemidir. Görüntünün tümüne ya da bir kısmına uygulanabilen bu yöntem ile görüntünün olasılık dağılım fonksiyonu doğrusallaştırılmaktadır (Perihanoğlu, 2015). Böylelikle yoğunluk dağılımı normalize edilerek daha düzgün yoğunluk dağılımına sahip görüntü elde edilerek iyileştirme yapılmış olur (Burçin vd., 2010).

Histogram eşitlenirken görüntüdeki her gri tonun piksel sayısını gösteren histogramı bulunur. Daha sonra her gri tonun, kendisinden önceki tonların toplamıyla elde edilen değerleri içeren kümülatif histogram bulunarak değerleri normalize edilir, yani toplam piksel sayısına bölünerek, daha sonra bu değerler maksimum renk değerleriyle çarpılır ve sonuçlar tam sayıya yuvarlanır. Bu adım, yeni görüntüdeki gri seviyelerinin belirlenmesini sağlar. Orijinal gri seviyeli değerler ile üçüncü adımda elde edilen gri seviye değerleri karşılıklı olarak eşleştirilir ve yeni bir histogram elde edilerek (Perihanoğlu, 2015) histogram eşitlenir. Şekil 3.1 de histogram eşitleme uygulanmış bir fotoğraf ve histogram grafikleri gösterilmektedir.



Şekil 3.3. Histogram eşitleme yönteminin bir görüntüye uygulanması ve sonucu; (a) orijinal görüntü, (b) histogram eşitleme uygulanmış görüntü, (c) orijinal görüntünün histogramı, (d) histogram eşitleme uygulanmış görüntünün histogramı (Anonim).

2.1.1.2. Gama Düzeltme

Gama düzeltme işlemi, piksel değerlerine bireysel olarak doğrusal olmayan bir ayarlama uygulayan, görüntüde her bir piksel üzerinde doğrusal işlemler gerçekleştirirken, kaynak pikseller üzerinde doğrusal olmayan bir işlem yapan ve görüntünün doygunluğunu iyileştiren bir tekniktir. İnsan gözü, koyu renklere daha duyarlı bir yapıda olduğundan kamera sensörleri ile insan gözünün hassasiyeti arasındaki farkı dengelemek için gama düzeltmesi uygulanabilir (Hayıt, 2021). Bu teknik, fotoğrafçılık, görüntü işleme, televizyon yayıncılığı ve bilgisayar grafikleri gibi alanlarda sıkça kullanılır. Gama düzeltme, görüntülerin daha doğal ve gerçekçi bir görünüm kazanmasına yardımcı olurken, aynı zamanda görüntüyü daha kolay okunabilir hale getirir (Katırcıoğlu, 2021).

2.1.2. Görüntü Bölütleme (Segmentasyon)

Görüntü bölütleme veya segmentasyon, dijital bir resmin anlamlı bölgelere ayrılması işlemidir, her bir bölge kendi içinde belirli özelliklere sahiptir (Perihanoğlu, 2015). Bu işlem, görüntüdeki farklı nesneleri veya yapıları ayırmak arka plandan soyutlamak için kullanılır.

Segmentasyon işlemi, bir görüntüdeki farklı nesne veya özelliklerin sınırlarını, toplam alanlarını veya şekillerini belirleyerek ham verilerin analiz edilmesini sağlar (Başaran vd., 2023). Bu sayede, görüntü içindeki farklı bileşenlerin daha iyi anlaşılması ve işlenmesi mümkün olur. Bağlamsal bölütleme ve bağlamsal olmayan bölütleme olmak üzere ikiye ayrılan bu teknikte bağlamsal olmayan bölütleme basit piksellerin birbiriyle ilişkisi olmayan bölütlemedir ve gri seviye değerleri gibi basit özellikler dikkate alınmaktadır. Bağlamsal bölütlemeye ise piksel yakınlıkları hesaba katılarak yapılır ve daha başarılı bir yöntemdir.

2.1.3. Filtreleme

Sayısal görüntülerdeki detayların vurgulanması veya bastırılması, kenar tespiti, gürültünün azaltılması ve olumsuz etkilerin giderilmesi için kullanılan görüntü işleme yöntemi olan görüntü filtreleme, farklı fiziksel özellikler arasındaki ayrımı artırarak görsel yorumlanabilirliği artırır. Bu yöntemde, her piksel için yeni gri tonları hesaplanır ve renkli görüntüler gri tonlu hale getirildikten sonra filtreleme işlemine tabi tutulur (Çelikdemir vd., 2014).

Filtreleme temel olarak görüntü içerisindeki hatalı ya da çevre koşullarından kaynaklı bileşenleri yok etmek için kullanılsa da görüntü yumuşatma, kenar keskinleştirme, kenar yakalama gibi farklı görüntü filtreleme operatörleri de bulunmaktadır. Medyan filtre, Gauss filtresi, Laplace operatörü en çok bilinen ve kullanılan filtreler arasındadır (Perihanoğlu, 2015).

2.1.4. Geometrik Dönüşümler

Matematiksel morfoloji, küme teorisi, topoloji ve rastgele fonksiyonları temel alarak geometrik yapılar üzerinde analiz ve işlemler gerçekleştiren bir yöntemdir. Bu yöntem, topolojik ve geometrik kavramlarla birlikte devamlılık, boşluk, şekil, ayrıklık, birleşiklik, dışbükeylik, içbükeylik ve uzaklık gibi özellikleri karakterize eder. Matematiksel morfoloji, görüntüdeki belirli nesneleri diğer bölgelerden veya nesnelerden ayırmak için kullanılır (Perihanoğlu, 2015).


Geometrik fonksiyonlar, bir görüntü üzerinde genişleme, daralma, eğme ve döndürme gibi işlemleri gerçekleştiren matematiksel fonksiyonlardır. Bu tür dönüşümler, çeşitli uygulamalarda kullanılmakta olup, örneğin görüntülerin duvarlara yerleştirilmesi veya nesne tanıma algoritmalarının eğitim setlerinin genişletilmesi gibi amaçlarla kullanılabilirler. Geometrik dönüşümler sonucunda görüntünün içeriği değişmese de piksel ızgaralarının şekilleri değişir ve böylece görüntünün görünümü değişir (Doğan vd., 2020).

2.1.5. Renk Dönüşümleri

Renk uzayları, görüntü işleme ve grafik tasarım alanlarında renklerin sayısal olarak temsil edilmesi ve işlenmesi için kullanılan koordinat sistemleridir. Bu uzaylar, renkleri matematiksel olarak tanımlayarak, farklı renkler arasındaki ilişkileri ve uzaklıkları belirler. Örneğin, RGB, CMYK, HSL ve Lab gibi yaygın renk uzayları, belirli renkleri tanımlamak için kullanılan standart sistemlerdir ve farklı uygulama alanlarına yönelik gereksinimleri karşılamak üzere tasarlanmıştır. Bu renk uzayları, görüntü oluşturma, renk düzeltme, baskı ve diğer görsel işlemlerde geniş bir kullanım alanına sahiptir (Pişkin, 2016). Renk uzayı dönüşümleri, akademik çalışmalarda, renklerin analizi, karşılaştırılması ve uyumlanması, renk doğruluğu, renk düzeltilmesi, nesne tanıma ve sınıflandırma, renk duyarlılığı analizi gibi çeşitli amaçlar için yaygın olarak kullanılmaktadır (Göçeri & Yaldir, 2007). Bu bağlamda renk dönüşümleri farklı çalışmalarda farklı özellik çıkarımları ve daha sonraki bilgisayarlı görü çalışmaları için daha uygun materyal elde etmekte kullanılmaktadır.

3. MAKİNE ÖĞRENİMİ

Doğadaki varlıkların akıllı davranışlarını taklit etmeyi hedefleyen yapay zekâ çalışmaları, canlı sistemlerin ve insan beyninin model alındığı bir yaklaşımı benimser. Bu çalışmalar, günlük yaşamın çeşitli alanlarında ürünlerin geliştirilmesinin yanı sıra, tahmin, sınıflandırma, kümeleme gibi amaçlar için de kullanılmaktadır. Uzman sistemler, genetik algoritmalar, bulanık mantık, yapay sinir ağları ve makine öğrenmesi gibi teknikler, genel olarak yapay zekâ teknolojileri olarak adlandırılmaktadır (Atalay & Çelik, 2017). Şekil 3.1’de yapay zeka, makine öğrenimi ve derin öğrenme arasındaki ilişkiyi gösteren şema verilmiştir.



Şekil 3.1. Yapay zekâ şeması (Kaynak: Gökalp, 2022)

Makine öğrenimi (Machine Learning, ML), yapay zekanın bir alt kümesidir ve bir yazılımın deneyimlerden öğrenmesini ve belirli bir görevde kendini geliştirmesini sağlama çabasıdır. Bu yaklaşım, minimum insan müdahalesi ile açık bir şekilde programlanmadan öğrenme yeteneği vererek, makinelerin davranışlarında ve karar verme yetilerinde insan benzeri bir gelişim sağlama amacıyla uygulanır (Hayıt, T., 2021). Verinin büyük miktarlarda elle işlenmesinin ve analizinin pratik olmaması, gelecekteki tahminlerin yapılabilmesi amacıyla Makine Öğrenmesi yöntemlerinin geliştirilmesine yol açmıştır. Bu yöntemler, geçmiş verilerden yeni veriler için en uygun modelin belirlenmesine odaklanırken, Veri Madenciliği ise bu verilerden anlamlı bilgilerin çıkarılmasını hedefler (Diri, B., 2014). Genellikle verilerin elde edilmesi, veri setinin hazırlanması, model seçimi, eğitim, değerlendirme, parametre ayarlama ve tahmin olmak üzere 7 aşamadan oluşur (Hayıt, 2021).

3.1. Makine Öğrenimi Yaklaşımları

3.1.1. Denetimli Öğrenme

Makine öğrenimi alanında en yaygın ve popüler yöntem olan denetimli öğrenmede, her eğitim örneği bir girdiye karşılık gelen bir çıktı etiketiyle ilişkilendirilir. Sistemi eğitmek için bu etiketli veriler kullanılır ve sistemin belirli bir görevi öğrenmesi sağlanır ve bir eğitim veri seti oluşturulur. Algoritma, bu eğitim veri seti üzerinde öğrenir ve daha sonra yeni veriler üzerinde sınıflandırma ve regresyon gibi yöntemler kullanılarak tahminler yapılır (Gökalp, Ö.M., 2022). En Yakın Komşu, Naive Bayes(NB), Karar Ağaçları (DT), Doğrusal Regresyon (LR), Destek Vektör Makineleri (SVM) ve Yapay Sinir Ağları (ANN) gibi algoritmalar, genellikle sınıflandırma problemlerinde yaygın olarak kullanılan denetimli öğrenme algoritmalarıdır. Bu algoritmalar, veri kümesindeki desenleri tespit etmek ve tahmin yapmak için modeller oluştururlar (Şenol vd., 2021).

3.1.2. Denetimsiz Öğrenme

Denetimsiz makine öğrenimi algoritmaları, genellikle kümeleme algoritmaları olarak adlandırılır ve herhangi bir verinin sınıf etiketlerini bilmeyi gerektirmez. Veri kümesindeki öğelerin benzerliklerine dayanarak veri kümesini farklı kümeler halinde ayırır ve bu sayede yapılandırılmamış verilerden anlamlı desenler ve ilişkiler çıkarılabilir (Şenol vd., 2021). Bu yaklaşımda, etiketlenmemiş verilerdeki içgörülerini ve ilişkileri keşfetmek amacıyla eğitim verilir. Etiketsiz verilerden elde edilen bilgiler, sistem tarafından anlaşılması, tanımlanması ve keşfedilmesi için kullanılır. Bu nedenle, sistemden beklenen sonuçlar önceden bilinmemektedir. Eğitim ve denetim dışı verilerden elde edilen sonuçlar, modelin doğru cevaplarla eğitilmemiş olduğunu ve kendi başına desenleri bulması gerektiğini gösterir (Gökalp, 2022). En yaygın kullanılan denetimsiz öğrenme algoritması K-Means Algoritması (Yiğidim, 2012) gibi genellikle kümelemede kullanılırlar.

3.1.3. Yarı denetimli Öğrenme

Yarı-denetimli öğrenme hem etiketlenmiş hem de etiketlenmemiş örneklerin birlikte incelenerek uygun fonksiyon ve sınıflandırıcıların oluşturulduğu (Yiğidim, 2012) bir öğrenme yaklaşımıdır. Bu yöntem, etiketlenmiş verilerin modelin performansını artırmada önemli bir rol oynadığı bilgisinden yararlanırken, denetimli ve denetimsiz makine öğrenme algoritmaları arasında seçim yapmaksızın veri kümesini işleme imkânı sunar. Yarı-denetimli SVM, Kendi Kendine Eğitim ve Ortak Eğitim gibi algoritmalar bu yaklaşıma

örnek olarak gösterilebilir; konuşma analizi, internet içeriği sınıflandırması ve protein dizisi sınıflandırması gibi çeşitli alanlarda kullanılmaktadır (Şenol vd., 2021).

3.1.4. Pekiştirmeli Öğrenme

Pekiştirmeli öğrenme yaklaşımında, makine öğrenme modeli, davranışlarını pekiştirme araçlarına veya geri bildirimlere dayalı olarak şekillendirmek için eğitilir. Karmaşık ve belirsiz durumlarda sonuç elde etmeyi öğrenen makine, bu süreçte hedefe ulaştıkça pekiştirilir. Denetimli öğrenmeden farklı olarak, takviyeli öğrenmede çıktılar doğrudan verilmez; pekiştirme aracı, bir görevi gerçekleştirme adımlarının belirlenmesinde karar mekanizmasını temsil eder. Makine, eğitim verileri olmadığında kendi deneyimlerinden yararlanarak hareket eder (Hayıt, 2021). Algoritma, gerçek dünya algısına dayalı bir öğrenme biçimini benimser ve işlemlerini bu temelde gerçekleştirir. Her bir eylem, çevresel etkileşimlerin bir sonucu olarak ortamda belirli bir etkiye yol açar ve bu etkileşimler, öğrenme algoritmasına yön veren geri bildirimler sağlar (Yiğidim, 2012).

3.2. Makine Öğreniminde Sınıflandırma


Makine öğrenimi, sınıflandırma alanında, veri kümesindeki örneklerin belirli sınıflara atanması için kullanılan bir dizi algoritma ve teknikler bütünüdür. Bu algoritmalar ve teknikler, veri özelliklerini analiz ederek örnekleri farklı sınıflara ayırmak için bir model oluşturur (Ersöz & Çınar, 2021).

3.3. Sınıflandırma Algoritmaları

3.3.1. K-en Yakın Komşu Algoritması

K-en yakın komşu (KNN: K-Nearest Neighbors) algoritması, genellikle sınıflandırma ile regresyon problemleri için kullanılan temel bir örnek tabanlı denetimli makine öğrenmesi algoritmalarından biridir. Öğrenme süreci, eğitim setinde bulunan örnek verilere dayanan bu öğrenme yaklaşımında yeni bir örnek karşılaştığında, bu örnek, eğitim setindeki örneklerle olan benzerliğine göre sınıflandırılır (Taşcı & Onan, 2016). Özellikle küçük veri kümeleri ve belirgin sınıf ayrımlarının olduğu durumlarda etkili bir şekilde çalışır. KNN, sınıflandırılacak yeni bir örnek ile eğitim kümesindeki örnekler arasındaki uzaklıkları ölçerek en yakın k tane komşunun sınıf değerlerini kullanarak sınıflandırma işlemini gerçekleştirir. Öklid, Manhattan ve Minkowski uzaklık ölçüm formülleri genellikle bu amaçla kullanılır. KNN algoritması regresyon problemlerinde ise veri noktasına en yakın k komşusunu hesaplayarak bu komşulara ait hedef değerlerinin

interpolasyonunu yaparak tahminde bulunur. Optimum k değerin seçimi, k değerin belirli aralıklarda test edilmesini gerektirir (Hacıbeyoğlu vd., 2023).




Şekil 3.2. $k=5$ için KNN sınıflandırıcısı (Kaynak: Sanal Kumar & Bhavani, 2017)

Ancak, sınıflandırma performansı, k değerin seçimi, mesafe ölçüleri gibi faktörlerden etkilenebilir (Zhang vd., 2017). Hesaplama süresi hızlı, basit yapısı, kısa sürede doğrulukla çalışması gibi avantajlara (Hayıt, 2021) sahiptir.

3.3.2. Destek Vektör Makineleri

Destek Vektör Makineleri (Support Vector Machine:SVM), iki sınıf arasında ayırıcı bir hiper düzlem bulma amacıyla güçlü bir sınıflandırıcı olarak kullanılır. SVM, doğrusal olarak sınıflandırılabilen veri kümelerinde birden fazla ayırıcı hiper düzlemin olabileceğini belirtir. Temel amacı maksimum marjine sahip bir hiper düzlem belirlemektir. SVM sınıflandırıcısı, doğrusal olmayan sınıflandırma problemlerini çözmek için çekirdek fonksiyonlarını kullanabilir. Çekirdek fonksiyonları, giriş vektörlerini yüksek boyutlu bir uzaya taşımak için kullanılır, böylece giriş uzayında doğrusal olarak ayrılamayan veriler, genişletilmiş uzayda doğrusal olarak sınıflandırılabilir hale gelir. Bu özellik SVM'nin çok çeşitli veri kümesi tiplerinde etkili bir şekilde kullanılmasını sağlar (Gezer, 2023).




Şekil 3.3. SVM hiper düzlemi ve maksimum marjini (Kaynak: Sanal Kumar & Bhavani, 2017).

SVM'nin en büyük avantajı hem doğrusal hem de doğrusal olmayan sınıflandırmaları başarılı bir şekilde gerçekleştirmesidir (Sanal Kumar & Bhavani, 2017).

3.3.3. Karar Ağaçları

Karar ağaçları (Decision Trees:DT), sınıflandırma ve örüntü tanımlama alanında yaygın olarak kullanılan (Kavzoğlu vd., 2010), önemli bir veri madenciliği yöntemidir (Hayit, 2021). Bu yöntemin popülerliğinin temel nedeni, ağaç yapısını oluşturmak için kullanılan kuralların anlaşılabilir ve basit olmasıdır. DT, genellikle çok aşamalı veya ardışık bir yaklaşımı benimseyerek sınıflandırma işlemini gerçekleştirir (Kavzoğlu vd., 2010).

Karar ağacı oluşturma işlemi, genellikle tüm veri kümesiyle başlar. Daha sonra, bir özelliğin bir değerine göre veri kümesi iki alt kümeye bölünür. Bu bölme işlemi sırasında kullanılan özellikler ve değerler karar düğümlerine yerleştirilir. Ardından, her alt küme için aynı prosedür uygulanır ve her alt kümede sadece tek bir sınıfa ait örnekler kalıncaya kadar işlem tekrarlanır. Bu şekilde, karar ağacı adım adım oluşturulur, veri kümesi alt kümelerine ayrılır ve sonunda sınıflandırma işlemi tamamlanır (Diri, 2014).



 ekil 3.4. D rt boyutlu  zellik uzayına sahip    sınıftan olu an bir karar a acı (Kaynak: Kavzo lu vd., 2010).


Karar a a larının olu turulması, dallanmanın hangi kritere veya  znitelik de erlerine g re yapılaca ına karar vermekle ba lar. Bu karar,  e itli yakla ımlar kullanılarak belirlenir. Literat rdeki  nemli yakla ımlardan biri bilgi kazancı ve bilgi kazanç oranıdır. Bu yakla ım, her dallanma adımımda bilgi kazancını hesaplayarak en bilgi verici  zniteli i se er (de Ville, 2013). Gini indeksi yakla ımı ise dallanmanın homojenli ini  l er ve en homojen dallanma noktasını belirler. Towing kuralı ve Ki-Kare olasılık tablo istatisti i de di er yaygın kullanılan y ntemler arasındadır. Bu y ntemler, veri k mesinin yapısına ve problemin gerekliliklerine ba lı olarak farklılık g sterebilir. Karar a a larının olu turulmasında do ru yakla ımın se ilmesi, modelin do rulu unu ve etkinli ini belirlemede  nemli bir rol oynar (Akpınar & Dili, 2007).

