

**T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**



**LAZER İŞARETLERİ İLE YAPAY ZEKA TEMELLİ HEDEF
ANALİZİ**

Nevzat OLGUN

Doktora Tezi

YAZILIM MÜHENDİSLİĞİ ANABİLİM DALI

TEMMUZ 2022

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Yazılım Mühendisliği Anabilim Dalı

Doktora Tezi

LAZER İŞARETLERİ İLE YAPAY ZEKA TEMELLİ HEDEF ANALİZİ

Tez Yazarı
Nevzat OLGUN

Danışman
Prof. Dr. İbrahim TÜRKOĞLU

TEMMUZ 2022
ELAZIĞ

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Yazılım Mühendisliği Anabilim Dalı

Doktora Tezi

Başlığı:	Lazer İşaretleri ile Yapay Zeka Temelli Hedef Analizi
Yazarı:	Nevzat OLGUN
İlk Teslim Tarihi:	06.06.2021
Savunma Tarihi:	04.07.2022

TEZ ONAYI

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına göre hazırlanan bu tez aşağıda imzaları bulunan jüri üyeleri tarafından değerlendirilmiş ve akademik dinleyicilere açık yapılan savunma sonucunda OYBİRLİĞİ ile kabul edilmiştir.

Danışman:	Prof. Dr. İbrahim TÜRKOĞLU Fırat Üniversitesi, Teknoloji Fakültesi	<i>İmza</i> Onayladım
Başkan:	Prof. Dr. Burhan ERGEN Fırat Üniversitesi, Mühendislik Fakültesi	Onayladım
Üye:	Prof. Dr. Asaf VAROL Maltepe Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi	Onayladım
Üye:	Prof. Dr. Engin AVCI Fırat Üniversitesi, Teknoloji Fakültesi	Onayladım
Üye:	Prof. Dr. Mehmet Sıraç ÖZERDEM Dicle Üniversitesi, Mühendislik Fakültesi	Onayladım

Bu tez, Enstitü Yönetim Kurulunun/...../20..... tarihli toplantısında tescillenmiştir.

İmza
Prof. Dr. Kürşat Esat ALYAMAÇ
Enstitü Müdürü

BEYAN

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım “Lazer İşaretleri ile Yapay Zeka Temelli Hedef Analizi” Başlıklı Doktora Tezimin içindeki bütün bilgilerin doğru olduğunu, bilgilerin üretilmesi ve sunulmasında bilimsel etik kurallarına uygun davrandığımı, kullandığım bütün kaynakları atıf yaparak belirttiğimi, maddi ve manevi desteği olan tüm kurum/kuruluş ve kişileri belirttiğimi, burada sunduğum veri ve bilgileri unvan almak amacıyla daha önce hiçbir şekilde kullanmadığımı beyan ederim.

04.07.2022

Nevzat OLGUN



ÖNSÖZ

Bu tez çalışmasında derin öğrenme ve tek bir lazer işareti kullanarak uzak mesafedeki bir materyalin türünün tespit edilmesi, cinsiyet tespiti, aydınlık veya tamamen karanlık ortamlarda bir materyalin renginin tespiti ve canlı ile cansız nesnelerin sınıflandırılması yapılmıştır. Uzak mesafeden temassız bir şekilde materyal türünün tespitini yapabilen bir hizmet robotu tanımladığı materyali kırılkanlık ve esneklik değerlerine uygun bir şekilde bir kavrama metodolojisi geliştirecektir. Aynı şekilde karanlık bir ortamda veya düşük ışık koşullarında üretim yapan bir sistemde malzemeler renklerinden kolaylıkla ayırt edilebilecektir. Benzer bir şekilde uzak mesafeden çatışma ortamındaki hedef saptırma amaçlı kullanılan bir mankenin cansız bir nesne olduğu tespit edilebilecektir. Lazer işaretleri ile farklı hedef türlerinin tespitinin derin öğrenme kullanılarak yapılması ile literatüre yenilik kazandırılmıştır.

Doktora eğitimim süresince değerli önerileri ile hayatımda yeni ufuklar açan ve her türlü desteği sağlayan kıymetli hocam Prof. Dr. İbrahim TÜRKOĞLU'na, Fırat Üniversitesi Teknoloji Fakültesinde görevli birbirinden değerli hocalarıma sonsuz teşekkürlerimi sunarım. Son olarak her zaman yanımda olan çok değerli aileme teşekkürlerimi sunarım.

Çalışmalar Fırat Üniversitesi Sosyal ve Beşeri Bilimler Araştırmaları Etik Kurulu'nun 09.08.2019 tarih ve 342810 sayılı izni ile gerçekleştirilmiştir.

Nevzat OLGUN

ELAZIĞ, 2022

İÇİNDEKİLER

Sayfa

ÖNSÖZ.....	iv
İÇİNDEKİLER	v
ÖZET	viii
ABSTRACT	ix
ŞEKİLLER LİSTESİ	x
TABLolar LİSTESİ	xv
SİMGELER	xvii
KISALTMALAR	xviii
1. GİRİŞ.....	1
1.1. Çalışmanın Kapsamı ve Amacı	1
1.2. Literatür İncelemesi	5
1.3. Problem Çözümleri ve Yönelim Gereçekleri.....	14
1.4. Çalışmanın Katkıları.....	15
1.5. Tezin Organizasyonu	16
2. LAZERLER.....	17
2.1. Işık.....	17
2.2. Lazer Işığının Oluşumu	18
2.3. Lazerin Özellikleri.....	19
2.4. Lazerlerin Sınıflandırılması	20
2.4.1. Lazerlerin Darbe Genişliğine Göre Sınıflandırılması.....	21
2.4.2. Güç Aralığına Göre Lazerler.....	21
2.4.3. Aktif Ortam Türüne Göre Lazerlerin Sınıflandırılması.....	21
2.5. Diyot Lazer Türleri.....	23
2.5.1. Kenar Yayınımlı Diyot Lazerler.....	24
2.5.2. Dikey Boşluklu Yüzey Yayan Lazer Diyotlar.....	24
2.6. Lazer Güvenliği.....	25
2.7. Hedef Tanımlamada Kullanılan Lazer Temelli Cihazlar	26
2.7.1. LIDAR Sistemleri	26
2.7.2. ToF Kameralar	29
2.7.3. İnterferometriye Dayalı Sistemler	31
3. YAPAY ZEKA.....	34
3.1. Makine Öğrenmesi Algoritmaları	37
3.1.1. K-En Yakın Komşu.....	37
3.1.2. Destek Vektör Makineleri	38
3.1.3. Naive Bayes	39
3.1.4. Karar Ağaçları	40
3.1.5. Doğrusal Ayırma Analizi	40
3.1.6. Yapay Sinir Ağları	41
3.2. Derin Öğrenme Mimarileri	43
3.2.1. Derin Sinir Ağları.....	44
3.2.2. Boltzmann Makineleri.....	44
3.2.3. Kısıtlı Boltzmann Makinesi.....	45

3.2.4. Derin İnanç Ağları.....	45
3.2.5. Oto-Kodlayıcılar.....	46
3.2.6. Tekrarlayan Sinir Ağları.....	47
3.2.7. Uzun Kısa Vadeli Bellek Ağları.....	49
3.2.8. Nöral Devre Politikaları	50
3.2.9. Evrişimli Sinir Ağları	51
3.3. Derin Öğrenme Mimarilerinde Kullanılan Başarım Ölçütleri	55
4. UZAK MESAFEDEKİ MATERYALLERİN LAZER İŞARETLERİ İLE TANIMLANMASI	58
4.1. Lazer Ölçümlerinin Teorik Temelleri.....	59
4.2. Veri Hazırlama Metotları.....	61
4.2.1. Çıkarma İşlemi	61
4.2.2. Welch Güç Spektral Yoğunluğu.....	62
4.2.3. Yule- Walker Otoregresif Güç Spektral Yoğunluğu	63
4.3. Lazer Işık Kaynağı ve Algılayıcı Sistem Tasarımı	64
4.4. Materyal ve Yöntem	65
4.4.1. Sistem Tasarımı.....	66
4.4.2. Materyal Türleri	67
4.4.3. Veri Toplama Adımları	68
4.4.4. Veri Hazırlama Adımları.....	70
4.4.5. Önerilen Derin Öğrenme Modelleri	76
4.5. Başarım Değerlendirmesi	79
4.6. Bulgular ve Tartışma	80
4.6.1. LSTM ve Derin LSTM Modellerinin Sınıflandırma Sonuçlarının İncelenmesi.....	80
4.6.2. NCP Modelinin Sınıflandırma Sonuçlarının İncelenmesi	85
4.6.3. Klasik Makine Öğrenimi Sınıflandırıcılarının Sınıflandırma Sonuçlarının İncelenmesi	87
4.6.4. Önerilen Derin Öğrenme Modellerinin Literatürdeki Çalışmalarla Karşılaştırması	88
4.7. Sonuçlar.....	89
5. LAZER İŞARETLERİ İLE CİNSİYET BELİRLENMESİ	91
5.1. Lazer Işığının Canlı Doku ile Etkileşimi	92
5.2. Materyal ve Yöntem	93
5.2.1. Sistem Tasarımı.....	93
5.2.2. Kullanıcı Seçimi.....	94
5.2.3. Deney Düzenegi ve Veri Toplama	94
5.2.4. Veri Hazırlama Adımları.....	95
5.2.5. Önerilen Derin Öğrenme Mimarisi	97
5.3. Bulgular ve Tartışma	98
5.4. Sonuçlar.....	99
6. CANLI/CANSIZ VARLIKLARIN LAZER İŞARETLERİ İLE SINIFLANDIRILMASI.....	101
6.1. Materyal ve Yöntem	101
6.1.1. Sistem Tasarımı.....	101
6.1.2. Kullanıcı Seçimi.....	102
6.1.3. Materyal seçimi	102
6.1.4. Veri Toplama Adımları	103
6.1.5. Veri Hazırlama Adımları.....	104

6.1.6. Önerilen Derin Öğrenme Mimarisi	107
6.2. Bulgular ve Tartışma	107
6.3. Sonuçlar.....	109
7. LAZER İŞARETLERİ İLE RENK ALGILAMA.....	110
7.1. Lazer Işık Kaynağı ve Algılayıcı Sistem Tasarımı	110
7.2. Materyal ve Yöntem	111
7.2.1. Sistem Tasarımı.....	111
7.2.2. Materyal Seçimi	112
7.2.3. Deney Düzenneği ve Veri Toplama	113
7.2.4. İşaret İşleme Adımları	114
7.3. Bulgular ve Tartışma	117
7.4. Sonuçlar.....	119
8. ATMOSFERİK OLAYLARIN LAZER İŞARETLERİ İLE HEDEF TANIMAYA ETKİSİ	121
8.1. Ortamdaki Farklı Nem Oranlarının ve Sis Sınıflandırma Başarımına Etkisi.....	121
8.1.1. Materyal ve Yöntem.....	122
8.1.2. Bulgular ve Tartışmalar.....	129
8.1.3. Sonuçlar.....	132
8.2. Gün Işığının Sınıflandırma Başarımına Etkisi	132
8.2.1. Materyal ve Yöntem.....	132
8.2.2. Bulgular ve Tartışmalar.....	135
8.2.3. Sonuçlar.....	139
9. SONUÇLAR VE ÖNERİLER	141
KAYNAKLAR.....	143
ÖZGEÇMİŞ	

ÖZET

Lazer İşaretleri ile Yapay Zeka Temelli Hedef Analizi

Nevzat OLGUN

Doktora Tezi

FIRAT ÜNİVERSİTESİ
Fen Bilimleri Enstitüsü

Yazılım Mühendisliği Anabilim Dalı

Temmuz 2022, Sayfa: xix + 156

Hedef türlerinin sınıflandırılması bilgisayarlı görme alanında popüler olmasına rağmen halen zorlu bir görevdir. Hedef türleri çalışılan alana göre materyal türleri, renkler, cinsiyet ve canlı/cansız varlıklar şeklinde olabilmektedir. Hedef tespit sistemlerinde genel olarak kameralar kullanılmaktadır. Düşük ve yüksek ışıklı ortamlarda kameraların kullanımı sistemlerin başarımının olumsuz etkilemekte ve hatta sistemin çalışmasını tamamen engellemektedir. Bunların yanı sıra kameraların kullanımı günümüzde mahremiyet endişelerine sebep olmaktadır.

Bu tez çalışmasında lazerlerin tek yönlü ve aynı fazda yayılma özelliğinden ve ışığın nesnelerle olan etkileşiminden faydalanarak temassız olarak uzak mesafedeki materyal türlerinin tespiti, bir kişinin cinsiyetinin tespiti, bir materyalin renginin tespiti ve canlı/cansız varlıkların tespiti yapılmıştır. Bu amaçla hedefe lazer ışığı yansıtılmış ve hedeften yansıyan lazer ışığı elektro optik alıcı sensör yardımı ile sayısal işaret olarak kaydedilmiştir. Kaydedilen bu lazer işaretleri veri hazırlama adımlarından sonra önerilen derin öğrenme ağında eğitilerek hedef türünün tespiti yapılmıştır.

Hedef türü tanımlama çalışması kapsamında yapılan deneysel uygulamalarda günlük hayatta sıklıkla kullanılan 10 farklı materyal türünün tespiti ortalama %93,62 başarımla yapılmıştır. Deneklerin kolundan alınan tek bir lazer işareti kullanılarak, cinsiyet tespiti ortalama %76,2 başarımla yapılmıştır. 9 farklı rengin tespiti ortalama %91,3 başarımla yapılmıştır. Bu tez çalışmasında farklı nem oranları, sis, gün ışığı ve karanlık gibi farklı atmosferik şartların önerilen hedef tespit yaklaşımları üzerindeki başarımların etkisi de incelenmiştir.

Yapılan bu tez çalışmasında düşük güçlü tek bir lazer işareti ile önerilen yapay zekâ temelli yaklaşımlar kullanılarak uzak mesafedeki bir hedef türünün temassız olarak tespitinin yüksek başarımla gerçekleştirilebileceği ortaya konmuştur.

Anahtar Kelimeler: Lazer, Derin öğrenme, Materyal tanıma, Cinsiyet tanıma, Renk tanıma, NCP

ABSTRACT

Artificial Intelligence Based Target Analysis with Laser Signals

Nevzat OLGUN

Ph.D. Thesis

FIRAT UNIVERSITY
Graduate School of Natural and Applied Sciences
Department of Software Engineering

July 2022, Pages: xix + 156

Although classification of target types is popular in the field of computer vision, it is still a challenging task. Target types can be in the form of material types, colors, gender and living/inanimate objects depending on the area of study. In target detection systems, cameras are commonly used. The use of cameras in low and high light environments adversely affects the performance of the systems and even completely blocks the operation of the system. In addition of these, the use of cameras causes privacy concerns these days.

In this thesis study, by taking advantage of the unidirectional and coherent propagation of lasers and the interaction of light with objects, the detection of types of materials, the detection of a person's gender, the detection of the color of a material and the detection of living /inanimate objects were carried out contactless at a long distance. For this purpose, laser light was reflected to the target and the laser light reflected from the target was recorded as a digital signal with the help of an electro-optical receiver sensor. These recorded laser signals were trained in the deep learning network after the data preparation steps and the target type was determined.

In the experimental applications made within the scope of the target type identification study, the detection of 10 different types of materials that are often used in daily life was carried out with an average success rate of 93.62%. Using a single laser signal taken from the subjects' arm, gender determination was performed with an average success rate of 76.2%. The detection of 9 different colors was done with an average success rate of 91.3%, and the detection of living/inanimate objects with an average success rate of 99.7%. In this thesis, the effect of different atmospheric conditions such as different humidity rates, fog, daylight and darkness on the proposed target detection approaches has also been studied.

In this thesis study, it was revealed that non-contact detection of a target type at a long distance using artificial intelligence-based approaches proposed with a single low-power laser signal can be performed with high performance.

Keywords: Laser, Deep Learning, Material Detection, Gender Detection, Color Detection, NCP

ŞEKİLLER LİSTESİ

	Sayfa
Şekil 2.1.	Elektromanyetik spektrum ve görünür ışık [89] 17
Şekil 2.2.	Elektronların farklı şekillerde uyarılması ve meydana gelen tepkiler a) Soğurma b) Kendiliğinden emisyon c) Uyarılmış emisyon..... 18
Şekil 2.3.	Optik kavite ve pompalama mekanizması ile lazer ışınlarının oluşması 19
Şekil 2.4.	Lazer ve sıradan ışık kaynağı arasındaki farklar 20
Şekil 2.5.	a) TO-Can diyot lazer b) TO-Can lazer diyot kesitsel görünümü c) GaAs diyot lazerin yapısı 23
Şekil 2.6.	Diyot lazerlerde kullanılan katkılı yarı iletkenler ve dalga boyu aralıkları [114] 23
Şekil 2.7.	a) PN birleşimli diyot lazerlerin aynasal yapı için kesme doğrultuları b) Kenar yayınlı lazerin ışınma şekli 24
Şekil 2.8.	a) Tipik bir VCSEL hücresi b) VCSEL dizisi..... 25
Şekil 2.9.	ToF tekniği ile mesafe algılama..... 27
Şekil 2.10.	Dolaylı ToF tekniği ile mesafe algılama..... 27
Şekil 2.11.	a) Faro Focus lazer tarayıcı cihazı b) Bir dış mekânın RGB görüntüsü c) Faro Focus cihazı ile taranan mekândan yansıyan yoğunluk verilerinden oluşturulmuş 3B nokta bulutu [123,124] 29
Şekil 2.12.	ToF kameranın çalışma prensibi 30
Şekil 2.13.	a) PMD Flexx2 ToF kamera b) Kinect v2 RGB-D ToF kamera..... 30
Şekil 2.14.	Lazer interferometrenin çalışma prensibi [134,135] 31
Şekil 2.15.	Lazer dopler vibrometrenin çalışma prensibi..... 32
Şekil 2.16.	1B ve 2B titreşim sonuçları [137] 32
Şekil 3.1.	Geleneksel makine öğrenmesi yöntemlerinin veriyi işleme yaklaşımları 35
Şekil 3.2.	Derin öğrenme yaklaşımları..... 35
Şekil 3.3.	$K=3$ olduğunda oluşan komşuluklar..... 38
Şekil 3.4.	DVM ile sınıflandırma örneği a) 2 sınıfı birbirinden ayıran hiper düzlemler b) DVM ile 2 sınıfı birbirinden ayıran hiper düzlem Destek vektörleri hiper düzleme paralel ve eşit uzaklıkta olan kesikli çizgilerin üzerinde yer almaktadır 38
Şekil 3.5.	Basit bir karar ağacı yapısı..... 40
Şekil 3.6.	a) 4 özellikten oluşan 3 sınıflı bir veri kümesinin DAA ile 2 boyuta indirgenmesi b) DAA ile 2 boyuta indirgenen özelliklerin DAA ile sınıflandırılması için oluşturulan ve her bir sınıfı birbirinden ayıran hiper düzlemler..... 41
Şekil 3.7.	Yapay sinir hücresi modeli 42
Şekil 3.8.	Çok katmanlı YSA örneği..... 43
Şekil 3.9.	4 görünür, 3 gizli düğümden oluşan BM 45

Şekil 3.10.	m adet görünür, n gizli düğümden oluşan RBM	45
Şekil 3.11.	1 adet görünür, 3 adet gizli katmandan oluşan DBN modeli	46
Şekil 3.12.	Temel oto-kodlayıcı yapısı	47
Şekil 3.13.	Derin oto-kodlayıcı yapısı	47
Şekil 3.14.	RNN hücresi ve açılımı.....	48
Şekil 3.15.	LSTM modeli, yapısında bulunan kapılar ve LSTM hücresinin iç yapısı	49
Şekil 3.16.	NCP ile geleneksel ağ mimarilerinin karşılaştırılması. a) Tam bağlı ağlar, b) Rastgele seyrek yapıdaki bağlı ağlar, c) NCP mimarisi.	51
Şekil 3.17.	Temel CNN mimarisi[154]	52
Şekil 3.18.	4x4 boyuttaki bir giriş verisine 2x2'lik filtrenin uygulandığı evrişim işlemi	53
Şekil 3.19.	4x4 boyutundaki giriş verisi üzerinde 2x2 boyutunda maksimum havuzlama işlemi	54
Şekil 3.20.	Evrişim katmanından sonra kullanılan tam bağlı katmanlar	54
Şekil 3.21.	10 kat çapraz doğrulama tekniğine göre eğitim ve test verilerinin grafiksel modeli	56
Şekil 4.1.	Farklı materyallerden üretilmiş bardaklar ve aynı görünüme sahip farklı materyal türleri a) Plastik bardak b) Ahşap bardak c) Siyah kumaş d) Magnet e) Granit	58
Şekil 4.2.	Lazer ışığı ve yansıma türleri a) pürüzsüz bir yüzeyden speküler yansıma b) Pürüzlü bir yüzeyden yüzey altı ve dağınık yansıma.....	60
Şekil 4.3.	Lazer ışık kaynağı ve algılayıcı sistem	64
Şekil 4.4.	Lazer ışık kaynağı ve algılayıcı sistemin blok şeması	65
Şekil 4.5.	Tasarlanan deney düzeneği ve materyalin düzeneğe yerleştirilmesi.....	66
Şekil 4.6.	Önerilen hedef sınıflandırma yaklaşımı.....	67
Şekil 4.7.	Deneyisel çalışmalarda kullanılan materyaller ve materyal üzerindeki örnek lazer ışığı.....	68
Şekil 4.8.	Alüminyum materyalinden veri toplama aşaması ve ölçüm almada kullanılan Kartezyen robotun hareket düzeni a) Deney düzeneği b) Lazer ile tarama yöntemi.....	69
Şekil 4.9.	Gürültülü lazer işaretlerinin her bir materyal türü için enerji dağılımlarını gösteren kutu grafiği	70
Şekil 4.10.	Çıkarma işlemi sonrası lazer işaretlerinin her bir materyal türü için ortalama enerji dağılımlarını ve aykırı değerlerini gösteren kutu grafiği	71
Şekil 4.11.	10 farklı materyal için ham lazer işaretleri ve gürültüsüz lazer işaretleri	73
Şekil 4.12.	10 farklı materyal için çıkarma işlemi sonrasında Welch ve Yule – Walker AR metoduna göre hesaplanan PSD dönüşümlerine birer örnek	75
Şekil 4.13.	Deneyisel çalışmalarda kullanılan granit materyali, çıkarma işlemi sonrası ham lazer işareti, Welch ve Yule Walker AR methoduna göre PSD değerleri	75
Şekil 4.14.	Çalışmada önerilen LSTM modeli ve veri hazırlama sonrası oluşan işaretlerin giriş olarak kullanımı	77
Şekil 4.15.	NCP derin öğrenme modelinin blok şeması	78
Şekil 4.16.	NCP model parametreleri ve lazer işaretlerinin modele sunum şekli	79