DT; sonu larının kolay yorumlanabilmesi ve anlaşılır olması, do rusal olmayan verileri modelleyebilmeleri,  e itli problemlerde etkin olabilmeleri ve eksik veya aykırı verilerle ba a  ıkabilmeleri y nlerinden avantajlıdırlar.

Ancak b y k ve karma ık veri k meleriyle  alı ırken, karar a a ları aşırı uyum (overfitting) e ilimindedirler. Ayrıca, veri dengesizli i durumunda, yani sınıflar arasında belirgin bir dengesizlik oldu unda, karar a a ları do ru sonu lar  retmekte zorlanabilirler ve genelleme yetenekleri azalır. Ayrıca di er makine   renimi modellerine kıyasla daha az hassas sonu lar verebilirler (Alta  vd., 2012). Bu nedenle, veri k mesinin  zelliklerine ve problem gereksinimlerine ba lı olarak, karar a a larının avantajları ve dezavantajları dikkate alınarak uygun bir model se ilmelidir.

3.3.4. Yapay Sinir Ağları

Yapay Sinir Ağları (Artificial Neural Networks: ANN), özellikle doğrusal olmayan, çok boyutlu, gürültülü ve karmaşık veri setlerinde başarı sağlayan bir veri madenciliği tekniğidir (Altaş vd., 2021). ANN, insan beyninin çalışmasını modelleyen şekilsel ve işlevsel olarak onu taklit eden (Atalay & Çelik, 2017) biyolojik sinir sisteminin basit bir simülasyonu olarak kabul edilebilir. Biyolojik sinir sistemleri, milyarlarca sinir hücresinden oluşan karmaşık ağlarla karakterizedir. Bu sinir hücreleri arasındaki bağlantılar, doğal bir sinir sistemi oluşturur ve insan beyni de bu karmaşık yapıya sahiptir. İnsan beyninin öğrenme ve çıkarım yetenekleri, yapay sinir ağları (ANN) modellerinin tasarlanmasında ilham kaynağı olmuştur (Hayıt, 2021). Bu bağlamda, yapay sinir ağları doğal sinir sistemlerine dayalı olarak geliştirilmiş güçlü bir yapay zekâ aracıdır. Biyolojik sinir hücresi ve yapay sinir ağı benzetimleri Şekil 3.5'te, biyolojik sinir sistemi elemanları ve yapay sinir sisteminde karşılıkları tablo 3.1'de verilmiştir.



Şekil 3.5. Biyolojik Sinir Hücresi ve Yapay Sinir Ağı (Kaynak: Öztürk & Şahin, 2018)

Tablo 3.1. Biyolojik sinir sistemi elemanları ve yapay sinir sisteminde karşılıkları

Biyolojik Sinir Sistemi	Yapay Sinir Sistemi
Nöron	İşlemci Elemanı (Yapay Nöron)
Dentrit	Toplama Fonksiyonu
Hücre Gövdesi	Transfer Fonksiyonu
Aksonlar	Yapay Nöron Çıkışı
Sinapslar	Ağırlıklar

Yapay sinir ağlarında, biyolojik sinir ağlarındaki nöronlara karşılık gelen yapay sinir hücreleri bulunur. Her bir yapay sinir hücresi, girdileri, ağırlıkları, toplama fonksiyonunu, transfer fonksiyonunu ve çıktıyı içeren temel bileşenlerden oluşur. Bu yapay sinir hücreleri, katmanlar halinde bir araya gelerek yapay sinir ağını oluşturur. Yapay sinir ağında genellikle üç tür katman bulunur: girdi katmanı, çıktı katmanı ve ara katman(lar). Her bir katmandaki nöron sayısı, bağımsız ve bağımlı değişkenlerin sayısına bağlıdır. Ara katmanlardaki nöron sayısı ve katman sayısı ise kullanıcı tarafından belirlenerek en iyi performans elde edilir. Bu yapı, yapay sinir ağlarının esnek ve ölçeklenebilir olmasını sağlar, çünkü ağın mimarisi ve bileşenleri, belirli bir problem veya veri setine uyacak şekilde kolayca ayarlanabilir (Atalay & Çelik, 2017).


3.3.4.1. Yapay Sinir Ağları Elemanları

Girdiler: Bir yapay sinir hücresine, dış dünyadan gelen ve ara katmanlara iletmek üzere rastgele alınan bilgilerdir (Altaş vd., 2021).

Ağırlıklar: Ağırlıklar, yapay sinir hücresine gelen bilginin önemini ve hücre üzerindeki etkisini belirleyen uygun katsayılardır. Her bir girişin yapay sinire güçlü veya zayıf bağlanmasını temsil ederler. Ağırlıkların büyüklüğü, girişin sinire olan etkisini belirler; büyük ağırlıklar güçlü bağlantıyı, küçük ağırlıklar ise zayıf bağlantıyı ifade eder. Bir ağırlığın sıfır olması, ilgili girişin sinir hücresine herhangi bir etkisinin olmadığını gösterirken, eksi değerler önemsiz olmadığı gibi ağırlıkların artı veya eksi olması, etkinin pozitif veya negatif olduğunu belirtir. Ağırlıklar değişken veya sabit değerler alabilirler (Koltan Yılmaz, 2017)

Toplama Fonksiyonu: Toplama fonksiyonu, bir yapay sinir hücresine gelen tüm girdilerin, bu girdilere ilişkin ağırlıklarla çarpılması sonucunda elde edilen ağırlıklı toplamı hesaplar. Bu toplama işlemi, her bir girdinin ağırlığı ile çarpıldıktan sonra elde edilen değerlerin toplanmasıyla gerçekleştirilir. Sonuç olarak, toplama fonksiyonu, sinir hücresinin içindeki işlemlerde önemli bir rol oynar ve girdi sinyallerinin etkilerini bir araya getirerek sinir hücresinin çıktısını belirler (Öztürk & Şahin, 2018).

Aktivasyon Fonksiyonu: Aktivasyon fonksiyonu, bir yapay sinir ağının içindeki nöronların etkileşim düzeyi ile çıktı arasındaki ilişkiyi tanımlar. Bu fonksiyon, nöronun aldığı toplam girdiye dayanarak nöronun ne kadar "aktif" olduğunu belirler. Doğrusal veya doğrusal olmayan ilişkileri ifade edebilir ve ağın işleyişini belirlemek için özel olarak seçilmiş bir etkinleştirme fonksiyonu kullanılır. Etkinleştirme fonksiyonu olmaksızın, çok katmanlı ağlarda çıktı değerleri genellikle çok büyük olabilir, bu da ağın performansını olumsuz yönde etkileyebilir (Sayın & Yakar, 2018). Bu nedenle, etkinleştirme fonksiyonu, nöronların çıktılarını uygun bir şekilde sınırlayarak anlamlı çıktı değerleri oluşturmaya çalışır.



Şekil 3.6. Yapay sinir ağlarında kullanılan başlıca aktivasyon fonksiyonları (Kaynak: Hayıt, 2021)


Çıktılar: Aktivasyon fonksiyonu tarafından belirlenen başka bir hücre veya dışarıya gönderilen çıktılar, sinir ağının çeşitli katmanları arasında iletilir ve sonuç üretilir. Bir hücreye ait sadece bir çıktı bulunmaktadır (Koltan Yılmaz, 2017).

3.4.4.2. Yapay Sinir Ağlarının Yapısı

Yapay Sinir Ağları ANN, yapay sinir hücrelerinin bir araya gelmesiyle oluşan bir sistemdir. Bu hücrelerin gruplanmasıyla katmanlar oluşturulur ve ANN, bu katmanlar arasında bağlantılarla şekillenir (Koltan Yılmaz, 2017). ANN 'nin temel yapısı, girdi katmanından alınan gerçek dünya verilerinden başlayarak, çıktı katmanına kadar olan süreci yöneten ve bu süreci işleyen birbirine bağlı katmanlardan oluşur. Genellikle girdi, çıktı ve ara katmanlardan oluşan bu yapının ara katmanlarında, veri işleme ve çıktı üretimi gerçekleştirilir. Bu katmanlar, gerçek dünya verilerini alıp işleyerek istenen sonuçları üreten bir yapı oluşturur (Akkaya vd., 2007).

3.4.4.3. Mimarilerine Göre Yapay Sinir Ağları

İleri Beslemeli Yapay Sinir Ağları: İleri beslemeli yapay sinir ağı mimarisinde, hücreler katmanlar halinde düzenlenir. Bu mimaride, girdi katmanı, orta (gizli) katman veya katmanlar aracılığıyla çıktı katmanına bağlanır. Veri, ağı içinde girdi katmanından çıktı katmanına doğru bir akış içinde ilerlemelidir. Yani, bir katmandaki hücreler, ardışık gelen katmandaki hücrelerle bağlantı kurarlar.




Şekil 3.7. İleri Beslemeli Sinir Ağı Yapısı (Kaynak: Öztemel, 2006)

Bu nedenle, aynı katmandaki hücreler arasında doğrudan bağlantı olmadığı için, veri akışı sadece ileriye doğru gerçekleşir. İlk örneklerinden biri olan Perceptron ve Adaline ağları, bu mimarinin temel örnekleridir. Bu ağlar, girdi katmanından başlayarak orta katmanlar aracılığıyla çıktı katmanına kadar olan ileriye doğru veri akışını sağlarlar.

Geri Beslemeli Yapay Sinir Ağları: Geri beslemeli yapay sinir ağı mimarisinde, ileri beslemeli yapay sinir ağlarından farklı olarak, gecikmeli geri besleme elemanları bulunur. Bu ağı mimarisi, dinamik ve geri etkileşimli bir yapıya sahiptir. İleri beslemeli ağların aksine, geri beslemeli ağı mimarisi, Anderson, Hopfield ve Kohonen gibi örneklerle temsil

edilebilir. Geri beslemeli yapay sinir ağı mimarisi, ileri beslemeli yapay sinir ağı mimarisine benzerlik göstermekle birlikte, verinin önceki katmanlara dönmesi veya katmanlar arasında döngü oluşturması gibi kısıtlamalara sahip değildir. Bu mimari, verinin sadece ileriye doğru tek yönlü iletiminin yanı sıra geri yönlü ve aynı katman üzerinde hareket etmesine olanak tanır. Bu durum, ağın dinamik davranışlar sergileyebilmesini ve hafızasını kullanarak dizileri işleyebilmesini sağlar (Sayın & Yakar, 2018).



Şekil 3.8. Geri Beslemeli Sinir Ağı Yapısı (Kaynak: Öztürk & Şahin, 2018)

3.4.4.4. Öğrenme Yöntemlerine Göre Yapay Sinir Ağları

Yapay Sinir Ağlarının öğrenme süreci, çevresel uyarıcılar tarafından ağırlıkların düzenlenmesi ve en uygun değerlerin belirlenmesiyle gerçekleşir. Bu süreçte, gerçek çıkış istenen çıkışla karşılaştırılarak ağ tarafından rastgele değişen ağırlıklar ayarlanır ve bir sonraki döngüde daha yakın karşılaştırmalar elde edilir. Öğrenme yöntemi, tüm işlem elemanlarının anlık hatalarını en aza indirmeyi hedefler ve bu azaltma işlemi, kabul edilebilir doğruluk seviyesine ulaşılan kadar sürekli olarak devam eder. ANN'nin öğrenme biçimleri, danışmanlı öğrenme, danışmansız öğrenme ve destekleyici öğrenme olarak üçe ayrılır.

Danışmanlı Öğrenme: Danışmanlı öğrenme (supervised learning) sürecinde, yapay sinir ağı eğitim verileriyle önceden hazırlanmalıdır. Bu süreçte, ağa giriş ve çıkış bilgileri sunulur ve her bir giriş kümesi için uygun çıkış kümesi sağlanmalıdır. Perceptron, Delta ve Geri Yayımlı yapay sinir ağları, danışmanlı öğrenme prensiplerine göre çalışır. Girdi ve çıktı değerleri ağa sağlandıktan sonra, ağ girdileri işler ve elde edilen çıktıları istenen çıktılarıyla karşılaştırır. Bu karşılaştırma sonucunda oluşan hata değeri, ağı kontrol eden ağırlıkların düzenlenmesi için kullanılır. Hataların geriye yayılması ve ağırlıkların düzenlenmesi süreci, hata değerinin azaltılması amacıyla birçok kez tekrarlanır. Eğitim


işlemi, hata değeri istenen seviyeye ulaştığında ağırlıkların sabitlenmesiyle tamamlanır. Ancak, ağa sunulan girdi değerleri istenen çıktılar elde etmek için yeterli bilgi içermiyorsa veya ağ problemi çözme konusunda başarısız olursa, ağın yapısal özellikleri ve başlangıç ağırlıkları gözden geçirilmelidir (Sayın & Yakar, 2018).

Danışmansız Öğrenme: Danışmansız öğrenme (unsupervised learning) biçiminde, öğrenme algoritmaları geçmiş veri kümesinin içindeki gizli istatistiksel bilgilerin elde edilmesini hedefler. Girdiler aynı zamanda çıktı görevi görür ve yapay sinir ağı, sadece girdi katmanından bilgileri alır ve bunları işledikten sonra tamamen özgür bir şekilde sınıflara ayırır. Kullanıcı bu noktada kendi sınıflandırmasını yapma özgürlüğüne sahiptir. Bu yaklaşımda hem girdi hem de çıktı olan veriler arasındaki kurallar ve ilişkiler araştırılır ve en uygun olanı bulunur, bu da ağın eğitilmesi anlamına gelir. Sistemin doğru çıkış hakkında bilgisi olmadığından, girişlere göre kendi kendini örnekler ve giriş bilgilerinin özelliklerine göre ağırlık değerlerini ayarlar. Bu yöntemde, ağa hiçbir çıkış örneği sağlanmadığı için verilen giriş vektörleri için önceden bilinebilen performansı ölçmek mümkün değildir ve istenen çıkışlar ağa hiç verilmediğinden, hata dikkate alınmaz (Koltan Yılmaz, 2017).

Destekleyici Öğrenme: Destekleyici öğrenme (reinforcement learning), danışmanlı öğrenmenin belirli bir formu olup, giriş değerlerine karşılık istenen çıktının önceden bilinmesine ihtiyaç duyulmaz. Bu öğrenme yönteminde, çıkış değerleri bilinmemesine rağmen elde edilen çıktının girişlere uygunluğunu değerlendiren bir kriter kullanılır. Ağ, bir girdi vektörüne karşılık olarak ürettiği çıktı için alınan geri bildirimlere göre ağırlıklarını günceller. Bu süreçte, olumlu veya olumsuz geri bildirimler ağın performansını iyileştirmek için kullanılır (Koltan Yılmaz, 2017).


3.4.4.5. Katman Sayılarına Göre Yapay Sinir Ağları

Tek Katmanlı Algılayıcılar: Tek katmanlı yapay sinir ağı, sadece girdi ve çıktı katmanlarından oluşur, ara katman bulunmaz. Bu nedenle "tek katmanlı" olarak adlandırılır. Girdi katmanında veri alınır, ardından doğrudan çıktı katmanına iletilir. Bu yapıda her bir girdi, çıktı katmanındaki her bir nörona bağlanır ve her bir bağlantıya bir ağırlık atanır. Tek katmanlı ANN, basit işlemler için kullanılabilir ve genellikle doğrusal problemleri çözmek için tercih edilir. Ancak daha karmaşık problemler için yetersiz kalabilir çünkü ara katmanın esnekliği ve karmaşıklığı sağlayan yeteneklerinden yoksundur (Sinem & Kargi, 2013).



Şekil 3.9. Tek Katmanlı Algılayıcı Modeli (Kaynak: Öztürk & Şahin, 2018)

Çok Katmanlı Algılayıcılar: Çok katmanlı yapay sinir ağı (ANN), birden fazla ara katman içeren bir yapay sinir ağıdır. Bu ara katmanlar, girdi ve çıktı katmanları arasına yerleştirilir ve her bir ara katmanda birden çok yapay sinir hücresi bulunur. Çok katmanlı yapay sinir ağları, daha karmaşık problemleri çözmek için kullanılır çünkü ara katmanlar, veriler arasındaki karmaşık ilişkileri öğrenmek ve temsil etmek için daha fazla esneklik sağlar. Bu yapı, derin öğrenme ve karmaşık desen tanıma gibi alanlarda yaygın olarak kullanılmaktadır. Her bir ara katman, girdi katmanından aldığı bilgileri işler, ardından sonuçları bir sonraki katmana iletir. Çok katmanlı ANN'ler, gelişmiş öğrenme algoritmaları ve daha fazla hesaplama gücü gerektirebilir, ancak daha geniş bir problem yelpazesini çözmek için daha uygun olabilir (Arı vd., 2017).



Şekil 3.10. Çok Katmanlı Algılayıcı Modeli (Kaynak: Öztürk & Şahin, 2018)

3.4.4.6. Yapay Sinir Ağlarının Kullanım Alanları

Yapay sinir ağları, çeşitli disiplinlerde, özellikle tıp, kimya, işletme yönetimi, iktisat, mühendislik, biyokimya ve havacılık gibi alanlarda çeşitli fonksiyonların yerine getirilmesi

için yaygın olarak kullanılmaktadır. Bu teknolojilerin geniş bir kullanım alanı bulmasının temel nedeni, bilgi işleme sürecinde sağladığı avantajlardır. Finansman, muhasebe, insan kaynakları, pazarlama, üretim gibi veri yoğun alanlarda yapay sinir ağları üzerine yapılan araştırmalar, bu teknolojilerin karar verme süreçlerinde etkin bir şekilde kullanılmasını sağlamaktadır (Yakar, 2018). Örneğin, finansal ve ekonomik tahminlerde, menkul kıymetlerde fiyat hareketlerinin analizinde, risk değerlendirmelerinde ve portföy yönetiminde yapay sinir ağları yaygın bir şekilde kullanılmaktadır. Bu teknolojiler, piyasa davranışlarını simüle etmek, temerrüt ve iflas risklerini tahmin etmek, veri madenciliği yapmak gibi birçok alanda da değerlidir. Yapay sinir ağlarının genel olarak kullanım nedenleri, verinin yoğun olduğu ve analiz edilmesi gereken alanlarda karar verme sürecini iyileştirmek, riskleri azaltmak, verimliliği artırmak ve daha doğru tahminler yapmak olarak özetlenebilir (Arı vd., 2017). Bu nedenlerle, yapay sinir ağları disiplinler arası bir alan oluşturmuş ve geniş bir uygulama alanı bulmuştur.

3.4.4.7. Yapay Sinir Ağlarının Avantaj ve Dezavantajları

ANN'ler, birçok farklı alanda geniş bir uygulama alanına sahiptir. Tıp, finans, endüstriyel üretim, otomotiv, doğal dil işleme, görüntü tanıma gibi birçok alanda başarıyla kullanılabilirler. ANN'ler, veriye dayalı öğrenme süreçleriyle bilgiyi işleyebilir ve modellerini veri üzerinden geliştirebilirler. Bu sayede, belirli bir görev veya problem alanında performanslarını zamanla artırabilirler (Sinem & Kargı, 2013)

ANN'nin diğer bir avantajı da değişken etkileşimlerinin tam olarak anlaşılmaması durumunda bile doğru çıktılar üretebilme yetenekleridir. Bu, karmaşık veri setlerindeki ilişkileri analiz edebilme ve modelleyebilme kabiliyetinden kaynaklanır. Yapay sinir ağları, veri setindeki değişkenler arasındaki karmaşık ilişkileri yakalayabilir ve bu ilişkileri temel alarak tahminlerde bulunabilir. Böylece, karmaşık veri yapılarında dahi etkili sonuçlar elde edebilir ve değişken etkileşimlerini anlamadan bile doğru çıktılar üretebilir (Kaya vd., 2005). Bu özellik, YSA'ların geniş bir uygulama alanına sahip olmalarını sağlar ve gerçek dünya problemlerinin çözümünde kullanılmalarını destekler.

Yapay sinir ağları, ağdaki birçok işlem birimi arasında paralel işleme yapabilirler. Bu, büyük veri kümeleri üzerinde hızlı bir şekilde çalışabilmelerini sağlar (Sinem & Kargı, 2013).