Şekil 4.17.	Ham lazer işaretleri için doğruluk grafikleri a) Ham lazer işaretlerinin eğitildiği LSTM modelindeki çapraz doğrulama adımlarından biri için doğruluk grafiği b) Ham lazer işaretlerinin eğitildiği Derin LSTM modelindeki çapraz doğrulama adımlarından biri için doğruluk grafiği	81
Şekil 4.18.	Boyutu düşürülmüş lazer işaretleri için doğruluk grafikleri a) Boyutu düşürülmüş lazer işaretlerinin eğitildiği LSTM modelindeki çapraz doğrulama adımlarından biri için doğruluk grafiği b) Boyutu düşürülmüş lazer işaretlerinin eğitildiği Derin LSTM modelindeki çapraz doğrulama adımlarından biri için doğruluk grafiği	82
Şekil 4.19.	Çapraz doğrulama adımlarında test verisinde en yüksek başarıma sahip karışıklık matrisi	83
Şekil 4.20.	Çapraz doğrulama adımlarında test verisinde en düşük başarıma sahip karışıklık matrisi	84
Şekil 4.21.	Welch PSD metodu ile boyutu indirgenmiş işaretlerin NCP modelindeki kayıp ve doğruluk grafikleri a) Boyutu düşürülmüş lazer işaretlerinin eğitildiği NCP modelindeki çapraz doğrulama adımlarından biri için kayıp grafiği b) Boyutu düşürülmüş lazer işaretlerinin eğitildiği LSTM modelindeki çapraz doğrulama adımlarından biri için doğruluk grafiği	86
Şekil 4.22.	Test veri setinde en yüksek başarıma sahip karışıklık matrisi	86
Şekil 4.23.	Test veri setinde en düşük başarıma sahip karışıklık matrisi	87
Şekil 5.1.	Lazer ışığının doku ile etkileşimi. Doku üzerine gelen lazer ışığı, doku da lazerin ve dokunun özelliklerine bağlı olarak yansıma, emilim, saçılma ya da iletim özelliği gösterebilmektedir.	93
Şekil 5.2.	Önerilen cinsiyet tespiti yaklaşımı	93
Şekil 5.3.	a) Deneysel çalışma düzeneği b) Deneklerin ölçüm esnasındaki pozisyonu	94
Şekil 5.4.	Ölçümler esnasındaki erkek deneğin kol pozisyonu ve yansıtılan lazer ışığı	95
Şekil 5.5.	Kadın ve erkek deneğin kolundan elde edilen gürültülü lazer işareti, lazer ışığı kapatılarak ölçülen gürültü işareti ve çıkarma işlemi sonucu elde edilen gürültüsüz lazer işareti	95
Şekil 5.6.	Çıkarma işlemi sonrası lazer işaretlerinin her iki cinsiyet türü için ortalama enerji dağılımlarını ve aykırı değerlerini gösteren kutu grafiği	96
Şekil 5.7.	Kadın/erkek deneğe ait önışlemden çıkmış lazer işaretleri ve Welch PSD dönüşümü değerleri .	96
Şekil 5.8.	Çalışmada önerilen LSTM modeli ve veri hazırlama sonrası oluşan işaretlerin giriş olarak kullanımı	98
Şekil 5.9.	a) Çalışmadaki en yüksek başarıma sahip doğruluk grafiği b) Çalışmadaki en yüksek başarıma sahip karışıklık matrisi	99
Şekil 6.1.	Önerilen canlı/cansız sınıflandırma yaklaşımının blok diyagramı	102
Şekil 6.2.	Deneysel çalışmada kullanılan cansız materyaller. Soldan sağa sırasıyla; yapay mermer, pvc, polistiren, polietilen, mermer, alüminyum, galvaniz, cam, buzluca, demir, granit, çömlek, magnet, mdf, mukavva, siyah kumaş, ıhlamur	103
Şekil 6.3.	Çalışmada kullanılan canlı ve cansız varlıkların deney düzeneğindeki konumu	104
Şekil 6.4.	Canlı, cansız(alüminyum), cansız(galvaniz) materyallerine ait ham lazer işaretleri, beyaz gürültü ve çıkarma işlemi sonucundaki lazer işaretleri	105
Şekil 6.5.	Canlı ve cansız varlıklardan yansıyan ham lazer işaretlerinin çıkarma işlemi sonrası enerji dağılımları	106

Şekil 6.6.	Canlı, cansız(alüminyum), cansız (ıhlamur ağacı), cansız (çömlek) materyallerine ait ön işleme yapılmış lazer işaretleri ve Welch spektral güç yoğunluğu uygulanmış lazer işaretleri 106
Şekil 6.7.	Çalışmada önerilen LSTM modeli ve veri hazırlama sonrası elde edilen işaretlerin giriş olarak kullanımı 107
Şekil 6.8.	Canlı/Cansız varlıkların sınıflandırılma başarımında en yüksek sonuçları gösteren karışıklık matrisi 108
Şekil 7.1.	Lazer modülünde bulunan faz karşılaştırma devresinin blok diyagramı..... 111
Şekil 7.2.	Önerilen renk tespiti yaklaşımının blok diyagramı 112
Şekil 7.3.	Lazer işaretleri ile renk tespiti yaklaşımında kullanılan 9 farklı renkteki eva kağıtları 113
Şekil 7.4.	Çıkarma işleminden sonra siyah, beyaz ve kırmızı renkli eva kağıdının aynı ölçüm noktasından elde edilen 3 farklı modülasyon frekanslı lazer işaretleri 114
Şekil 7.5.	FFT algoritmasına göre DFT değerlerinin hesaplanmasından sonra siyah, beyaz ve kırmızı renkteki eva kağıdının 3 farklı modülasyon frekansı için genlik değerleri 115
Şekil 7.6.	3 farklı modülasyon frekansı için elde edilen DFT değerlerinin kutu grafiği ve 3 farklı değerlerin birleşimi ile elde edilen kutu grafiği 116
Şekil 7.7.	Farklı renklerden yansıyan lazer işaretlerine ait 3 boyutlu DFT değerlerinin t-SNE kullanılarak görselleştirmesi 116
Şekil 7.8.	Çalışmadaki en yüksek başarıma sahip sınıflandırıcının karışıklık matrisi 117
Şekil 7.9.	8 renk tespit çalışmasında en yüksek başarımlı KNN sınıflandırıcısının karışıklık matrisi... 118
Şekil 8.1.	Lazer işaretleri ile hedef tespit yaklaşımında lazer ışıklarının ortamdaki sis taneciklerinden saçılması 121
Şekil 8.2.	Canlı/cansız varlıkların farklı nem oranlarında ve sisli ortamlarda sınıflandırma yaklaşımı. 122
Şekil 8.3.	Çalışmada kullanılan canlı ve cansız varlıkların deney düzeneğindeki konumu 123
Şekil 8.4.	Sisli ortamda yapılan ölçüm örneği 124
Şekil 8.5.	Farklı ortam koşullarında canlı, cansız(ıhlamur) materyallerine ait ham lazer işaretleri, beyaz gürültü ve çıkarma işlemi sonucundaki lazer işaretleri..... 126
Şekil 8.6.	Doğal laboratuvar ortamında, %60, %70, %80 nemli ortamda ve sisli ortamdaki çıkarma işlemi sonrasında elde edilen ham lazer işaretlerinin normalize edilmiş enerji dağılım grafiği 127
Şekil 8.7.	Doğal laboratuvar ortamında, %60, %70, %80 nem oranlarında ve sisli ortamdaki canlıdan ve ıhlamurdan yansıyan lazer işaretlerine çıkarma işleminden sonra elde edilen ham lazer işaretlerine Welch PSD dönüşümü uygulanması sonucu oluşan işaretler..... 128
Şekil 8.8.	Sisli ortamda en düşük başarıma ait doğruluk grafiği ve test verileri için karışıklık matrisi . 130
Şekil 8.9.	Birleştirilmiş verilerle yapılan eğitim işleminde en düşük başarıma ait doğruluk grafiği ve test verileri için karışıklık matrisi..... 131
Şekil 8.10.	Karanlık ortamda yapılan renk tespiti çalışmasında çıkarma işleminden sonra siyah, beyaz ve kırmızı renkli eva kağıdının aynı ölçüm noktasından elde edilen 3 farklı modülasyon frekanslı lazer işaretleri..... 133

Şekil 8.11.	Karanlık ortamda yapılan renk tespiti çalışmasında FFT algoritmasına göre DFT değerlerinin hesaplanmasından sonra siyah, beyaz ve kırmızı renkteki eva kağıdının 3 farklı modülasyon frekansı için genlik değerleri	134
Şekil 8.12.	Karanlık ortamda yapılan renk tespiti çalışmasında, 3 farklı modülasyon frekansı için elde edilen DFT değerlerinin kutu grafiği	135
Şekil 8.13.	Karanlık ortamda yapılan renk tespiti çalışmasında farklı renklerden yansıyan lazer işaretlerine ait 3 boyutlu DFT değerlerinin t-SNE kullanılarak görselleştirmesi.....	135
Şekil 8.14.	Karanlık ortamda test verileri için en yüksek başarıma ait karışıklık matrisi	136
Şekil 8.15.	Birleştirilmiş verilerle yapılan eğitimde test verileri için karışıklık matrisi.....	138
Şekil 8.16.	Gündüz aydınlık ortamda elde edilen verilerin ve gece karanlık ortamda elde edilen verilerden bir gurubun eğitim ve diğer grubun ise test verisi olarak kullanılması sonucu elde edilen karışıklık matrisleri.....	139



TABLÖLAR LİSTESİ

	Sayfa
Tablo 2.1. Işığın oluşturan dalga boyları ve sınıflandırılması.....	17
Tablo 4.1. Çalışmada kullanılan materyaller	67
Tablo 4.2. Çalışmada kullanılan ham lazer işaretinin uzunluğu ve Welch PSD, Yule- Walker AR modellerine göre PSD dönüşümleri sonrası oluşan işaretlerin uzunlukları.....	73
Tablo 4.3. Derin öğrenme modellerinin girişinde kullanılan işaretlerin kombinasyonları.....	74
Tablo 4.4. LSTM modelinin katmanları ve parametreleri.....	76
Tablo 4.5. LSTM modelinin eğitim aşamasında kullanılan hiper-parametreler.....	77
Tablo 4.6. Derin LSTM modelinin katmanları ve parametreleri.....	77
Tablo 4.7. NCP derin öğrenme modelinin parametreleri	78
Tablo 4.8. Ham lazer işaretlerinin eğitim ve test süreleri, sınıflandırma başarımları sonuçları	81
Tablo 4.9. Boyutu düşürülmüş lazer işaretlerinin eğitim ve test süreleri, sınıflandırma başarımları sonuçları	82
Tablo 4.10. LSTM modelinde test veri setinde farklı gizli birim sayıları için yapılan çalışmaların ortalama eğitim süreleri ve doğruluk oranları.....	84
Tablo 4.11. Boyutu düşürülmüş lazer işaretlerinin kullanıldığı NCP modelindeki ortalama sınıflandırma başarımları	85
Tablo 4.12. Farklı makine öğrenmesi algoritmalarının sınıflandırma başarımları	87
Tablo 4.13. Lazer işaretleri ile materyal tanımlanmasının literatürdeki çalışmalarla karşılaştırılması	89
Tablo 5.1. Cinsiyet sınıflandırmasında önerilen LSTM modelinin katmanları ve parametreleri	97
Tablo 5.2. Önerilen LSTM modelinin eğitim aşamasında kullanılan hiper-parametreler.....	97
Tablo 5.3. Cinsiyet sınıflandırmasında önerilen LSTM modelinin başarımları değerleri	98
Tablo 6.1. Canlı/cansız varlıkların sınıflandırmasında önerilen LSTM modelinin katmanları ve parametreleri	107
Tablo 6.2. Farklı gizli birim sayısından oluşan LSTM modellerinin ortalama başarımları değerleri ve eğitim süreleri	108
Tablo 7.1. Çalışmada kullanılan modülasyon ve referans frekansları.....	113
Tablo 7.2. Klasik makine öğrenimi algoritmalarının renk tespiti uygulamasındaki başarımları oranları	117
Tablo 7.3. 8 rengin tespiti için elde edilen ortalama başarımları oranları	118
Tablo 7.4. Lazer işaretleri ile renk tespiti çalışmasının literatürdeki çalışmalarla karşılaştırılması.....	119
Tablo 8.1. Önerilen hedef analiz çalışmasında deneysel çalışmaya katılan deneklerin yaş aralığı.....	123
Tablo 8.2. Farklı ortam türlerinde canlı/cansız varlıklardan elde edilen işaret sayısı	125
Tablo 8.3. Cansız varlıklardaki işaretlerin örneklenmesi sonucu oluşan yeni işaret sayıları	125
Tablo 8.4. 10 kat çapraz doğrulama tekniği ile her bir bağımlı nem oranı ve sisli ortam için yapılan Canlı/Cansız sınıflandırmasının ortalama başarımları	129

Tablo 8.5.	Farklı bağıl nem ortamlarında ve sisli ortamda alınan verilerin birleştirilmesi ile yapılan canlı/cansız sınıflandırmasının başarımları.....	130
Tablo 8.6.	10 kat çapraz doğrulama tekniği ile her bir bağıl nem oranı ve sisli ortam için yapılan canlı/cansız sınıflandırmasının ortalama başarımları.....	131
Tablo 8.7.	10 kat çapraz doğrulama tekniği ile her bir bağıl nem oranı ve sisli ortam için yapılan Canlı/Cansız sınıflandırmasının ortalama başarımları	136
Tablo 8.8.	Gündüz vakti aydınlık ortamdan ve gece vakti karanlık ortamdan alınan verilerin birleştirilmesi ile yapılan renk tespiti uygulamasının başarımları	137
Tablo 8.9.	Gündüz aydınlık ortamda elde edilen verilerin ve gece karanlık ortamda elde edilen verilerden bir grubun eğitim ve diğer grubun ise test verisi olarak kullanılması sonucu oluşan başarımları.....	138



SİMGELER

c	: Işık hızı
CO	: Karbonmonoksit
CO ₂	: Karbondioksit
E_1	: Alt enerji seviyesi
E_2	: Yüksek enerji seviyesi
E_{foton}	: Foton enerjisi
f	: Frekans
m/s	: Metre/saniye
λ	: Dalga boyu
μm	: Mikro metre



KISALTMALAR

3D-SLDV	: 3D Scanning Laser Doppler Vibrometer (3 boyutlu tarama lazer doppler vibrometresi)
ADC	: Analog to Digital Converter (analog dijital dönüştürücü)
AE	: Auto-Encoders (oto-kodlayıcılar)
APD	: Avalanche Photo Diode (çığ foto diyot)
AR	: Auto-Regressive (otoregresif)
BGS	: Bilgisayarlı Görme Sistemi
BiLSTM	: Bidirectional Long Short Term Memory (çift yönlü uzun kısa vadeli hafıza ağları)
BM	: Boltzmann Makineleri
BRDF	: Bidirectional Reflectance Distribution Function (çift yönlü yansıma dağılım fonksiyonu)
CNN	: Convolutional Neural Networks (evrişimli sinir ağları)
DBN	: Deep Belief Networks (derin inanç ağları)
DBR	: Distributed Bragg Reflector (dağıtılmış bragg aynası)
DAA	: Doğrusal Ayırma Analizi
DFT	: Discrete Fourier Transform (ayrık fourrier dönüşümü)
DNN	: Deep Neural Networks (derin sinir ağları)
DVM	: Destek Vektör Makinesi
FFT	: Fast Fourier Transform (hızlı fourrier dönüşümü)
GN	: Gerçek Negatif
GP	: Gerçek Pozitif
GPU	: Graphics Processing Unit (grafik işlemcisi)
He-Ne	: Helyum-Neon
HSL	: Hiper Spektral LIDAR
IMU	: Inertial Measurement Unit (atalet ölçüm birimi)
KA	: Karar Ağaçları
KNN	: K-Nearest Neighbors (K-En yakın komşular)
LDV	: Lazer Doppler Vibrometresi
LIDAR	: Light Detection And Ranging (ışık algılama ve mesafe algılama)
LPF	: Low Pass Filter (alçak geçiren filtre)
LSTM	: Long Short-Term Memory (uzun kısa bellek ağları)
LTC	: Liquid Time Constant (sıvı zaman sabiti)
MEMS	: Micro Electro Mechanical Systems (mikro elektromekanik sistem)
MINC	: Materials in Context Database (materyal veri tabanı)
NB	: Naive Bayes
NCP	: Neural Circuit Policies (nöral devre politikaları)
Nd:YAG	: Neodymium Yttrium Aluminium Garnet (neodimyum katkılı itriyum alüminyum garnet)
PLL	: Phase Lock Loop (faz kilitlemeli çevrim)
PSD	: Power Spectral Density (güç spektral yoğunluğu)
PTZ	: Pan-Tilt-Zoom
RBM	: Restricted Boltzmann Machine (Kısıtlı Boltzmann makinesi)
RNN	: Recurrent Neural Networks (tekrarlayan sinir ağları)
SLDV	: Scanning Laser Doppler Vibrometer (tarama lazer doppler vibrometresi)
SPAD	: Single-Photon Avalanche Diode (tek fotonlu çığ diyotu)
TLS	: Terrestrial Laser Scanning (karasal lazer tarama sistemi)
ToF	: Time of Flight (uçuş süresi)
t-SNE	: t-distributed Stochastic Neighbor Embedding (t-dağıtılmış stokastik komşu gömme)

UV-A	: Ultraviyole – A
UV-B	: Ultraviyole – B
UV-C	: Ultraviyole – C
VCSEL	: Vertical Cavity Surface Emitting Laser (dikey kaviteli yüzey ışıması yapan lazer)
YN	: Yanlış Negatif
YP	: Yanlış Pozitif
YSA	: Yapay Sinir Ağı



1. GİRİŞ

1.1. Çalışmanın Kapsamı ve Amacı

Görme ve görsel algılamanın temel kaynaklarından biri olan ışık aynı zamanda dünyadaki canlı yaşamının temel gereksinimlerinden biridir. İnsanların temel duyu organlarından biri olan görme işlemi de ışık sayesinde olmaktadır. Işık kaynaklarının çevredeki nesneleri aydınlatması ve bu nesnelerden yansıyan ışığın gözdeki algılama hücrelerini uyarması sonrasında oluşan işaretlerin beynimizdeki görme merkezinde yorumlanması ile görme olayı ve görsel algılama meydana gelmektedir. Meydana gelen bu görme olayı sonrasındaki görsel algılama ile etrafımızdaki cisimlerinin rengini algılayabilir, türlerini sınıflandırabilir veya yapıldıkları malzemeler hakkında da yorum yapabiliriz. Aynı şekilde görme yardımı ile çevremizdeki insanların cinsiyeti için çıkarımda bulunabilir veya uzakta bulunan bir insanın canlılığı hakkında da fikir sahibi olabiliriz. Tüm bu olguların gerçekleşmesi için nesnelerin bir şekilde ışıkla etkileşime girmesi ve görme olayının gerçekleşmesi gerekmektedir.

Günlük yaşamda, görsel algılama sistemimiz sayesinde çevremizdeki nesneler hakkında bilgiler ediniriz ve edindiğimiz bu bilgiler doğrultusunda birçok nesne türü ile farklı şekillerde etkileşime gireriz. Etkileşim içinde bulunduğumuz bu nesnelerden bazıları sert veya yumuşak olabilmekte, bazıları sağlam veya kırılğan özellikte olabilmekte, bazıları ise ağır veya hafif olabilmektedir. Nesneler, bu özelliklerini yapıldıkları malzemelerin özelliklerinden almaktadır. Örneğin metaller sert, kumaşlar yumuşak, cam ise kırılğan olabilmektedir. Yapısal özelliklerini bildiğimiz nesnelerle etkileşimlerimiz de farklı olabilmektedir. Örneğin cam bir bardağı tutarken kırılğanlık özelliğinden dolayı daha dikkatli davranırız, metal bir eşyayı kaldırırken ağır olabileceğinden daha çok güç harcamamız gerektiğini veya buzlu bir yoldan giderken kayabileceğimizi biliriz ve bu durumlara göre bir hareket tarzı geliştiririz. Verilen bu örneklerle benzer şekilde; karşısındaki hedefin malzeme türünü tespit edebilen bilgisayarlı görme sistemleri de önemli avantajlara sahip olacaktır. Örneğin otonom sürüşe sahip bir robot sistemi kırılğan ve kaygan özelliğe sahip bir cam yüzeyin üzerinden gitmeyecek ve kendisine yeni bir rota çizecektir. Aynı şekilde bir robotik kavrama sistemi, karşısındaki nesnenin yapıldığı malzemeyi ve yapısal özelliklerini bilirse (yumuşaklık, sertlik, kırılğanlık gibi...) malzemeyi kavramak için uygun bir strateji yürütebilecektir. Buna benzer şekilde robotik sistemler etkileşim kurduğu yüzeylerin malzeme türünü bilirse daha başarılı ve verimli olacaktır.

Günlük yaşamımızda sıklıkla etkileşim içinde bulunduğumuz nesnelerin ayırt edici özelliklerinden biri de nesnelerin rengidir. Süt, su, kola, sıvı deterjan ve diğer sıvıları ilk bakışta renklerine bakarak birbirinden ayrılabilir. Benzer şekilde bir meyvenin olgunluk seviyesini de rengine bakarak algılayabiliriz. Örneğin yeşil renkteki bir domates daha olgunlaşmamışken, kırmızı

renkteki bir domates ise olgunlaşmıştır. Renk algılaması nesnenin yüzey yapısına, nesneyi aydınlatan ışığın rengine ve algılayıcının hassasiyetine bağlıdır. Nesnenin görünür ışık ile aydınlatılması sonrasında nesneden yansıyan ışığın miktarına göre insanlarda ve algılayıcılarda renk algılaması gerçekleşmektedir. Doğal aydınlatma ortamında bir nesneye çarpan görünür ışık dalgaları nesne tarafından tamamen yansıtılırsa nesne insanlar tarafından beyaz, tamamen emilirse nesne siyah olarak algılanacaktır. Örneğin nesneye çarpan doğal beyaz ışık sonrasında nesneden kırmızı ışıklar yansır ve beyaz ışık içindeki diğer renkler nesne tarafından emilirse (absorbe), nesnenin rengi kırmızı olarak algılanacaktır. Tamamen karanlık ortamlarda ise nesneler siyah renk olarak algılanmaktadır. Nesneler doğal beyaz ışık haricinde farklı bir renkteki ışık kaynağı ile aydınlatıldığında ise nesnenin rengi yansıtılan ışık kaynağının rengine göre gerçek renginden farklı olarak algılanacaktır. Gün ışığında, farklı ışık kaynaklarında veya gece karanlığında nesnelerin renginin doğru algılanması insanlar ve bilgisayarlı görüş uygulamaları için önem arz etmektedir. Örneğin, sürücülerin yolda güvenli bir şekilde manevra yapmasına yardımcı olan gelişmiş sürücü destek sistemlerinde bulunan şerit takip sistemlerinde; şerit tespiti, şerit türünün tespiti ve şerit renginin tespiti üzerine odaklanılmaktadır. Şerit renklerinin her türlü ortamda doğru bir şekilde sınıflandırılabilmesi sürücü güvenliği açısından önemlidir. Benzer şekilde Endüstri 4.0 formundaki bir fabrikada ise nesnelerin veya materyallerin rengine göre ayırt edilmesi ve buna göre üretim işlemlerinin idame edilmesi de önem arz etmektedir.

Günlük hayatta insanlar birbiri ile iletişim kurarken görsel algılama sayesinde elde ettikleri bilgileri kullanırlar. Bir kişinin yüzüne baktığımızda kişinin kim olduğunun yanı sıra kişinin cinsiyeti, yaşı ve genel fiziksel özellikleri hakkında da bilgi sahibi oluruz. Başarılı bir cinsiyet tanıma işlemi beyin bilgisayar ara yüzü sistemlerinde, güvenlik sistemlerinde, pazarlama sektöründe, biyometrik doğrulama sistemlerinde faydalı olabilmektedir. Örneğin cinsiyete özel giriş yapılabilen mekanlarda otomatik cinsiyet tanımlama işlemi önemli kolaylıklar sağlayacaktır. Benzer şekilde otomatik cinsiyet tanımlamasının yapıldığı beyin bilgisayar ara yüzü sisteminde kişinin cinsiyetine göre önermeler ve seslendirmeler yapılabilecektir. Otomatik cinsiyet tespiti sonrasında büyük veri tabanları cinsiyete göre filtrelendiğinde veri tabanındaki işlem yükü azalacak ve diğer arama işlemleri daha az hesaplama maliyeti ile yapılabilecektir. Adli bir olayda cinsiyetin tespiti sonrasında, adli veri tabanında cinsiyet odaklı arama yapıldığında daha hızlı sonuçlar alınabilecektir. Alışveriş merkezleri, sinema salonları gibi toplu yaşam alanlarında cinsiyet tespiti otomatik yapıldığında ise bu alanlarda bulunan kadın veya erkek cinsiyetinin yoğunluğuna göre reklamlar yapılarak daha başarılı pazarlama stratejileri geliştirilebilecektir.