Yapay sinir ağlarının dezavantajı, ağdaki bilginin en iyi sonucu verecek şekilde kullanıcı tarafından tespit edilen katmanlar ve bu katmanlardaki nöronlarda gizli olmasıdır. Ağ, en

iyi sonucu elde etmek için bu ağırlıkları günceller, ancak bu ağırlıkların anlamı veya yorumu açık değildir. Bu nedenle, yapay sinir ağlarının bir kara kutu olarak nitelendirilmesine sebep olur. Ağırlıkların anlamsal özelliklerini açıklamak veya ağdaki daha önceki bilgileri birleştirmek zor olduğundan, sistem bilgisi ağırlıklarla tüm ağa dağıtılmıştır. Bu durum, yapay sinir ağlarının anlamsal açıdan anlaşılmasını zorlaştırır ve ağın iç işleyişi hakkında tam bir anlayışı engeller (Atalay & Çelik, 2017).


ANN, eğitim verilerine aşırı uyum sağlayarak eğitim setine çok iyi uyum sağlayabilirler, ancak genelleme yetenekleri zayıf olabilir. Bu, modelin yeni verilere uygulandığında performansının düşük olmasına neden olabilir (Karaali & Eminağaoğlu, 2021).

ANN'ler veriye çok fazla bağımlı olabilirler. Yetersiz veya yanlış veri setleriyle eğitildiklerinde, yanlış sonuçlar üretebilirler veya istenmeyen davranışlar sergileyebilirler (Arı vd., 2017).

4. DERİN ÖĞRENME

Makine öğrenimi, günümüz teknolojisinin temelini oluşturan ve birçok alanda kullanılan bir konsept haline gelmiştir. Bu alandaki gelişim, McCulloch-Pitts nöronları olarak adlandırılan matematiksel sinir ağı modeli, Warren McCulloch tarafından oluşturulmuştur. Makine öğreniminin temelleri, 1950'de Alan Turing ve 1952'de Arthur Samuel tarafından atılmıştır. 1959'da David Hubel ve Torsten Wiesel, basit ve karmaşık hücre yapılarını ortaya çıkararak derin öğrenme sürecine katkıda bulunmuşlardır. 1960'ta Heury J. Kelley, uçak rotalarıyla ilgili bir kontrol teorisi geliştirmiştir, bu da geri beslemeli öğrenme algoritmalarının başlangıç noktası olarak kabul edilmiştir. 1965'te Alexey Ivakhnenko, çok değişkenli veri setlerini kullanarak bilgisayar tabanlı bir matematiksel model oluşturmuş ve bu modeli sinir ağlarına uyarlayarak ilk derin öğrenme ağlarını geliştirmiştir (Ercan & Şahin, 2023).

Alexey Ivakhnenko ve V.G. Lapa tarafından eğitilen ve bilinen ilk derin ağ mimarisi Şekil 4.1'de gösterilmiştir.




Şekil 4.1. Eğitilen ve bilinen ilk derin ağ mimarisi (Kaynak: Ercan & Şahin, 2023)

1988'de Fukushima, el yazısı tanıma ve desen tanıma gibi sorunlar için önerilen Neocognitron adlı hiyerarşik ve çok katmanlı yapay sinir ağı modelini sunmuştur. Ardından, 1992'de Weng, Cohen ve Herniou, karmaşık sahnelerden otomatik olarak üç boyutlu nesne tanıma yeteneğine sahip Cresceptron yöntemini yayınlamışlardır. Benzer şekilde, 1995'te Cortes ve Vapnik, benzer verilere sahip iki grubun sınıflandırılması için destek vektör ağlarını kullanmışlardır. Son olarak, 1997'de Hochreiter ve Schmidhuber, bilgiyi tekrarlayan geri yayılım yoluyla uzun süreli belleği öğrenen LSTM (Uzun Kısa-Süreli Bellek) modelini önermişlerdir (Daş vd., 2019).

"Derin öğrenme" kavramı ise 2000'li yılların başlarında önem kazanmıştır. Geoffrey Hinton ve diğer araştırmacılar, bilgisayarların resim ve videolardaki nesneleri tanıyabilmesine yardımcı olabilecek yeni algoritmalar geliştirmiştir (Lecun vd., 2015). 2012'de gerçekleştirilen bir çalışmada, Google'ın araştırma ekibi tarafından tasarlanan yapay desen tanıma algoritmaları, 16.000 işlemci ve bir milyardan fazla bağlantıdan oluşan bir yapıya sahipti ve insan düzeyine ulaşan performans sergilemiştir. Benzer şekilde, 2014 yılında Facebook, kullanıcıları otomatik olarak etiketlemek için fotoğraflarda yüz tanıma görevlerini gerçekleştiren DeepFace adlı derin öğrenme teknolojisini kullanmak için 120 milyon parametre içeren bir R-CNN modeli geliştirmiştir (Daş vd., 2019).

Derin öğrenme (Deep Learnig:DL), günümüzde yapay zekâ ve makine öğrenimi alanlarında büyük ilgi gören ve önemli bir alt alanı oluşturan bir paradigmadır. Bu yaklaşım, genellikle yapay sinir ağları üzerine odaklanır ve geleneksel sinir ağı yapılarından farklı olarak daha fazla gizli nöron ve katman içerir. Derin öğrenme yöntemleri, karmaşık veri setlerinden anlamlı özellikler çıkarmak ve karmaşık problemleri çözmek için kullanılmaktadır. Yapay sinir ağlarındaki derin mimariler, daha yüksek seviyede öğrenme ve daha karmaşık veri temsilleri elde etmek için tasarlanmıştır. Bu sayede, derin öğrenme, görüntü tanıma, doğal dil işleme, ses tanıma gibi birçok uygulama alanında başarılı sonuçlar elde etmiştir (Küçük vd., 2018).

Derin öğrenme modellemesi için yapılan süreçler, problem tanımı ve derin öğrenmeye uygunluğun tespitiyle başlar. İlgili veri kümeleri belirlenir ve analiz için hazırlanır. Ardından, kullanılacak algoritma modeli seçilir ve tanımlı veriler, seçilen algoritmaya göre analitik model oluşturularak eğitilir. Eğitim sürecinde model gerektiğinde revize edilir ve test edilir. Son olarak, model çalıştırılarak test skorları elde edilir ve çıkan sonuca göre ileriye yönelik tahminler yapılır. Derin öğrenme modellemesi için önemli faktörler arasında büyük bir veri havuzu, eğitecek bir algoritma, veri özniteliklerinin sınıflandırılması, transfer fonksiyonu seçimi, ağ yapısının ve gizli katman sayısının belirlenmesi gibi etkenler bulunmaktadır (Ercan & Şahin, 2023). Genellikle, derin öğrenme modelleri girdi katmanı, gizli katmanlar ve çıktı katmanından oluşur. Gizli katmandaki düğümler veya nöronlar, giriş ve çıkış düğümleri, eğitim algoritması, ağ yapısı ve aktivasyon fonksiyonunun türü gibi faktörlerden etkilenir. Gizli katmandaki düğümlerin sayısını belirlemek için farklı türde ağları eğitmek ve test verisindeki hatayı araştırmak önemlidir (Lecun vd., 2015). Şekil 4.1'de derin öğrenme çalışma basamakları verilmiştir.



Şekil 4.2. Derin Öğrenme çalışma basamakları (Kaynak: Ercan & Şahin, 2023)

4.1. Derin Öğrenme Yöntemleri

Derin öğrenme, insan beyninin fonksiyonel işlevlerinden esinlenerek oluşturulan yapay sinir ağları modelleriyle gerçekleştirilir. Bu modeller, algılama, kontrol, analiz yapma, verileri saklama ve çıkarımda bulunma gibi çeşitli yeteneklere sahiptir ve öğrenme sürecini matematiksel olarak modelleyebilirler. Uygulama alanına göre birçok yapay sinir ağı modeli bulunmaktadır (Ercan & Şahin, 2023). Her bir model, belirli bir problem veya uygulama için en uygun olan yapının seçilmesini sağlar, böylece derin öğrenme süreci en etkin ve verimli şekilde gerçekleştirilebilir. Tablo 4.1’de derin öğrenme yöntemleri ve kullanıldığı alanlar sunulmuştur.

Tablo 4.1. Derin Öğrenme Yöntemleri ve Kullanıldığı Alanlar

DERİN ÖĞRENME YÖNTEMİ	ÖZELLİKLERİ
Derin Sinir Ağları	Birçok alanda başarıyla uygulanmaktadır. Ancak öğrenme süreci uygulama alanına bağlı olarak oldukça yavaş olabilmektedir.
Derin Oto-kodlayıcılar	Öğrenme için işaretli veri gerektirmeyen denetimsiz bir derin öğrenme yöntemidir.
Derin İnanç Ağları	Denetimli ve denetimsiz şekilde kullanılabilir. Ancak eğitim süreci yavaş olabilmektedir.
Derin Boltzman Makinesi	Derin inanç ağlarından farkı sadece en üst iki katman dışında tüm katmanlar arasında yönsüz bağlantıların olmasıdır. Bu nedenle daha maliyetlidir.
Yinelenen Sinir Ağları	Sıralı desenleri belirlemede başarılıdır. Bu nedenle bazı türleri doğal dil işleme gibi alanlarda başarılıdır.
Evrimsel Sinir Ağları	Genellikle bilgisayarlı görü alanında ve görsel veriler üzerinde kullanılmakta ve büyük boyutta işaretli veri gerektirmesine rağmen başarılı sonuçlar vermektedir. Doğal dil işleme alanındaki problemlere de başarıyla uygulanmıştır.

4.1.1. Derin Sinir Ağları

Literatürdeki ilk sinir ağı algoritması olan perseptron, Rosenblatt tarafından 1958'de tanıtılmıştır. Bu tip ağlarda, bir girdi katmanı bulunur ve doğrudan çıktıya bağlanır. Perseptron algoritması, lineer olarak ayrılabilen desenlerin sınıflandırılması için kullanılabilir. Daha karmaşık problemler için ise bu algoritmanın üzerine birden fazla gizli katman eklenebilir ve her katmanın ağırlığı delta kuralı adı verilen bir öğrenme yöntemiyle ayarlanabilir (Küçük vd., 2018).

Gizli katman sayısının artırılmasıyla, doğrusal olmayan karmaşık ilişkilerin tespiti mümkün hale gelir ve bu tür sinir ağlarına derin sinir ağları (DSA) adı verilir. DSA'lar, hem denetimli (işaretli veriler varsa) hem de denetimsiz öğrenme problemleri için kullanılabilir. Sınıflandırma ve regresyon amaçlarıyla yaygın olarak kullanılan DSA'lar, genellikle başarılı sonuçlar elde ederler. Ancak öğrenme süreçleri genellikle yavaş olabilir (Lecun vd., 2015).

4.1.2. Derin Oto-Kodlayıcılar

Derin Oto Kodlayıcılar, 1980'lerde Hinton ve PDP grubu tarafından geliştirilen ve literatüre kazandırılan bir derin öğrenme algoritmasıdır. Bu algoritma, birden fazla katmandan oluşur ve girdi olarak aldığı veriyi çıktı olarak üretmeye çalışır. Derin Oto

Kodlayıcıların amacı, verilen girdiye en çok benzeyen çıktıyı üretebilecek olan veriye ait önemli yapısal bilgileri içeren fonksiyonu bulmaktır (Kayaalp & Süzen, 2018). Bu teknik, işaretlenmemiş veri kümeleri üzerinde çalışabilir, yani denetimsiz bir öğrenme yöntemidir. Ancak, uygun ağırlıkları bulabilmek için bir ön-öğrenme aşamasına ihtiyaç duyar. Bu ön-öğrenme aşamasında, yönteme son konfigürasyona uygun yaklaşık ağırlıklar sağlanır (Küçük vd., 2018).

4.1.3. Derin İnanc Ağları

Derin inanc ağları, özellikle denetimsiz öğrenme süreçlerinde kullanılan, sınırlandırılmış Boltzmann makineleri (stochastic blok model: SBM) adı verilen bir algoritmanın temelini oluşturur. SBM algoritması, stokastik bir sinir ağı olarak tanımlanır ve bu ağlarda belirli bir dağılıma sahip stokastik birimler kullanılır. Öğrenme sürecinde Gibbs örnekleme gibi yöntemlerle ağırlıklar adım adım ayarlanır. Derin inanc ağları, birden fazla SBM'nin bileşkesi olarak görülebilir. Her bir SBM'nin gizli katmanı, bir sonraki SBM'nin görünür katmanına bağlanır ve en üst seviyede yönsüz bağlantılar bulunur. Bu yapı hem denetimli hem de denetimsiz öğrenme amaçları için kullanılabilir. Ağı başlatmak için, katman-katman bir açgözlü algoritma kullanılarak öğrenme gerçekleştirilir. Bu sayede, derin inanc ağları geniş bir uygulama alanına sahip olabilir, özellikle de karmaşık veri yapılarının öğrenilmesi ve temsili için kullanılabilirler (Küçük vd., 2018).

4.1.4. Tekrarlayan Sinir Ağları

Tekrarlayan Sinir Ağı (Recurrent Neural Network:RNN), yapay sinir ağlarının bir alt sınıfını oluşturan bir modeldir, bu modelde birimler arasında yönlendirilmiş bir döngü bulunur. Bu döngü, ağ içinde dinamik bir zaman serisi davranışını sağlamak için kullanılan bir iç durum oluşturur (Küçük vd., 2018). RNN'ler, giriş dizisini bir elemanı işleyerek zaman içinde adım adım işlerler ve gizli birimlerinde bir 'durum vektörü' tutarak, bu vektör geçmişteki tüm elemanlar hakkında bilgi içerir (Şeker vd., 2017). İleri beslemeli sinir ağlarından farklı olarak, RNN'ler kendi giriş belleğini girdilerin sıralı dizilerini işlemek için kullanabilirler. RNN'lerin temel fikri, sıralı verileri işlemektir (Küçük vd., 2018). (RNN'ler), veri akışlarını analiz edebilen gizli katmanlara sahip sinir ağlarıdır ve çıktının bir önceki hesaplamalara bağlı olduğu problemlerin çözümü için oldukça uygundur (Lecun vd., 2015). Ancak, yinelenen sinir ağlarının öğrenme sürecinde ortaya çıkan bazı zorluklar bulunmaktadır. Geri yayılan gradyanlar her zaman adımında büyüme veya küçülme eğilimindedir ve bu da uzun süreçler boyunca genellikle patlamalara veya kaybolmalara

neden olabilir (Küçük vd., 2018). Bu zorlukların üstesinden gelmek için, literatüre farklı versiyonları girmiştir. Örneğin, uzun kısa-dönem bellek (Long Short-Term Memory-LSTM) gibi modeller, RNN'lerin öğrenme sürecindeki belirli sınırlamaları aşmak ve daha etkili sonuçlar elde etmek için geliştirilmiştir (Lecun vd., 2015).


Farklı diskret zaman adımlarında gizli birimlerin çıktılarını, derin çok katmanlı bir ağdaki farklı nöron çıktıları gibi düşünürsek, RNN'leri eğitmek için geri yayılma yöntemini nasıl uygulayabileceğimiz açık hale gelir. Ancak, RNN'leri eğitmek bazen zorlu olmuştur, çünkü. Bu zorluklara rağmen, RNN'ler hala dinamik sistemlerde güçlü bir araç olarak kabul edilir ve özellikle ardışık veri analizi gibi alanlarda yaygın bir şekilde kullanılmaktadır.

Yinelenen sinir ağları (RNN'ler), veri akışlarını analiz edebilen gizli katmanlara sahip sinir ağlarıdır ve çıktının bir önceki hesaplamalara bağlı olduğu problemlerin çözümü için oldukça uygundur. Bu özellikleri nedeniyle özellikle doğal dil işleme alanında çeşitli problemlerin çözümünde başarılı olmuşlardır (Şeker vd., 2017).

4.1.5. Evrişimsel Sinir Ağları

Evrişimsel Sinir Ağları (Convolutional Neural Network:CNN), hayvanların görme sistemleri örnek alınarak Hubel ve Wiesel 1968 yılında oluşturulmuş (Şeker vd., 2017), derin öğrenmenin temel mimarisi sayılan (İnik vd.,2017) özellikle renkli görüntüler gibi çok diziden oluşan verileri işlemek için kullanılan mimaridir (Lecun vd., 2015). CNN insan beyninin korteks bölgesinin işleyişinden ilham alınarak geliştirilmiş ve bilgisayarla görme alanında çeşitli problemlere başarıyla uygulanmaktadır (Hayıt, 2021). Bu yapı, farklı dizi boyutlarıyla temsil edilen çeşitli veri tiplerine uyum sağlayabilen esnek bir mimariye sahiptir (Lecun vd., 2015).

Evrişimli Sinir Ağı (CNN) algoritmaları, son yıllarda görüntü ve ses işleme alanları başta olmak üzere birçok farklı alanda geniş bir uygulama yelpazesine sahiptir. Özellikle, görüntü işleme alanında, CNN tabanlı yöntemlerin en üst düzey (state of the art) sonuçlar elde ettiği gözlemlenmektedir. CNN'ler, görüntü ve ses verilerinin yanı sıra doğal dil işleme (NLP), biyomedikal görüntüleme ve diğer alanlarda da başarıyla kullanılmaktadır. Bu algoritmalar, veri özelliklerini otomatik olarak çıkarmak, karmaşık desenleri tanımak ve veri analizi yapmak gibi çeşitli görevlerde etkili bir şekilde kullanılmaktadır (Şeker vd., 2017). Bu sayede, CNN tabanlı yaklaşımlar, birçok alanda hızla gelişen ve yenilikçi çözümler sunan önemli bir araç haline gelmiştir.



Şekil 4.3. Bir CNN mimarisinin Genel Yapısı (Kaynak: Dandıl vd., 2020)

4.1.5.1.CNN Katmanları

Giriş Katmanı: Giriş Katmanı (Input Layer), Evrişimli Sinir Ağlarının temel bileşenlerinden birini oluşturur. Bu katman, ağa giren veriyi doğrudan alır ve işlemeye başlar. Modelin başarımı için bu katmandaki verinin boyutu oldukça önemlidir. Giriş görüntü boyutunun seçimi, bellek gereksinimleri, eğitim süresi ve test süresi gibi faktörleri etkiler. Yüksek boyutlu giriş görüntülerinin seçilmesi, daha fazla bellek ve daha uzun eğitim süreleri gerektirebilir, ancak aynı zamanda ağın başarımını artırabilir. Öte yandan, düşük boyutlu giriş görüntülerinin seçilmesi, bellek ihtiyacını azaltabilir ve eğitim süresini kısaltabilir, ancak ağın derinliğini ve performansını olumsuz yönde etkileyebilir (İnik vd., 2017). Bu nedenle, görüntü analizi uygulamalarında, uygun bir giriş görüntü boyutunun seçilmesi, ağın derinliği, donanım maliyeti ve başarımı gibi çeşitli faktörleri dikkate alarak yapılmalıdır.

Evrişim Katmanı: Evrişim Katmanı (Convolution Layer) dönüşüm katmanı olarak da bilinen bu katman, görüntü işleme sürecinde önemli bir rol oynar ve genellikle birinci katman olarak adlandırılır. Bu katmanda, belirli bir filtrenin tüm giriş görüntüsü üzerinde kaydırılması ve konvolüsyon işleminin uygulanmasıyla dönüşüm gerçekleştirilir. Filtreler, farklı boyutlarda (2x2, 3x3, 5x5) olabilir ve katmanın girişinden gelen görüntüler üzerinde konvolüsyon işlemi uygulayarak çıkış verisini oluştururlar (İnik vd., 2017). Evrişim işlemi, bir filtre çerçevesi içindeki piksel değerlerinin, filtrenin katsayılarıyla çarpılması ve sonuçların toplanarak çıkış görüntüsünün bir pikselinin değeri olarak belirlenmesiyle gerçekleşir. Bu süreç, görüntü üzerindeki her bir piksele filtre uygulanarak, piksel değerlerinin ve filtrenin etkileşimi sonucunda yeni bir değer elde edilmesini sağlar. Bu

işlem, her bir piksel için ayrı ayrı tekrarlanarak, evrişim operatörünün uygulanması sağlanır (Bayram, 2020). Şekil 4.4'te bu evrişim işlemi görsel olarak gösterilmiştir. Evrişim işlemi, görüntü verilerinin belirli özelliklerinin vurgulanması ve çıkarılması için kullanılan önemli bir işlemdir.


$$\begin{bmatrix} 3 & 5 & 2 \\ 9 & 7 & 5 \\ 2 & 4 & 6 \end{bmatrix} \otimes \begin{bmatrix} 1 & 0 & 0 \\ 1 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix} \Rightarrow (3 \times 1) + (5 \times 0) + (2 \times 0) + (9 \times 1) + (7 \times 1) + (5 \times 0) + (2 \times 0) + (4 \times 0) + (6 \times 1) = 25$$

Şekil 4.4. Evrişim operatörünün uygulanması (Kaynak: Bayram, 2020).