Aktif savaş ortamlarında, terörle mücadelede, kentsel savaş operasyonlarında düşman cephe hattındaki unsurların canlılığının tespiti önem arz etmektedir. Buna benzer aktif savaş ortamlarında bazı hedefler canlı insan olabilirken bazı hedefler ise farklı materyallerden yapılan mankenlerin kullanıldığı sahte senaryolardan oluşabilmektedir. Bu hedeflerin canlı olup olmama durumunun

tespiti insan hayatı için önemlidir. Bu tür durumların uzaktan tespit edilebilmesi halinde önemli kazanımlar elde edilebilmektedir. Bunlara benzer şekilde rehine operasyonlarında gerçek canlı hedeflerin tespitinin yapılabilmesi halinde birçok kişinin hayatı kurtarılabilir.

Bunun yanı sıra biyometrik güvenlik sistemlerinde parmak izinin, fotoğrafın, retinanın bir canlıya ait olup olmadığının belirlemek için de canlılık tespitinin yapılması önemlidir. Bu şekilde bir kişinin biyometrik verisini taklit eden girişim tespit edilebilir ve önlem alınabilir. Biyometrik önlemleri aşmak için insan yüzüne ait basılı fotoğraflar, parmak izi için kalıplar, yüz tespiti için üç boyutlu (3B) maskeler sıklıkla kullanılmaktadır [1–3].

Teknolojinin gelişmesi ile birlikte insanlardaki görme olayına benzer şekilde çalışan kameralar geliştirilmiştir. Bu kameralar insan gözüne benzer şekilde, doğal güneş ışığı veya yapay ışık kaynakları tarafından aydınlatılan nesnelerden yansıyan ışığı toplamakta ve nesnelerin görüntüsünü oluşturmaktadırlar. Elde edilen görüntüler bilgisayarlı görme sistemleri tarafından işlenerek görüntülerden anlamlı bilgiler çıkartılmaya çalışılmaktadır. Literatür incelendiğinde; görüntülerden nesne tespiti, nesnelerin yapıldığı malzemenin tanımlanması, farklı şartlar altındaki nesnenin gerçek renginin algılanması, cinsiyet tespiti ve insan canlılığının tespiti üzerine yoğun çalışmaların olduğu görülmektedir. Bu çalışmaların büyük çoğunluğu uzaktan temassız bir şekilde optik algılamaya dayalı olarak verilerin elde edilmesi ve bu verilerin işlenmesi şeklinde olmaktadır.

Optik uzaktan algılama, aktif ve pasif sistemleri içerecek şekilde ikiye ayrılabilir. Herhangi bir ışık kaynağı kullanmayan ve sadece nesnelerden yansıyan ışıkları toplayan RGB kameralar pasif sistemler olarak adlandırılmaktadır. Bu tür sistemlerin halen birçok zorluğu bulunmaktadır. Işığın yeterli olmadığı durumlarda veya ışığın çok fazla olduğu durumlarda bu tür sistemler sağlıklı bir şekilde veri toplayamamakta ve sonuç olarak bu verilerden başarılı sonuçlar üretilmemektedir. Işığın belirli bir seviyenin altında olduğu durumlarda ise bu tür sistemler hiçbir şekilde çalışmamaktadır.

Aktif ölçüm sistemleri ise kullanıcı tarafından kontrol edilebilen farklı aydınlatma sistemleri kullanılmaktadır. Bunlardan biri de ilk defa 1960 yılında Theodore Maiman tarafından icat edilen lazeri kullanan sistemlerdir [4]. İlk defa yakut kristali kullanılarak üretilen lazerlerin üretim tekniklerinde de zaman içerisinde büyük gelişmeler yaşanmış ve farklı dalga boylarında, farklı çıkış güçlerinde, farklı darbe sürelerinde çalışan çeşitleri ortaya çıkmıştır. Lazerler üretiminde kullanılan maddeye göre gaz lazerleri, sıvı – boya lazerleri, katı hal lazerleri ve yarı iletken (diyot) lazerleri olarak dört gruba ayrılmaktadır. Diyot lazerler küçük boyutta olmaları, sağlamlıkları ve yüksek güvenilirlikleri nedeniyle birçok sektörde kullanılmaktadır [5,6]. Sürekli dalga formunda kullanılan lazerler hedefe nispeten daha düşük miktarda ve sürekli olarak iletirken, darbeli dalga formundaki lazerler ise hedefe belirli aralıklarla anlık olarak daha yüksek güçlü enerji iletebilmektedir. Lazerlerin bu üstün özelliklerinden dolayı bilimsel çalışmalarda, tıbbi, askeri, endüstriyel ve daha birçok alanda kullanımı bulunmaktadır.

Monokromatik, tutarlı ve polarize ışıktan oluşan yoğun miktardaki paralel ışın üretme kabiliyetlerinden dolayı lazerler optik uzaktan algılama için de önemli bir araç haline gelmiştir. Lazer ışığı hedefteki bir cisme çarptığında kısmen yansıtılmakta, kısmen iletilmekte veya kısmen emilmektedir. Hedef bir biyolojik doku olduğunda ise doku ile etkileşime giren lazer ışığı faz değişimi, emilim ve saçılma süreçlerinden geçmektedir [7]. Hedeften yansıyan lazer ışınları elektro-optik düzenekler içinde bulunan yüksek kazanç katsayısına sahip çıkış foto diyotlar yardımı ile ölçülebilmekte ve işaretlere dönüştürülebilmektedir. Farklı hedef türlerinin farklı şekillerde saçılma ve emilim özellikleri göstermelerinden dolayı hedeflerden yansıyan lazer işaretleri kullanılarak çevremizdeki birçok canlı/cansız hedef türü hakkında bilgi sahibi olunabilir. Lazer ışığı bir hedefe yansıtıldığında, çalışma ortamının yüksek seviyede nemli veya sisli olması durumunda hedefe ulaşan ışık miktarında bir miktar zayıflama olacaktır. Bunun yanında böyle bir ortamda bulunan yoğun su moleküllerinden de saçılmalar olacak, elektro-optik lazer alıcısına bu moleküllerden yansıyan işaretlerde de ulaşacaktır. Lazer ışınları ile hedef türlerini belirleme çalışmalarında; bu türdeki olumsuz atmosferik şartlar dikkate alındığında daha başarılı sonuçlar elde edilebilecektir.

Bu tez çalışmasında; nesnelerin lazer ışığı ile etkileşime girmesi, farklı hedef türlerinin farklı şekillerde saçılma ve/veya yansıma özelliği göstermesi ve 1 mW çıkış gücüne sahip düşük güçlü lazerlerin insan göz sağlığına zararlı olmaması sebebiyle lazerlerin birer sensör olarak kullanılması üzerine odaklanılmıştır. Bu tez çalışmasında düşük güçlü lazer işaretleri ile herhangi bir kimyasal analize ve temasa gerek olmaksızın, laboratuvar ortamı dışında kullanımı çok mümkün olmayan, yüksek maliyetli ve büyük cihazlara ihtiyaç olmadan, uzaktan algılama ile farklı hedef türlerinin tespiti amaçlanmıştır. Bu amaç doğrultusunda hedefe bir lazer ışığı yansıtılmakta ve hedeften yansıyan lazer ışığı alıcı sensör yardımı ile ölçülerek bilgisayar ortamına kaydedilmektedir. Kaydedilen bu lazer işaretleri veri hazırlama adımlarından sonra, tasarlanan yapay zeka mimarisi ile eğitilerek hedef türünün tespiti yapılmaktadır. Tez çalışması kapsamında; düşük güçlü tek bir lazer ışık kaynağı kullanılarak uzaktan algılamaya yönelik önerilen yapay zekâ temelli yaklaşımlar ile yapılan çalışmalar:

- a) Günlük hayatta sıklıkla kullanılan farklı materyal türlerinin sınıflandırılması
- b) Uzak bir mesafeden temassız olarak bir kişinin cinsiyetinin tespit edilmesi
- c) Farklı türdeki cansız nesneler ile canlı bir insan dokusunun ayırt edilmesi
- d) Gün ışığı ve karanlık ortamda hedefin gerçek renginin tespitinin yapılması

Yapılan bu çalışmaların yanında atmosferik şartların (nem, sis, gün ışığı, karanlık ortam) hedef türü tespiti üzerine etkileri de değerlendirilmiştir.

1.2. Literatür İncelemesi

Literatür incelendiğinde çalışılan hedef türlerine göre farklı temellere dayalı lazer sistemlerinin kullanıldığı görülmektedir. Bunlar;

- Laboratuvar ortamlarında sıklıkla kullanılan Michelson interferometresi tabanlı titreşim ölçerler ile hedefteki en ufak titreşimler tespit edilebilmektedir [8].
- Hedefteki titreşimleri ölçmede kullanılan bir diğer ölçüm tekniği ise Lazer Doppler Vibrometresidir (LDV). LDV ölçüm tekniğinde lazer ışını bir yüzey üzerindeki hedef konuma yönlendirilmekte ve lazer ışınının yönündeki yüzeyin yer değiştirmesi veya hızı Doppler efekti ve interferometri ilkeleri aracılığıyla ölçülmektedir [9–12].
- Lazer ile yapılan çalışmalardan bir diğeri ise mesafe tabanlı çıkarımlardır. Bu tekniklerde cisimler Lidar ile taranarak elde edilen nokta bulutlarından nesneler tespit edilmeye çalışılmaktadır.
- Lazerlerin sıklıkla kullanıldığı sensörlerden bir tanesi de karasal lazer tarama (Terrestrial Laser Scanning, TLS) sistemleridir. TLS ile uzaktan ve temassız bir şekilde ilgilenilen nesneye ait yoğun ve ayrıntılı bir şekilde 3 boyutlu nokta bilgisi alınabilmektedir [13]. TLS, içerisinde bulunan dahili RGB kamera sayesinde nesne görüntüsünün yanı sıra ölçülen nesneye ait uzaklık bilgisini renkli nokta bulutları halinde verebilmektedir. TLS aynı zamanda nesneye ait yansıma bilgilerini de verebilmektedir.
- Mesafe çıkarımına dayalı bir diğer cihaz ise derinlik kameralarıdır. Bu kameralar RGB görüntüsünün yanında derinlik bilgisi için lazer sensör dizisi kullanmaktadır. Uçuş süresi (Time of Flight, ToF) kamera veya RGB-D olarak adlandırılan bu kameralar ile lazer ışıkları malzeme üzerine yönlendirilmekte ve malzemeden yansıyan ışığın sensöre ulaşma süresi kayıt altına alınarak derinlik bilgisi oluşturulmaktadır. Bunun yanında bu kamera ile malzemeden yansıyan lazer ışınlarının yoğunluk bilgisi de kayıt altına alınabilmektedir.

Yukarıda belirtilen bu lazer tabanlı algılama sistemlerinin kullanımı genellikle laboratuvar ortamında hassas bir kurulum gerektirmekte ve günlük hayatta kullanımını kısıtlayacak seviyede maliyetli donanımlar içermektedir. Bunun yerine bu tez çalışmasında sürekli modda çalışan, düşük güçlü ve düşük maliyetli olan tek bir lazer ölçüm noktasına dayalı olarak çalışan taşınabilir bir elektro-optik lazer sistemi kullanılmaktadır.

Literatür incelemelerinde materyal tanımlama, gerçek renk tespiti, cinsiyet tespiti ve canlılık tespiti çalışmalarında lazer tabanlı algılama sistemlerinin yanı sıra kamera, ses, termografi, dokunma sensörü, basınç sensörü, titreşim sensörü ve benzeri sensörlerin de kullanıldığı görülmektedir.

Materyal türü tespitine yönelik yapılan çalışmalar:

Materyal türü tespitine yönelik çalışmalar lazer tabanlı sistemlerin kullanıldığı sistemler ile lazer teknolojisinin kullanılmadığı sistemler olmak üzere iki ana kategori altında incelenmiştir.

Lazer tabanlı sistemler ile materyal türü tespitine yönelik yapılan çalışmalar:

Han ve diğerleri ise yaptıkları çalışmada TLS ve kamera kullanmışlardır. TLS’de lazer ışıkları kullanılarak oluşturulan nokta bulutları ile farklı açılardan çekilen yapı nesnelerine ait görüntüler birleştirilerek görüntülerin hizalanması yapılmakta ve ardından Destek Vektör Makinesi (DVM) ile sınıflandırılma yapılmaktadır. Çalışmalarında 100x100 pikselden oluşan asfalt, tuğla, beton, yeşillik, kalıp, çakıl, izolasyon malzemesi, mermer, metal, kaplama, toprak, taş, su yalıtım boyası, ahşap görüntüleri ve bu malzemelerin farklı varyasyonlarını kullanarak ortalama %92,4 başarımla elde etmişlerdir [14].

Hassan ve diğerleri TLS ve renkli kamera kullanarak homojen özelliklerdeki gri renkli beton, gözenekli gri renkli gaz beton ve dokulu kiremidin tanımlanması üzerine çalışma yapmışlardır. Yapılan çalışmada, her malzemenin lazer ışıklarını yansıtma özelliğinin farklı olduğu ve aydınlatma koşullarının etkisinin olmadığı bildirilmektedir [15]. Bu çalışmalarında bir materyalin tanımlanması için birden fazla noktadan lazer yoğunluk bilgisi elde etmişlerdir. Malzeme tanımlamada yansıtma özelliklerinin yanında RGB renk değerlerinin ikincil bir parametre olarak kullanabileceğini göstermişlerdir.

Yuan ve diğerleri ise TLS ve dahili RGB kamera kullanarak yaptıkları çalışmada 10 farklı malzemenin tanımlamasını yapmışlardır [16]. Malzeme tanımlama çalışmalarında, 400 cm²’lik bir alandan oluşan her bir örneğin birçok noktasından elde ettikleri lazer ışıkların yansıma bilgilerini, materyallerin pürüzlülük değerlerini ve kamera görüntülerini kullanmışlardır. Materyal tanımlama çalışmalarında materyallerin yansıma, pürüzlülük ve HSV renk değerlerini ayrı ayrı test etmişler ve en yüksek malzeme tanımlama başarımlarını her üç özelliği kullandıklarında elde etmişlerdir. Tanımlama işlemi için birden fazla makine öğrenmesi tekniğini kullanarak karşılaştırma yapmışlardır.

Shen ve diğerleri TLS ile yaptıkları çalışmada yığma yapılarıdaki tuğla şekillerini çıkarmak için, tuğla ve aradaki harçtan yansıyan lazer ışık yoğunluk miktarlarının farkından ve tuğlaların geometrik yapısından yola çıkmışlardır [17]. Çalışmalarında tuğlalardan elde ettikleri çok sayıda 3B nokta bulutlarını kullanarak dikdörtgen şeklindeki tuğlaların şekillerini ortaya çıkarabilmişlerdir.

Martino ve diğerleri yaptıkları çalışmada demir, köknar ağacı, kontrplak, plastik, polistiren, yansıtıcı yüzey, beyaz kumaş, koyu renkli kumaş, alüminyum ve camdan oluşan 10 farklı malzemeyi sınıflandırmak için derinlik kamerası kullanmışlardır. Çalışmada 1 metre uzaklıktaki

malzemelerden elde edilen 3B derinlik ve yoğunluk bilgileri kullanılarak Karar Ağaçları (KA) ile sınıflandırma yapılmıştır. Çalışmanın yaklaşık başarımları oranı %80 olarak bildirilmiştir [18].

Callenberg ve diğerleri düşük maliyetli ve tek foton algılamaya dayalı olan 16x16 piksel çözünürlüğünde tek fotonlu çıkış diyotu (Single-Photon Avalanche Diode, SPAD) dizisi kullanarak materyal tanımlama çalışması yapmışlardır. SPAD tek foton gibi düşük yoğunluklu işaretleri tespit edebilen ve fotonun varış zamanını tespit edebilen bir fotodedektör türüdür. Çalışmalarında havlu, kâğıt, mum, insan derisi ve köpükten oluşan 5 çeşit materyalin farklı noktalarının üzerinde sensörü konumlandırarak her bir materyal türü için toplamda 40 adet ölçüm yapmışlardır. Elde ettikleri veri setini kullanarak evrişimli sinir ağları (Convolutional Neural Networks, CNN) ile materyal sınıflandırması yapmışlardır [19]. Benzer bir çalışma da Su ve diğerleri tarafından kâğıt, köpük, havlu ve mumdan oluşan 4 çeşit materyalin tanımlanması üzerine yapılmıştır. Farklı sınıflandırıcı algoritmaları kullanarak yaptıkları çalışmada en yüksek başarımları DVM kullanarak yaklaşık %80,9 oranı ile elde etmişlerdir [20].

Lang ve diğerleri ise darbeli ToF kamera kullanarak 9 çeşit materyali yakın mesafeden sınıflandırmışlardır. Bu çalışmalarında 640x480 piksel çözünürlüğünde ToF kamera ve Yapay Sinir Ağı (YSA) kullanarak malzemeleri ortalama %93,3 başarımları oranı ile sınıflandırmışlardır [21].

Kim ve diğerleri ToF kamera kullanarak yaptıkları çalışmada malzemelerden yansıyan IR ışıklarının yoğunluğunu ve RGB renk değerlerini kullanarak 7 çeşit malzeme türünü sınıflandırmışlardır [22]. Çalışmalarında %74,09 doğru sınıflandırma başarımları elde etmişlerdir.

Conde ve diğerleri ToF kamera kullanarak 5 çeşit malzemeyi sınıflandırmak için çalışmışlardır. Çalışmalarında DVM ile materyallerden yansıyan birden çok noktadaki IR yoğunluk bilgilerini kullanarak malzemeleri ortalama %78 oranında doğru bir şekilde sınıflandırmışlardır [23].

Lazer tabanlı olmayan sistemler ile materyal türü tespitine yönelik çalışmalar:

Lu ve diğerleri yapı malzemelerinin tespiti için görünüm tabanlı bir yöntem üzerinde çalışmışlardır [24]. Bu çalışmada görüntülerden elde edilen renk ve doku özellikleri kullanılarak 4 farklı renkteki tuğla türü, 3 farklı renkteki beton ve ahşap malzemelerin sınıflandırılması yapılmıştır. Farklı ortam aydınlatma şartları yaptıkları çalışmalarında ortam aydınlatmasının çok karanlık veya çok aydınlık olması durumunda başarımları düştüğünü bildirmişlerdir.

Liu ve diğerleri boyanmamış metal, plastik, seramik, kumaş ve ahşap materyalleri sınıflandırmak için yüzeylerin çift yönlü yansıma dağılım fonksiyonunu (Bidirectional Reflectance Distribution Functions, BRDF) kullanmışlardır. Bu amaçla ayırt edici aydınlatma olarak isimlendirdikleri LED'lerden oluşan kubbemsi bir yapı oluşturmuşlar ve her bir materyalin ışığa karşı yansımasını kamera ile kayıt altına alarak DVM ile sınıflandırma yapmışlardır [25].

Son ve diğerleri ise çalışmalarında inşaat ortamlarında sıklıkla kullanılan çelik, beton ve ahşaptan oluşan 3 çeşit malzemenin görüntülerini ve malzemelerin renk bilgisini kullanarak malzeme sınıflandırılması yapmışlardır [26]. RGB renk değerlerinin dış ortam aydınlatmasının olumsuz etkilerinden kaçınmak için ton (H), doygunluk (S) ve yoğunluk (I) değerlerini kullanmışlardır. Çalışmalarında DVM, YSA, KA, Naive Bayes (NB), Lojistik Regresyon (LR), K-En yakın komşular (K-Nearest Neighbors, KNN) ve topluluk sınıflandırıcı algoritmalarından faydalanmışlardır. Topluluk sınıflandırma algoritmasının daha iyi sonuçlar ürettiğini belirtmişlerdir.

Dimitrov ve diğerleri yaptıkları vizyon tabanlı malzeme tanımlama çalışmasında 20 çeşit inşaat malzemesini sınıflandırmışlardır. Çalışmalarında 200x200 ve 30x30 pikselden oluşan görüntülerdeki malzemelerin doku ve renk bilgilerini kullanarak DVM ile sınıflandırma yapmışlardır [27]. Çalışmalarında yüksek çözünürlüklü görüntülerden daha yüksek başarımlar elde etmişlerdir. Renk bilgilerinin günün belirli saatlerinde değişkenlik gösterdiğini bildirmişlerdir.

Bian ve diğerleri görüntülerden malzeme tanıma çalışması kapsamında oluşturulan Materials in Context Database (MINC) veri tabanı üzerinde çalışmışlardır [28]. MINC veri tabanı 23 kategoriden oluşan 3 milyondan fazla görüntü içermektedir [29]. Çalışmalarında malzeme tanımanın doğruluğunu arttırmak için topluluk öğrenme tabanlı CNN'leri önermektedirler. Burada özellik çıkarımı için CNN kullanılmakta, ardından topluluk tabanlı sınıflandırma ile materyal tanımlanması yapılmaktadır. Çalışmalarında yaklaşık %85 doğru sınıflandırma başarımları elde etmişlerdir.

Wu ve diğerleri tek bir milimetre dalga radyo frekansı kullanarak, hedeften yansıyan radyo işaretlerine göre malzeme sınıflandırması yapmışlardır. Çalışmalarında farklı boyutlarda ve kalınlıklarda alüminyum, seramik, plastik, ahşap ve su kullanmışlardır [30]. Benzer bir çalışmayı ise Dhekne ve diğerleri kablosuz işaretlerin sıvılardan veya diğer materyallerden geçerken uğramış oldukları faz kaymasından yararlanarak yapmışlardır [31].

Windau ve diğerlerinin yaptığı materyal tanımlaması çalışmasında; robotik kol materyale bir kere vurmakta ve tekrar eski konumuna dönmektedir. Bu esnada kol üzerinde bulunan ivmeölçer, oluşan salınım hareketlerini ölçmektedir [32]. KNN tekniğini kullandıkları bu çalışmalarında 5 farklı yüzey malzemesi için %85 oranında doğru sınıflandırma başarımları elde etmişlerdir. Liu ve diğerleri ise malzemeleri tanımlamak için dokunsal bir sensöre sahip robotik bir parmak kullanmışlardır [33]. Bu sensör ile parmağın materyale sürmesi aşamasındaki titreşimler kayıt altına alınmaktadır. NB sınıflandırıcı kullanarak 12 çeşit materyali %88,5 oranında doğru bir şekilde sınıflandırmışlardır.

Baglio ve diğerleri ise çalışmalarında dokunsal algılamaya dayalı bir yöntem önermektedir [34]. Bu yöntemde geliştirdikleri sistem malzemeye belli bir eşik değerine kadar baskı yapmaktadır.

Bu esnada sistemdeki piezosensörden elde edilen çıkış değerleri kayıt altına alınmakta ve kayıtlar frekans spektrumu bilinen malzemeler ile karşılaştırılarak materyal tanımlanması yapılmaktadır.

Erickson ve diğerleri robotların evlerde kullanılan 8 çeşit malzeme kategorisini doğru bir şekilde sınıflandırması için yakın kızılötesi spektroskopi ve yakın mesafeli yüksek çözünürlüklü doku görüntülemeyi birleştiren bir yöntem önermektedir [35]. Sınıflandırma için CNN kullandıkları modelde ortalama %90,8 oranında başarımlar elde etmişlerdir.

Materyal tanıma işlemlerinin başarısız olduğu durumlara bakıldığında materyalin renk, doku, geometri bilgisinin alınamadığı durumlar ve uygun aydınlatma koşulları sağlanamadığı durumlar olduğu görülmektedir. RGB görüntü kullanılan yöntemlerde gerçek nesne yerine materyalin basılı fotoğrafı kullanılarak sistem kolaylıkla yanıltılabilmektedir.