Bu süreç sonucunda, her bir filtreye özgü özelliklerin keşfedildiği aktivasyon haritaları (özellik haritaları) elde edilir (İnik vd., 2017).

Düzleştirilmiş Doğrusal Birim Katmanı: Evrişim katmanlarının çıkış verilerine uygulanan bu katman, Düzleştirilmiş Doğrusal Birim ((Rectified Linear Units Layer: ReLu) aktivasyon fonksiyonudur. ReLU fonksiyonu, öznitelik haritalarındaki negatif değerleri sıfıra sabitleyerek, pozitif değerleri aynen aktarır. Matematiksel olarak $f(x) = \begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases}$ denklemi ile tanımlanan bu fonksiyon, evrişim katmanlarının çıkışlarını geçerek, negatif değerleri sıfıra dönüştürerek ve pozitif değerleri koruyarak, sonraki katmanlara iletilmesini sağlar (Demir vd., 2021). Bu işlem, özellik haritalarındaki bilgiyi daha net ve anlamlı hale getirerek, modelin daha iyi öğrenmesine katkı sağlar.

Havuzlama Katmanı: Havuzlama Katmanı (Pooling Layer: PL), CNN mimarilerinde önemli bir rol oynayan ve boyut azaltma işlemini gerçekleştiren katmandır. Bu katmanda, tanımlanan filtreler kullanılarak görüntüdeki piksel değerleri üzerinde farklı işlemler uygulanır (Demir vd., 2021). Maksimum değer alma (maksimum havuzlama) veya ortalama değer alma (ortalama havuzlama) gibi yöntemlerle, öznitelik haritaları oluşturulur. Bu işlem, bir sonraki katmana iletilmeden önce hesaplama yükünü azaltır ve bilgiyi daha derin katmanlara daha etkili bir şekilde iletebilir hale getirir. Yeni öznitelik haritaları, tam bağlı katmana iletilmeden önce düzleştirme işlemi ile tek boyutlu bir vektör haline getirilir, böylece ağına daha ileri katmanları tarafından işlenebilir hale gelir (İnik vd., 2017). Bu katmandaki filtreler, evrişim katmanındaki filtrelerden farklı olarak maksimum veya ortalama alan filtreleri olarak işlev görür (Bayram, 2020). Şekilde havuzlama katmanındaki filtrelerin nasıl uygulandığı gösterilmektedir.



Şekil 4.5. 4x4 boyutunda görüntüye 2x2 boyutunda maksimum ve ortalama havuzlama operatörünün uygulanması (Kaynak: Bayram, 2020).


Tam Bağlantılı Katman: Tam bağlantılı katman (Fully Connected Layer:FCL), kendisinden önceki katmandaki tüm nöronlarla tam bağlantılı olan bir yapay sinir ağından oluşmaktadır. Bu katman, önceki katmandaki tüm çıktıları alarak nöronlar arasında bağlantıları oluşturur ve bu bağlantılar aracılığıyla gelen bilgileri işler. Son tahmin, genellikle sınıflandırma gibi belirli bir probleme yöneliktir ve bu tahminler, tercih edilen aktivasyon fonksiyonu kullanılarak elde edilir (İnik vd., 2017). CNN mimarisi oluşturulduktan sonra, ağın eğitimi gerçekleştirilir. Eğitim sürecinde, ağın tahminleri gerçek etiketli verilerle karşılaştırılarak bir hata değeri hesaplanır. Geriye yayılım algoritması kullanılarak, her eğitim adımında ağıdaki ağırlık değerleri güncellenir ve hatanın minimize edilmesi sağlanır. Bu süreçte, ağın doğru sonuçlar üretebilmesi ve istenilen çıktıya ulaşabilmesi için ağırlıkların uygun şekilde ayarlanması önemlidir (Demir vd., 2021).

Bırakma Katmanı: Bırakma (Dropout) katmanın temel amacı, ağın bazı düğümlerini geçici olarak devre dışı bırakmaktır. Bu şekilde, eğitim sırasında ağın farklı bölümleri birbirlerine bağımlı hale gelmez ve daha sağlam bir model elde edilir. Bırakma katmanı, ağın öğrenme sürecindeki çeşitliliği artırarak aşırı uyumu azaltır ve genel performansı artırır (İnik vd., 2017).

Derin öğrenme yöntemlerinde, modellerin birleştirilerek kullanılması genellikle daha iyi sonuçlar verir. Ancak, bu yaklaşımın bazı zorlukları vardır. Özellikle büyük ağların eğitimi çok fazla hesaplama gücü gerektirir ve en uygun parametreleri bulmak zor olabilir. Ayrıca, gelişmiş ağların eğitimi için genellikle büyük miktarda veriye ihtiyaç duyulur ve farklı ağların farklı veri setleriyle eğitilmesi gerekebilir, bu da bazen yeterli miktarda veri bulunamaması anlamına gelir. Bu zorluklarla başa çıkmak için, modellerin birleştirilerek kullanılması sırasında hızlı bir test süreci gereklidir, ancak bu genellikle mümkün olmaz.

Bu tür zorluklarla başa çıkmanın bir yolu, bırakma yöntemidir. Bırakma işlemi, eğitim sırasında nöronların bağlantıları ile modelden rastgele olarak atılması işlemidir. Bu,

modelin ezberleme eğilimini azaltır ve daha genellemeye dayalı bir öğrenmeyi teşvik eder. Bırakma işlemi, yalnızca eğitim sırasında uygulanır ve test aşamasında kullanılmaz. Ayrıca, bırakma yöntemi farklı tipteki modellere uygulanabilir ve genellikle aşırı uyum sorununu azaltmada etkilidir (Dandıl vd., 2020). Şekil 4.6’da bırakma işleminden önce ve sonra ağı yapısı verilmiştir.



Şekil 4.6. DropOut katmanının uygulanması (Kaynak: İnık vd., 2017).

Sınıflandırma Katmanı: Genellikle tam bağlantılı katmandan sonra gelir ve derin öğrenme modellerinde sınıflandırma işlemini gerçekleştirir. Bu katmanın çıkış değeri, sınıflandırılacak nesne sayısına eşittir (İnik vd., 2017). Bu katmanda, farklı sınıflandırıcılar kullanılabilir, ancak genellikle başarısı nedeniyle softmax sınıflandırıcı tercih edilir. Softmax sınıflandırıcı, 15 farklı nesne için 0 ile 1 arasında olasılık değerlerinin bir çıkış üretir. Bu çıkışlardan 1'e en yakın olan değer, ağı tahmin ettiği nesneyi temsil eder. Bu şekilde, sınıflandırma katmanı, modelin girişini doğru şekilde sınıflandırarak çeşitli nesneleri tanımlamada ve ayırt etmede önemli bir rol oynar (Özkan vd., 2021).

4.1.5.2. Aşırı Uyum (Overfitting) ve Yetersiz Uyum (Underfitting)


Aşırı uyum ve yetersiz uyum, yapay sinir ağları modellerinde sıklıkla karşılaşılan kritik problemlerdir. Aşırı uyum, bir modelin eğitilmesinin etkili olmasına rağmen, doğrulama setinde zayıf bir performans sergilemesi durumunda ortaya çıkar. Bu durumda, model görünmeyen verilere genellikle doğru bir şekilde uygulanamaz, bu da modelin genelleme yeteneğini azaltır ve amacından sapmasına neden olur (Decuyper vd., 2019). Aşırı uyumun önlenmesi için eğitim veri setinin bir kısmı aşırı uyumu kontrol etmek için ayrılır ve eğitim verilerinin hata oranı ile test verilerinin hata oranı karşılaştırılır. Aşırı uyumu engellemek için erken durdurma (bırakma), daha fazla veri ile eğitim, veri artırma ve özellik sayısının azaltılması gibi yöntemler kullanılabilir (Karaali & Eminağaoğlu, 2021).

Yetersiz uyum ise modelin yeterince eğitilmemesi veya girdi ve çıktı değişkenleri arasında anlamlı bir ilişki kuramaması durumunda ortaya çıkar. Yetersiz uyumda genellikle yüksek bir hata oranı elde edilir ve modelin çok basit bir yapıya sahip olması nedeniyle gerçek dünya verilerine uyum sağlayamaz. Yetersiz uyumu önlemek için modelin karmaşıklığını artırırken aşırıya kaçılmaması önemlidir (Hayıt, 2021). Modelin başlangıçta girdi ve çıktı değişkenleri arasındaki ilişkiyi iyi anlaması için doğru bir şekilde tasarlanması gerekmektedir. Yetersiz uyumu engellemek için gürültülü ve aykırı değerlerin azaltılması, eğitim süresinin artırılması ve doğru öznitelik seçiminin yapılması gibi yöntemler kullanılabilir.

4.1.5.3. Başlıca CNN Modelleri

4.1.5.3.1. LeNet

1988 yılında Yann LeCun tarafından geliştirilen ve 1998'e kadar sürekli iyileştirilen LeNet isimli mimari, ilk CNN ağlarından biridir. LeNet mimarisinde, alt katmanlar ardışık olarak konvolüsyon ve maksimum havuzlama katmanlarından oluşurken, üst katmanlar tamamen bağlı geleneksel çok katmanlı algılayıcı (MLP) yapılarına karşılık gelmektedir (Şeker vd., 2017).




Şekil 4.7. LeNet ağının mimarisi (Kaynak: Şeker vd., 2017).

4.1.5.3.2. AlexNet

2012'de Alex Krizhevsky, Ilya Sutskever ve Geoffrey Hinton tarafından geliştirilen AlexNet modeli, gerçekleştirilen ILSVRC ImageNet görsel tanıma yarışmasında %83,6 doğruluk oranı elde etmiştir. Bu başarı, doğrusal olmayan fonksiyonlar için Tanh yerine Relu kullanılmasıyla eğitim süresini kısaltarak hızı altı kat artırmıştır. Model ImageNet yarışmasında çığır açan bir başarı elde ederek derin öğrenmenin popülerleşmesini sağlamıştır (Ercan & Şahin, 2023).


Nesneleri tanımak için bir giriş, beş evrişim, üç havuzlama, iki seyreltme, üç tam bağlı, yedi ReLU, iki normalizasyon ve sınıflandırma katmanlarını içermektedir (Büyükarıkan, 2019).




Şekil 4.8. AlexNet Mimarisi (Kaynak: Toğaçar vd., 2019).

4.1.5.3.3. VGGNet

Oxford Üniversitesi'nden Visual Geometry Group (VGG) tarafından 2014'te geliştirilen bu mimarinin VGG16 ve VGG19 modelleri bulunmaktadır (Erçelik vd., 2023). VGG16 mimarisinde on üç evrişim, üç tam bağlı ve diğer katmanlar ile 41 katman, VGG19 mimarisinde ise on altı evrişim, üç tam bağlı ve diğer katmanlardan oluşan 47 adet katman bulunmaktadır (Büyükarıkan, 2020).



Şekil 4.9. VGG16 Mimarisi (Kaynak: Blauch vd., 2021).



Şekil 4.10. VGG19 Mimarisi (Kaynak: Büyükarıkan, 2020).

4.1.5.3.4. GoogleNet (Inception)

2014 yılında gerçekleştirilen ILSVRC ImageNet yarışmasında 22 katman derinliğine ve 144 katmana sahip GoogleNet, %94,3 doğruluk oranı elde ederek başarılı olmuş, 5 milyon parametre kullanarak AlexNet'e kıyasla 12 kat daha az işlem yüküne sahip olduğu gözlemlenmiştir (Akın vd., 2017). GoogLeNet, Inception modülleri sayesinde karmaşık bir mimariye sahip, geleneksel olarak ardışık bir yapıda konvolüsyon ve havuzlama katmanlarını üst üste istiflemek yerine, paralel olarak birbirine bağlı modüller kullanarak bellek ve güç kullanımında önemli iyileştirmeler sağlar. Bu yaklaşım, ağır hesaplama ve bellek maliyetini azaltırken ezberleme olasılığını da düşürür (İnik vd., 2017).




Şekil 4.11. GoogLeNet ağ mimarisi (Kaynak: İnik vd., 2017)

4.1.5.3.5. ResNet

ResNet, Evrimsel Sinir Ağları mimarisinde önemli bir ilerleme olarak kabul edilen evrişim katmanları, artık blokları ve tam bağlantılı katmanlardan oluşan derin bir sinir ağı mimarisidir (Wang vd., 2021). Küçük değişikliklerle oluşturulan bu mimari, derin ağların eğitiminde ve performansında önemli iyileştirmeler sağlamıştır. ResNet'in temel amacı, ağı derinliğini artırırken kaybolan gradyanlar ve optimizasyon zorlaşması gibi sorunları

gidermektir. ResNet'in özellikle dikkat çeken özelliği, artık bağlantılı konvolüsyonun (skip connection) kullanılmasıdır. Bu bağlantılar, ağıın bir katmanından diğerine direkt geçişi sağlar ve bu sayede gradyan kaybı problemi minimize edilir. Bu yapı, ağıın daha derin olmasını sağlarken aynı zamanda daha az parametreye sahip olmasını da sağlar, bu da ağıın eğitimini hızlandırır ve daha az veriyle daha iyi sonuçlar elde edilmesine olanak tanır. (Dağlı vd., 2021).




Şekil 4.12. ResNet mimarisinin şematik görünümü (Kaynak: Hayıt, 2021)

Gerçek üretim ortamında kusurlu örneklerin çok az olması nedeniyle, bir sınıflandırıcı aracılığıyla örnekleri kusurlu veya kusursuz olarak ilk olarak sınıflandırmak, algoritmanın ortalama çalışma süresini önemli ölçüde azaltabilir. Bu nedenle, bu makalede, doğruluğu artırmak ve ortalama çalışma süresini azaltmak için ikili görüntü sınıflandırması ve nesne algılama algoritması aynı anda kullanılmaktadır. ResNet, derin ağlar için etkili bir çözüm sunarak, büyük veri setleri üzerinde yüksek doğrulukla çalışabilir ve karmaşık örüntüleri tanıyabilmektedir (Wang vd., 2021).

4.1.5.3.6. MobileNet

MobileNet mimarisi, görsel işleme alanında kullanılmak üzere tasarlanmış (Erçelik vd., 2023) derinlemesine ayrışabilir evrişim (depthwise separable convolution) işlemiyle öne çıkan bir yöntemdir (Hayıt, 2021). Bu yöntem, filtreleme ve birleştirme işlemlerini ayrı ayrı gerçekleştirerek hesaplama maliyetini azaltırken derinlik sağlar. MobileNet'in dikkate değer özelliklerinden biri, derin öğrenme mimarisinde kullanılan evrişim türlerini (derinlemesine evrişim ve noktasal evrişim) optimal bir şekilde bir araya getirmesidir (Erçelik vd., 2023). MobileNet, bu derinlemesine ve noktasal evrişim katmanları dahil olmak üzere toplamda 28 katmandan oluşur. Bu mimari hem hesaplama maliyetini azaltarak hem de derinlik sağlayarak etkili bir şekilde özellik çıkarımı yapar (Hayıt, 2021).



Şekil 4.13. MobileNet Mimarisi (Kaynak: Erçelik vd., 2023)


4.1.5.3.7. EfficientNet

EfficientNet, 2019 yılında Google tarafından geliştirilen ve ImageNet veri kümesi üzerindeki görüntü sınıflandırma performansını büyük ölçüde artıran bu model, önceki birçok görüntü sınıflandırma modelinin aksine, "Compound Scaling" adı verilen bir ölçeklendirme yöntemini kullanarak aynı anda birden fazla hiperparametreyi optimize eder. Bu yaklaşım, modelin daha az parametreye sahip olmasını sağlarken daha yüksek doğruluk elde etmesine olanak tanır (Veziroğlu vd., 2023). EfficientNet modeli, diğer gelişmiş modellerden farklı bir yaklaşım benimseyerek modeli küçültmeye çalışırken derinlik, genişlik ve çözünürlük açısından ölçekleme yaparak daha verimli sonuçlar üretir. Bu modelde kullanılan bileşik ölçekleme yöntemi, temel ağın farklı ölçeklendirme boyutları arasındaki ilişkiyi belirlemek için bir ızgara arama algoritması kullanır. Bu sayede derinlik, genişlik ve çözünürlük boyutları için uygun bir ölçekleme katsayısı belirlenir. Daha sonra bu katsayılar, temel ağı istenen hedef ağı ölçeklemek için uygulanır (Uçar, 2021).

EfficientNet, önceki modellere kıyasla daha hafif bir yapıya sahip olmasına rağmen, diğer popüler modeller olan "MobileNet" ve "ResNet" gibi modellere göre daha iyi bir performans sergiler. Bu nedenle, özellikle kaynak sınırlı cihazlar üzerinde görüntü sınıflandırma uygulamaları için ideal bir seçenektir (Veziroğlu vd., 2023).

4.1.5.3.8. DenseNet

DenseNet (Yoğun Bağlantılı Ağlar), geleneksel derin öğrenme mimarilerinden farklı olarak yoğun bağlantılar ile yapılan bir yapısal değişiklik sunar. Bu mimaride, her katmanın çıkışı, kendisinden önceki tüm katmanların çıkışlarına bağlanır. Bu yoğun bağlantılar, önceki katmanlardan gelen daha düşük düzeyli özelliklerin daha yüksek düzeyli özelliklere daha etkili bir şekilde iletilmesini sağlar. Bu sayede, daha derin ve daha etkili öğrenme gerçekleştirilir (Zhang vd., 2018). DenseNet mimarisinin avantajlarından biri, özelliklerin daha iyi yayılmasını sağlayarak parametre sayısını azaltmasıdır. Bu yoğun bağlantılar, özelliklerin her katmana daha doğrudan ve etkili bir şekilde iletilebilmesini sağlar, bu da daha derin ve daha etkili öğrenme sağlar (Aksoy vd., 2020).



Şekil 4.14. DenseNet Mimarisi (Kaynak: Feng vd., 2019)

5. LİTERATÜRDEKİ ÇALIŞMALAR

Bu tez çalışmasının kapsamı doğrultusunda, gıdalardaki yağışın tespiti ve sınıflandırılması üzerine yapılan literatür taraması sonucunda belirlenen bazı önemli çalışmalar aşağıda sunulmuştur. Gıda endüstrisindeki yağış vakalarının tespiti ve önlenmesi amacıyla çeşitli görüntü işleme ve yapay zeka teknikleri kullanılarak gerçekleştirilen araştırmalar, bu alanda önemli ilerlemeler kaydedilmesini sağlamıştır. Görüntü analizi yöntemleri, özellikle renk, doku, yapı ve benzeri özelliklerin analiz edilmesini içeren görüntü işleme teknikleri, gıda ürünlerindeki yağış materyallerini tespit etmek için etkili bir yaklaşım sunmaktadır. Literatürdeki bazı çalışmalar, gıda ürünlerindeki yağışın tespiti için özellikle görüntü işleme ve yapay zeka tekniklerini değerlendirmiş ve bu yöntemlerin etkinliğini ortaya koymuştur. Özellikle, derin öğrenme ve makine öğrenme tekniklerinin kullanımıyla geliştirilen sınıflandırma modelleri, gıdalardaki yağış materyallerini doğru bir şekilde tespit etme ve sınıflandırma konusunda başarılı sonuçlar elde etmiştir. Bu çalışmalar, gıdalardaki yağış tespiti alanında yapay zekâ ve görüntü işleme tekniklerinin önemli bir potansiyele sahip olduğunu göstermektedir.

Medeiros vd., tereyağı yağlarının yağış tespiti ve kalite özelliklerinin tahmin edilmesi amacıyla düşük maliyetli taşınabilir yakın kızılötesi (NIR) spektrometresi kullanarak bir çalışma gerçekleştirmiştir. Saf tereyağı ile yağış edilmiş tereyağı örneklerine PLSD-DA, DD-SIMCA ve SVM-C sınıflandırma modelleri uygulanmıştır. DD-SIMCA ve SVM-C modelleri yağışın tespiti ve yağış türünün ayırt edilmesi konularında etkili bulunmuştur. Ayrıca, PLS ve SVM regresyon modelleri, süt yağının diğer yağlarla değiştirilme yüzdesi ile tereyağı yağlarının oksidatif stabilitesinin tahmininde kullanılmıştır. Sonuçlar, yağış araştırması için DD-SIMCA ve SVM-C modellerinin >%90 doğrulukla başarılı olduğunu ve PLS ve SVM-R regresyon modellerinin süt yağının diğer yağlarla değiştirilme yüzdesini yüksek oranda tahmin ettiğini göstermiştir. Izquierdo vd. ise saf ve yağışlı ekstra sızma zeytinyağının soğutma sürecindeki termal evrimlerin karşılaştırılmasıyla güvenilir bir yağış tespit yöntemi sunmuştur. Saf ve yağışlı yağların farklı termografik görüntülerinin analizi ve sınıflandırması için CNN'e dayalı algoritmalar test edilmiştir. Sınıflandırma doğruluğu açısından %97 ila %100 arasında değişen bir CNN performansı görülmüştür.

Başka bir yağ çalışmasında da De vd. çalışmasında maliyeti yüksek çuha çiçeği, kuşburnu ve andiroba yağlarının düşük maliyetli yağlarla (soya, mısır ve ayçiçek yağları) yağışının

saptanmasını amaçlamış, FTIR-HATR spektroskopisi ve yakın kızılötesi (NIR) spektroskopisi kullanılarak elde edilen görüntülere random forest algoritması ile yapay aykırı üretimi birleştirilerek yeni bir metodoloji önermişlerdir. Bu metodoloji, PLS-DA ve SIMCA modellerine oranla daha başarılı sonuçlar vermiştir. Benzer şekilde Teng vd. susam yağı ürünlerinin tanımlanması ve nicel olarak belirlenmesi, daha düşük fiyatlı yağlarla tağış ve susam yağı oranlarının yanlış etiketlenmesi sorunları nedeniyle Raman spektrometresi kullanarak yağ türlerinin ayrımı ve tağışın çoklu nicel belirlenmesi için iyileştirilmiş bir veri artırma yöntemi önermiş ve verilerle CNN modelleri oluşturmuşlardır. Ayrıca, her bileşeni aynı anda doğru şekilde tahmin etmek için vektör regresyonunu içeren yeni bir sinir ağı yapısı tanıtılmıştır. Önerilen yöntem, çok bileşenli tağışın tespitinde kimyasal metriklerle göre daha yüksek doğruluk elde etmiştir.

Sütte bitkisel yağ tağışının tespiti için ise Tian vd., flaş gaz kromatografisi elektronik burun (FGC E-nose) yöntemi ile dört makine öğrenme algoritması birleştirilerek bir yöntem geliştirilmiştir. Kalitatif analizde, rastgele orman (RF) ve destek vektör makinesi modelleri ile %1.000 ve %0.9565 doğruluk elde edilmiştir. Bu çalışma, FGC E-nose yönteminin makine öğrenme ile birleştirilerek, sütte bitkisel yağ tağışının hızlı ve kesin bir şekilde tespiti için etkili bir yöntem olduğunu öne sürmektedir.

Diğer bir çalışmada ise Shao vd. tarafından hiperspektral görüntüleme ve kemometri teknolojisinin bal tağışı tespiti için kullanıldığı gözlemlenmiştir. Bal ve tağışlı bal örneklerinin hiperspektral görüntülemesi yapılarak PCA ve SPA gibi yöntemler kullanılarak tağış tespitinde etkili olan dalga boyları belirlenmiş ve LIBSVM ve PLSR modelleri kullanılarak tağışın tespiti ve seviyesinin tahmini gerçekleştirilmiştir. Wojcik vd. de doğal bal tağışının tanınmasında bilgisayar vizyonuna dayalı bir derin öğrenme yaklaşımı sunmuştur. Kimyasal verilerin kullanıldığı makine öğrenme modelleri ile sonuçlar karşılaştırılmıştır.

Yine hiperspektral görüntülerle yapılan başka bir çalışmada Zheng vd. buğday unu örneklerinde farklı tağış türlerini ve oranlarını belirlemek amacıyla rafine buğday unu, yer fıstığı unu ve ceviz unu içeren farklı tağış konsantrasyonlarının homojen bir şekilde karıştırıldığı örnekler üzerinden hiperspektral görüntüleme yaparak elde edilen görsellere, destek vektör makinesi (SVM), lojistik regresyon (LR) ve multi-grained cascade forest (gcForest) algoritmalarına uygulamış ve en başarılı modelin %94 doğruluk oranıyla gcForest modeli olduğu belirlemişlerdir.

Wei vd. ise siyah çayda bulunan yapay bir renklendirici olan karminin tespiti için spektrofotometri ve makine öğrenimi yöntemlerinin birleştirildiği bir çalışma gerçekleştirmiştir. Karminin varlığının spektral verilerle etkili bir şekilde belirlenmesi için yapılan bu çalışma, yüksek başarı elde etmiştir.

Wang vd., tağışli et örneklerinin tespit edilmesinde tek termal görüntüleme ve tek CCD görüntüleme performansını artırmak için, bu iki görüntüleme tekniği, derin kalıntı ağı ile sinerjik bir şekilde birleştirmiştir. En iyi performans, renkli görüntü birleştirme ile elde edilmiştir. Et ürünlerindeki tağışli belirlemek için bir diğer çalışma Rady vd. tarafından yapılmış, makine öğrenme algoritmaları ile RGB renk görüntüleme kullanılarak, kıymada bitkisel ve hayvansal tağışliğin tespiti incelenmiş, tağışli miktarını tahmin etmek için regresyon modelleri geliştirilmiştir. Tüm özellikler kullanılarak geliştirilen lineer diskriminant sınıflayıcı, saf veya tağışli örneklerin tespitinde %99,1'e kadar ve seçilen özellikler kullanılarak %100 doğruluk elde etmiştir.

Li vd. meyve kurusu dökme karışımlarında titanyum dioksit tağışliğinin tespiti için Raman spektroskopisi kullanarak makine öğrenimi ile bütünleştirilmiş bir yöntem incelemiş ve bu çalışma ile, Raman spektroskopisi ve CNN ile titanyum dioksit tağışliğinin tespitinin umut vadeden bir yöntem olduğunu göstermişlerdir.

Pirinç tağışliğinin tespiti için, Pradana vd. tarafından terahertz zaman alanı spektroskopisine dayalı bir desen tanıma yöntemi sunulmuştur. Makine öğrenimi modelleri, özellik işleme ve spektral veri sınıflandırma işlemleri kullanılarak, %100'lük bir doğruluk elde edilmiştir.

Yine Hou vd. pirinç tohumlarında tağışliğin önlenmesi amacıyla, terahertz zaman alanı spektroskopisi tabanlı desen tanıma yöntemi sunmaktadır. Toplanan terahertz zaman alanı spektral verilerine dayanarak, özellik frekanslarını seçmek için Relief algoritması, rastgele orman (RF) algoritması ve maksimum korelasyon minimum gereksizlik (mRMR) algoritması geliştirilmiştir. Spektral verileri işlemek ve orijinal spektral verilerle birleştirmek için Hilbert dönüşümü, Butterworth düşük geçişli filtre gibi iki tür sinyal işleme yöntemi uygulanmıştır. Son olarak, özellik işleme sonrası spektral veri örneklerini sınıflandırmak için destek vektör makinesi (SVM) modeli ve aşırı öğrenme makinesi (ELM) modeli kullanılmış, %100 doğrulukla sınıflandırma gerçekleştirmişlerdir.

6. MATERYAL VE METOT

Gıdada tağşışın doğru ve güvenilir bir şekilde tespit edilmesi için oluşturulmak istenen model için yapılan çalışmalar bu bölümde anlatılacaktır. Başarılı bir modelin elde edilmesi gerek tüketiciler gerekse araştırmacılar tarafından büyük öneme sahiptir. Gıdada tağşış tespiti çalışması için ülkemiz ve dünya için önemli bir besin ve ihracat ürünü olan Antep fıstığı seçilmiş ve görsel veri seti oluşturulmuştur.

Materyal ve metot bölümüne tez çalışmasında kullanılan tağşışlı Antep fıstığı örneklerinin elde edilmesi, ham ve tağşışlı örneklerden görsel veri setinin oluşturulması ve görüntü işleme ile veri setinin oluşturulması ve veri setine uygulanan modeller ile sonuçları anlatılmıştır.

6.1. Kullanılan Araç ve Yazılımlar

Tez çalışmasında, görüntü işleme araştırmaları ve veri artırma teknikleriyle önerilen derin öğrenme modeli, Python programlama dili ve OpenCV, PİLOW kütüphanesi kullanılarak kodlanmıştır. CNN ve DenseNET modellerinin oluşturulmasında, Tensorflow kütüphanesini içeren Keras DL kütüphanesi tercih edilmiştir. Tüm kodlama işlemleri, Windows 10 işletim sistemine sahip bir istasyonda gerçekleştirilmiştir. Derin sinir ağlarının eğitiminde güçlü bir bilgisayar altyapısının kullanılması, hesaplama süresini kısaltmada önemli bir avantaj sağlamaktadır. DL modelleri için özellikle ekstra bir ekran kartının kullanılması, haftalar sürebilecek bir işlemi saatlerle sınırlayabilir. Bu nedenle, önerilen modelin geliştirilme süreci, Xenon işlemcili, 32GB RAM, 512 GB SSD ve Nvidia GTX 1080 Ti ekran kartına sahip bir iş istasyonunda tamamlanmıştır.

6.2. Veri Setinin Oluşturulması

Antep fıstığında tağşış çalışması için modele uygulanacak veri setinin belirli kalitede standartlaştırılmış olması modelin başarısı açısından elzemdir. Eşsiz bir veri seti olarak sıfırdan oluşturulan Antep fıstığı ve tağşışe uğramış versiyonları laboratuvar ortamında elde edilerek bir düzenek içerisinde görüntü alınmış ve daha sonra bu görüntüler üzerinde işlemler yapılmıştır.

6.2.1. Antep Fıstığı ve Tağşışlı Örneklerinin Hazırlanması

Tez çalışması kapsamında kullanılan çiğ Antep fıstığı Gaziantep ilinden temin edilmiştir. Sert kabuğundan ayrılmış ve bütün olarak temin edilmiş olan Antep fıstığı laboratuvar

öğütücüsü (Kiwi Brand) kullanılarak öğütülmüş ve bu haliyle kullanılmıştır. Elde edilen örnek, şekil 6.1’de verilmiştir.



Şekil 6.1. Antep Fıstığı örneği

Kabuğu soyulmuş yer fıstığını boyamak için yeşil gıda boyası, Yozgat ilindeki yerel marketlerden alınmış ve laboratuvar öğütücüsü kullanılarak önce öğütülmüş daha sonra 100 gr. yer fıstığına 10 damla yeşil gıda boyası eklenerek yeşil renge boyanmış ve 55 °C’de kurutulmuştur. Elde edilen örnek şekil 6.2’de verilmiştir.



Şekil 6.2. Yer Fıstığı örneği

Bezelye nem dengesinin sağlanması için kurutucuda (WMF KITCHEN) 55 °C’de 12 saat kurutulmuş ve laboratuvar öğütücüsü ile öğütülmüştür. Örnek resimler şekil 6.3 ve şekil 6.4’te verilmiştir.



Şekil 6.3. Bezelyelerin WMF KITCHEN kurutucuda kurutulması



Şekil 6.4. Bezelye örneği

Ispanak karışımı için 250 gr. ıspanak ayıklanıp yıkanmış püre haline getirilmiş, 200 gr. şeker, 4 yumurta, 200 gr. süt, 200 gr. Ayçiçek yağı karıştırılarak bir harç hazırlanmış ve 180 °C’de 40 dk. pişirilmiştir. Piştikten sonra soğutularak öğütülmüş ve nem dengesini sağlamak için 50 °C’de kurutulmuştur. Elde edilen örnek, şekil 6.5’de verilmiştir.



Şekil 6.5. Ispanak örneği

Örneklerin elde edilmesiyle Antep fıstığı, bezelye, ıspanak ve yer fıstığı örneklerinden sınıflandırma için gruplar oluşturulmuştur.

6.2.2. Görsellerin Elde Edilmesi

Antep fıstığı ve taklitleri Şekil 6.2’de görüldüğü üzere dijital bir fotoğraf makinesi, yatay bir tripod ve çekim kabini içeren özel olarak tasarlanmış bir mekanizma kullanılarak laboratuvar ortamında fotoğraflanmıştır.



(a)

(b)

(c)

Şekil 6.6. Çekim kabini dış görüntüsü (a), Çekim kabini iç görüntüsü (b), Çekim kabini ve fotoğraf makinesi mekanizması görüntüsü (c).

Antep fıstığı ve taklitleri aynı büyüklükteki petri kaplarına silme bir şekilde doldurularak, ortası işaretlenmiş çekim kabinine yerleştirilmiş, kabin dışarıdan ışık almayacak şekilde kapatılarak ürünler fotoğraflanmıştır. Petri kabındaki maddeler her bir fotoğraf çekiminden önce boşaltılıp karıştırılmış silme olarak tekrar doldurulmuş ve kabine yerleştirilerek fotoğraflanmıştır. Bu şekilde dış etmenlerden bağımsız ve içerik olarak standart bir veri seti elde edilmiştir. Her ürün grubundan ve karışımlarından 50-55 adet fotoğraf elde edilmiştir.



(a)

(b)

(c)

(d)

Şekil 6.7. Laboratuvar ortamında çekilmiş ürün fotoğrafları; (a) Antep fıstığı, (b) bezelye, (c) ıspanak, (d) yer fıstığı

6.2.3. Görsellerin Etiketlenmesi

Makine öğrenimi, bir modelin belirli bir girdiye uygun bir çıktıyı öğrenmesini sağlayan bir süreçtir. Denetimli makine öğrenimi modellerinde, modele doğru kararlar verebilmesi için etiketlenmiş bir veri seti gereklidir. Veri etiketleme, bu etiketlenmiş veri setini oluşturma sürecidir ve makine öğrenimi modelinin doğru şekilde eğitilmesi için kritik öneme sahiptir.

Yanlış etiketlenmiş veriler, makine öğrenimi modelinin yanlış yönlendirilmesine ve sonuçların güvenilirliğinin azalmasına neden olabilir. Bu nedenle, veri etiketleme sürecinin doğru ve güvenilir olması, makine öğrenimi modelinin başarılı bir şekilde eğitilmesi için hayati önem taşır (Bozyiğit & Tarhan, 2020).

Veri etiketleme, ham veri örneklerinin insanlar tarafından anlamlı etiketlere veya kategorilere atanması işlemine verilen isimdir. Bu etiketler, veri örneklerinin içerdikleri bilgileri temsil eder: Örneğin, bir resimdeki nesnelerin etiketlenmesi "araba" veya "elma" veya bir metin belgesindeki cümlelerin etiketlenmesi "olumlu" veya "olumsuz" gibi (Hayit, 2021).

Veri elde etme aşamasından sonra, elde edilen Antep fıstıklı ve tağşişli görseller denetimli makine öğrenmesi modellerinde kullanılabilmesi için etiketlenmiştir. Yapılan etiketlemeler ve elde edilen ham veri sayılarına ilişkin istatistikler Tablo 6.1'deki gibidir.

Tablo 6.1. Elde edilen ham veri seti istatistikleri

Antep fıstığı	Bezelye	Ispanak	Yer fıstığı	TOPLAM
61	57	52	50	220

6.2.4. Görüntü İşleme Ön Aşamaları

6.2.4.1. Maskeleme

Görüntü tabanlı yapay zekâ modellerinin eğitimi sırasında, modelin istenmeyen özellikler öğrenmesini önlemek amacıyla belirli bölgelerin gizlenmesi için maskeleme tekniği kullanılabilir. Bu yöntem, genellikle belirli bir bölgenin siyah, beyaz veya ortalama bir renk ile doldurulmasıyla gerçekleştirilir, böylece gizlenen bölge diğer görüntü piksellerinden ayırt edilemez hale gelir. Görüntü işleme uygulamalarında, maskeleme genellikle piksel değerlerinin değiştirilmesi veya örtülerin eklenmesi yoluyla gerçekleştirilir.


Diğer bir ifadeyle, maskeler görüntü işlemede belirli özellikleri vurgulamak veya belli bölgeleri gizlemek için kullanılan filtrelerdir. Bir maske, genellikle bir görüntünün üzerine bindirilerek, belirli bir işlemi uygulamak için pikselleri seçmek veya filtrelemek amacıyla kullanılır (Perihanoğlu, 2015).

Görüntü segmentasyonu, bir görüntünün piksel bölgelerine ayrıştırılarak bir maske veya etiketlenmiş görüntüyle temsil edilen bir koleksiyona dönüştürülmesini içerir. Bu yöntem, görüntünün önemli parçalarını işleyerek tüm görüntüyü değil, sadece ilgili bölgeleri analiz

etmeyi sağlar (Anonim, 2020).

Bu aşamada Python Imaging Library (PIL) ve OpenCV kütüphaneleri ile belirtilen klasördeki görüntülerin listesi alınmış ve her biri için işlem yapılmıştır. Görüntülerin boyutlarına göre, yuvarlak bir maske oluşturulmuş ve bu maske görüntüye uygulanmış, maskenin dışında kalan pikseller de siyah yapılarak yuvarlak kırpılmış görüntü arka plandan ayrılmıştır.

Burada maskeleme ile segmentasyon(bölütleme) gerçekleştirilmiş, görüntülerin merkezindeki yuvarlak bölge (yuvarlak petri kabındaki Antep fıstığı ve tağşişli örnekler) belirlenerek bölgeyi diğer kısımlardan ayırma işlemi yapılmıştır. Sonuç olarak, her bir görüntü için, merkezdeki yuvarlak bölge dışında kalan pikseller siyaha dönüştürülerek görseller bu işlemten sonra yeni bir klasöre kaydedilmiştir. Bu sayede görsellerdeki petri kabının çevresindeki gürültü içerebilecek gereksiz kısımlar filtrelenmiş ve sadece modelin eğitileceği Antep fıstığı ve tağşişli örneklerin odaklanıldığı görseller oluşturulmuştur.



Şekil 6.8. Maskeleme; (a) orijinal Antep fıstığı görüntüsü, (b) gri seviye görüntüsü, (c) maske ile kırpılmış görüntü


6.2.4.2. Kırpma

Otsu eşikleme yöntemi, bir görüntüyü iki sınıfa ayırmak için optimal bir eşik değeri seçerken sınıflar arasındaki varyansı maksimize etmeyi hedefler. Bu, nesne ve arka plan sınıflarının en iyi şekilde ayrılmasını sağlar. Kenar tespiti işleminde, Otsu eşikleme yöntemi kullanılarak gri tonlamalı bir görüntüyü ikili bir forma dönüştürülür. Bu dönüşüm

sonucunda, kenarlar daha belirgin hale gelir ve işlem yapılacak olan nesne daha iyi tanımlanabilir hale gelir. Kenar tespiti, genellikle bir görüntüdeki nesnelerin sınırlarını belirlemek için kullanılan bir işlemdir. Bu yöntem, özellikle nesne tespiti, kenar tespiti ve görüntü segmentasyonu gibi birçok görüntü işleme uygulamasında yaygın olarak kullanılır (Elen, 2020).