Gerçek renk tespitine yönelik yapılan çalışmalar:

Bir nesnenin renginin doğru bir şekilde algılanması birden fazla etkene bağlıdır. Gerçek renk tespiti insandan insana farklı olarak algılanabildiği gibi, ışık kaynağının türüne ve açısına, gözlemleyenin bakış açısına, nesnenin bulunduğu ortama ve sensörün performansına bağlıdır. Belirtilen bu parametrelerdeki herhangi bir değişim gözlemlenen rengin farklı olmasına sebep olacaktır [36,37]. Literatür incelendiğinde gerçek rengin tespitine yönelik farklı sensörlerin kullanımı ve bunlara bağlı olarak farklı metodların varlığı görülmektedir. Literatürde pasif algılama kaynağı olarak kamera ve aktif algılama kaynağı olarak farklı dalga boylarındaki ışık kaynaklarının kullanımı bulunmaktadır. Bu tür cihazlar arasında spektrofotometreler, kolorimetreler, yansıma ilkesine göre çalışan farklı dalga boylarındaki LED'ler ve lazer ışık kaynakları bulunmaktadır [38].

Gerçek renk tespitine yönelik çalışmalar lazer sistemlerinin kullanıldığı ve lazer sistemlerinin kullanılmadığı sistemler olmak üzere iki ana kategoride incelenmiştir.

Lazer tabanlı sistemler ile gerçek renk tespitine yönelik yapılan çalışmalar:

Chen ve diğerleri 32 kanallı süper sürekli Hiper-Spektral LIDAR (HSL) kullanarak gerçek renk tespiti ve renkleri kullanarak nesnelerin sınıflandırılması üzerine çalışmışlardır [39]. Tamamen karanlık laboratuvar ortamında kullandıkları optik ışık kaynağı 8W çıkış gücüne ve 400–2400 nm arasındaki dalga boylarına sahiptir. Hassas bir kurulum gerektiren deneysel düzenek sistem maliyetini arttırmaktadır. Deneyde kullanılan 431–751 nm spektral aralığını kapsayan 32 kanallı HSL verileri ise hesaplama maliyetini arttırmaktadır. 3 farklı spektral veriyi kullanarak yaptıkları nesne tanımlama çalışmasında ortalama %77,11 oranında sınıflandırma doğruluğu, 3 farklı spektral verinin RGB renklerine dönüştürülmesiyle yaptıkları nesne tanımlamasında ise ortalama %91,71 oranında sınıflandırma doğruluğu elde etmişlerdir. DVM ve NB ile yaptıkları bu çalışmada en yüksek başarımları DVM algoritması vermiştir. 9 farklı renkten oluşan kartonların rengini ise %91,91 oranında doğru bir şekilde tespit etmişlerdir.

Leung ve diğerkleri kırmızı ve yeşil lazeri sırasıyla kısmen opak bir maddeye yansıtmışlar ve kısmi opak maddenin arkasındaki renkli hedefi 200 Hz’de titreştirerek, kısmi opak maddenin yüzeyinde ortaya çıkan lazer benek desenini dijital kamera ile kayıt altına almışlardır [40]. Bu benek desenlerinin konstat farkını kullanarak camgöbeği ve macenta rengi arasındaki farklı renk tonlarının tespitini yapmışlardır. Çalışmalarındaki sınıflandırma doğruluğu %55-%88 arasında olmuştur.

Lazer tabanlı olmayan sistemler ile gerçek renk tespitine yönelik yapılan çalışmalar:

Milovanovic ve diğerkleri süt ve süt ürünlerinin renk değerlendirmesi için bilgisayarlı görme sistemi (BGS) kullanmışlardır [41]. Benzer bir şekilde Goni ve diğerkleri de farklı gıda maddelerinin renk tespiti için BGS kullanmışlardır [42]. BGS ile farklı gıda malzemeleri için renk tespiti çalışmaları [43–45]’de mevcuttur. BGS ile yapılan bu çalışmalarda görüntüleme ortamı için kapalı bir kutu içerisinde sabit bir aydınlatma düzeneği ve dijital kamera bulunmaktadır. Bu sistemde elde edilen renk değerlerinin kullanılan ışık kaynağına ve kameraya göre kalibre edilmesi gerekmektedir. Bu çalışmalarda BGS sisteminden elde edilen renk değerleri kolorimetre veya spektrofotometre ile karşılaştırılmaktadır. Spektrofotometreler ve kolorimetreler temas gerektiren ve küçük bir alanın ortalama rengini veren cihazlardır. BGS’ler ise temassız ölçüm alabilmesi ve birden çok noktanın renk bilgisini vermesine rağmen kapalı kutu şeklinde olmalarından dolayı mobil sistemler için kullanımı uygun değildir. Heng ve diğerkleri de kaşmir kumaşının renk ölçümü için BGS kullanmışlardır [46].

Yang ve diğerkleri yansıtıcı renk algılamaya dayalı olarak yaptıkları çalışmada üç renkli RGB LED diyot kullanmışlar ve hedeften yansıyan farklı dalga boylarındaki ışığın yoğunluğunu ölçmek için ise foto diyot kullanmışlardır [47]. Benzer bir şekilde Saracoglu ve diğerkleri de renk tanıma için RGB LED ve fotodiyot kullanmışlardır [48]. Çalışmalarında hedeften yansıyan renk değerlerinin karşılığı olan analog gerilim değerlerini bilgisayarda YSA kullanarak eğitmişler ve analog çıkış değerlerini RGB renk değerlerine dönüştürmüşlerdir. Bu tür sensörlerin kullanımı için materyal ile yakın teması gerekmektedir.

Qui ve diğerkleri mikroskobik hiperspektral görüntüleme sistemine dayalı renk ölçümü yapmışlardır. Çalışmalarında stereo mikroskop, görüntüleme spektrografi ve kameradan oluşan bir düzenek kullanmışlardır [49].

Li ve diğerkleri algılayıcı olarak RGB LED dizisi kullanarak yaptıkları çalışmada aydınlatıcı bir lambadan gelen renk bilgisini RGB LED ile algılamakta ve algıladığı rengi yansıtmaktadır [50].

İnsan cinsiyetinin tespitine yönelik yapılan çalışmalar:

Lazer işaretleri ile cinsiyet tespitine yönelik bir literatüre rastlanmamakla birlikte farklı cihaz ve tekniklerle yapılan çalışmalar aşağıda irdelenmiştir.

Cinsiyet sınıflandırması için çeşitli cihazlar kullanılmaktadır. Bunların bir kısmı temas gerektiren cihazlardır ve pratik kullanımı mümkün gözükmemektedir. Diğer bir tür ise temas gerektirmeyen cihazlardır. Bu cihazların bir kısmı uygun bir kalibrasyon gerektirme, bir kısmı ise ışık koşullarından etkilenmektedir. Kamera ve mikrofonların kullanımı esnasında kişisel veriler de elde edilebilmekte ve kişinin mahrumiyetini etkileyebilmektedir. Cinsiyet tanıma işlemi çoğunlukla yürüyüş modeline göre [51,52], yüz görüntülerine göre [53–55], sese göre [56,57] veya diğer sensörlere [58] göre yapılabilmektedir.

Zhang ve diğerleri cinsiyet tanımlama amacı ile yaptıkları çalışmada RGB-D kamera kullanmışlardır. Çalışmalarında erkekleri ve kadınları birbirinden ayırt etmek için RGB ve derinlik görüntülerinden CNN ile özellik çıkarımı yaptıktan sonra her iki görüntüye ait özellikleri önerdikleri kendi kendine dikkat modülünde birleştirmişler ve ardından sınıflandırma yapmışlardır [59].

Anchal ve diğerleri sismik sensörleri kullanarak cinsiyet sınıflandırması yapmışlardır [52]. Çalışmalarında kadın ve erkek deneklerin yürüyüş esnasında ayaklarından çıkardıkları sesi incelemişlerdir. Bu çalışma için deneyin yapıldığı zeminlere sismik sensörler yerleştirilmiştir. Bales ve diğerleri de akıllı bir binanın zeminine yerleştirilen 212 adet sismik sensörü kullanarak cinsiyet sınıflandırması yapmışlardır [58]. Bu tür çalışmalar yüksek maliyet gerektiren ve kurulum zorlukları bulunan sistemlerdir. Aynı zamanda bu tür sistemler kısıtlı bir alanda çalışmakta ve bakım maliyetleri yüksek olmaktadır.

Qadri ve diğerleri konuşma işaretinden cinsiyet ayrımı üzerine çalışmışlardır [57]. Deneklerden elde ettikleri ses işaretlerinden özellikler çıkartarak cinsiyetin işaret üzerine etkilerini incelemişlerdir.

Nixon ve diğerlerinin kamera kullanarak yaptığı çalışmada, davranış modelinden cinsiyet sınıflandırması yapılmıştır [60]. Çalışmalarında kadınların yürürken kalçalarını, erkelerin ise daha çok omuzlarını salladıklarını öne sürmüşler ve bu davranış farklılıklarından yola çıkarak sınıflandırmanın yapılabileceğini öne sürmüşlerdir.

Kwon ve diğerleri kameradan elde ettikleri iskelet görüntülerine dayalı cinsiyet sınıflandırması yapmışlardır [61]. Çalışmaları için farklı yaş gruplarındaki deneklerden yürüyüş videoları elde etmişlerdir. Kadın ve erkelerin farklı yürüyüş modellerinin olduğu fikrinden yola çıkmışlardır.

Zhang ve diğerleri ise otomatik cinsiyet sınıflandırması için birden fazla açıda bulunan kameralardan elde ettikleri video görüntüsü üzerinden yürüyüşe dayalı cinsiyet sınıflandırması yapmışlardır [62]. Do ve diğerleri birden fazla açıdan elde edilen kamera görüntülerinden yürüyüş özelliklerini kullanarak cinsiyet sınıflandırması yapmışlardır [55]. CASIA B veri tabanını kullanan Russel ve diğerleri ise CNN ile farklı açılardaki görüntülerden yürüyüş modeline dayalı cinsiyet ve yaş grubu sınıflandırması yapmışlardır [63].

Nayak ve diğerleri yüz görüntülerine dayalı cinsiyet sınıflandırmasını önermişlerdir [53]. Dileep ve diğerleri ise yüz görüntülerinden yaş grubu ve cinsiyet tespiti üzerine çalışmışlardır [64]. Çalışmalarında sınıflandırıcı olarak YSA kullanmışlardır. Mustafa ve diğerleri ise kamera görüntülerinden cinsiyet ve yaş tespiti için Resnet ve CNN kullanmışlardır [54].

Cansız nesneler ile canlı bir insan dokusunun ayırt edilmesine yönelik yapılan çalışmalar:

Literatürde canlılık tespiti üzerine yapılan çalışmalara bakıldığında, bu çalışmaların bir kısmı radyo frekansı üzerine yoğunlaşırken bir kısmı ise lazerler üzerine yoğunlaşmıştır. Duvar radarı ile duvarın arkasındaki bir insanın lokalizasyonu ve yaşam belirtileri üzerine çalışmalar bulunmaktadır [65–68]. Bu tür çalışmaların odak noktası insanın nefes alıp vermesi esnasında vücutta oluşan küçük titreşimlerin neden olduğu mikro-dopler karakteristiğinden faydalanmak şeklindedir. Bu tür sistemlerde vücuda bir radyo frekans işareti gönderilmekte ve işaret vücuda ulaştığında solunum/kalp atışı hareketi nedeni ile vücuttaki küçük yer değiştirme bilgileri faz kaydırma işareti olarak geri döndürülmektedir.

LDV ile yapılan bir çalışmada kalbin atması sonucu göğüs duvarında oluşan titreşimler ölçülmüş ve elde edilen sonuçlar EKG ile ilişkilendirilmiştir [69]. Başka bir çalışmada ise kardiyak hızına bağlı olarak boyundaki cilt yüzeyinin titreşimleri üzerine çalışma yapılmıştır [70,71]. Qu ve ekibi ise Pan-Tilt-Zoom (PTZ) kamera ve LDV kullanarak insan sesinin tespiti üzerine çalışma yapmışlardır. Bu çalışmada PTZ kamera ile hareketli insanın tespiti ve ses çıkarımı için hareketli insanın üzerine LDV'nin yönlendirilmesi üzerine odaklanmışlardır [72]. Marchionni ve diğerleri erken doğan çocuklarda yaklaşık 2 m uzaklıktan kalp ve akciğer aktivitelerini ölçmede kablosuz ölçüm tekniği olan LDV kullanmışlardır [73].

Takano ve diğerleri yaptıkları çalışmada ise bir lazer ışık kaynağını deneklerin yanağına yansıtılmışlar ve deneklerde oluşan lazer beneklerini zaman atlatmalı kamera ile 30 sn boyunca kayıt altına almışlardır. Video kayıtlarından deneklerin kalp atış bilgilerini çıkarmışlardır [74].

Ozana ve diğerleri ise çiftlikteki hayvanlar üzerinde yaptıkları çalışmada, hedeflere lazer ışık kaynağı yansıtılmışlar ve hedefteki lazer beneklerini 500 fps hızındaki bir kamera ile kayıt altına almışlardır. Kayıt altına altıkları videodan işaret işleme yöntemleri ile deneklerin kalp atım ve solunum bilgilerini elde etmişlerdir [75].

Atmosferik şartların lazer üzerine etkilerinin araştırılmasına yönelik yapılan çalışmalar:

Lazer ile yapılan hedef tanımlama çalışmalarındaki önemli zorluklardan biri atmosferik ortam şartlarıdır. Güneş ışığı, yağmur, nem, sis ve kar olumsuz atmosferik şartlar arasında sayılabilir. Olumsuz atmosferik şartlar lazer işaretlerinde gürültüye sebep olabilmekte ve yansıyan işaretin yoğunluğunu düşürebilmektedir. Karlı, yağmurlu ve sisli ortamlarda ise lazer ışıkları

hedefin yanı sıra sis, kar ve yağmur taneciklerinden de saçılmakta ve hatalı ölçümlere sebep olabilmektedir. Lazer ile algılama sisteminde bu tür olumsuz etkileri azaltacak çalışmalara ihtiyaç duyulmaktadır.

Rasshofer ve diğerleri yaptıkları çalışmalarda otonom otomobillerde kullanılan LİDAR ile yapılan ölçümlerde güneş, nem, sis, kar, yağmur gibi hava olaylarının olumsuz etkilerini araştırmışlar ve buna ait bir simülasyon yapmışlardır [76]. Yağmur ve sis küçük su parçacıklarından oluşmaktadır. Kar ise farklı kütle yoğunluğuna sahip buz kristalleri olarak modellenmiştir. Çalışmada su damlacıklarının farklı büyüklüklerdeki modellenmesi ile sis ve yağmur modeli çıkarılmıştır. Şiddetli yağmur ve kar zaten düşük olan maksimum algılama aralığının daha da azaltılmasına yol açmaktadır. Çalışmada sisli, yağmurlu ve karlı ortamdaki lazer mesafe algılama değerlerinin gerçek dünya ölçümleri simülasyon ölçümleri ile karşılaştırılmıştır. Yapılan deneysel ve simülasyon çalışmalarında olumsuz hava olaylarının lazer sensörünün ölçüm aralığını düşürdüğünü belirtmişlerdir.

Kijima ve diğerleri sisli ortamlarda darbeli ToF görüntülemenin başarımı üzerine çalışma yapmışlardır. Bu çalışmalarında yapay sisle ilgili çeşitli deneylerde farklı pozlama sürelerine sahip darbeli ToF kamera kullanarak, hedef haricinde sisteki su damlacıklarından yansıyan işaretlerin oluşturduğu gürültüyü gidermeye çalışmışlardır [77]. Benzer bir çalışmada da Muraji ve diğerleri sürekli modda genlik modülasyonu ile çalışan ticari ToF kamerasının sisli ortamlardaki ölçüm doğruluğunu arttırmak için kameranın farklı frekanstaki yanıtlarından faydalanmışlardır [78].

Kutilla ve diğerleri sisin otomotiv Lidar sensörleri üzerindeki olumsuz etkilerini incelemek için olumsuz hava koşullarının trafikteki etkisini ölçmek için kurulan Fransız Cerema laboratuvarında çalışma yapmışlardır [79,80]. Çalışmalarında 905 nm ve 1550 nm dalga boyunda çalışan Lidarların farklı görüş mesafelerine sahip yapay sisli ortamdaki etkilerini araştırmışlardır. Her iki dalga boyunda da alınan işaretin gücünde normal şartlara göre zayıflama olduğunu, ancak daha fazla optik çıkış gücüne sahip ve göze daha az zararlı olan 1550 nm dalga boyunda çalışan Lidarın daha iyi sonuçlar verdiğini belirtmişlerdir.

Heinzler ve diğerleri farklı marka otomotiv Lidar sensörleri için yağmur ve sisin etkisini ölçmeye ve hava durumunu tahmin etmeye yönelik çalışmalar yapmışlardır [81,82]. Hava tahmini için klasik makine öğrenmesi ve derin öğrenme yöntemlerini kullanmışlardır. Cerema laboratuvarında yaptıkları çalışmalarında normal hava koşullarına kıyasla sisli ve yağmurlu havalarda nesnelerden yansıyan ışık yoğunluğunun önemli ölçüde düştüğünü göstermişlerdir. Görüş mesafesinin çok düşük olduğu durumlarda yayalardan yansıyan ışık yoğunluğun tespit edilemediği görülmüştür. Li ve diğerleri Cerema laboratuvarında sisli hava koşullarının ToF Lidarlar üzerindeki etkilerini incelemişlerdir [83]. Çalışmalarında hedeften yansıyan işaretin gücünün sisin damlacık boyutuna, su içeriği miktarına ve hedef nesne üzerinde oluşan ıslak yüzeyin miktarına da bağlı olduğunu bildirmişlerdir.

Nolet ve diğerlerinin sahil kumu üzerinde 350 nm – 2100 nm aralığındaki farklı dalga boylarında yaptıkları çalışmada kuru kumun nemli kuma oranla daha yüksek yansımaya değerleri verdiğini, nemin artmasıyla birlikte tüm dalga boylarında hedeften yansıyan işaretin miktarında da doğrusal olmayan bir azalma olduğunu belirtmişlerdir [84]. Benzer bir çalışmayı da Suchocki ve diğerleri yapı malzemelerinden biri olan yalıtım sıvasının üzerindeki nem tespiti için yapmışlardır [85]. Çalışmalarında pürüzlü yüzeylerden ve nemli yüzeylerden alınan yoğunluk değerlerinin pürüzsüz ve kuru yüzeylere göre azaldığını belirtmişlerdir.

Jin ve diğerleri destek vektör regresyonuna dayalı TLS yoğunluk verilerinden sahil kumunun neminin tahmini üzerine çalışmışlardır [86]. Çalışmalarında 1550 nm lazer dalga boyunda çalışan Lidar kullanmışlardır. Her bir eğitim verisi 1 m²'lik alan içinden alınan çok sayıdaki TLS verisinden oluşmaktadır.

1.3. Problem Çözümleri ve Yönelim Gerekçeleri

Materyal türü tanımlama, gerçek renk tespiti, canlı doku tespiti ve insan cinsiyet tespiti çalışmaları incelendiğinde kameraların yoğun olarak kullanıldığı görülmektedir. Bunun yanı sıra materyal tanımlama çalışmalarında, sürtünmeye dayalı sensörler, materyalin ses ile etkileşimine dayalı yöntemler, yakın temas dayalı spektroskopik yöntemler, materyal ile temastan sonra oluşan titreşimlerin ölçümüne dayalı yöntemler, termal etkinin materyal üzerindeki etkisini kullanan yöntemler ve materyalin radyo işaretleri ile etkileşiminden faydalanan yöntemler de bulunmaktadır. Cinsiyet tanımlama çalışmalarında da kişinin yürürken zeminde oluşturduğu titreşimleri ve kişinin sesini dikkate alan yöntemler de mevcut olmakla birlikte bu tür yöntemlerin çalışabilmesi için çalışılacak zeminde çok sayıda özel ekipmanın kurulumu gerekmektedir [52,58].

Görsel görünüme dayalı materyal türü tanımlama çalışmalarında renk, doku, yansımaya ve geometrik özellikler sıklıkla kullanılmaktadır ve bu çalışmaların halen birçok zorluğu bulunmaktadır. Uygun ortamlarda görüntü alınamadığında bu tür yöntemler başarısız olabilmektedir. Materyal tanımlanmasındaki en büyük zorluklardan biri, farklı malzemelerin benzer görünüme sahip olabilmesidir. Örneğin bir granit, siyah kumaş ve magnet görsel olarak aynı görüntüye sahip olabilmekte ve birbirlerinden ayırt edilmesi oldukça zor olabilmektedir. Bunun yanı sıra baskı makinesinden çıktısı alınmış bir materyal ile gerçek bir materyalin kamera görüntüsü de aynı olabilmektedir. Ayrıca doğal olmayan bir aydınlatma ortamında materyallerin rengi farklı gözükabilmekte ve materyal rengine dayalı çalışmalar başarısızlığa uğrayabilmektedir.

Gerçek renk tespiti çalışmalarında da farklı aydınlatma şartlarında kamera görüntülerinde farklı tonlarda renkler ölçülebilmektedir. Bunun yanı sıra çok aydınlık ortamlarda kamera doygunluğa erişecek ve gerçek rengi yansıtmayacaktır. Karanlık ortamda ise görüntüler tamamen siyah çıkmaktadır. Gün ışığı haricinde farklı renkte aydınlatılan nesnelerin gerçek rengi ise kamera görüntüsünde farklı renkte görüntülenecektir.

Görünüm tabanlı cinsiyet tespit çalışmaları çoğunlukla kişilerin yürüyüş modellerine ve yüz görüntülerine göre yapılmaktadır. Bu tür çalışmalarda kişinin kendini gizleme isteği, kamera çekim açısının uygun olmaması, düşük çözünürlük, görüntünün bulanık olması, yüz ifadesinin tam olarak yakalanamaması problem olmaktadır.

Tez çalışması kapsamında yapılan materyal türü tanımlama, gerçek renk tespiti, canlı doku tespiti ve insan cinsiyet tespiti çalışmalarında yukarıda belirtilen tekniklerin aksine aktif bir ölçüm tekniği kullanılmaktadır. Bu yöntemde hedefe düşük güçlü bir lazer ışığı yansıtılmakta ve hedeften yansıyan lazer işaretleri kayıt altına alınmaktadır. Bu işaretler veri işleme adımlarından sonra yapay zekâ ile eğitilmekte ve istenilen amaca göre çıktı üretilmektedir. Diğer yöntemlerin aksine temassız olan bu yöntem ile 2 m mesafeden uzaktan algılama yapılabilmekte ve aktif ölçüm tekniği kullandığından dolayı ise aydınlatma ortamından kaynaklı problemlerden en az seviyede etkilenmektedir.

1.4. Çalışmanın Katkıları

Literatür incelendiğinde materyal türü tanımlama, gerçek renk tespiti, canlı doku tespiti ve insan cinsiyet tespiti çalışmalarında genellikle kameraların kullanıldığı görülmektedir. Kameraların kullanıldığı sistemlerde ortam ışığı önemli rol oynamaktadır. Düşük aydınlatma koşullarında kamera ile yapılan sistemlerin başarımı düşmektedir. Aydınlatmanın çok düşük olduğu durumlarda veya hiç olmadığı durumlarda ise kameralı sistemler tamamen çalışamaz duruma gelmektedir. Önerilen sistem ile sadece lazer ışığını kullanan aktif bir ölçüm yöntemi sunulmaktadır. Lazer ışığı ile yapılan çalışmanın aydınlatma koşullarından daha az etkilenme potansiyeli bulunmaktadır.

- Tek bir ölçüm noktasına dayalı lazer işareti ve derin öğrenme mimarisi kullanılarak materyal sınıflandırması yapılmıştır.
- Materyal tanımlama ve canlı doku tespiti işlemlerinde ham lazer işaretleri yerine boyutu düşürülmüş lazer işareti kullanılarak daha hızlı bir sınıflandırma zamanı elde edilmiştir.
- Lazer işaretleri kullanılarak farklı türdeki cansız nesneler ile canlı bir insan dokusunun sınıflandırması gerçekleştirilmiştir.
- Sadece bir dalga boyuna sahip lazer kullanılarak 2 m mesafedeki hedefin rengi tek bir ölçüm noktasından temassız olarak tanımlanmıştır.
- Temassız bir şekilde 2 m mesafedeki bir kişinin cinsiyeti tek bir lazer işareti ile tespit edilmiştir.
- Farklı atmosferik şartların (nem, sis, gün ışığı, karanlık ortam) hedef türü tespiti üzerine etkileri ölçülmeye çalışılmıştır.