Canny kenar tespiti algoritması, kenar tespitinde sıklıkla kullanılan bir yöntemdir. Canny kenar tespiti, görüntüdeki kenarları tespit etmek için birden fazla aşamadan oluşur. İlk olarak, görüntüdeki gürültüyü azaltmak için Gauss filtresi uygulanır. Ardından, kenar yoğunluğunu ve yönünü hesaplamak için gradyanlar kullanılır. Daha sonra, kenar piksellerinin bağlantılarını sağlamak için non-maximum suppression tekniği uygulanır. Son olarak, eşik değerleriyle kenarları belirlemek için histerezis eşikleme uygulanır (Tekin & Çetin, 2019).

Bu çalışma kapsamında Python kodu ile, verilen bir klasördeki görüntü dosyalarını kırpma işlemi gerçekleştirilmiştir. Otsu eşikleme yöntemi, görüntünün gri tonlamalı hâline uygulanarak, Otsu'nun eşik değeri hesaplanmıştır. Bu hesaplanan eşik değeri, Canny kenar tespiti yöntemi için kullanılmış ve kenarlar belirlenmiş ve belirlenen kısımlardan kırpma işlemi gerçekleştirilmiş böylelikle veri setindeki görseller boyut olarak küçültülmüş ve daha kolay işlenebilir hale gelmiştir.



(a)

(b)

Şekil 6.9. Kırpma; Maskelenmiş Orijinal Antep fıstığı görüntüsü(a) ve sınırlarından kırılmış görüntü(b)


6.2.4.3. Veri Artırımı

Bu tez çalışması kapsamında Python OpenCV kütüphanesi kullanılarak, verilen bir giriş klasöründeki görüntü dosyalarını döndürerek veri artırma işlemi gerçekleştirilmiştir.

Veri artırma işlemi şu aşamaları içermektedir:

- İlk olarak, belirtilen giriş klasöründeki her bir görüntü dosyası için bir döngü oluşturulur,
- Döngü içinde, her bir görüntü dosyası 10 derecelik açılarla döndürülür,
- Döndürülen her bir görüntü yeni bir klasöre kaydedilir,
- Sonuç olarak her bir görsel için 36 adet yeni görsel elde edilir.

Bu kod, veri artırma yöntemlerinden biri olan döndürme işlemi kullanılarak, veri setindeki çeşitliliği artırmak amacıyla kullanılmıştır. Özellikle, eğitim veri setinin boyutunu artırmak ve modelin genelleme yeteneğini iyileştirmek için bu tür veri artırma teknikleri kullanılmaktadır.



Şekil 6.10. Maskelenmiş ve kırılmış Antep fıstığı görüntüsünün, 10'ar derece döndürülmesiyle elde edilen görüntüler

Derin öğrenmeye dayalı sınıflandırma için oluşturulan sınıflar ve veri sayıları tablo 6.2' de verilmiştir. Veri artırma işlemi sonucu toplamda 7886 adet görsel elde edilmiştir.

Tablo 6.2. Elde edilen veri setinin eğitim (öğrenme süreci sırasında kullanılan örnek veri kümesi) ve doğrulama (modelde ince ayar yapmak için kullanılan örnek veri kümesi) ve test (eğitim ve doğrulama veri kümelerinden bağımsız veri kümesi) grupları.

	Antep fıstığı	Bezelye	Ispanak	Yer fıstığı	TOPLAM
Eğitim	1511	1435	1309	1262	5517
Doğrulama	216	206	188	181	791
Test	431	411	375	361	1578
TOPLAM	2158	2052	1872	1804	7886

6.3. Derin Öğrenmeye Dayalı Sınıflandırma Yöntemi


6.3.1. CNN

Evrişimli Sinir Ağları (CNN), görsel verilerin işlenmesinde sıklıkla kullanılan, görsel verilerden etkin bir şekilde özellik çıkarımı yapabilen bir modeldir. Mimarileri hayvan görsel korteksinin organizasyonundan esinlenerek oluşturulan bu ağlar, görüntülerin ve videoların işlenmesinde yüksek performans göstermektedir (Aalami vd., 2020). Dolayısıyla görüntü tabanlı verilerde etkili bir şekilde özellik çıkarımı yapabilen ve karmaşık yapıları tanımlayabilen bu model, taşıt belirlleme görevi için oldukça uygundur.

6.3.1.1. DenseNet-201

DenseNet, geleneksel CNN'lere kıyasla daha derin ve daha bağlantılı bir yapıya sahip olan bir derin öğrenme modelidir. Bu model, bağlantılı katmanlar arasında daha fazla bilgi akışı sağlar ve etkin parametre kullanımıyla bilinir. Yoğun bloklar adı verilen özel yapılarıyla, bilgi paylaşımını artırarak daha etkili öznetelik çıkarma yeteneği sunar. Buradan yola çıkarak, taşıt belirlleme gibi karmaşık ve ince ayrıntılar gerektiren görevlerde daha iyi performans gösterebilir bir model olduğu düşünülmektedir (Özdemir, 2023).


DenseNet-201, derin öğrenme ve bilgisayarla görme alanlarında önemli bir yer tutan DenseNet ailesinin bir üyesidir. DenseNet-201, 201 katmanlı bir yapı sunar ve bu sayede oldukça derin bir ağ olarak karmaşık özellikleri öğrenebilir. Bu mimaride, her katman, kendisinden önceki tüm katmanların çıktısını kullanarak çalışır, bu da parametre verimliliğini artırır ve aşırı öğrenmeyi (overfitting) azaltır (Hayıt & Çınarer, 2022). Derinliğinin fazla olmasına rağmen, dense bloklar ve geçiş katmanları, parametre sayısını etkin bir şekilde azaltır. Bu özellik, daha verimli bir model eğitimi ve parametre kullanımı sağlar. DenseNet-201, bu yenilikçi yapısıyla, derin ağların eğitiminde karşılaşılan zorlukların üstesinden gelerek, bilgisayarla görme ve görüntü tanıma gibi görevlerde yüksek doğruluk oranları elde eder (Doğan & Türkoğlu, 2022).



Şekil 6.11. DenseNet-201 Mimarisi (Hayıt, 2021)

6.3.1.2. ResNet-18


ResNet-18, derin öğrenme alanında başarılı yayılım işlemleri gerçekleştiren yenilikçi bir mimaridir. Klasik modellerden farklı olarak, ResNet mimarisi, sonraki katmanları besleyen artık bloklardan (residual blocks) oluşur. ResNet-18, 18 katmanlı bir derin sinir ağı olup, her biri iki katmandan oluşan toplam dokuz residual blok içerir. Artık bloklar, normal yapay sinir ağlarından daha derin yapıların eğitimini kolaylaştırır. Tahmin sağlayan ve modelin performansına katkı yapmayan katmanlardan kaçınarak modelin derinliği ve performans düşüşü yaşanmadan doğruluk oranı artırılabilir. Bu yapı, daha derin ağların eğitilmesini mümkün kılarak, modelin daha karmaşık özellikleri öğrenmesini sağlar. Böylece, derin ağların eğitiminde karşılaşılan hız ve zaman tüketimi problemleri minimize edilirken, model doğruluğu hızlı bir şekilde sağlanır (Ateş vd., 2022). Özellikle görüntü sınıflandırma, nesne algılama ve sahne tanıma gibi çeşitli bilgisayarla görme görevlerinde yaygın olarak kullanılır ve yüksek performansı ile dikkat çeker.



Şekil 6.12. ResNet-18 Mimarisi (Kim vd., 2019)

6.3.1.3. InceptionV3

InceptionV3, InceptionV'i temel alan, Google tarafından geliştirilen ve ImageNet veri kümesi ile eğitilen bir derin öğrenme modelidir. Mimari, 299x299x3 boyutunda girdi işleyebilen ve toplamda 48 katman içeren bir yapıya sahiptir. Inception V3'ün temel yapısı, evrişim katmanları, havuzlama katmanları ve son olarak softmax katmanından oluşur (Bozkurt, 2021). Mimari, önceki versiyonlarda maliyetli olan 5x5 evrişimlerin yerine daha küçük boyutlu 3x3 evrişimlerin kullanılmasıyla optimize edilmiştir. Bu değişiklik sayesinde hesaplama süresi azalmış ve dolayısıyla eğitim hızı artmıştır. Inception V3 modeli, 1x1, 3x3 ve 5x5 evrişim katmanlarını kullanan inception modüllerini içerir. Parametre sayısını azaltarak eğitim hızını artırmak ve ağı derinlik ve genişliğini optimize etmek amacıyla tercih edilmektedir (Foto, 2022).




Şekil 6.13. InceptionV3 Mimarisi (Kaynak: Ali vd., 2021)

6.3.1.4. Transfer Öğrenimi

Transfer öğrenimi, önceki bir görevde edinilen bilgilerin yeni bir görevde kullanılmasını sağlayarak öğrenme sürecini iyileştiren, ikinci görevin modellenmesinde daha hızlı gelişme ve artırılmış performans elde etmeye yardımcı olan bir eğitim yaklaşımıdır (Erdem, 2022). Transfer öğrenimi, yeterli veri bulunmayan durumlarda derin ağların eğitiminde güçlü bir çözüm sunan bir tekniktir. Önceden eğitilmiş parametrelerin yeni ve spesifik problemlere adapte edilmesiyle, belirli bir göreve yönelik derin yapılar modifiye edilerek ilişkili başka görevler için yeniden yapılandırılabilir. Bu sayede, derin bir modeli sıfırdan eğitmek için yeterli veri olmadığında, transfer öğrenimi kullanışlı ve etkili bir alternatif yaklaşım olarak öne çıkar (Polat & Özerdem, 2021).

Transfer öğreniminde kaynak görev; eğitilebilirliği yüksek, bilginin hedef göreve aktarılacağı ana alan olarak tanımlanırken hedef görev ise kaynak görevden bilgi aktarımının sonucunda daha iyi öğrenmenin gerçekleştiği bir görev olarak tanımlanır. Transfer öğrenimi sürecinde, kaynak görevde elde edilen bilgi ve hızlı ilerleme, yeni bir hedef görevin öğrenilmesine ve gelişmesine katkı sağlar. Ancak, aktarılan bilginin hedef görev performansında düşüşe yol açması durumu Negatif Transfer olarak adlandırılır. Transfer öğrenme yöntemlerini kullanırken en büyük zorluklardan biri, görevler arasında pozitif transfer sağlamak ve alakasız etkinlikler arasında negatif transferden kaçınmaktır (Maral, 2022). CNN tabanlı transfer öğrenimi mimarisi, öğrenmenin aktarımı yoluyla görüntüler üzerinde yüksek başarılı çalışmalar yapılmasını sağlamaktadır (Kurt & Arabacı, 2022).



Şekil 6.14. Transfer öğrenme çalışma prensibi (Kaynak: Fırıldak & Talu, 2019)


6.3.2. Önerilen Model

Bu çalışma, Antep fıstığı tağşışını görüntüler üzerinden saptamak için bir önerilen model sunmaktadır. Bu amaçla veri setine Densenet-201, ResNet-18 ve InceptionV3 modelleri uygulanarak her bir model için sınıflama başarısı belirlenmiştir. Model eğitimi, Python programlama dili kullanılarak gerçekleştirilmiştir. Ayrıca, önceden belirlenen veri artırma teknikleri kullanılarak veri seti artırılmış ve eğitim, doğrulama ve test veri kümeleri oluşturulmuştur. Modeller içerisinde en başarılı model InceptionV3 olmuştur. Önerilen InceptionV3 modeli, çeşitli hiper parametrelerle optimize edilmiştir. Modelin optimizasyonu için Adam algoritması tercih edilmiştir. Kayıp fonksiyonu olarak kategorik çapraz entropi (Categorical Crossentropy) kullanılmıştır. Momentum değeri 0.9 olarak belirlenmiş ve öğrenme oranı $1e-05$ olarak ayarlanmıştır. Eğitim sürecinde, erken durdurma (Early Stopping) stratejisi kullanılarak, eğitim doğruluğu 10 dönem boyunca iyileşmediğinde süreç sonlandırılmıştır. Maksimum epoch sayısı 20 olarak belirlenmiş ve mini batch boyutu 32 olarak seçilmiştir. Modelin eğitim verileri, her epoch'ta karıştırılarak (shuffle) eğitim sürecinin daha etkili olması sağlanmıştır. Bu parametreler, modelin performansını optimize etmek ve aşırı öğrenmeyi (overfitting) önlemek amacıyla dikkatle seçilmiştir. Önerilen model için seçilen parametreler tablo 6.3'te verilmiştir.

Tablo 6.3. Önerilen InceptionV3 modeline ait parametre değerleri

Parametre Adı	Değeri
Optimizer	Adam
Loss function	Categorical crossentropy
Momentum	0.9
Learning rate	$1e-05$
Early stopping patience	10
Maximum epoch	20
Mini batch size	32
Shuffle	Every epoch
Validation frequency	50

Modelin performansı, eğitim ve doğrulama veri kümelerindeki doğruluk derecesi ile test veri kümesinde elde edilen sonuçlar karşılaştırılarak değerlendirilmiştir. Modelin aşırı uyum sorununu önlemek amacıyla, eğitim süreci boyunca hiç kullanılmamış küçük bir test veri kümesi ile test yapılmış ve bu süreçte elde edilen doğruluk oranı ile test sonuçları karşılaştırılmıştır. Önerilen modelinin oluşturulma süreci şekil 6.15’deki iş akışında görsel olarak anlatılmıştır.



Şekil 6.15. Önerilen derin öğrenme modeli iş akışı

6.4. Performans Değerlendirme Ölçütleri

Bu araştırmada, Antep fıstığındaki tağşişin saptanması için geliştirilen modellerin performansını değerlendirmek amacıyla literatürde önerilen belirli değerlendirme ölçütleri kullanılmıştır. Görüntü tabanlı tağşiş tespit problemi, doğru ve güvenilir sonuçlar elde etmek için çeşitli performans metriklerinin dikkate alınmasını gerektirir. Bu nedenle, modelin sınıflandırma doğruluğunun yanı sıra kesinlik, duyarlılık, F1 skoru ve ROC eğrisi altında kalan alan gibi ölçütler de incelenmiştir. Bu metrikler, modelin tağşiş tespitindeki performansını daha kapsamlı bir şekilde değerlendirmeye olanak tanır ve gerçek dünya uygulamaları için daha güvenilir sonuçlar sağlar. Bu ölçütlerin kullanılmasıyla, geliştirilen CNN modelinin Antep fıstığındaki tağşişin saptanması konusundaki etkinliği daha detaylı bir şekilde değerlendirilmiştir.

CNN gibi derin öğrenme modellerinin performansını değerlendirmek için çeşitli ölçütler kullanılmaktadır. Bu ölçütler, modelin sınıflandırma yeteneğini ve genel performansını belirlemek için önemlidir.

6.4.1. Karışıklık Matrisi (Confusion Matrix)

Karışıklık Matrisi (Confusion Matrix), modelin sınıflandırma performansını detaylı bir şekilde değerlendirmek için kullanılır. Gerçek sınıfların tahmin edilen sınıflarla karşılaştırıldığı bir tablodur.

Bu ölçütleri hesaplamak için bazı ara parametreler ve formüller kullanılmaktadır. Ölçütlerin hesaplanmasında kullanılan bu parametreler Doğru Pozitif (DP), Yanlış Negatif (YN), Yanlış Pozitif (YP) ve Doğru Negatif (DN) olarak adlandırılır. Makine öğreniminde hata matrisi olarak da bilinen karışıklık matrisleri, genellikle bir denetimli öğrenme algoritmasının performansını görselleştirmede kullanılan tablolardır (Ciran & Özbay,2022). Bir sınıflandırma işlemindeki tüm doğru ve yanlış tahminlerin sınıflara sayısal dağılımını gösteren bu matrisin her satırı, gerçek bir sınıftaki örneklerin temsilini sağlarken; her sütun, tahmin edilen bir sınıftaki örnekleri temsil eder (Hayıt, 2021). Örneğin, "Pozitif" ve "Negatif" sınıflarından oluşan bir sınıflandırma işlemi sonucu ortaya çıkan karışıklık matrisi, doğru ve yanlış tahminlerin sayısını (veya yüzdesini) özetler.

6.4.2. Doğruluk (Accuracy)

Doğruluk (Accuracy) ölçütü, modelin öngörülen sınıf ile gerçek sınıf arasındaki uyumu oransal olarak ifade eden ve doğru sınıflandırma oranını temsil eden bir metriktir (Ciran & Özbay,2022). Toplam doğru sınıflandırmaların, toplam veri noktalarına oranı olarak hesaplanır. Ancak, dengesiz sınıf dağılımlarında yanıltıcı olabilir. Doğruluk formülü aşağıdaki formülde verilmiştir:

$$\text{Doğruluk} = \frac{DP + DN}{DP + DN + YP + YN}$$

6.4.3. Kesinlik (Precision)

Kesinlik (Precision), sınıflandırma işlemi sonucunda "Pozitif" olarak tahmin edilen örneklerin gerçekten "Pozitif" sınıfına ait olma oranını gösteren önemli bir sınıflandırma ölçütüdür. Bu ölçüt, belirli bir sınıfa ait doğru tahmin edilen örneklerin, tüm bu sınıfa tahmin edilen örneklerin oranını ifade eder. Başka bir deyişle, sınıflandırma işleminde "Pozitif" olarak tahmin edilenlerin hangi oranda gerçekten "Pozitif" sınıfına ait olduğunu

belirler (Çakmak & Selvi, 2022). Kesinlik değerin matematiksel hesaplaması aşağıdaki eşitlikte gösterilmiştir:

$$Kesinlik = \frac{DP}{DP + YP}$$

6.4.4. Duyarlılık (Recall-Sensitivity)

Duyarlılık (Recall), "Pozitif" sınıftaki örneklerin hangi oranda "Pozitif" olarak tahmin edildiğini gösteren bir sınıflandırma ölçütüdür ve çok sınıflı tahmin çalışmalarında, her sınıf için ayrı ayrı, doğru tahmin edilen pozitif durumların (TP) pozitif durumların toplamına bölünmesiyle hesaplanır; bu hesaplama yanlış tahmin edilen negatif durumları (FN) da dikkate alır (Alparslan & Dursun, 2023). Duyarlılığı ifade eden eşitlik aşağıdaki gibidir:

$$Duyarlılık = \frac{DP}{DP + YN}$$

6.4.5. F1 Skor (F1-Score)

F1 Skoru, kesinlik ve duyarlılığın harmonik ortalamasıdır. Dengeli bir performans ölçüsü sağlar ve özellikle dengesiz sınıf dağılımlarında doğruluktan daha güvenilirdir. F1-Skorun formülü aşağıdaki gibidir:

$$F1 - Skor = 2 * \frac{Kesinlik * Duyarlilik}{Kesinlik + Duyarlilik}$$

6.4.6. ROC Eğrisi (Receiver Operating Characteristic Curve)

ROC (Receiver Operating Characteristic) eğrisi, sınıflandırma problemlerinde önemli bir performans ölçütüdür. ROC, bir olasılık eğrisi olup, altında kalan alan (AUC - Area Under the Curve) ayrılabilirliğin derecesini veya ölçüsünü temsil eder. AUC, [0, 1] aralığında değerler alır ve değerin 1'e yaklaşması, sınıflandırıcının daha doğru tahminler yaptığını gösterir. AUC değeri 0,5 ise, sınıflandırıcının rastgele tahminler yaptığı anlamına gelirken, bu değerin altındaki değerler, sınıflandırıcının performansının yetersiz olduğunu vurgular (Ciran & Özbay,2022)

7. ARAŞTIRMA BULGULARI

Çalışmada, önceden eğitilmiş CNN modellerine girdi olarak sunulan veri setine ait ham görüntüler, özel bir düzenek kullanılarak laboratuvar ortamında elde edilmiştir. Ardından, toplanan ham veriler etiketlenmiştir.


Elde edilen ham veri kümesi, önceden eğitilmiş CNN modellerini eğitmek için yetersiz kalmıştır. Bu nedenle, verilerin sınıflar arasındaki dağılımının dengelenmesi ve ayrıca modellerin eğitiminde ortaya çıkabilecek aşırı uyum veya yetersiz uyum gibi sorunların üstesinden gelmek için yaygın yöntemler kullanılarak ham veri kümesi artırılmıştır.