Çalışmada düşük güçlü lazer işaretleri ile farklı hedef türlerinin tespit edilmesi için önerilen yapay zekâ temelli yaklaşımların hızlı ve yüksek başarımlı sonuçlar üretmesi literatüre katkı sağlamıştır.

1.5. Tezin Organizasyonu

Tez çalışması 9 bölümden oluşmaktadır. Birinci bölümde tezin kapsamı, problemin tanımı, amacı, ortaya konulan çözümler ve yönelim gerekçelerinden bahsedilmiştir. İkinci bölümde lazerler, lazerlerin yapısı, çeşitleri, kullanım alanları hakkında genel bir bilgi verilmiştir. Üçüncü bölümde makine öğrenmesi ve derin öğrenme modelleri hakkında bilgiler verilmiştir. Dördüncü bölümde uzak mesafedeki materyallerin lazer işaretleri ile tanımlanması üzerine yapılan çalışmalar açıklanmıştır. Bu bölümde aynı zamanda tez çalışması kapsamında kurulan deney düzeneği, farklı hedef türlerinden lazer işaretlerinin alınmasını sağlayan elektro optik lazer algılayıcı modülü hakkında bilgiler ve işaret elde etme yöntemi verilmektedir. Tezin beşinci bölümünde lazer işaretleri ile cinsiyet tespiti, altıncı bölümünde canlı/cansız varlıkların uzak mesafeden lazer işaretleri ile sınıflandırılması için yapılan çalışmalara yer verilmiştir. Tezin yedinci bölümünde ise tek bir lazer işareti ile hedefin renginin algılanması üzerine yapılan çalışmalar verilmiştir. Tez çalışmasının sekizinci bölümünde, farklı atmosferik olayların lazer işaretleri ile hedef tanımaya etkisi incelenmiştir. Tez çalışmasının son bölümünde ise tez çalışmasının amaçlarına ne ölçüde ulaşıldığı ve gelecekte yapılabilecek çalışma önerileri anlatılmıştır.

2. LAZERLER

2.1. Işık

Elektromanyetik spektrumun bir parçası olan ışık parçacık ve dalga özellikleri gösteren fotonlardan oluşmaktadır. Fotonlar elektrik ve manyetik alandan oluşmakta ve uzayda elektromanyetik dalga olarak yayılmaktadır. Tek dalga boyuna sahip monokromatik bir elektromanyetik dalganın dalga boyu Denklem 2.1'deki şekilde hesaplanabilir.


$$\lambda = \frac{c}{f} \quad (2.1)$$

Denklem 2.1'deki formülde dalga boyu λ , ışığın boşluktaki hızı c , frekansı ise f ile ifade edilmektedir. Işığın boşluktaki hızı $2,99792458 \times 10^8$ m/s'dir. Işık hem görünür hem de görünmez dalga boylarında olmaktadır. Işığın oluşturan dalga boyları ve sınıflandırmaları Tablo 2.1'de görülmektedir.

Tablo 2.1. Işığın oluşturan dalga boyları ve sınıflandırılması

Işığın Sınıflandırması	Dalga boyu (nm)
Ultraviyole	100 – 380
UV-C	100 – 280
UV-B	280 – 320
UV-A	320 – 380
Görünür	380 – 780
Uzak kırmızı	700 – 800
Yakın kızılötesi	780 – 2500
Kızılötesi	2500 ve üzeri

İnsanlar tarafından algılanan görünür ışığın dalga boyu yaklaşık olarak 380 – 780 nm arasındadır ve elektromanyetik spektrumun çok az bir kısmında yer almaktadır [87,88]. Elektromanyetik spektrumdaki dalga boyları ve görünür ışık tayfı Şekil 2.1'de görülebilir.



Şekil 2.1. Elektromanyetik spektrum ve görünür ışık [89]


2.2. Lazer Işığının Oluşumu

Uyarılmış ışınım yayınımlı ile ışığın yoğunlaştırılması anlamına gelen lazer, ışığın yoğunlaştırılmış bir şekilde elde edilmesi ilkesine dayanmaktadır [90]. Lazerin ilk kuramsal temellerini Albert Einstein 1917 yılında kuantum teorisi ile literatüre kazandırmıştır [91]. İlk çalışan lazer ise aktif ortamında yakut kristali kullanılan ve Maiman tarafından geliştirilen yakut lazeridir [4]. Gelişen teknoloji ile birlikte lazer teknolojisinin kullanımı ticari, endüstriyel, savunma sanayi, tıbbi ve bilimsel uygulamalar için günden güne artış göstermektedir. Hali hazırda lazerler fotoğrafçılık, spektroskopi, veri saklama, holografi ve ameliyatlarda kullanılmaktadır [9].

Lazer ışığı ile normal ışık arasındaki temel fark yüksek enerji seviyesinde (E_2) bulunan elektronların alt enerji seviyesine (E_1) geçme aşamasındaki süreçlerden kaynaklanmaktadır. Atomların veya moleküllerin son yörüngesindeki elektronlar düşük enerji seviyesindeki yörüngede bulunmak istemektedir. E_1 düşük enerji seviyesinde bulunan bir elektron Denklem 2.2’de belirtilen enerji düzeyine sahip bir foton tarafından uyarıldığında, uyarıcı foton enerjisi elektron tarafından soğrulmakta ve elektron E_2 enerji seviyesine çıkmaktadır [89]. Çok kısa bir süre sonra yüksek enerji seviyesinde bulunan bu elektron düşük enerji seviyesine tekrar düşmekte ve bu süreçte dışarı foton yaymaktadır. Bu şekilde uyarılmış bir atomun elektronlarının üst seviyedeki enerji düzeyinden daha alt seviyedeki enerji düzeyine kendiliğinden düşmesi ve dışarı foton yayılması olayına kendiliğinden emisyon denilmektedir [92]. Bu işlem geliş güzel bir zamanlamada olduğu için yayılan fotonların fazları ve yönleri de farklı olmaktadır. Normal ışık kaynakları bu özellikte olup farklı fazlarda ve farklı yönlerde ışık saçmaktadır.


$$E_{foton} = E_2 - E_1 \quad (2.2)$$

Lazerlerde ise bu durum farklı olmaktadır. Yüksek enerji seviyesindeki bir elektrona kendiliğinden emisyon gerçekleşmeden önce Denklem 2.2’de belirtilen enerji düzeyine sahip bir foton ile uyarılması durumunda bu elektron düşük seviyedeki bir enerji düzeyine geçecek ve kendini uyarıcı foton ile aynı fazda, aynı dalga boyunda ve aynı yönde dışarı bir foton daha yayınlayacaktır. Bu olaya ise uyarılmış emisyon denilmektedir. Şekil 2.2’de soğurma, kendiliğinden emisyon ve uyarılmış emisyon tarif edilmektedir.



Şekil 2.2. Elektronların farklı şekillerde uyarılması ve meydana gelen tepkiler a) Soğurma b) Kendiliğinden emisyon c) Uyarılmış emisyon

Lazer ışığının oluşabilmesi için çok sayıda ve sürekli olarak uyarılmış emisyon durumunun gerçekleşmesi gerekmektedir. Elektronlar düşük seviye enerji seviyesinde kalmayı tercih etmektedir. Düşük seviyedeki elektronların sürekli olarak üst seviyedeki enerji seviyesine çıkarılması için başka bir ışık kaynağı veya elektrik enerjisi benzeri bir dış kaynakla uyarılması gerekmektedir. Bu işleme pompalama denilmektedir. Pompalama işlemi ile üst enerji seviyesindeki elektronların sayısının düşük enerji seviyesindeki elektronların sayısından fazla olması sağlanmaktadır. Güçlü bir lazer ışığının elde edilebilmesi için üst seviyedeki elektronların sürekli uyarılması ve bunun sonucunda da aynı özellikte yeni foton salınımlarının sağlanması gerekmektedir. Bunun için ise optik kavite denilen bir mekanizma kullanılmaktadır [90]. Bu mekanizmada bir tanesi ışığı tam olarak yansıtan, bir diğeri ise ışığı belirli bir oranda yansıtan ve birbirine tamamen paralel ayna ikilisi kullanılmaktadır. İki ayna arasına yerleştirilen sistemde elektronları üst enerji seviyesinde sürekli olarak tutmak için pompalama işlemi yapılmaktadır. Yüksek enerji seviyesindeki elektronlar ise birbirine paralel iki ayna arasında gidip gelen fotonlar tarafından uyarılarak foton sayısı artırılmakta ve bu şekilde lazer ışığının gücü de artırılmış olmaktadır. Belirli bir güce ulaşan fotonlar yansıtma oranı daha az olan aynadan geçerek dışarı çıkmaya başlamaktadır. Dışarı çıkan ışıklar aynı fazda, aynı dalga boyunda ve aynı doğrultuda hareket etmektedir. Pompalama mekanizması ile elektronların üst enerji seviyesine geçişine imkân sağlayan atomların bulunduğu yapıya ise aktif ortam denilmektedir. Şekil 2.3'te lazerin temelini oluşturan optik kavite sistemi görülmektedir. Aktif ortam lazerin türüne göre katı, sıvı-boya veya gaz olabilmektedir.



Şekil 2.3. Optik kavite ve pompalama mekanizması ile lazer ışınlarının oluşması

2.3. Lazerin Özellikleri


Güneş tarafından üretilen beyaz ışık birden fazla renkteki ışığın birleşmesinden oluşmaktadır. Beyaz ışık prizma yardımı ile kendini oluşturan renklerine kolaylıkla ayrılabilir. Özel yöntemlerle üretilen lazer ise normal ışıklardan farklı özellikler taşımaktadır. Uyarılmış emisyon sebebiyle lazeri oluşturan fotonlar aynı dalga boyuna sahip olmaktadır. Dalga boyu aynı zamanda ışığın rengini de belirlemektedir. Bu özelliklerinden dolayı lazerler monokromatik özelliktedir ve tek bir renge sahip olmaktadır [93,94]. Lazerin rengi yani

dalga boyu lazerin üretiminde kullanılan aktif ortamın türüne göre değişmektedir. Günümüzde derin ultraviyole ışık bölgesinden başlamak üzere, görünür ışık bölgesi ve uzak kızılötesi ışık bölgesi arasında dalga boylarına sahip lazerler mevcuttur [9,95,96]. Lazerin tek dalga boyuna sahip olması ve farklı özelliklerdeki maddelerle etkileşim biçiminin madde ayak izi oluşturması sebebiyle lazerler uzaktan algılamaya da olanak sağlamaktadır [97,98].

Geleneksel ışık kaynaklarında ışık her yöne doğru yayılmaktadır. Lazer ışınları ise aynı doğrultuda ve birbirine paralel olarak yol almaktadır. Lazerler çıkış noktasından sonra çok az bir sapma ile kilometrelerce yol alabilmektedir. Lazer ışığının bu özelliği doğrusalılık (kolimasyon) olarak bilinmektedir. Doğrusallık özelliğinden dolayı lazerler çok parlak bir ışığa ve ısı gücüne sahip olmakta, parlaklığını ve yoğunluğu kaybetmeden uzun mesafeler boyunca yol almaktadırlar [99]. İhmal edilebilir bu sapmalarından dolayı atmosferik algılamada, ay yüzeyi araştırmalarında kullanım alanı bulunmaktadır.

Lazer ışınlarının açısal sapması çok az miktarda olduğu için optikler yardımı ile lazer ışınları istenilen bir noktaya odaklanılabilmektedir. Optik düzenekler yardımı ile lazer ışığının dalga boyunun çapına kadar odaklanabilen yüksek yoğunluklu lazerler sayesinde, yüksek çözünürlüklü mikroskop, doğrusal olmayan optik ve fotolitografi uygulamaları geliştirilmiştir.

Lazer ışınları aynı doğrultuda hareket ederken, aynı fazda, aynı dalga boyunda ve aynı genliktedirler. Bu özellikleri sebebi ile tutarlılık (koherant) olarak isimlendirilmektedirler. Lazer ışığının genliği herhangi bir zaman diliminde aynı seviyededir. Şekil 2.4’de lazer ve sıradan bir ışık kaynağı arasındaki farklar görülebilmektedir. Lazer ışığının tutarlılık özelliği doppler frekans kayması olarak da adlandırılan hareketli bir nesnenin uzaklığının tespitini mümkün kılmaktadır. Benzer bir uygulama da uzaktaki bir cisme çarpan lazer ışığında oluşan faz farkından mesafe tespitinin yapılmasıdır.



Şekil 2.4. Lazer ve sıradan ışık kaynağı arasındaki farklar

2.4. Lazerlerin Sınıflandırılması

Lazerler darbe genişliği, güç aralığı ve üretildikleri aktif ortam türüne göre farklı sınıflara ayrılmaktadır.

2.4.1. Lazerlerin Darbe Genişliğine Göre Sınıflandırılması

Darbe genişliği lazerlerin yayıldığı süreyi ifade etmektedir. Genel olarak lazerler darbe genişliğine göre iki ana grupta sınıflandırılmaktadır. Sürekli olarak ışık yayan lazerler sürekli dalga lazer olarak anılmaktadır. Bu tür lazerlere diyot lazerler, CO₂ lazerler, Helyum-Neon (*He-Ne*) lazerler örnek verilebilir. Bir diğer lazer türü ise darbeli modda ışınım yapan lazerlerdir. Bu tür lazerler belirli bir süreliğine lazer ışınımı yapmaktadır. Darbeli lazerler kendi içerisinde tek lazer darbesinin süresine göre milisaniye (*ms*), mikro saniye (*μs*), nanosaniye (*ns*), piko saniye (*ps*) ve femto saniye (*fs*) olarak sınıflandırılmaktadır [92,100].

2.4.2. Güç Aralığına Göre Lazerler

Lazerler aynı zamanda üretebildikleri optik güce göre de sınıflandırılmaktadır. Lazerlerin optik gücü lazerin parlaklığı ile ilgili bir kavramdır ve ısı etkisi yaratmaktadır. Yüksek güçteki bir lazer yansıtıldığı yüzeyde yüksek miktarda ısı oluşturacaktır. Bu özelliklerinden dolayı lazerler metal işlemede ve cerrahi operasyonlarda sıklıkla kullanılmaktadır.

Bir lazerin ortalama çıkış gücü genellikle miliWatt (*mW*), watt (*W*) veya kiloWatt (*kW*) birimleriyle belirtilir. Sürekli dalga lazerlerin çıkış gücü zamanla sabitken, darbeli lazerlerin ortalama çıkış gücü darbe enerjisinin ve tekrarlama süresinin bir fonksiyonu olarak tanımlanabilir. Sürekli dalga lazerlerin çıkış gücü genel olarak *mW* ile *100 W* aralığında olmaktadır. Darbeli lazerler sürekli dalga lazerlere oranla çok yüksek çıkış gücüne sahip olabilmektedir [100]. Örneğin *ps* lazerler 10^{13} *W* anlık çıkış gücüne sahip olabilmektedir.

2.4.3. Aktif Ortam Türüne Göre Lazerlerin Sınıflandırılması

İlk lazerin üretilmesinden bu yana farklı türlerde lazerler geliştirilmiştir. Lazerler üretim aşamasında aktif ortamda kullanılan malzemeye göre de sınıflandırılmaktadır. Üretildiği aktif ortama göre lazerler 4 gruba ayrılmaktadır.

Katı Hal Lazerleri

Bu türdeki lazerlerde kullanılan malzemeler normal oda koşullarında katı olmaktadır. Kullanılan aktif ortama genellikle yalıtkan bir dielektrik kristal, cam veya yarıiletken katkı maddesi eklenmesi ile oluşturulmuştur [101]. Bu tür lazerlerin pompalanması için bir flash lambası veya aktif katkı maddesinin üretildiği dalga boyundan daha küçük dalga boylu diğer lazer türleri kullanılmaktadır [102]. Bu lazerler yüksek seviyede çıkış gücü sağlamaktadır. Plastik, seramik gibi metal olmayan malzemelerin işlenmesinde, metal işlemede, lazer yazıcılarda, optik iletim sistemlerinde ve cerrahi uygulamalarda kullanımı mevcuttur [103]. Katkılandığı maddeye göre bu tür lazerlerin dalga boyu aralığı ultraviyole ile orta kızılötesi spektrumunda olabilmektedir. Farklı

miktarlarda çıkış gücü üretebildiklerinden bu lazerler farklı sektörlerde kullanım alanı bulmaktadır. Neodimyum katkılı itriyum alüminyum garnet (Neodymium Yttrium Aluminium Garnet, *Nd:YAG*) lazerler en çok kullanılan katı hal lazer türüdür ve dalga boyu 1064 nm 'dir.

Gaz Lazerler

Bu tür lazerlerde ise aktif ortamda gaz bulunmaktadır. He-Ne lazeri ilk üretilen gaz lazerlerindendir ve dalga boyu 632.8 nm 'dir. He-Ne lazerlerin çıkış gücü mW seviyesinde olmaktadır [104]. $10.6\text{ }\mu\text{m}$ dalga boyuna sahip CO_2 lazerler ise yüksek çıkış gücüne sahiptir. Gaz lazerlerinin gücü mW seviyesinden başlayarak teraWatt seviyelerine kadar çıkabilmektedir [105,106]. Bunların haricinde Argon lazer, Excimer lazer, CO lazer, Zenon lazer, Kripton lazer ve farklı metal türlerinin buharından üretilmiş gaz lazerler de mevcuttur.

Sıvı – Boya Lazerler


Bu tür lazerlerin aktif ortamında sıvılar bulunmaktadır. Bu türdeki lazerlerde sıvı kristal içerisine istenilen dalga boyuna göre belirli bir miktarda boya eklenmektedir. Boya lazerlerde aktif ortam, sıvı içerisine katılan boya maddesidir. Kumarin, Ksanten, Bor-dipirometen, Oksazin katkılı boya lazerleri bulunmaktadır [107]. Dalga boyları kullanılan malzemeye göre geniş bir aralıkta olup $320\text{-}1500\text{ nm}$ arasında olmaktadır [108]. Katı hal ve gaz lazerlerinde bulunmayan dalga boyundaki lazerlerin gerekli olduğu uygulamalarda boya lazerler kullanılmaktadır.

Diyot Lazerler

Bu tür lazerlerde aşırı katkılanmış P-N tipi yarıiletken malzemeler kullanılmakta ve pompalama işlemi için elektrik enerjisinden faydalanılmaktadır. Diyot lazerler küçük boyutlu, düşük maliyetli, geniş dalga boyu spektrumunda ($350\text{ nm} - 55\text{ }\mu\text{m}$) ve $mW - kW$ arasındaki farklı çıkış güçlerinde olmaktadır [98,109,110]. Diyot lazerler projeksiyon, TV, otomobil aydınlatması, fiber optik iletişim, denizaltı kablosuz iletişimi, veri depolama, tıbbi uygulamalar, mesafe ölçme, uzaktan algılama uygulamaları, 3B sensör uygulamaları, hava ve su kalitesinin izlenmesi, kimyasal analiz prosesleri, metal işleme vb. kullanım alanına sahiptir. Diyot lazerler aynı zamanda diğer lazer türlerinin pompalama mekanizmasında da kullanılmaktadır.


Yapısal olarak LED diyotlara benzemektedirler. Aşırı katkılanmış P-N birleşimden oluşmaktadır. İleri yönde besleme voltajı sağladığında üst enerji seviyesinde bulunan elektronların sayısı arttırılmış olunur. Üretim aşamasında karşılıklı iki tarafı kesilerek ve parlatılarak oluşturulan optik yansıtıcı yüzeyler sayesinde optik kavite içerisinde çok sayıda uyarılmış emisyon oluşmaya başlamakta ve belirli bir eşik değerinden sonra lazer ışığı dışarı çıkmaya başlanmaktadır. Diyot lazerlerde aktif bölge P-N birleşimin olduğu bölgededir ve kalınlığı μm seviyesindedir [111,112]. P-N yarı iletkenlerin yanlamasına kesitleri ise aktif bölgeden daha fazla olduğu için oluşan lazer ışınları eliptik bir şekilde olmaktadır. Bu sebeple paralel ışınlar oluşturmak için optik düzenekler

kullanılmaktadır. Şekil 2.5'te TO-Can diyot lazer, TO-Can kılıf içerisindeki yerleşimi ve diyot lazerin yapısı görülmektedir.



Şekil 2.5. a) TO-Can diyot lazer b) TO-Can lazer diyot kesitsel görünümü c) GaAs diyot lazerin yapısı

Diyot lazerlerde dalga boyu kullanılan malzemeye, kırılma indisine ve aktif ortamın boşluk uzunluğuna göre değişmektedir [110]. Diyot lazerlerde yarı iletken olarak Alüminyum (Al), Galyum (Ga), İndiyum (In), Azot (N), Fosfor (P), Arsenik (As) ve Antimon (Sb) elementlerin ikili, üçlü veya dördü olarak farklı oranlarda birbirine katkılanması ile oluşturulan bileşikler kullanılır. Şekil 2.6'da yaygın olarak ticari lazer diyotlarda kullanılan yarıiletken malzemelere göre oluşan dalga boyu spektrumu görülmektedir. Farklı materyallerin birleşimi ile oda sıcaklığında diyot lazerlerin dalga boyları yaklaşık olarak 0.3-3 μm arasında üretilebilmesine rağmen, quantum katlamalı diyot lazerlerde dalga boyu 5,5 μm seviyelerinde olabilmektedir [113].




Şekil 2.6. Diyot lazerlerde kullanılan katkılı yarı iletkenler ve dalga boyu aralıkları [114]

2.5. Diyot Lazer Türleri

Günümüzde üretim şekillerine göre farklı türde lazer diyotlar olmakla birlikte temelde ışığı yayma şekline iki tür lazer diyot bulunmaktadır.

2.5.1. Kenar Yayınımı Diyot Lazerler

Geleneksel diyot lazerlerde birbirine paralel aynasal yapılar oluşturmak için P - N birleşiminin olduğu bölge dikey olarak kesilmekte ve parlatılmaktadır. Bu işlem sonucunda aynasal bölge yan yüzeylerde oluşmaktadır. Biri tamamen parlatılmış, bir diğeri de kısmen parlatılmış birbirine tamamen paralel yapıdaki bu aynasal yapı içerisinde uyarılmış emisyon ile fotonların sayısı sürekli artmaya başlar ve bir süre sonra fotonlar P - N birleşiminin olduğu kenar bölgesinden yayınım yapmaya başlar. Aktif bölgenin boyutu yarı iletkenlerin boyutuna oranla küçük olduğundan oluşan lazer ışınları elips şeklinde olmakta ve paralel bir ışınım için ekstra optiklere ihtiyaç duyulmaktadır. 3 boyutlu görüntüleme vb. uygulamalarda lazer dizilerine ihtiyaç duyulmaktadır. Yapıları sebebiyle kenar yayınımı diyot lazer kullanılarak lazer dizilerinin üretilmesi mümkün olmamaktadır. Şekil 2.7’de kenar yayınımı diyot lazerin yapısı görülmektedir.




Şekil 2.7. a) PN birleşimli diyot lazerlerin aynasal yapı için kesme doğrultuları b) Kenar yayınımı lazerin ışınım şekli

2.5.2. Dikey Boşluklu Yüzey Yayan Lazer Diyotlar

Bu tür lazerler kenar yayınımı diyot lazerlerinin aksine üst yüzeye dik bir şekilde yayınım yapmakta ve dikey kaviteli yüzey ışıması yapan lazer (Vertical Cavity Surface Emitting Laser, VCSEL) olarak adlandırılmaktadır. Bu tür lazerlerde aynasal yapı P - N birleşimin yüzeyine dik bir şekilde üretilmektedir. Üretim aşamasında P - N yüzeyine farklı kırılma indislerinde ve üretilecek lazer ışığının dalga boyuna uygun kalınlıklarda eklemeli olarak üretilmektedirler. Bu şekilde üretilen aynasal yapıya dağıtılmış bragg aynası (Distributed Bragg Reflectors, DBR) denilmektedir. Kenardan yayınım yapan diyot lazerlere oranla VCSEL’ler dairesel çıkış sağlamakta ve üretim maliyetleri düşük olmaktadır [115]. En önemli dezavantajı ise sıcaklıktan önemli derecede etkilenmeleri ve dalga boylarının değişmesidir. İyi bir ışın kalitesi için sabit bir sıcaklıkta tutulmaları gerekmektedir [114]. VCSEL’ler P - N yüzeyine dikey olarak ışınım yaptıklarından binlercesi bir arada üretilerek sensör dizisi haline getirilebilmekte ve 3B görüntüleme uygulamalarında, mobil telefonlarda yüz tanıma, akıllı gözlüklerde, lazer yazıcılarda, fiber optik

iletiřim uygulamalarında kullanım potansiyeli yüksek olmaktadır [116]. řekil 2.8’de tipik bir VCSEL hücresi ve VCSEL dizisi yapıřı görölmektedir.



Şekil 2.8. a) Tipik bir VCSEL hücresi b) VCSEL dizisi

2.6. Lazer Güvenliđi

Lazerler günümüzde farklı kullanım alanlarına sahiptir. Lazerler yüksek yoğunlukta ısı ve ışık üretebildikleri için tehlikeli olabilmektedir. Lazer ışınları bir yüzeye çarptığında veya doğrudan göze tutulduğunda yüksek miktardaki ışık yoğunluğundaki bu ışıklar göz merceđi tarafından retinaya doğru odaklanabilir ve milisaniyeler içerisinde retinada yanıklar oluşturabilir. Lazerler cilde temas etmesi halinde de yanıklara ve kesiklere sebep olabilmektedir. Bu sebeple farklı dalga boyundaki ve farklı optik çıkış gücündeki lazerler, insan göz sađlığı açısından ve oluşabilecek potansiyel tehlikelere göre sınıflandırılmıştır. Bu tehlike sınıflandırmalarında oluşturabilecekleri tehlikeler ve tehlikelerden sakınmak için alınması gereken tedbirler açıklanmıştır. Lazerlerde temelde 4 çeşit tehlike sınıflandırması mevcuttur [102].

CD ve DVD oynatıcı gibi kapalı bir ortamın içinde kullanılan lazerler sınıf 1 lazer olarak anılmakta ve göz için güvenlidirler. Sınıf 1M ise optik cihazlarla lazer ışınına bakılmadıđı sürece güvenli olmaktadır. Sınıf 2 lazerler maksimum 1mW çıkış gücüne sahip olmaktadır ve sınıf 1 lazerler gibi kapalı bir muhafaza içerisinde bulunmamaktadır. 400-700 nm görünür spektral aralıkta ışınım yapan lazerler 0.25 sn gibi kısa bir süreliğine göz ile temasında göz kırpma hareketlerinden dolayı tehlikeli değildir. Düşük güçlü lazer olarak bilinmekte ve lazer işaretçi, barkod okuyucu gibi uygulamalarda kullanılmaktadırlar. Sınıf 2M ise sınıf 2 ile aynı kategoride olup, göze takılan optik cihazlarla kullanılmaması gerekmektedir. Lazer çıkış gücü 1mW’tan yüksek olabilmektedir. Sınıf 3R kategorisindeki lazerler çıkış gücü 5mW’tan aşağıda olmakta ve düşük güçlü lazer kategorisindedir. Bu tür lazerlere dereceli gözlük, teleskop, mikroskop gibi cihazlar ile doğrudan lazere bakılmamalıdır [117]. Bazı lazer işaretçilerinde kullanımı mevcuttur. Sınıf 3B tipi lazerler maksimum 500 mW çıkış gücünde olmaktadır ve doğrudan bakıldığında göze veya bazı durumlarda cilde zarar verebilmektedir. Bu tip lazerler orta güçlü lazerler olarak anılmaktadır. Herhangi bir

yere yansıtıldığında oluşan dağınık yansıma bakıldığında genelde zararlı olmamaktadır. Sınıf 4 lazerler ise yüksek güçlü lazerler kategorisindedir. Bu sınıftaki lazerler göz ve cilt için çok tehlikelidir. Dağınık yansımadan göze gelen ışınlar kalıcı hasarlara sebep olmaktadır. Bu tipteki lazere örnek olarak muhafaza edilmemiş 40W CO₂ lazerler örnek verilebilir. Sınıf 3B ve Sınıf 4 tehlike sınıflarında lazer kullanılırken kullanılan lazerin dalga boyuna uygun koruyucu gözlük ve kıyafetlerin kullanılması gerekmektedir [102]. Sınıf 1 ve Sınıf 2 tipindeki düşük güçlü lazerlerin kullanımında doğrudan lazer ışığına bakılmadığı sürece ek koruyucu ekipman gerekmemektedir. Diğer türdeki düşük güçlü lazerlerde ise optik aletlerin kullanılmaması ve doğrudan lazer ışığına bakılmaması gerekmektedir [118].

2.7. Hedef Tanımlamada Kullanılan Lazer Temelli Cihazlar

Literatürde hedef türü tanımlamada lazerlerin de aktif olarak kullanıldığı farklı çalışma ilkelerine dayalı cihazlar mevcuttur. Bu bölümde hedef tanımlamada kullanılan lazer temelli cihazların temel çalışma prensipleri verilmektedir.

2.7.1. LIDAR Sistemleri

Işık algılama ve mesafe algılama (Light Detection and Ranging, LIDAR) teknolojisi günümüzde haritalama, nesne algılama, engel algılama ve engellerden kaçınma, konum tespiti gibi birçok amaçla kullanılmaktadır. LIDAR teknolojisi temelde ışık ile mesafe algılama sisteminden ve tarama mekanizmasından oluşmaktadır.


Mesafe algılama işlemi için lazer ışık kaynağı modüle edilerek veya modüle edilmeden, darbeleri veya sürekli modda kullanılabilir. Literatürde lazer ışığı kullanılarak yapılan mesafe algılama yöntemlerinde uçuş süresi ve faz farkı tekniklerinin kullanıldığı görülmektedir [119].

Uçuş süresi tekniğinde, darbeleri bir lazer ışık kaynağı hedefe doğru birkaç ns gibi kısa bir süre boyunca yansıtılmakta ve hedeften saçılan lazer ışınları alıcı bir sistem tarafından algılanmaktadır. Bu alıcı sistemin temelinde optik lensler ve yüksek algılama hassasiyetine sahip çıkış foto diyot, PIN foto diyot veya çok pikseli foton sayaçları bulunmaktadır. Sistemde bulunan zamanlama modülü ise lazer ışığının LIDAR sisteminden çıkarak hedefe çarptıktan sonra tekrar LIDAR sisteminde algılandığında aradan geçen süreyi tespit etmektedir. Işığın boşluktaki hızı sabit olduğundan LIDAR ile hedef arasındaki mesafe Denklem 2.3'te belirtildiği gibi hesaplanır.

$$d = \frac{1}{2n} c \Delta_t \quad (2.3)$$

Denklem 2.3'te lazer ışığının sistemden çıkarak tekrar alıcı sistemde algılandığında aradan geçen süre Δ_t , ışığın hızı c , hedef ile sistem arasındaki mesafe d , yayılma ortamının kırılma indisi ise n ile gösterilmektedir. Hava için n değeri yaklaşık olarak 1 kabul edilir. Bu şekilde ışığın


hızından faydalanılarak mesafe tespit edilmesi yöntemine uçuş süresi (ToF) denir. ToF tekniği ile mesafe ölçme işlemi Şekil 2.9’da görülmektedir.



Şekil 2.9. ToF tekniği ile mesafe algılama

Şekil 2.9’da gösterilen ToF tekniği doğrudan ToF tekniği olarak da bilinmektedir. Doğrudan ToF tekniğinde kullanılan lazerin darbe süresi, anlık gücü ve dalga boyu ölçülen mesafenin büyüklüğünü ve doğruluğunu etkilemektedir. Göz güvenliği ve daha fazla çıkış gücü için IR lazerler tercih edilmektedir. 905 nm ve 1550 nm dalga boyundaki lazerlerin kullanımı yaygındır. 1550 nm göz güvenliği açısından daha fazla lazer gücüne izin verirken 905 nm dalga boyu ise daha az su emilim değerlerine sahip olduğundan atmosferik şartlardan daha az etkilenmektedir [120].

Dolaylı ToF mesafe ölçüm tekniği olarak da bilinen faz farkı ile mesafe algılama tekniğinde ise hedefe lazer ışığının frekansına göre daha düşük frekanslardaki genlik modülasyonlu sürekli dalga lazer ışığı gönderilmektedir. Modülasyon işareti genelde sinüs veya kare dalga şeklinde olmaktadır. Işık yoğunluğunun modüle edilerek hedefe yansıtılması sonrasında alıcı devreye tekrar geri dönüş yapan lazer işaretinin frekansı ile referans işareti arasındaki faz farkı hesaplanarak mesafe bulunmaktadır. Faz farkı ile mesafe ölçme tekniği Şekil 2.10’da görülmektedir.



Şekil 2.10. Dolaylı ToF tekniği ile mesafe algılama

Modülasyon frekansı cihazın ölçüm aralığına göre seçilmeli ve dalga boyundan kaynaklanan belirsizliği gidermek için hedefe farklı frekanslarda modüle edilmiş lazer ışareti gönderilmelidir. Faz farkından mesafe tespiti Denklem 2.4.'teki hesaplanabilir.

$$d = \frac{1}{2} c \frac{\Delta\phi}{2\pi f_m} \quad (2.4)$$

Denklem 2.4.'te d hedef ile cihaz arasındaki mesafeyi, $\Delta\phi$ hedeften yansıyan lazer ışareti ile referans ışareti arasında oluşan faz farkını, f_m ise modülasyon frekansını temsil etmektedir.

LIDAR sistemlerin en önemli özelliklerinden birisi hedefin birden çok noktasından ölçüm alabilmesidir. Bu işlem için farklı türlerde tarama mekanizması kullanılmaktadır. Tarama sistemi kullanılmayan LIDAR sistemi bir boyutta (1B) çalışarak klasik lazer metre işlevi görecektir. Tarama sistemleri yardımı ile Lidarlar iki boyutlu (2B) veya üç boyutlu olarak çalışabilmektedir. 2B Lidarlar sadece yatay düzlemde bilgi toplarken, 3B Lidarlar ise yatay ve dikey düzlemde bilgi toplama özelliğine sahiptir. 2B Lidarlarda tarama sistemi olarak tek bir galvanometre, poligon ayna veya parabolik ayna kullanılırken 3B Lidarlarda ise ikili galvanometre, elektromekanik tarama sistemleri, mikro elektromekanik sistem (Micro Electro Mechanical Systems, MEMS) aynaları ve 3B katı hal tarama sistemleri kullanılmaktadır [121]. Lidarlardan 2B veya 3B olarak elde edilen veriler nokta bulutuna dönüştürülerek yaya tanıma, otonom sürüş, nesne tanıma benzeri uygulamalarda kullanılmaktadır.

Her iki ölçüm tekniğinde de kullanılan algılayıcı sistemler hedeften yansıyan lazer ışığının yoğunluğunu temsilen bir sayısal değer verebilmektedir. Bu temsili değer kullanılan lazerin dalga boyuna, çıkış gücüne, kullanılan algılayıcı sisteme, cihazda kullanılan düzeltme katsayılarına ve sistemde kullanılan analog dijital dönüştürücünün (Analog to Digital Converter, ADC) konfigürasyonuna göre değişebilmekte ve cihazdan cihaza da değişkenlik göstermektedir. Ticari olarak üretilen bazı LIDAR sistemlerinde bu değerler kullanıcıların kullanımına sunulabilmektedir.

LIDAR Çeşitleri

Kullanıldıkları yere göre LIDAR sistemleri hava LIDAR sistemleri, yersel lazer tarama ve mobil LIDAR sistemleri olmak üzere üç gruba ayrılabilir.

Airbone LIDAR olarak da bilinen hava LIDAR sistemleri bir hava aracına bağlı olarak çalışır. Hassas ölçümlerin gerçekleştirilmesi için üzerinde atalet ölçüm birimi (Inertial Measurement Unit, IMU) ve GPS cihazı bulunur. Havadan yere doğru 2B ölçümler alabilen bu tür Lidarların ormancılık, tarım, harita, enerji ve inşaat sektörlerinde kullanımı bulunmaktadır.

Benzer bir şekilde mobil LIDAR sistemleri de hareketli bir platform üzerine entegre edilerek kullanılmaktadır. Mobil LIDAR sistemlerine kamera, IMU, GPS birimleri de dahil edilerek elde edilen veriler 3 boyutlu nokta bulutları haline getirilmektedir. Mobil Lidarların otonom araçlarda ve sürücü destek sistemleri benzeri alanlarda kullanımı mevcuttur.


Yersel lazer tarama sistemleri karasal lazer sistemleri olarak da bilinmektedir. TLS sistemlerinde dahili olarak RGB kamera, IMU ve GPS bulunmaktadır. Arazi veya peyzaj haritalama işlemleri için sıklıkla kullanılan TLS, yapısındaki tarama sistemi yardımı ile çalışma aralığında bulunan hedeflere lazer ışığı yayarak mesafe tespiti yapmakta ve her bir noktanın mesafe bilgisinin yanında açısal konumunu da kutupsal koordinatlarla cihaza kaydetmektedir. Sonraki aşamada harici bir yazılım yardımı ile taranan kutupsal koordinattaki veriler X, Y ve Z koordinat sisteminde 3B nokta bulutu olarak kaydedilmektedir. TLS cihazlarının açısal çözünürlüğü $0,009^{\circ}$ - $0,015^{\circ}$ arasında olabilmektedir. TLS cihazı dakikalar içerisinde hedeften binlerce lazer ölçüm örneği alabilmektedir. Bazı ticari TLS cihazları mesafe bilgisinin yanında, hedeften yansıyan lazer ışık yoğunluğuna benzer sayısal değerleri de kaydetmeye izin vermektedir. TLS cihazları konfigürasyonlarına bağlı olarak mesafe aralığına göre hedefe gönderilen lazer ışığının gücünü arttırabilmektedir. Bu durum elde edilen yoğunluk verilerinin cihaza bağlı olarak hatalı olmasına sebep olacaktır ve bu verilerin düzeltilmesi gerekecektir [122] . Ticari olarak bulunan çoğu TLS sisteminde taranan alanların görüntüleri aynı zamanda RGB kamera tarafından kaydedilerek uçuş tekniğine göre elde edilen mesafe bilgileri RGB renk bilgileri ile birlikte kullanılarak fotogerçekçi 3B görüntüler elde edilebilmektedir. Şekil 2.11'de literatürde de sıklıkla kullanılan Faro Focus lazer tarayıcı, bir mekânın RGB görüntüsü ve TLS ile taranan mekândan yansıyan yoğunluk verilerinden oluşturulmuş 3B nokta bulutu görülmektedir.



Şekil 2.11.a) Faro Focus lazer tarayıcı cihazı b) Bir dış mekânın RGB görüntüsü c) Faro Focus cihazı ile taranan mekândan yansıyan yoğunluk verilerinden oluşturulmuş 3B nokta bulutu [123,124]


2.7.2. ToF Kameralar

Uçuş süresi kamerası olarak bilinen ToF kameralar, kamerada bulunan sensörün görüş alanı içerisinde bulunan nesnelerden yansıyan işaretlerden mesafe tespiti yaparak çalışmaktadır. VCSEL gibi dikey boşluklu lazer sistemi kullanan bu kameralar hedefe modüle edilmiş darbeli veya sürekli dalga lazer ışığı göndermekte ve hedeften yansıyan lazer ışıkları kamerada bulunan sensörler yardımı ile algılanarak mesafe tespiti yapılmaktadır. Şekil 2.12'de ToF kameraların çalışma prensibi görülmektedir.



Şekil 2.12. ToF kameranın çalışma prensibi


Bu tür kameraların çoğunda RGB kamera mevcut olduğundan sahnenin RGB görüntüleri ve derinlik bilgileri aynı anda kaydedilebilmektedir. RGB kamera barındıran ToF kameralar RGB-D kamera olarak da adlandırılmaktadır. Hareketli bir tarama sistemi bulunmayan ToF kameralarda cihazın imkân tanıdığı görüş alanındaki görüntüler 3B olarak alınabilmektedir. Göz sağlığı ve güneş ışınlarının etkisinden kaçınmak için genellikle yakın kızılötesi ışınları kullanılmaktadır. Bu tür kameraların dezavantajı birden çok noktaya aynı anda lazer ışıklarının gönderilmesinden dolayı artan güç tüketimidir ve bu sebeple RGB kameralara oranla fiziksel boyutları büyük olmaktadır. Ölçülen mesafe aralığı hedefe gönderilen lazer ışınlarının gücüyle de orantılı olduğundan, düşük güçte aydınlatılan nesnelerden kamera sensörüne zayıf işaretler dönüş yapacağından hatalı ölçümlere sebep olacaktır. Hatalı ölçümlerden sakınmak ve güç tüketimini optimize etmek amacı ile genel olarak 4 metreye kadar ölçüm yapan kameralar mevcuttur. ToF kameralardaki diğer bir dezavantaj ise düşük çözünürlük ve düşük görüş açısına sahip olmalarıdır. Örneğin PMD Flexx2 ToF kamera 224x172 @ 90fps piksel çözünürlüğe ve 56 x 44 ° görüş alanına sahip iken oyun sektörü için geliştirilen ve bilimsel çalışmalarda da kendine yer bulan Kinect V2 kamera ise 512 x 424 @ 30fps piksel çözünürlüğe ve 70.6 x 60 ° görüş alanına sahiptir [125,126] . Şekil 2.13’de PMD Flexx2 ve Kinect v2 ToF kamera görülmektedir.



Şekil 2.13. a) PMD Flexx2 ToF kamera b) Kinect v2 RGB-D ToF kamera

2.7.3. İnterferometriye Dayalı Sistemler

İnterferometreler ışıktaki girişimin etkisini kullanan optik cihazlardır. Geleneksel Michelson interferometre tabanlı lazer titreşim ölçerleri ile kalp atışları, nefes alıp verme esnasında ciltte oluşan çok küçük miktardaki değişimler gibi hedefe ait çok küçük miktardaki titreşimler ölçülebilmektedir [8,127–132]. Şekil 2.14’te de görülebileceği üzere lazer ışık kaynağından çıkan ışın, ışın bölücüde referans (1) ve ölçüm (2) ışını olarak ikiye ayrılmaktadır. Aynadan ve hedeften yansıyan ışınlar foto dedektöre yansımaktadır. Bu şekilde dedektöre yansıyan işaretlerin işlenmesi ile hedefteki en ufak titreşimler tespit edilebilmektedir [133]. Bu teknik genellikle çok kararlı bir optik kurulum gerektirdiğinden ticari sistemlerde sıklıkla kullanılmamaktadır. Ayrıca bu ölçümler için laboratuvar ortamı gerekmektedir.




Şekil 2.14. Lazer interferometrenin çalışma prensibi [134,135]

Hedefteki titreşimleri ölçmede kullanılan bir diğer ölçüm tekniği ise lazer doppler vibrometresidir. LDV mekanik, sivil, otomotiv, havacılık, üretim ve biyomedikal mühendisliği dâhil birçok alanda yüzey titreşimlerinin temassız ölçümü için kullanılan bir tekniktir. LDV’de lazer ışını bir yüzey üzerindeki hedef konuma yönlendirilmekte ve lazer ışınının yönündeki yüzeyin yer değiştirmesi ve / veya hızı doppler efekti ve interferometri ilkeleri aracılığıyla ölçülmektedir [136].


Doppler etkisi kısaca dalga özelliği gösteren herhangi bir fiziksel varlığın frekans ve dalga boyunun hareketli (yakınlaşan veya uzaklaşan) bir gözlemci tarafından farklı zaman veya konumlarda farklı algılanması olayıdır. Bu ise frekansın değişmesi (kayma) ile olmaktadır. Bu frekans kayması gözlemci ile dalga kaynağı arasındaki hareket hızı ile orantılıdır. Klasik bir interferometrede iki lazer ışını birleştiğinde, ortaya çıkan yoğunluk, iki ışının yol uzunluklarındaki farka bağlı olan bir bileşene sahiptir. İki lazer ışınından birine referans, diğerine ölçüm ışını denilmektedir. LDV ile yaklaşık 30 metreye kadar ölçümler yapılabilir. Lazer ışını

genellikle 633 nm dalga boylu, düşük güçlü bir lazerdir. Şekil 2.15'te LDV'nin çalışma prensibi gösterilmektedir. Opto elektronik konfigürasyona bağlı olarak titreşimler 30 m / s'yi aşan hızlar ile ölçülebilmektedir [136]. Tek nokta (LDV), tarama (Scanning Laser Doppler Vibrometer, SLDV) veya 3 boyutlu tarama (3D Scanning Laser Doppler Vibrometer, 3D-SLDV) sistemleri ticari olarak bulunmaktadır. Tek nokta vibrometreleri, bir yüzey üzerindeki noktanın hızını lazer ışığının yönünde ölçmektedir.



Şekil 2.15. Lazer dopler vibrometrenin çalışma prensibi

Lazer radar görüntüleyicileri ile elde edilen mesafe bilgileri işlenerek hedeflerin tanımlanması, sınıflandırılması ve hedefin konum tespiti yapılabilmektedir. Bir boyutlu LDV işaretleri uzun mesafe lazer radar sistemlerinde kullanıldığında lazer ışını hedefin belirli bir noktasını ölçmekte ve uzamsal olarak çözülmemiş bir boyutlu işaretler elde edilmektedir. Elde edilen veriler lazer ışınının yansıtıldığı bölgeye ve yansıma açısına bağlı olmaktadır. Bu sebeple sistemden toplanan işaretin karakteristik özellikleri de konuma göre değişecektir. Tek boyutlu lazer sistemi hedef üzerinde taranarak iki boyutlu görüntüler oluşturulabilmekte ve uzak mesafedeki hedefin görüntüsü hakkında bilgi sahibi olunabilmektedir. Şekil 2.16'da küçük bir kamyonetten 1B lazer radarı ile elde edilen işaret ve 2B lazer radarı ile elde edilen görüntü görülmektedir. 2B görüntülerde tarama işlemi yapıldığından dolayı hedefin görüntüsünü oluşturabilmek için titreşim işareti verilerinin yanında açısall bilgileri de alınmalı ve bu bilgilere göre görüntü oluşturulmalıdır.



Şekil 2.16. 1B ve 2B titreşim sonuçları [137]


Lazer radarları sayesinde birkaç km uzaklıktaki bir hedefin durumu tespit edilebilmektedir. Lutzmann ve diğerlerin yaptığı çalışmada termal kamerada yalnızca iki adet sıcak nokta olarak görülen hedeflere lazer ışığı yansıtılmış ve hedeflerin frekans spektrumları birbirinden oldukça farklı çıkmıştır. Bu hedeflerden biri ısıtılmış metal kutu diğeri ise rölantide çalışan bir kamyonettir [137]. Aynı çalışma kapsamında taramalı lazer ışınları kamuflajın altına gizlenmiş bir kamyonete işaret ettirilmiş ve kamuflajdaki açıklıklardan dolayı hedef hakkında bilgi sahibi olmuşlardır.