Sıfırdan oluşturulan veri seti Inception, ResNet ve DenseNet gibi önceden eğitilmiş CNN modelleri kullanılarak sınıflandırılmıştır. Deneysel süreçte, CNN ağlarının InceptionV3, ResNet-18 ve DenseNet-201 versiyonları işe koşulmuştur. Deneysel sonuçlar, InceptionV3 ve DenseNet-201 ağlarının ResNet-18 ağına nazaran daha başarılı olduğunu göstermiştir. Tablo 7.1 tüm modellerin sınıflama doğruluk oranlarını sunmaktadır. Bu sonuçlara göre InceptionV3 ve DenseNet-201 her ne kadar birbirine yakın sonuçlar sergilese de modellerin eğitim süreleri ve ağ derinliği ölçütleri dikkate alındığında InceptionV3 modelinin öne çıktığı görülmüştür.

Tablo 7.1. CNN modellerinin eğitim süresince elde edilen sınıflandırma doğruluk oranları


Model	Doğruluk (%)	Eğitim Zamanı	Katman Derinliği
InceptionV3	%99,6	66 dk. 56 sn.	48
DenseNet-201	%98,8	175 dk. 24 sn.	201
ResNet-18	%95,9	12 dk. 52 sn.	18

Hem eğitim hem de doğrulama sonuçlarının grafikleri en başarılı modeller için Şekil 7.1 üzerinde gösterilmiştir. Modeller, 20 dönem (epoch) boyunca 5520 adet görsel ile eğitilmiş ve her dönem sonunda 788 adet görsel ile doğrulanarak doğrulama değeri hesaplanmıştır. Grafiklere göre eğitim sürecinde eğitim ve doğrulama sonuçlarında artış görülmektedir.




Şekil 7.1. InceptionV3 ve DenseNet-201 eğitim ve doğrulama doğruluk grafikleri

Ek olarak en başarılı modellerin kayıp grafikleri Şekil 7.2 üzerinde sunulmuştur. Eğitim ve doğrulama sürecinde kayıp verilerinde azalma oluşu gözlemlenmektedir.




Şekil 7.2. InceptionV3 ve DenseNet-201 eğitim ve doğrulama kayıp grafikleri

Modellerin eğitimi tamamlandıktan sonra, tüm modeller eğitim süresince hiç karşılaşmadığı 1577 görsel ile test edilmiştir. Test işlemlerinin hata matrisleri Şekil 7.3 üzerinde sunulmuştur. Sınıf isimleri İngilizce isimleriyle adlandırılmıştır. Burada özellikle InceptionV3 modelinin Antep fıstığı örneklerinin hepsini başarılı bir şekilde sınıflandırabildiği görülmektedir. Bununla birlikte DenseNet-201 modelinin ıspanak ve yer fıstıklarını başarıyla ayırt edebildiği söylenebilir.



Şekil 7.3. InceptionV3 ve DenseNet-201 modelleri için test veri kümesine ait hata matrisleri. Sınıfların isimlendirmeleri pistachio: Antep fıstığı, pea: bezelye, spinach: ıspanak, peanut: yer fıstığı

Diğer yandan InceptionV3 için örnek bir Antep fıstığı karışımı girdisi, ilk iki evrişim katmanını kullanarak görselleştirilmiştir. Burada birinci katman olan girdi katmanında 299x299x3 boyutuna dönüştürülen görsel, ilk evrişim katmanına girdi olarak verilir ve 36 filtre uygulanır. Ardından toplu normalleştirme işleminden sonra elde edilen çıktı ikinci evrişim katmanına girdi olarak verilir ve tekrar 36 filtre uygulanır. Birinci ve ikinci evrişim katmanını süreçleri ve uygulanan aktivasyonlar Şekil 7.4 üzerinde sunulmuştur.



Şekil 7.4. InceptionV3 ve DenseNet-201 modelleri için test veri kümesine ait hata matrisleri. Sınıfların isimlendirmeleri pistachio: Antep fıstığı, pea: bezelye, spinach: ıspanak, peanut: yer fıstığı

Son olarak, InceptionV3'ün performansı doğruluk oranının yanı sıra kesinlik, hassasiyet ve F1 Skor ölçütleri hesaplanarak değerlendirilmiştir. Ölçütlerin sonuçları modelin sınıflama başarısını desteklemektedir. InceptionV3'ün diğer metrikler açısından her sınıf için performansı tablo 7.2 üzerinde detaylandırılmıştır.

Tablo 7.2. InceptionV3'ün diğer ölçütler açısından performans sonuçları

Ölçüt	Antep f.	Bezelye	Ispanak	Yer f.	Ortalama
Kesinlik	1,00	1,00	0,98	0,98	0,99
Hassasiyet	0,97	0,99	1,00	1,00	0,99
F1 Skor	0,98	0,99	0,99	0,99	0,98

8. TARTIŞMA

Bu çalışma, Antep fıstığındaki tağşişi tespit etmek amacıyla oluşturulan veri seti üzerinde InceptionV3, ResNet-18 ve DenseNet-201 gibi CNN modellerinin uygulanmasıyla gerçekleştirilmiştir. Elde edilen sonuçlar, özellikle InceptionV3 modelinin diğer modellere kıyasla daha yüksek bir başarı oranı yakaladığını göstermektedir. Modelin doğruluk derecesi %99,6 olarak hesaplanmış olup, kesinlik (%99,4), hassasiyet (%99,7) ve F1 skoru (%99,55) gibi performans ölçütleri de modelin etkinliğini doğrulamaktadır. InceptionV3'ün karmaşık veri yapılarını ve detaylı özellikleri etkili bir şekilde yakalama yeteneği, tağşiş tespiti konusunda önemli bir avantaj sağlamaktadır.

Tez çalışmasında elde edilen performans sonuçları, ilgili çalışmalar bölümünde bahsedilen ve literatürde yer alan benzer amaca ve yöntemlere sahip diğer çalışmalarla karşılaştırılmıştır. Tablo 8.1'de görüleceği üzere, bu çalışmada olduğu gibi makine öğrenimine dayalı yöntemlerin gıdada tağşiş probleminin çözümüne yönelik katkısı belirgindir.

Tablo 8.1. Literatürdeki benzer çalışmalar

Yazar(lar)	Tağşişi Yapılan Ürün	Önerilen model	Doğruluk
Izquierdo vd. (2019)	Extra Sızma Zeytinyağı	ANN	%97-%100
Liv d. 2020)	Bal	SVM	%97.09
Wei vd. (2020)	Siyah Çay	ANN	%100
Jahanbakhshi vd. (2021)	Zerdeçal Baharatı	CNN	% 99.36
Pradana vd. (2022)	Pirinç	CNN (ResNet34)	% 98.8
Zheng vd. (2022)	Buğday Unu	CNN	% 92.45
Geng vd. (2022)	Balık Unu	Yolo-V3	% 93.02
Zhang vd. (2022)	Kuzu Eti	RP-CNN	%99.95
Wojcik vd. (2023)	Bal	CNN	%100
Jin vd. (2023)	Süt	SVM	%99.05
Momeny vd. (2023)	Safran Baharatı	Inception-V4	% 99.5
Medeiros vd. (2023)	Tereyağı	SVM	% 90
Teng vd. (2024)	Susam Yağı	CNN	%100
Önerilen Çalışma	Antep Fıstığı	Inception-V3	%99,3

Ancak, çalışmamızın bazı sınırlamaları bulunmaktadır. Veri setimizin laboratuvar ortamında oluşturulmuş olması, gerçek dünya koşullarındaki değişkenlikleri tam olarak yansıtmayabilir. Gerçek üretim süreçlerinde karşılaşılabilecek farklı ışık koşulları, görüntü kalitesi ve diğer çevresel faktörler, modelin performansını etkileyebilir. Bu nedenle, gelecekteki çalışmalar için daha geniş ve çeşitlendirilmiş veri setlerinin oluşturulması önemlidir.

Çalışmamızda kullanılan veri setinde Antep fıstığı ve taklitleri %100 saf halde yer almakta olup, karışım olarak eklenmemiştir. Oysaki piyasada, Antep fıstığı ve taklitlerinin karışımlarından oluşan ürünlerin yaygın olduğu bilinmektedir. Veri setine, Antep fıstığı ve taklitlerinin çeşitli oranlarda karışımını içeren fotoğrafların eklenmesi ve bu karışımların oransal olarak sınıflandırılmasının yapılması, tağşiş tespiti açısından büyük önem taşımaktadır. Bu, modelin gerçek dünya uygulamalarında karşılaşılabileceği farklı tağşiş türlerine karşı daha doğru ve güvenilir sonuçlar verebilmesi için gereklidir. Bu nedenle, veri setinin genişletilmesi ve çeşitlendirilmesi, araştırmamızın güvenilirliği ve genel geçerliliği açısından kritik bir adımdır.

Ayrıca InceptionV3 gibi derin öğrenme modelleri, yüksek hesaplama gücü gerektirdiğinden, bu tür çözümlerin küçük ölçekli işletmelerde uygulanabilirliği sınırlı olabilir. Bu sorunun üstesinden gelmek için, daha verimli ve hafif modellerin geliştirilmesi veya mevcut modellerin optimizasyon teknikleri ile iyileştirilmesi gerekmektedir.

9. SONUÇ VE ÖNERİLER

Gıdada tağşiş, ülkemiz başta olmak üzere tüm dünyada gıda güvenliğini tehdit eden bir problemdir. Normal şartlarda tüketicinin ve uzmanların gözle ayırt edemeyecekleri yapısal farklılıkları sağlam ve kullanışlı bilgisayar destekli sistemler sayesinde ayırt edebilmek mümkündür.

Bu tez çalışmasında gıdada tağşişin bir örneği olarak Antep fıstığına yönelik tağşiş ürünlerini ayırt edebilen bir model geliştirilmeye çalışılmıştır. Bu amaçla model için farklı derin CNN mimariler işe koşulmuştur. Seçilen mimariler katman yapıları ve imajenet performansları açısından birbirlerinden farklı mimarilerdir.

Laboratuvar ortamında sıfırdan elde edilen veri seti gerçek Antep fıstığı ve piyasada Antep fıstığını taklit amaçlı kullanılan bezelye, ıspanak ve yer fıstığı ürünlerinden oluşturulmuştur. Her ürün grubunun materyalleri kendi içerisinde hazırlanarak ham veri seti elde edilerek etiketlenilmiş ve yaygın bilinen yöntemlerle gerçekleştirilen veri artırma işlemi sonucu dört sınıflı (Antep fıstığı, bezelye, ıspanak ve yer fıstığı) 7886 adet görsel elde edilmiştir.

Elde edilen nihai veri seti kullanılarak InceptionV3, ResNet-18 ve DenseNet-201 CNN modelleri ile sınıflandırma işlemi gerçekleştirilmiş ve elde edilen sonuçlar değerlendirilmiştir. InceptionV3 ve DenseNet-201 modellerinin sınıfları başarılı bir şekilde ayırt edebildikleri gözlemlenmiştir. Ağ karmaşıklığı ve eğitim süresi dikkate alındığında InceptionV3 modelinin test veri kümesi için %99,3'lük bir doğruluk oranı ile yüksek bir performans sergilediği görülmüştür. Bu sonuç DenseNet-201 modeli için %99,3 ve ResNet-18 modeli için de %94,6 olarak hesaplanmıştır. Hata matrisleri değerlendirildiğinde modellerin sınıf bazında başarısı ve diğer performans metrikleri (kesinlik, hassasiyet ve F1 skor), CNN mimarilerinin gıdada tağşiş problemlerinde başarılı bir şekilde kullanılabileceğini desteklemektedir.

Önerilen model, gıda sektöründe kalite kontrol süreçlerinin iyileştirilmesi açısından önemli bir adım niteliğindedir. Özellikle Antep fıstığı gibi yüksek değerli tarım ürünlerinde tağşişin önlenmesi hem ekonomik kayıpların azaltılması hem de tüketici güveninin sağlanması açısından kritik öneme sahiptir. Bu çalışma, tağşiş tespiti gibi önemli bir sorunun çözümüne yönelik yenilikçi bir yaklaşım sunmakta ve literatürde bu alanda özgün bir katkı sağlamaktadır.

Gelecekteki alıřmalar iin bazı neriler sunulabilir. ncelikle, daha geniř ve eřitlendirilmiř veri setlerinin kullanılması, modelin gerek dnya kořullarındaki performansını artırabilir. Ayrıca, mobil cihazlar iin geliřtirilecek uygulama arayzleri, taęřiř tespitini daha kullanıcı dostu ve eriřilebilir hale getirebilir. Bu tr uygulamalar, gıda reticileri, denetleyiciler ve tketiciler tarafından etkin bir řekilde kullanılabilir ve rnlerin saflıęını yerinde kontrol etme imknı saęlayabilir.

Ayrıca, bulut tabanlı zmler, modelin srekli olarak gncellenmesini ve geniř veri setleriyle eęitilmesini saęlayarak, doęruluk oranının korunmasına ve iyileřtirilmesine katkıda bulunabilir.

Sonu olarak, bu alıřma Antep fıstıęı tarımında taęřiř tespiti konusunda nemli bir adım olmuřtur. Gelecekte, daha geniř veri setleri ve farklı modellerin kullanımıyla yapılacak daha kapsamlı arařtırmaların, Antep fıstıęı tarımında ve pazarlamasında taęřiř sorununa zm getirmek adına deęerli katkılar saęlayabileceęi dřnlmektedir.

10. KAYNAKLAR

- Aalami, N. (2020). Derin öğrenme yöntemlerini kullanarak görüntülerin analizi. *Eskişehir Türk Dünyası Uygulama ve Araştırma Merkezi Bilişim Dergisi*, 1(1), 17-20.
- Abbas, O., & Baeten, V. (2016). Advances in the identification of adulterated vegetable oils. *Advances in food authenticity testing*, 519-542.
- Adak, M. F. (2016). *Elektronik burun verilerinin yapay zeka tabanlı algoritmalarla sınıflandırılması* [Doktora Tezi, Sakarya Üniversitesi Fen Bilimleri Enstitüsü, Sakarya]
- Aksoy, B., Halis, H. D., & Salman, O. K. M. (2020). Elma bitkisindeki hastalıkların yapay zekâ yöntemleri ile tespiti ve yapay zekâ yöntemlerinin performanslarının karşılaştırılması. *International Journal of Engineering and Innovative Research*, 2(3), 194-210.
- Ali, L., Alnajjar, F., Jassmi, H. A., Gocho, M., Khan, W., & Serhani, M. A. (2021). Performance evaluation of deep CNN-based crack detection and localization techniques for concrete structures. *Sensors*, 21(5), 1688.
- Alparslan, G., & Dursun, M. (2023). Konvolüsyonel sinir ağları tabanlı Türkçe metin sınıflandırma. *Bilişim Teknolojileri Dergisi*, 16(1), 21-31.
- Altaş, D., & Gülpınar, V. (2012). Karar ağaçları ve yapay sinir ağlarının sınıflandırma performanslarının karşılaştırılması. *Trakya Üniversitesi Sosyal Bilimler Dergisi*, 14(1), 1-22.
- Arı, A., & Berberler, M. E. (2017). Yapay sinir ağları ile tahmin ve sınıflandırma problemlerinin çözümü için arayüz tasarımı. *Acta Infologica*, 1(2), 55-73.
- Atalay, M., & Çelik, E. (2017). Büyük veri analizinde yapay zekâ ve makine öğrenmesi uygulamaları-artificial intelligence and machine learning applications in big data analysis. *Mehmet Akif Ersoy Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 9(22), 155-172.
- Ateş, F. F., Çalışkan, A., & Toğaçar, M. (2022). Meme kanserinin tespiti için yapay zekâ tabanlı hibrit bir model önerisi. *Fırat Üniversitesi Fen Bilimleri Dergisi*, 34(2), 189-199.

- Ay, N., & Hürkan, K. (2023). A novel high-resolution melting method for detection of adulteration on pistachio (*Pistacia vera* L.). *Brazilian Archives of Biology and Technology*, 66, e23220550.
- Ayper, B., & Binokay, S. (2010). Gıda katkı maddeleri ve sağlığımıza etkileri. *Arşiv Kaynak Tarama Dergisi*, 19(3), 141-154.
- Balkır, P., Kemahlioğlu, K., & Yücel, U. (2019). Machine vision system: Food industry applications and practices. *Turkish Journal of Agriculture-Food Science and Technology*, 7(7), 989-999.
- Bansal, S., Singh, A., Mangal, M., Mangal, A. K., & Kumar, S. (2017). Food adulteration: Sources, health risks, and detection methods. *Critical reviews in food science and nutrition*, 57(6), 1174-1189.
- Başaran, Z., & Elbasan, B. (2023). Fizyoterapi ve rehabilitasyonda güncel yazılım teknolojisi: Görüntü işleme tekniği. *Gazi Sağlık Bilimleri Dergisi*, 8(2), 79-88.
- Bayram, F. (2020). Derin öğrenme tabanlı otomatik plaka tanıma. *Politeknik Dergisi*, 23(4), 955-960.
- Blauch, N. M., Behrmann, M., & Plaut, D. C. (2021). Computational insights into human perceptual expertise for familiar and unfamiliar face recognition. *Cognition*, 208, 104341.
- Boran, M. (2023). Gıdalarda yapılan hileler ve fikhî hükme etkisi. *Darulhadis İslami Araştırmalar Dergisi*, (5), 1-15.
- Bozkurt, F. (2021). Derin öğrenme tekniklerini kullanarak akciğer X-Ray görüntülerinden COVID-19 tespiti. *Avrupa Bilim Ve Teknoloji Dergisi*, 24, 149-156.
- Bozyiğit, B. Ş., & Tarhan, Ç. (2020). Makine öğrenmesi yöntemleri kullanılarak sosyal medyada marka itibar analizi. *Yönetim Bilişim Sistemleri Dergisi*, 6(2), 57-76.
- Burçin, K., & Nabiye, V. V. (2010). Dijital mamografi görüntülerinin kontrast sınırlı adaptif histogram eşitleme ile iyileştirilmesi. *Proceedings of the VII. Ulusal Tıp Bilişimi Kongresi, Gazimağusa, KKTC*, 14-17.

- Büyükarık, B., & Ülker, E. (2020). Aydınlatma özneteliği kullanılarak evrişimsel sinir ağı modelleri ile meyve sınıflandırma. *Uludağ Üniversitesi Mühendislik Fakültesi Dergisi*, 25(1), 81-100.
- Büyükcan, M. B. (2008). *Kayısıda bazı içsel kalite kriterlerinin Fourier dönüşümlü-yakın kızıl ötesi (FT-NIR) spektroskopi kullanarak belirlenmesi* [Yüksek Lisans Tezi, Çanakkale Onsekiz Mart Üniversitesi Fen Bilimleri Enstitüsü, Çanakkale]. AGRIS
- Büyükcan, M., & Kavdır, İ. (2020). Yakın kızıl ötesi spektroskopi (FT-NIR) kullanarak sütte NaHCO₃ varlığının tespiti. *ÇOMÜ Ziraat Fakültesi Dergisi*, 8(2), 327-334.
- Ciran, A., & Özbay, E. (2022). Ön eğitilmiş CNN mimarilerinin füzyonu ile mısır yaprağı hastalıklarının sınıflandırılması. *Avrupa Bilim ve Teknoloji Dergisi*, (44), 74-83.
- Çağlar, A., Tomar, O., Vatansever, H., & Ekmekçi, E. (2017). Antepfıstığı (*Pistacia vera* L.) ve insan sağlığı üzerine etkileri. *Akademik Gıda*, 15(4), 436-447.
- Çağlar, M. Y., Demirci, M., Şahiner, A., Çakır, B., & Çağlar, A. F. (2019). Gıda analizlerinde kullanılan spektroskopik teknikler. *Akademik Gıda*, 17(1), 121-130.
- Çakmak, E., & Selvi, İ. H. (2022). Derin öğrenme (CNN, RNN, LSTM, GRU) kullanarak protein ikincil yapı tahmini. *Acta Infologica*, 6(1), 43-52. <https://doi.org/10.26650/acin.1008075>
- Çelikdemir, M. Y., & Akbal, A. (2014). Beton yapılarda görüntü filtreleme tekniklerinin uygulanması. *URSI-TÜRKİYE'2014 VII. Bilimsel Kongresi*.
- Çınar, B., & Yeşim, O. K. A. Y. (2014). Vitaminler yönüyle antepfıstığı. *Bahçe*, 42(1-2), 35-43.
- Dağlı, İ., & Öztürk, A. (2021). Görüntü sınıflandırmada derin öğrenme yöntemlerinin karşılaştırılması. *Konya Journal of Engineering Sciences*, 9(4), 872-888.
- Dandıl, E., & Serin, Z. (2020). Derin sinir ağları kullanarak histopatolojik görüntülerde meme kanseri tespiti. *Avrupa Bilim ve Teknoloji Dergisi*, 451-463.