3. YAPAY ZEKA


Hedef tanımlama sistemlerinde kamera gibi bir görüntüleme sistemi, farklı türdeki sensörler veya farklı çalışma ilkelerine sahip lazer sistemlerinden oluşan bir sensör ile hedef hakkında tanımlayıcı bilgiler elde edilerek hedef türünün tespiti yapılmaktadır. Hedef türü tespitinde yaygın olarak yapay zekanın alt dalı olan makine öğrenmesi ve derin öğrenme mimarileri kullanılmaktadır. Yapay zekâ ile bilgisayar veya diğer makinelerin, insan ve doğadaki diğer varlıkların akıllı davranışlarını taklit ederek farklı alanlardaki karmaşık problemleri çözmesi amaçlanmaktadır. Bu amaç çerçevesinde yapay zekanın zeki varlıklar gibi öğrenme, akıl yürütme, iletişim kurma, algılama ve karar verme yeteneklerine sahip olması beklenmektedir.

Yapay zekanın bir alt dalı olan makine öğrenimi tekniklerinde çözülmek istenen probleme uygun olarak eldeki mevcut verilerden bazı özellikler çıkartılmakta, sistem eğitilmekte ve sonrasında sınıflandırma veya regresyon analizi yapılmaktadır. Kısaca makine öğrenimi algoritmaları, çözümleri istenen problem ile ilgili veriler arasındaki ilişkileri öğrenmekte ve sonrasında kendisine verilen yeni verileri kullanarak sonuçlar üretmektedir. Makine öğrenmesi örnek verileri veya geçmiş deneyimleri kullanarak belirlenen bir başarımlar kriterlerine göre çıkarımlar yapmaktadır [138]. Geleneksel makine öğrenmesi yöntemlerinin veriyi işleme yaklaşımı genel olarak 4 adımdan oluşmaktadır. Bu adımlar veri hazırlama ve ön işleme, özellik çıkarma, modelin eğitimi ve modelin değerlendirilmesi şeklindedir. Veri hazırlama ve ön işleme adımlarında; yapılan çalışmaya göre değişebilen bir veri kaynağından ham verilerin elde edilmesi sonrası eksik verilerin giderilmesi, varsa verilerden gürültülerin giderilmesi, kullanılacak veri türüne göre dalgacık dönüşümü, hızlı Fourier dönüşümü (FFT) gibi veri dönüştürme işlemleri yapılmaktadır. Veriler çözülmesi istenen probleme göre ses kayıtlarından, titreşim bilgilerinden, konum bilgilerinden, fotoğraflardan, video kayıtlarından, derinlik bilgilerinden, yansıma bilgilerinden, renk değerlerinden veya daha farklı türdeki bilgilerden oluşabilmektedir. Veri hazırlama ve ön işleme adımlarından sonra çözülecek probleme uygun olarak ham verilerden özellikler çıkarılmakta veya seçme işlemi yapılmaktadır. Ham verilerden özellik çıkarımı sonrası seçilen makine öğrenimi algoritmasının eğitimi gerçekleştirilmektedir. Eğitim sürecinden sonra modelin başarımları değerlendirilmekte ve sistem çıktısı gerçekleştirilmektedir. Şekil 3.1’de geleneksel makine öğrenmesi yöntemlerinin veriyi işleme yaklaşımı görülmektedir.



Şekil 3.1. Geleneksel makine öğrenmesi yöntemlerinin veri işleme yaklaşımları

Son yıllarda popüler olan derin öğrenme ise makine öğrenmesi algoritmalarından biri olan yapay sinir ağlarının bir çeşididir. Derin öğrenme nesne tanıma [139–141], görüntü bölütleme [142,143], konuşma tanıma [144,145], makine çevirisi [146,147], doğal dil işleme [148–150], ilaç keşfi [151] ve benzeri birçok alanda kullanılmaktadır. YSA ve diğer geleneksel makine öğrenmesi algoritmalarındaki en önemli adım ham verilerden özelliklerin çıkarılmasıdır [152]. Derin öğrenme ağlarının ortaya çıkması ile bu özelliklerin çıkartılmasına gerek kalmamaktadır. Derin öğrenme ağları, yapısı gereği kendisine verilen ham verilerden öznelilikler çıkarabilmekte ve elde ettiği bu önemli verileri bir sonraki katmanına giriş olarak aktarmaktadır [153]. Bu önemli avantaj yüksek işlem maliyetlerine sebep olmaktadır. Teknolojideki gelişmelere paralel olarak grafik kartlarında da hesaplamaların yapılabilmesi ile bu problemin üstesinden gelinmeye başlanmıştır. Yüksek oranda veri işleme ve hesaplamaların olduğu alanlarda derin öğrenme mimarileri başarılı sonuçlar sunmaktadır. Şekil 3.2’de derin öğrenme algoritmalarının veri işleme yaklaşımı görülmektedir.



Şekil 3.2. Derin öğrenme yaklaşımları

Geleneksel makine öğrenmesi ve derin öğrenme mimarileri denetimli ve denetimsiz öğrenme modelleri olmak üzere iki ana kategoriye ayrılmaktadır. Denetimli öğrenmede sisteme girdi olarak uygulanan her bir veri grubu için çıkışta olması gereken değerler önceden belirlenmektedir. Bu işlem için oluşturulan verilere etiketli veri denilmektedir. Problemin türüne ve verilerin miktarına göre etiketli veri oluşturmak uzun bir süreçten oluşabilmektedir. Denetimli öğrenmede eğitim aşamasında etiketli veriler analiz edilerek giriş ile çıkış değerleri arasındaki ilişkiler tespit edilmeye çalışılmaktadır. Test aşamasında ise çıkış değeri bilinen ve daha önceden sisteme girilmemiş yeni giriş değerleri kullanılarak eğitilen modelin başarımı kontrol edilmektedir. Denetimli öğrenme sınıflandırma uygulamalarında sıklıkla kullanılmaktadır [154]. Etiketli veriler oluşturmak yerine hangi tür etiketlerin verileri daha iyi açıkladığını tespit etmek istenildiğinde denetimli öğrenme modeli yerine denetimsiz öğrenme modeli kullanılmaktadır. Bu algoritma ile veriler otomatik olarak gruplara ayrılmakta ve benzer verilere sahip gruplara aynı çıktı etiketi atanmaktadır [155]. Başka bir deyişle birbiri ile ilişkili veriler sistem tarafından analiz edilerek verilerin anlamlı gruplara bölünmesi sağlanmaktadır. Denetimsiz öğrenmede veriler etiketsiz olduğundan elde edilen sonuçların doğruluğunun değerlendirilmesi yerine sonuçlar uzman kişilerce incelenebilmektedir. Denetimsiz öğrenmeye anomali tespiti örnek olarak verilebilir.

Geleneksel makine öğrenmesi ve derin öğrenme algoritmalarının birbirleri ile karşılaştırmaları aşağıda verilmiştir.

- Derin öğrenme mimarilerinde veri miktarı arttıkça veriler arasındaki ilişkiler daha iyi öğrenilmekte ve sistemin başarımı artmaktadır. Geleneksel makine öğrenmesinde ise belirli bir miktarda verinin olması yeterli olabilmektedir.
- Derin öğrenme mimarileri işledikleri büyük miktardaki veri miktarı ve yoğun matematiksel hesaplamalar sebebi ile geleneksel makine öğrenmesi algoritmalarına oranla daha çok işlem gücüne ihtiyaç duymaktadır. Bu amaçla yüksek hızda çalışan grafik işlemciler (Graphics Processing Unit, GPU) kullanılmaktadır. Geleneksel makine öğrenmesi algoritmaları ise daha kısıtlı mikro işlemciler veya mikro denetleyiciler üzerinde de çalışabilmektedir.
- Ham verilerdeki karmaşık ilişkilerin çözülmesi ve öğrenme algoritmalarının daha performanslı çalışmasını sağlamak için ham verilerden özelliklerin çıkartılmasına ihtiyaç duyulmaktadır. Özellik çıkarma işlemi zaman alan bir süreçtir ve uzmanlık gerektirmektedir [156]. Çoğu geleneksel makine öğrenmesinin başarımı çıkarılan özelliklerin doğruluğuna bağlı olmaktadır. Derin öğrenme algoritmalarında ise özellik çıkarma süreçlerine genel olarak ihtiyaç duyulmamaktadır.
- Yüksek miktardaki veri ve yoğun matematiksel işlemler sebebi ile derin öğrenme mimarilerinin eğitim süreçleri geleneksel makine öğrenmesi algoritmalarına göre daha uzun sürmektedir. Bazı durumlarda eğitim günlerce hatta haftalarca

sürelebilmektedir. Geleneksel makine öğrenmesi algoritmalarında ise eğitim birkaç dakika ile birkaç saat arasında olabilmektedir. Test süreçleri ise makine öğrenme algoritmalarına benzer şekilde hızlı olmaktadır.

Geleneksel makine öğrenmesi algoritmalarına KNN, DVM, NB, KA, doğrusal ayırma analizi (DAA) ve YSA örnek verilebilir. Derin öğrenme algoritmalarına derin sinir ağları (Deep Neural Networks, DNN), Boltzmann Makineleri (BM), kısıtlı boltzmann makinesi (Restricted Boltzmann Machine, RBM), derin inanç ağları (Deep Belief Networks, DBN), oto-kodlayıcılar (Auto-Encoders, AE), CNN, tekrarlayan sinir ağları (Recurrent Neural Networks, RNN), uzun kısa bellek ağları (Long Short-Term Memory, LSTM), nöral devre politikaları (Neural Circuit Policies, NCP) örnek verilebilir.


Bu bölümde hedef tanımlama sistemlerinde sıklıkla kullanılan ve bu tez çalışmasında da mevcut çalışmalarla karşılaştırma amaçlı olarak kullanılan makine öğrenimi teknikleri ve derin öğrenme mimarileri hakkında bilgiler verilmektedir.

3.1. Makine Öğrenmesi Algoritmaları

3.1.1. K-En Yakın Komşu

K-En yakın komşu algoritması uygulaması basit ve makine öğrenmesinde sıklıkla kullanılan algoritmalarından biridir. KNN algoritması, bir veri kümesi içindeki örneklerin genellikle benzer özelliklere sahip diğer örneklerin yakınında olacağı ilkesine dayanmaktadır [157]. Bu yöntemde herhangi bir eğitim süreci gerekmemekle beraber, test için kendisine verilen bir veri için daha önceden algoritmaya sunulan etiketli tüm veriler ile arasındaki mesafe hesaplanmakta ve en yakın komşuluğa sahip olan sınıfa dahil edilmektedir. Bu yöntemde K sayısı genelde tek sayılardan seçilmektedir. K sayısı 1 olduğunda verinin en yakın olduğu komşu sınıfı tespit edilir ve bu durumda algoritma en yakın komşu algoritması olarak isimlendirilir. K sayısının birden fazla olduğu durumlarda ise, K tane en yakın komşu veri tespit edilmekte ve test verisi sayıca en fazla komşu veri sınıfına dahil edilmektedir. Şekil 3.3'te görülebileceği üzere 2 boyutlu bir özelliğe sahip elemanlardan oluşan 2 sınıflı bir problemde, sisteme girilen yeni bir elemanın K komşuluk sayısı 3 seçildiği durumda hesaplanan komşuluklar gösterilmektedir. Böyle bir durumda sisteme sunulan yeni elemanın sınıf 2 kategorisindeki elemanlara en yakın komşuluk sayısı daha fazla olduğundan, yeni eleman sınıf 2 kategorisine dahil edilecektir.


KNN algoritmasında test verisi ile eğitim verileri arasındaki mesafeleri hesaplamak için öklid, manhattan, minkowski, euclidean vb. yöntemler kullanılmaktadır. KNN algoritmasında K sayısının seçimi probleme göre belirlenmeli, çok yüksek veya çok düşük olduğu durumlarda başarı oranı düşebilmektedir. Bu algoritmada sınıflandırma için bütün veriler tarandığı için büyük miktarda veri içeren uygulamalarda hesaplama maliyeti yüksek olabilmektedir [158,159].



Şekil 3.3. $K=3$ olduğunda oluşan komşuluklar

3.1.2. Destek Vektör Makineleri

Denetimli öğrenme algoritmalarından biri olan destek vektör makineleri regresyon ve sınıflandırma problemlerinde sıklıkla kullanılmaktadır [156]. DVM algoritması iki sınıfa ait verileri birbirinden ayırmak için bir karar fonksiyonunun belirlenmesi esasına dayanmaktadır. Bu karar fonksiyonu kullanılarak eğitim verisindeki sınıfları birbirinden ayıracak bir hiper düzlem belirlenmektedir [160]. Şekil 3.4.a’da görülebileceği üzere X_1 ve X_2 özelliklerinden oluşan 2 sınıflı eğitim verisini birbirinden ayıracak birden fazla hiper düzlem oluşturulabilmektedir. DVM’deki ana amaç belirlenen hiper düzlemin kendisine yakın veri noktalarından maksimum derecede uzakta seçilmesidir. Şekil 3.4.b’ de 2 sınıflı veriyi birbirinden doğrusal olarak ayırabilen hiper düzlem görülebilir.



Şekil 3.4. DVM ile sınıflandırma örneği a) 2 sınıflı birbirinden ayıran hiper düzlemler b) DVM ile 2 sınıflı birbirinden ayıran hiper düzlem Destek vektörleri hiper düzleme paralel ve eşit uzaklıkta olan kesikli çizgilerin üzerinde yer almaktadır

Hiper düzleme en yakın veri noktalarına destek vektörleri, hiper düzlem ile destek vektörleri arasındaki uzaklığa ise marjın denilmektedir. DVM ile oluşturulan maksimum aralıktaki hiper düzlem eğitimde ezberleme riskini en aza indirmekte ve sınıflandırıcının genelleme yapma başarımının arttırmaktadır. DVM’de doğrusal olarak ayıramayan veriler için sıklıkla polinom,

radyal tabanlı fonksiyon, Pearson VII fonksiyonu, normalleştirilmiş polinom vb. çekirdekler (kernel) kullanılmaktadır [160–164]. DVM’ler başlangıçta ikili sınıflandırma için geliştirilmiş, fakat ilerleyen zamanlarda çoklu sınıflandırma problemlerine uyarlanmıştır [165].

3.1.3. Naive Bayes

Olasılık tabanlı bir makine öğrenimi yaklaşımı olan naive bayes, istatistikte kullanılan bayes teoremine dayalı olarak sınıflandırma problemlerinde kullanılmaktadır [166]. NB, sınıflandırılacak verilerdeki özelliklerin birbirinden bağımsız olduğunu varsayarak her bir özelliğin sınıflandırmaya olan etkisinin olasılığını hesaplamaktadır [167]. Örneğin bir meyve turuncu, yuvarlak, tatlı ve yaklaşık çapı 9 cm ise portakal olarak kabul edilmektedir. NB, olasılık hesaplamasında bağımsız olarak katkı sağlayan renk, şekil, tat ve büyüklük kriterlerini dikkate almaktadır. Örnek verilecek olunursa bir meyve turuncu ise portakal olma olasılığı %70, yuvarlaksa portakal olma olasılığı %40, meyvenin çapı 9 cm’ye yakın ise portakal olma olasılığı %50, tatlı ise portakal olma olasılığı %65’tir. Belirtilen bu özellikler birbirinden bağımsız olarak karar vermeye katkı sağladığından dolayı bu sınıflandırıcı NB olarak sınıflandırılmaktadır. NB sınıflandırıcıda eğitim verilerindeki birbiri ile ilişkili özelliklerin eğitim aşamasında kullanılması durumunda bu özelliklerin sonuç üzerindeki etkisi fazlaca olacağından, birbiri ile ilişkili özelliklerin eğitim verilerinde kullanılmaması NB sınıflandırıcının başarımının arttıracaktır. Bayes algoritmasının formülü denklem 3.1’de verilmiştir.

$$P(y|x) = \frac{P(x|y)P(y)}{P(x)} \quad (3.1)$$

Denklem 3.1’de $P(y|x)$ eğitim veri kümesi içindeki x özellik değeri için y sınıfının gerçekleşme olasılığını, $P(x|y)$ y sınıfı için x özellik değerinin gerçekleşme olasılığını, $P(y)$ y sınıfının gerçekleşme olasılığını, $P(x)$ x özellik değerinin gerçekleşme olasılığını göstermektedir. Sınıf sayısı i adet olan bir veri kümesinde n adet özellik olduğunda bayes teoremi denklem 3.2’deki gibi yazılabilir.

$$P(y_i|x_1, \dots, x_n) = \frac{P(x_1|y_i)P(x_2|y_i) \dots P(x_n|y_i)P(y_i)}{P(x_1)P(x_2) \dots P(x_n)} \quad (3.2)$$

Bir problemin çözümüne yönelik veri kümesinde denklem 3.2’de paydada bulunan veriler sabit olacağından bu eşitlik denklem 3.3’teki gibi sadeleştirilebilir.

$$P(y_i|x_1, \dots, x_n) \propto P(x_1|y_i)P(x_2|y_i) \dots P(x_n|y_i)P(y_i) \quad (3.3)$$


Denklem 3.3’e göre sınıflandırıcıya sunulan n adet özellikten oluşan bir verinin dahil olacağı sınıfı tahmin etmek için x_j ($j=1,2,\dots,n$) özellikleri için y_i sınıflarının gerçekleşme olasılıkları

hesaplanmaktadır. Sonraki aşamada sınıf tahmini için en yüksek gerçekleşme olasılığına sahip y_i sınıfı seçilmektedir.

NB eğitim için az sayıda veriye ihtiyaç duymaktadır. NB hesaplama maliyeti açısından hızlı çalışan bir algoritmadır ve büyük veri kümelerinde iyi bir başarımla sergilemektedir [168].

3.1.4. Karar Ağaçları

Karar ağaçları parametrik olmayan, yorumlanması ve anlaşılması kolay olan denetimli makine öğrenmesi algoritmalarından biridir. KA sınıflandırma ve regresyon problemlerinde sıklıkla kullanılmaktadır. KA ile eğitim verileri kullanılarak en tepeden aşağı inen hiyerarşik bir yapıda karar ağacı oluşturulmaktadır. Oluşturulan ağaç yapılarında, etiket olarak da adlandırılan yaprak düğümler sınıflandırmaları, yaprak olmayan düğümler özellikleri ve dallar ise özellik değerlerinin birleşimini temsil etmektedir [169]. KA oluşturulurken temel amaç minimum derinliğe sahip bir ağaç yapısı oluşturmaktır. Bunun için bilgi kazancına dayalı ID3 algoritması sıklıkla kullanılmaktadır [170]. Bunun yanı sıra ID3 algoritmasının gelişmiş bir modeli olan C4.5, Chaid ve CART algoritması da literatürde kullanılmaktadır. KA ile kategorik ve sayısal veriler işlenebilmektedir. Şekil 3.5'te hava durumu tahminine göre tenis oynanıp oynanmayacağı ile ilgili temel bir KA yapısı görülmektedir.




Şekil 3.5. Basit bir karar ağacı yapısı

3.1.5. Doğrusal Ayırma Analizi

Doğrusal ayırma analizi boyut indirgemedi ve sınıflandırmada yaygın bir şekilde kullanılmaktadır. Genellikle ikili sınıflandırma uygulamalarında kullanılan DAA ikiden fazla sınıflandırma problemlerine de uyarlanabilmektedir. DAA tüm sınıflara ait verilerin birbirinden doğrusal ayrılabilceğini varsayarak, sınıfları birbirinden ayırt etmek için özellik uzayında sınıf sayısınınca hiper düzlemler oluşturmayı amaçlayan doğrusal ayırma fonksiyonları oluştur. DAA ile sınıf içi veriler arasındaki varyasyon en az olacak şekilde ve sınıfların ortalaması arasındaki mesafe

ise maksimum olacak şekilde hiper düzlemler oluşturmak hedeflenmektedir [171]. Başka bir deyişle yöntemin amacı sınıflar arası varyans ile sınıf içi varyans oranını maksimize etmektir [172,173]. Bu oran maksimum olduğunda her sınıftaki veriler mümkün olan en küçük dağılıma sahip olmakta ve sınıflar birbirinden maksimum derecede birbirinden ayrılabilir. Şekil 3.6'da 4 özellikten oluşan 3 sınıflı bir veri kümesinin DAA ile 2 boyuta indirgenmesi ve sonrasında 2 boyutlu özelliklerin DAA ile sınıflandırılması için oluşturulan hiper düzlemler görülmektedir. Şekilde her hiper düzlem bir sınıfı diğer sınıflardan ayırmaktadır.




Şekil 3.6. a) 4 özellikten oluşan 3 sınıflı bir veri kümesinin DAA ile 2 boyuta indirgenmesi b) DAA ile 2 boyuta indirgenen özelliklerin DAA ile sınıflandırılması için oluşturulan ve her bir sınıfı birbirinden ayıran hiper düzlemler

3.1.6. Yapay Sinir Ağları

İnsan beyninden esinlenerek geliştirilen ilk yapay sinir ağı modeli 1940'lı yılların başında McCulloch ve Pitts tarafından yayınlanan makalede basit mantık problemlerinin çözümü için önerilmiştir [174]. Biyolojik nöronları örnek alan YSA tıp, finans, biyoloji, endüstri, sosyal bilimler gibi birçok alanda kullanıma sahiptir. YSA eğitim aşamasında kendisine verilen örnekleri kullanarak genelleme yapmakta ve daha öncesinde hiç görmediği bir örnek ile karşılaştığı durumlarda eğitim sonucunda elde ettiği ağırlıklar yardımı ile karar verebilmektedir [175].

YSA'lar tek katmanlı ve çok katmanlı algılayıcılar olmak üzere iki gruba ayrılmaktadır. Tek katmanlı YSA doğrusal problemlerin çözümünde kullanılmakta olup giriş ve çıkış katmanından oluşmaktadır. Bir katmanda çözülmek istenilen probleme göre birden fazla yapay sinir hücresi bulunabilmektedir. Temel bir yapay sinir hücresinde giriş değerleri, giriş değerlerinin çıktı üzerindeki etkisini ayarlamaya yarayan ağırlık değerleri, sinir hücresine giriş yapan değerlerin çıktısını hesaplayan bir transfer fonksiyonu, hücrenin çıktısının bir sonraki hücreye hangi oranda aktarılacağına karar veren aktivasyon fonksiyonu bulunmaktadır. YSA'larda transfer fonksiyonu olarak en sık kullanılan toplama işleminde girdi değerleri ile ağırlıkları çarpıldıktan sonra elde edilen değerler toplanmakta ve hücrenin çıkış değeri elde edilmektedir. Şekil 3.7'de tek bir hücreden oluşan basit bir yapay sinir hücresi modeli görülmektedir.



Şekil 3.7. Yapay sinir hücresi modeli

Şekil 3.7’de gösterilen tek hücreli YSA modelinde Denklem 3.4’de belirtildiği üzere sinir hücresinin çıktı değeri m boyutlu X girdi değerlerinin ağırlıklarının çarpımının eşik değeri (bias) ile toplamından oluşmaktadır [175,176].

$$v = \sum_{i=1}^m w_i x_i + b \quad (i=1,2,...,m) \quad (3.4)$$


Denklem 3.4’de X_i ağırlık giriş değerlerini, W_i bu giriş değerlerine karşılık gelen ağırlık değerlerini, b eşik değerini, v ise hücresinin çıktısını ifade etmektedir. Elde edilen hücresinin çıktısı çözülmek istenilen probleme göre seçilen φ aktivasyon fonksiyonundan geçirildiğinde ağırlık çıktı değeri elde edilmektedir. Örneğin aktivasyon fonksiyonu olarak step fonksiyonu seçildiğinde ağırlık çıktı (y) değeri 0 veya 1 değerini almaktadır. Bu durum Denklem 3.5 ve Denklem 3.6’ da ifade edilmiştir.

$$\varphi(v) = \begin{cases} 1, & v \geq 0 \\ 0, & v < 0 \end{cases} \quad (3.5)$$

$$y = \varphi(v) \quad (3.6)$$

Tek katmandan oluşan YSA modeli komplike problemleri çözmekten yoksundur ve doğrusal problemlerin çözümünde kullanılmaktadır. Gerçek dünya problemleri genellikle doğrusal yapıda olmayan çözümlere sahiptir. Bunun için çok katmanlı YSA modelleri geliştirilmiştir. İnsan beyninde olduğu gibi yapay sinir hücreleri de kendi aralarında birbirine ağırlıklar yardımı ile bağlanabilmekte ve hücreler arası veri aktarımı yapabilmektedirler. Daha karmaşık problemlerde çok katmanlı YSA mimarileri kullanılmaktadır. Çok katmanlı YSA Şekil 3.8’de de görüleceği üzere giriş katmanı, ara katmanlar (gizli katmanlar) ve çıkış katmanından oluşmaktadır. Çok katmanlı YSA mimarisinde giriş katmanında bulunan tüm hücreler bir sonraki katmanda bulunan hücrelerin tamamına bağlıdır. Aynı şekilde her bir ara katmanda bulunan hücreler bir sonraki ara

katmanda bulunan hücelere bağlıdır. En son ara katmanda bulunan hücelere ise çıktı katmanındaki hücelerin hepsine bağlıdır [154,177].