- Daş, R., Polat, B., & Tuna, G. (2019). Derin öğrenme ile resim ve videolarda nesnelerin tanınması ve takibi. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 571–581.
- De Ville, B. (2013). Decision trees. *Wiley Interdisciplinary Reviews: Computational Statistics*, 5(6), 448-455.
- Demir, F. B., & Yılmaz, E. (2021). X-ray görüntülerinden Covid-19 tespiti için derin öğrenme temelli bir yaklaşım. *Avrupa Bilim ve Teknoloji Dergisi*, (32), 627-632.
- Diri, B. (2014). Makine Öğrenmesine Giriş. Retrieved from Lecture Notes Online Web site: <https://www.ce.yildiz.edu.tr/personal/banud/file/2634/Makine+Ogrenmesi-ML-10.pdf>.
- Doğan, O. (2019) Gıdada tağşişin tarihi ve politik ekonomisi üzerine bir inceleme. *Toplum ve Hekim*, 34(4)
- Doğan, T., Sert, E., & Taşkın, D. (2013). Araç destek sistemleri için kuş bakışı görüntü dönüşümü. <https://ab.org.tr/ab13/kitap/eski/91.pdf>
- Doğan, F., & Türkoğlu, I. (2022). Comparison of deep learning models in terms of multiple object detection on satellite images. *Journal of Engineering Research*, 10(3A).
- Elbistanli, Ö., Davran, M. K., & Emeksiz, Ö. F. (2020). Gaziantep ili Antep fıstığı ihracat pazarlama organizasyonu. *Elektronik Sosyal Bilimler Dergisi*, 19(74), 724-749.
- Elen, A. (2020). Görüntü ikileştirme için global eşikleme yöntemleri üzerine bir inceleme. *Mühendislik Bilimleri ve Araştırmaları Dergisi*, 2(2), 38-49.
- Elma, E., Turkal, G., & Doğruer, Y. Gıda tağşişi. *Sağlık Bilimlerinde Güncel Yaklaşımlar*, 155.
- Ercan, A., & Şahin, M. E. Derin öğrenme ve yapay sinir ağı modelleri üzerine bir inceleme. *EMO Bilimsel Dergi*, 14(1), 27-38.
- Erçelik, Ç., & Hanbay, K. (2023). Beyin tümörü sınıflandırmada histogram eşitleme yönteminin bazı derin öğrenme modellerine etkileri. *Computer Science*, 8(2), 83-92.

- Erdem, S. (2022). *Jet uçaklarında transfer öğrenimi yöntemiyle hasarlı parçaların tespiti= Detection of damaged parts via transfer learning method in jet aircrafts* [Yüksek Lisans Tezi]. Sakarya Üniversitesi, Sakarya.
- Ertürk, Y. E., Geçer, M. K., Gülsoy, E., & Yalçın, S. (2015). Production and marketing of pistachio. *Journal of the Institute of Science and Technology*, 5(2), 43-62.
- Ersöz, F., & Çınar, Y. (2021). Veri madenciliği ve makine öğrenimi yaklaşımlarının karşılaştırılması: Tekstil sektöründe bir uygulama. *Avrupa Bilim ve Teknoloji Dergisi*, (29), 397-414.
- Ertugay, M. F., & Başlar, M. (2011). Gıdaların kalite özelliklerinin belirlenmesinde yakın kızılötesi (NIR) spektroskopisi. *Gıda*, 36(1), 49-54.
- Fakhlaei, R., Selamat, J., Khatib, A., Razis, A. F. A., Sukor, R., Ahmad, S., & Babadi, A. A. (2020). The toxic impact of honey adulteration: A review. *Foods*, 9 (11), 1538.
- Feng, X., Yao, H., & Zhang, S. (2019). An efficient way to refine DenseNet. *Signal, Image and Video Processing*, 13, 959-965.
- Fengou, L. C., Lianou, A., Tsakanikas, P., Mohareb, F., & Nychas, G. J. E. (2021). Detection of meat adulteration using spectroscopy-based sensors. *Foods*, 10(4), 861.
- Fırıldak, K., & Talu, M. F. (2019). Evrimsel sinir ağlarında kullanılan transfer öğrenme yaklaşımlarının incelenmesi. *Computer Science*, 4(2), 88-95.
- Foto, Ö. (2022). *Transfer öğrenme modelleri ile akciğer X-ray görüntülerinden COVID-19 tespiti*. [Yüksek Lisans Tezi]. Aksaray Üniversitesi Sosyal Bilimler Enstitüsü.
- Gezginç, Y., & Duman, A. D. (2004). Antepfıstığı işleme tekniği ve muhafazasının kalite üzerine etkisi. *Gıda*, 29(5).
- Giray, H., & Soysal, A. (2007). Türkiye’de gıda güvenliği ve mevzuatı. *TSK koruyucu hekimlik bülteni*, 6(6), 485-490.

- Göçen, A. (2022). Eğitim bağlamında metaverse. *Uluslararası Batı Karadeniz Sosyal ve Beşerî Bilimler Dergisi*, 6(1), 98-122.
- Göçeri, E., & Yaldir, A. K. (2011). JPEG2000 standardının yeni özelliklerini destekleyen bir görüntü işleme uygulaması geliştirilmesi. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 13(3), 337-346.
- Gökalp, Ö. M. (2022). Makine öğrenmesi. *Gazi Üniversitesi, Gazi Bilişim Enstitüsü, Adli Bilişim Bölümü*.
- Görentaş, M. B., Uçkan, T., Ayata, F., & Dizkırııcı, A. (2023). Yapay zeka ve hukuk ilişkisine adli tıp özelinde bakış. *Euroasia Journal of Mathematics, Engineering, Natural & Medical Sciences*, 10(28), 61-76.
- Gündoğdu, H. (2019). *Gıda güvenliği yönetimi ve Elazığ-Bingöl yöresel gıda üretimine bir bakış*. [Yayımlanmamış Yüksek Lisans Tezi]. Recep Tayyip Erdoğan Üniversitesi Sosyal Bilimler Enstitüsü.
- Habza-Kowalska, E., Grela, M., Gryzińska, M., & Listos, P. (2019). Molecular techniques for detecting food adulteration. https://www.researchgate.net/profile/Magdalena-Gryzinska-2/publication/338298982_Molecular_techniques_for_detecting_food_adulteration/links/5e84974a92851c2f52714a89/Molecular-techniques-for-detecting-food-adulteration.pdf
- Hacıbeyoglu, M., Çelik, M., & Erdaş Çiçek, Ö. (2023). K en yakın komşu algoritması ile binalarda enerji verimliliği tahmini. *Necmettin Erbakan Üniversitesi Fen Ve Mühendislik Bilimleri Dergisi*, 5(2), 65-74. <https://doi.org/10.47112/neufmbd.2023.10>
- Hayıt, T., & Çınarar, G. (2022). X-RAY görüntülerini kullanarak GLCM ve derin özniteliklerin birleşimine dayalı Covid-19 sınıflandırılması. *İnönü Üniversitesi Sağlık Hizmetleri Meslek Yüksek Okulu Dergisi*, 10(1), 313-325.
- He, Y., Bai, X., Xiao, Q., Liu, F., Zhou, L., & Zhang, C. (2021). Detection of adulteration in food based on nondestructive analysis techniques: A review. *Critical Reviews in Food Science and Nutrition*, 61(14), 2351-2371.

- İçyer, N. C., & Durak, M. Z. (2020). Bitkisel yağlarda taşıyıcı belirleme metotları: fourier dönüşümlü kızılötesi (ftır) spektroskopisi. *Helal ve Etik Araştırmalar Dergisi/Journal of Halal and Ethical Research*.
- İnik, Ö., & Ülker, E. (2017). Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3), 85-104.
- Kahraman, N. *Gıdalarda hile amacıyla karıştırılan bitkisel kaynaklı bileşenlerin moleküler yöntemlerle tespiti*. [Yüksek Lisans Tezi]. Erciyes Üniversitesi Fen Bilimleri Enstitüsü, Kayseri.
- Kaplan, M., & Çat, A. Tarımsal üretimde bitki koruma çalışmalarına perspektif bir bakış. <https://www.researchgate.net/profile/Mehmet-Kaplan-7/publication/377659118>
- Karaali, I., & Eminağaoğlu, M. (2021). A convolutional neural network model for marble quality classification. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 36(1).
- Karacan, E. (2023). *Natürel sızma zeytinyağlarının karakterizasyonu ve taşıyıcının tespitinde FTIR, sterol kompozisyonu ve ΔECN42 yöntemlerinin karşılaştırmalı kullanımı*. [Yüksek Lisans Tezi]. Ege Üniversitesi Fen Bilimleri Enstitüsü, İzmir.
- Karakoç, M. (2011). *Görüntü işleme teknikleri ve yapay zeka yöntemleri kullanarak görüntü içinde görüntü arama*. [Yüksek Lisans Tezi]. Pamukkale Üniversitesi Fen Bilimleri Enstitüsü, Denizli
- Kargı, V. S. A. (2013). *Yapay sinir ağ modelleri ve bir tekstil firmasında uygulama* [Doktora Tezi]. Uludağ Üniversitesi Sosyal Bilimler Enstitüsü, Bursa
- Katırcıoğlu, F. (2021). Düşük ışıklı renkli görüntülerin iyileştirilmesinde kullanılan retineks algoritmalarının karşılaştırmalı analizi. *Mühendislik Bilimleri ve Araştırmaları Dergisi*, 3(2), 188-206.
- Kavzoğlu, T., & Çölkesen, İ. (2010). Classification of satellite images using decision trees: Kocaeli case. *Electronic Journal of Map Technologies*, 2(1), 36-45.

- Kaya, İ., Oktay, S., & Engin, O. (2005). Kalite kontrol problemlerinin çözümünde yapay sinir ağlarının kullanımı. *Erciyes Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 21(1-2), 92-107.
- Kaya, S. Y., & Yayla, F. (2020). Resmi verilere göre türkiye’de taklit ve tağşiş yapılan yiyecek ve içecekler (According to official data of adulteration and counterfeit made in turkey food & beverage). *Journal of Tourism & Gastronomy Studies*, 8(4), 3108-3128.
- Kayaalp, K., & Süzen, A. A. (2018). Derin öğrenme. *Derin öğrenme ve Türkiye’deki uygulamaları, Adıyaman, Türkiye: İKSAD Yayınevi*, 25-28.
- Kim, E., Dahiya, G. S., Løset, S., & Skjetne, R. (2019). Can a computer see what an ice expert sees? Multilabel ice objects classification with convolutional neural networks. *Results in Engineering*, 4, 100036.
- Koç, G., & Uzmay, A. (2015). Gıda güvencesi ve gıda güvenliği: Kavramsal çerçeve, gelişmeler ve Türkiye. *Tarım Ekonomisi Dergisi*, 21(1), 39-48.
- Kurt Pehlivanoğlu, M., & Arabacı, U. K. (2022). Çekişmeli üretici ağlar ve transfer öğrenimi kullanılarak göğüs X-Ray görüntülerinden COVID-19 tespiti üzerine bir derleme. *Mühendislik Bilimleri Ve Tasarım Dergisi*, 10(1), 328-340.
- Küçük, D., & Arıcı, N. (2018). A literature study on deep learning applications in natural language processing. *International Journal of Management Information Systems and Computer Science*, 2(2), 76-86.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444.
- Li, Y. C., Liu, S. Y., Meng, F. B., Liu, D. Y., Zhang, Y., Wang, W., & Zhang, J. M. (2020). Comparative review and the recent progress in detection technologies of meat product adulteration. *Comprehensive Reviews in Food Science and Food Safety*, 19(4), 2256-2296.
- Manning, L., & Soon, J. M. (2016). Food safety, food fraud, and food defense: a fast evolving literature. *Journal of food science*, 81(4), R823-R834.

- Maral, B. C. (2022). Kimyasalların gen düzenleyici etkilerinin tahmini için transfer öğrenimi [Yüksek Lisans Tezi]. Tobb Ekonomi ve Teknoloji Üniversitesi Fen Bilimleri Enstitüsü.
- Mutlu, A. (2007). Antepfıstığı (*Pistacia vera* L.) kabuklu ve iç meyvesinin bazı fiziksel özelliklerinin belirlenmesi. *Journal of Agricultural Faculty of Gaziosmanpaşa University (JAFAG)*, 2007(1), 19-25.
- Onay, A. (2022) Farmakoloji Toksikoloji ve Beslenme: *Et ve et ürünlerinde sahtecilik ve taşıması tespit yöntemleri*.
- Özata, E., Merve, O. , Onurlar, B., & Sarper, F. (2019). Science Direct veri tabanında yer alan Food Chemistry dergisinde baharatlar ile ilgili yayınlanan makalelerin bibliyometrik analizi (Bibliometric analysis of articles related to spices in Food Chemistry magazine in the Science Direct Database). *Journal of Tourism & Gastronomy Studies*, 7(4), 3014-3028.
- Özdemir, C. (2023). Derin öğrenme modelleri ve veri ön işleme yöntemleri ile çeltik yaprak hastalıklarının erken teşhisi. *Eylül 2023 Cukurova University Journal of the Faculty of Engineering*, 38(3), 2023.
- Özkan, K., Seke, E., & Işık, Ş. (2021). Wheat kernels classification using visible-near infrared camera based on deep learning. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 27(5), 618-626.
- Özoğul, Y., & Kılıç, A. B. (2023). Türkiye'de Safran (*Crocus sativus* L.) adı ile satılan bazı örneklerin Farmasötik Botanik açıdan değerlendirilmesi. *Biyolojik Çeşitlilik ve Koruma*, 16(1), 10-22.
- Öztep, R., & Işin, F. (2023). ARMA modeli ile Türkiye Antep fıstığı üretimi tahmini. *Kahramanmaraş Sütçü İmam Üniversitesi Tarım ve Doğa Dergisi*, 26(4), 878-887.
- Öztürk, K., & Şahin, M. E. (2018). Yapay sinir ağları ve yapay zekâ'ya genel bir bakış. *Takvim-i Vekayi*, 6(2), 25-36.
- Perihanoğlu, G. M. (2015). *Dijital görüntü işleme teknikleri kullanılarak görüntülerden detay çıkarımı*. [Yüksek Lisans Tezi]. İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü.

- Pişkin, M. (2016). OpenCV ile Görüntü İşleme. <https://mesutpiskin.com/blog/wp-content/uploads/2017/01/OpenCV%20Kitap.pdf>
- Polat, H., & Özerdem, M. S. (2021). Derin transfer öğrenimi yaklaşımı ile kamusal alanda medikal maske kullanımının otomatik kontrolü. *Türk Doğa Ve Fen Dergisi*, 10(2), 191-198. <https://doi.org/10.46810/tdfd.948098>
- Ruiz-Matute, A. I., Soria, A. C., Martínez-Castro, I., & Sanz, M. L. (2007). A new methodology based on GC– MS to detect honey adulteration with commercial syrups. *Journal of agricultural and food chemistry*, 55(18), 7264-7269.
- Samtaş, G., & Gülesin, M. (2011). Sayısal görüntü işleme ve farklı alanlardaki uygulamaları. *Ejovoc (Electronic Journal of Vocational Colleges)*, 2(1), 85-97.
- Sanal Kumar, K. P., & Bhavani, R. (2019). Human activity recognition in egocentric video using PNN, SVM, kNN and SVM+ kNN classifiers. *Cluster Computing*, 22(Suppl 5), 10577-10586.
- Sezer, B., Apaydin, H., Bilge, G., & Boyaci, I. H. (2019). Detection of Pistacia vera adulteration by using laser induced breakdown spectroscopy. *Journal of the Science of Food and Agriculture*, 99(5), 2236-2242.
- Siriken, F., Siriken, B., & Demirci, B. (2021). Bir derleme: Gıda sahtekârlığı. *Gazi Sağlık Bilimleri Dergisi*, 6(1), 48-60.
- Şeker, A., Diri, B., & Balık, H. H. (2017). Derin öğrenme yöntemleri ve uygulamaları hakkında bir inceleme. *Gazi Mühendislik Bilimleri Dergisi*, 3(3), 47-64.
- Şenol, A., Canbay, Y., & Kaya, M. (2021). Makine öğrenmesi yaklaşımlarını kullanarak salgınları erken evrede tespit etme alanındaki eğilimler. *Bilişim Teknolojileri Dergisi*, 14(4), 355-366.
- Taşcı, E., & Onan, A. (2016). K-en yakın komşu algoritması parametrelerinin sınıflandırma performansı üzerine etkisinin incelenmesi. *Akademik Bilişim*, 1(1), 4-18.
- Tekin, M., & Çetin, M. (2019). Uydu görüntülerinden zincir kod ve en uzun ortak alt küme yöntemleri ile yarı otomatik yol bulma. *Veri Bilimi*, 2(1), 61-72.

- Temiz, H. T. (2019). *Kemometrik yaklaşımlarla gıda taşıyıcılarının belirlenmesinde spektroskopik yöntemlerin kullanılması*. [Doktora Tezi]. Hacettepe Üniversitesi, Ankara.
- Toğaçar, M., & Ergen, B. (2019). Biyomedikal görüntülerde derin öğrenme ile mevcut yöntemlerin kıyaslanması. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 31(1), 109-121.
- Türkmen, S., & Ataseven, Y. (2020). Türkiye’de taklit ve taşıyıcı yapılan gıdalara ilişkin yasal düzenlemelerin ve uygulamaların değerlendirilmesi. *Tarım Ekonomisi Araştırmaları Dergisi*, 6(1), 65-75.
- Uçar, M. (2021). Glokom hastalığının evrimsel sinir ağı mimarileri ile tespiti. *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi*, 23(68), 521-529.
- Veziroglu, E., Pacal, I., & Coşkunçay, A. (2023). Derin evrimsel sinir ağları kullanılarak pirinç hastalıklarının sınıflandırılması. *Journal of the Institute of Science and Technology*, 13(2), 792-814.
- Wang, S., Xia, X., Ye, L., & Yang, B. (2021). Automatic detection and classification of steel surface defect using deep convolutional neural networks. *Metals*, 11(3), 388.
- Yakar, A., & Sayın, H. C. (2021). Kendini örgütleyen haritalar algoritması yöntemiyle Türkiye dokuma sektörünün analizi: Bist şirketleri üzerine bir uygulama. *Hacettepe Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 39(3), 491-510.
- Yeşilören, G., & Ekşi, A. (2014). Gıda gerçekliği ve kontrol yöntemleri. *Gıda*, 39(5), 315-322.
- Yiğidim, H. A. (2012). *Makine öğrenme algoritmalarını kullanarak ağ trafiğinin sınıflandırılması* (316521). [Yüksek Lisans Tezi]. TOBB Ekonomi ve Teknoloji Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.
- Ying, X. (2019, February). An overview of overfitting and its solutions. *In Journal of physics: Conference series* (Vol. 1168, p. 022022).

- Zhang, K., Guo, Y., Wang, X., Yuan, J., & Ding, Q. (2019). Multiple feature reweight densenet for image classification. *IEEE access*, 7, 9872-9880.
- Zhang, S., Li, X., Zong, M., Zhu, X., & Cheng, D. (2017). Learning k for knn classification. *ACM Transactions on Intelligent Systems and Technology (TIST)*, 8(3), 1-19.



Ayşe TUNCEL ÇİFTÇİ

Yüksek Lisans Tezi

YOZGAT 2024