Şekil 3.8. Çok katmanlı YSA örneği

Şekil 3.8’de belirtilen çok katmanlı YSA örneğinde giriş katmanındaki değerler ağırlıkları ile çarpılarak birinci ara katmana aktarılmaktadır. Ara katmandaki hücelere gelen veriler toplanarak aktivasyon fonksiyonundan geçirilmekte ve oluşan yeni değerler bir sonraki ara katmana ağırlıkları oranında aktarılmaktadır. Doğrusal olmayan problemlerin çözümü için çok katmanlı YSA’larda seçilecek aktivasyon fonksiyonunun türevinin kolay alınabilmesi ve doğrusal olmaması önemlidir. Aktivasyon fonksiyonu olarak Sigmoid, Hiperbolik tanjant, ReLU, Sızıntı ReLU, Swish, Softmax gibi fonksiyonlar sıklıkla kullanılmaktadır. Ara katman sayısı ve her bir ara katmanda kullanılacak hücre sayısı çözülmek istenilen probleme göre birbirinden farklı sayıda olabilmekte ve deneme yanılma yolu ile seçilmektedir [177].

3.2. Derin Öğrenme Mimarileri

Derin öğrenme algoritmalarının temelini oluşturan YSA’larda doğrusal olmayan problemlerin çözümü için çok katmanlı YSA modelleri kullanılmaya başlanmıştır. Günün şartlarında işlemcilerin yetersiz kalması sebebi ile bunların kullanımında zorluklarla karşılaşmış ve istenilen başarıya ulaşamamıştır. Teknolojinin gelişmesine paralel olarak grafik işlemcilerinin de hesaplama kapasitesinin artmasıyla birlikte, birden fazla katmana ve farklı mimarilere sahip YSA modelleri geliştirilmiştir.

Derin öğrenme, temel olarak birden fazla doğrusal olmayan katmandan oluşan yapay sinir ağlarıdır. Derin öğrenme bilgisayarlı görüş uygulamalarında, konuşma tanıma, metin ve sesden duygu analizi, nesne algılama, görüntü segmentasyonu, insan poz tahmini, hata teşhisi gibi çeşitli alanlarda ve biyoinformatik gibi farklı alanlarda gelişmiş performans sunmaktadır. Derin öğrenme mimarileri giriş verilerinin özelliklerine ve çözülmek istenilen problemin türüne göre derin sinir

ağları, evrişimli sinir ağları, tekrarlayan sinir ağları olmak üzere üç ana gruba ayrılabilir. Bunların yanı sıra çok sayıda ve farklı türlerde derin öğrenme mimarileri de mevcuttur.

Derin öğrenmede genellikle tüm sinir hücreleri birbirine bağlı olmaktadır. Tasarlanan derin öğrenme mimarisine göre milyonlarca eğitilebilir parametre ortaya çıkabilmekte ve bu durumda da ağın eğitilmesi için çok fazla işlem gücüne ihtiyaç duyulabilmektedir.


Derin öğrenme mimarileri denetimsiz, denetimli ve hibrit olmak üzere 3 ana gruba ayrılabilir. Literatürde denetimsiz derin öğrenme modelleri üretken mimari olarak isimlendirilirken, denetimli derin öğrenme modelleri ise ayırmacı mimari olarak isimlendirilmektedir.

3.2.1. Derin Sinir Ağları

Zaman içerisinde grafik işlemcilerin gelişmesi sonucu daha fazla sayıda ara katmana sahip YSA modellerinin eğitimi mümkün hale gelmiş ve çok katmanlı YSA'lar derin sinir ağları olarak isimlendirilmeye başlanmıştır. Temel bir DNN mimarisinde bir giriş katmanı, çok sayıda gizli katman ve bir çıkış katmanı bulunmaktadır. DNN'ler doğrusal olmayan özelliklerdeki veriler arasındaki ilişkileri modelleme yeteneğine sahiptir. Çok sayıda gizli katman ve nörondan oluşan DNN, oluşturulan modelin başarımını arttırırken, ağın eğitim süresini ve hesaplama maliyetini de arttırmaktadır. Ağın yapısı karmaşıktıkça ağın eğitimi için gereken kaynaklar da artmaktadır. Daha derin ağ modellerinin oluşturulması ağın öğrenme kapasitesini arttırmasına rağmen her zaman iyi sonuçlar verememektedir. Daha büyük ağ yapıları kaybolan gradyan problemine ve aşırı uyum problemlerine sebep olabilmektedir.

3.2.2. Boltzmann Makineleri


Boltzmann Makineleri denetimsiz, üretken ve olasılığa dayalı bir derin öğrenme modelidir. 1986'da ilk defa geliştirilen bu modelin kullanımı 2006 yılında Hinton ve diğerlerinin geliştirdiği hızlı öğrenme algoritması sayesinde popüler hale gelmiştir [153,178]. BM enerji tabanlı bir modeldir. BM kendisine sunulan veri setindeki olasılıksal dağılımları öğrenmede, özellik çıkarmada, regresyon ve sınıflandırma uygulamalarında kullanılabilir. 2 katmanlı olan bu modelde nöron benzeri görünür ve gizli düğümler bulunmaktadır. Görünür katmanlar ağın giriş katmanı olarak kullanılmaktadır. Görünür ve gizli düğümlerin birbirine tamamen çift yönlü olarak bağlı olduğu bu model, yinelemeli bir yapıya sahiptir. Gizli düğümlerin sayısı değiştirilerek BM'nin modelleme kapasitesi geliştirilebilmektedir [179]. Şekil 3.9'da 4 görünür, 3 gizli düğümden oluşan BM'nin yapısı görülmektedir. Gizli katman sayısı artırılarak derin BM modeli geliştirilebilir ve giriş verileri arasında daha derin ilişkilendirmeler yapılabilir [180].



Şekil 3.9. 4 görünür, 3 gizli düğümden oluşan BM

3.2.3. Kısıtlı Boltzmann Makinesi

Kısıtlı Boltzmann makinesi, Boltzmann makinesi modelinin güncellenmiş bir versiyonudur. Bu modelde BM'nin aksine görünür veya gizli katmanlardaki düğümler arasında bağlantı bulunmamaktadır. RBM'de görünür ve gizli birimler arasındaki ara bağlantılar simetrik ağırlıklar kullanılarak kurulmaktadır. Şekil 3.10'da m adet görünür, n adet gizli düğümden oluşan RBM'nin yapısı görülmektedir. Üretken bir model olarak RBM'ler sınıflandırmada, özellik çıkarmada, boyut indirgemede, işbirlikçi filtrelemede sıklıkla kullanılmaktadır. Görünür birimler ağırlık giriş verilerini, gizli birimler ise giriş verilerindeki ilişkileri temsil etmektedir [181].




Şekil 3.10. m adet görünür, n gizli düğümden oluşan RBM

3.2.4. Derin İnanç Ağları

Derin inanç ağları çok sayıda RBM katmanı içeren olasılıksal üretken bir modeldir. DBN modelinde iki katmanlı RBM'ler ardı ardına kullanılmaktadır [182]. Bu kullanım şeklinde ilk sıradaki RBM'nin gizli katmanı bir sonraki katmanın görünür katmanı olarak işlev görmektedir ve bu şekilde gizli katmanlarda öğrenilen ilişkiler bir sonraki katmana aktarılmaktadır [183]. DBN mimarisinde kullanılan her RBM katmanı, orijinal giriş verileri arasındaki daha yüksek seviyedeki ilişkileri ortaya çıkarmayı amaçlamaktadır. Ağırlık ilk katmanlarında giriş verilerinden daha düşük


seviyeli özellikler elde edilirken, üst katmanlarda ise daha soyut özellikler elde edilmektedir [184]. DBN modelinde ağın eğitimi denetimsiz olup RBM'lerin katman olarak bağımsız bir şekilde eğitilmesi prensibine dayanmaktadır [182]. Geleneksel çok katmanlı sinir ağlarına göre DBN ağının eğitimi daha az hesaplama maliyeti gerektirmektedir. Şekil 3.11'de 1 adet görünür, 3 adet gizli katmandan oluşan DBN modeli görülmektedir. DBN ile denetimli bir sınıflandırma işlemi yapılmak istenildiğinde son katmana bir Softmax katmanı eklenmektedir.



Şekil 3.11. 1 adet görünür, 3 adet gizli katmandan oluşan DBN modeli


3.2.5. Oto-Kodlayıcılar

Oto-Kodlayıcılar, denetimsiz öğrenme türlerinden olup üretken bir ağ türüdür [153]. AE ile hedef çıktı değerleri, giriş değerlerine eşit olacak şekilde geri yayılım uygulanmaktadır. Şekil 3.12'de görüleceği üzere AE, kodlayıcı ve kod çözücü olmak üzere 2 bölümden oluşmaktadır. Kodlayıcı bölümünde, giriş verileri daha düşük boyutta temsil edilecek şekilde sıkıştırılmaktadır. Buradaki amaç, giriş verilerinden daha düşük boyuttaki özelliklerin elde edilmesini sağlamaktır. Kod çözücü bölümünde ise sıkıştırılmış giriş verileri kullanılarak yeniden giriş verileri elde edilmektedir. Bu sebeple giriş katmanındaki nöron sayısı ile çıkış katmanında bulunan nöron sayısı eşit tutulmaktadır. Gizli katmandaki nöron sayısı ise genellikle giriş katmanındaki nöron sayısından daha azdır. AE'nin eğitimi DBN'nin eğitiminden daha kolay bir şekilde yapılabilir [185].



Şekil 3.12. Temel oto-kodlayıcı yapısı

Literatürde AE'lerin birçok çeşidi bulunmaktadır. Bunlardan biri olan derin oto-kodlayıcılar, ardışık olarak birden fazla AE katmanının birbirine bağlanması şeklindedir. Bu yapıda her bir katmanın çıktısı bir sonraki katmanın girişine bağlıdır. Şekil 3.13'te derin oto-kodlayıcı yapısı görülmektedir. Derin oto-kodlayıcıların haricinde giriş verilerinden seyrek öz nitelikleri öğrenebilen, giriş verilerindeki gürültüyü gideren, farklı boyuttaki giriş verilerinin arasındaki ilişkiyi öğrenebilen AE türleri de geliştirilmiştir [186–188].



Şekil 3.13. Derin oto-kodlayıcı yapısı


3.2.6. Tekrarlayan Sinir Ağları

İşaret işlemede, ses verisi işlemede, doğal dil işlemede ve zaman serisi benzeri ardışık verilerin işlenmesinde tekrarlayan sinir ağları sıklıkla kullanılmaktadır [189–192]. Geleneksel

DNN’lerde veriler sırasıyla giriş katmandan, gizli katmana ve çıkış katmanına doğru aktarılmaktadır ve bu katmanlardaki hücrelerin kendi arasında bağlantı bulunmamaktadır. Bu yapılarından dolayı geleneksel DNN’ler giriş verilerini birbirinden bağımsız olarak işlemektedir. Bu tür ağlar ses işareti gibi ardışık verilerin işlenmesinde yetersiz kalmaktadır.

RNN mimarisi diğer derin öğrenme mimarilerinden farklı olarak hafıza hücresine sahiptir. Bu yapısı sayesinde RNN mimarisinde girdilerdeki bağımlılıklar da dikkate alınmaktadır. Başka bir deyişle RNN kendisine verilen giriş dizisindeki verilerinin arasındaki ilişkiye odaklanmaktadır. Bu mimarideki hücrelerin çıkış değerleri bir sonraki işlemde giriş değeri ile birlikte girdi olarak kullanılmaktadır. Bu durumda her hücrenin çıkışı bir önceki çıkış değerine bağlı olmaktadır.

Örneğin bir konuşma metninde sonraki kelimeyi tahmin etmek için mevcut kelimeden önceki kelimelere de bakmak gerekmektedir. RNN mimarisi buna benzer problemlerde başarılı sonuçlar üretebilmektedir. Şekil 3.14’de basit bir RNN hücresi ve açılımı görülmektedir. Şekilde x_t t . iterasyondaki giriş değerlerini, h_t ise t . iterasyondaki çıkış değerlerini temsil etmektedir.



Şekil 3.14. RNN hücresi ve açılımı

Yukarıdaki örneğe göre x_1 cümledeki ilk kelimesini, h_1 ise tahmin edilen bir sonraki kelimeyi temsil etmektedir. Gizli katmandaki hücrenin t . Adımındaki çıktısı s_t ile gösterilirse, t . adımdaki giriş değeri ve bir önceki adımdaki hücrenin değeri kullanılarak s_t değeri hesaplanabilir. Bu durum Denklem 3.7’de verilmiştir. Denklemden f normalde doğrusal olmayan bir aktivasyon fonksiyonunu temsil etmektedir. Bu durumda s_t hafıza hücresi olarak çalışacaktır.

$$s_t = f(U * x_t + W * s_{t-1}) \quad (3.7)$$


RNN mimarisinin teorikte olmamasına karşın veriler arasındaki uzun vadeli ilişkiler arttığında pratikte problemlere yol açtığı görülmüştür [193]. RNN mimarisinin eğitim aşamasındaki en önemli problemlerden biri olan kaybolan gradyan sorununda, gradyan değerinin çok küçük olduğu durumlarda güncelleme değerleri önemsiz hale gelmekte ve ağır öğrenememe problemi

ortaya çıkmaktadır. RNN mimarisindeki problemlerden biri olan patlayan gradyan sorununun ise eğitim sürecinde gradyan değeri çok büyük olmakta ve ağıın başarımı önemli ölçüde düşmektedir.

Yukarıda verilen konuşma metni örneğinde; bir konuşma metninin ilk cümlelerinde geçen bir kelime ile birkaç sayfa sonrasında bir kelime ile ilişki kurması istendiğinde RNN mimarisi bu ilişkiyi kuramamaktadır. RNN mimarisi kısa süreli bağımlılıklarda başarılı olurken uzun süreli bağımlılıklarda başarısız olmaktadır.

3.2.7. Uzun Kısa Vadeli Bellek Ağları

Hochreiter ve diğerleri tarafından 1997 yılında yapılan çalışmada RNN mimarisinde ortaya çıkan uzun vadeli bağımlılıkları öğrenememe durumunun çözüldüğü bildirilmiştir. RNN benzeri bu yapıya uzun – kısa vadeli bellek ağları denilmektedir. LSTM zaman içerisinde durumunu koruyabilen bir hafıza hücresi ve hücreye bilgi giriş/çıkışını düzenleyen doğrusal olmayan kapılardan oluşmaktadır [194]. LSTM hücresi içerisinde bulunan giriş katmanı, unutma katmanı ve çıkış katmanı 4 adet sinir ağı ile birbirine bağlanmakta ve hücrenin hafızasını oluşturmaktadır. LSTM tasarım mimarisi ile RNN’de karşılaşılan gradyan kaybolma problemi ortadan kaldırılmıştır. RNN mimarisindeki gradyan kaybolma problemi; ağıın eğitimindeki hata değerinin geriye yayılım sürecinde kullanılan aktivasyon fonksiyonunun türevinin sıfır çıkması sonucunda ağıın öğrenememesinden kaynaklanmaktadır. Şekil 3.15’te LSTM modeli, yapısında bulunan kapılar ve LSTM hücresinin iç yapısı görülmektedir.



Şekil 3.15. LSTM modeli, yapısında bulunan kapılar ve LSTM hücresinin iç yapısı

Şekil 3.15’te gösterilen LSTM hücre modelinde f_t unutma kapısının çıkışını, i_t giriş kapısının çıktısını, C_t hücrenin belleğini, o_t çıkış kapısının çıktısını, h_t ise hücrenin çıktısını temsil etmektedir. f_t , i_t , C_t , o_t ve h_t değerleri Denklem 3.8-3.12’de verildiği şekilde hesaplanabilir. Denklemlerdeki σ sigmaoid aktivasyon fonksiyonunu, b eşik değerini, W ise ağırlık değerlerini temsil etmektedir.

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (3.8)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (3.9)$$

$$C_t = f_t * C_{t-1} + i_t * [\tanh(W_c \cdot [h_{t-1}, x_t] + b_c)] \quad (3.10)$$


$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (3.11)$$

$$h_t = o_t * \tanh(C_t) \quad (3.12)$$

LSTM mimarisinde giriş verileri arasındaki ilişkiler sırasıyla baştan sona doğru incelenerek ortaya çıkarılmaktadır. LSTM mimarisinin bir diğer versiyonu olan çift yönlü uzun kısa vadeli hafıza ağlarında (Bidirectional Long Short Term Memory, BiLSTM) ise ilişkiler çift yönlü olarak araştırılmaktadır. Son birkaç yılda yapılan çalışmalarda EKG, EEG, EOG ve EMG gibi biyomedikal işaretlerin sınıflandırılmasında LSTM modellerinin kullanımına yer verilmiştir [195–198].

3.2.8. Nöral Devre Politikaları

Nöral devre politikaları C. Elagans nematodunun sinir sisteminden ilham alınarak geliştirilmiş ve klasik derin öğrenme mimarilerine oranla çok az sayıda nöronun birbirine bağlanmasıyla oluşturulmuş yeni bir sinir ağı mimarisidir [199,200]. Klasik derin öğrenme mimarilerinin aksine NCP ile nöronların tamamı birbirine bağlanmamakta ve bu sayede ağın hesaplama maliyeti büyük bir oranda düşmekle birlikte benzer yapıdaki tam bağlantılı bir derin öğrenme mimarisi kadar da başarımlı sağlayabilmektedir. Seyrek yapıdaki sinir ağından oluşan NCP mimarisi Şekil 3.16’da görüleceği üzere sensör nöronları, inter-nöronlar, komut nöronlar ve motor nöronlardan oluşan 4 katmanlı bir yapıya sahiptir. Sensör nöronları dış ortamdan verilerin alınmasına imkân sağlamaktadır. Bu işlem için çözülmek istenilen probleme göre, verilerden özelliklerin çıkarılarak sensör nöronlara veri girişi olarak sunulması gerekmektedir. Derin öğrenme mimarilerinde özellik çıkarma işlemi genellikle CNN kullanılarak yapılmaktadır. Sensör nöronlardaki veriler ara katmanda bulunan inter-nöronlara seyrek bir yapıda ve ileri beslemeli bağlantı kullanılarak aktarılmaktadır. Inter-nöronlar bir sonraki katmanda bulunan komut nöronlarına ileri beslemeli bağlantılarla seyrek bir şekilde bağlanmaktadır. Komut nöronları son katmanda bulunan motor nöronlarına ileri beslemeli bağlantı ile bağlı olmaktadır ve motor nöronları bir çıktı değeri üretmektedir. Motor nöronlardaki RNN hücrelerinin hafıza özelliği bulunmakta ve gürültülü verilerle baş edebilme kapasitesine sahiptir [199]. Motor nöronlar aynı zamanda kendi aralarında da birbirlerine bağlantı kurabilmektedir.




Şekil 3.16. NCP ile geleneksel ağ mimarilerinin karşılaştırılması. a) Tam bağlı ağlar, b) Rastgele seyrek yapıdaki bağlı ağlar, c) NCP mimarisi.

Bu şekilde tasarlanan seyrek yapıdaki 4 katmanlı NCP mimarisi diğer derin öğrenme mimarilerine göre %90 oranında daha az nörondan oluşabilmektedir [201]. NCP'ler zaman serisi verileri üzerinde yüksek başarımlı doğrusal olmayan bir ağ yapısına sahiptir. NCP'lerin temel sinirsel yapı taşlarına sıvı zaman sabiti (Liquid Time Constant, LTC) ağırları denilmektedir [202]. NCP ile oluşturulan ağ mimarisinin küçük boyutlu olması, her bir hücrenin geliştirdiği ilişkilerin incelenmesine ve yorumlanmasına da olanak sağlamaktadır. Bu modelde ağ mimarisi oluşturulurken ağdaki inter-nöron ve komut-nöron sayısı, katmanlar arasında rastgele oluşturulacak bağlantı sayısı ve motor nöronlardaki RNN hücre sayısı seçilebilmektedir.

3.2.9. Evrişimli Sinir Ağları

Lecun ve diğerleri tarafından geliştirilen evrişimli sinir ağları, sınıflandırma, görüntü tanıma, görüntü segmentasyonu ve işaret işleme benzeri birçok alanda kullanılmaktadır [152,203,204]. Beynin görsel korteksinden ilham alan bu model özellikle iki boyutlu görüntüleri işlemek için tasarlanmıştır [205]. Görsel kortekste yer alan basit hücreler görüntülerdeki kenar benzeri temel özelliklere yoğunlaşırken, karmaşık hücreler ise basit hücrelerden gelen bilgileri sentezleyerek görüntülerdeki ince detaylara yoğunlaşmaktadır. Veri setindeki özelliklerin aşamalar halinde öğrenilmesine imkân tanıyan yapısından dolayı CNN mimarisi derin öğrenmede kullanılan temel tekniklerden birisi haline gelmiştir. CNN özellikle görüntüler üzerinde performanslı çalışan ileri beslemeli bir derin öğrenme modelidir. Şekil 3.17'de temel bir CNN mimarisi görülmektedir.

Klasik bir CNN modeli evrişimli katmanlardan, ReLU benzeri doğrusal olmayan aktivasyon katmanından, havuzlama katmanından ve tam bağlantılı çıktı katmanından oluşmaktadır. Geleneksel makine öğrenmesi algoritmalarında verilerden öznitelikler farklı yöntemler kullanılarak çıkartılırken, CNN mimarisinde bulunan evrişim, aktivasyon ve havuzlama katmanından oluşan bölümler yardımı ile öznitelikler ağ tarafından otomatik olarak çıkartılmaktadır. CNN mimarisinde bulunan tam bağlantılı katmanlar ise ağıın sınıflandırıcı olarak çalışmasına olanak sağlamaktadır.




Şekil 3.17. Temel CNN mimarisi[154]

Giriş Katmanı

Giriş katmanındaki veri Şekil 3.17'deki gibi $m \times n \times r$ boyutundaki bir görüntü olabilmektedir. Burada m görüntünün genişliğini, n görüntünün yüksekliğini, r ise görüntüdeki renk kanallarının sayısını temsil etmektedir. RGB renk değerlerini içeren renkli görüntülerde bu değer 3 olmaktadır. Giriş katmanında görüntünün yanı sıra video veya işaretler de kullanılabilir. Giriş verisinin büyüklüğü CNN modelinin başarımını önemli oranda arttırabilirken ağır eğitim sürecindeki bellek ihtiyacını ve işlem süresini de arttırmaktadır. Giriş verisinin az olması durumunda ise modelin başarımı düşebilmektedir. Giriş verisinin büyüklüğünün seçimi çözülecek problemin doğasına uygun bir şekilde yapılmalıdır.

Evrişim Katmanı

CNN mimarisinde bulunan evrişim katmanı giriş verilerinden özelliklerin çıkarıldığı ve bu mimaride hesaplama maliyetinin en fazla olduğu bölümdür. Evrişim işleminde 2×2 , 3×3 , 5×5 , 7×7 benzeri boyuttaki bir filtre önceki katmandan alınan veriler üzerinde belirlenen adım aralıkları ile gezdirilmektedir. Bu işlem esnasında filtre matrisi ile girdi verilerinin çakıştığı değerler birbiriyle çarpılır ve elde edilen değerler birbiriyle toplanır. Giriş verilerine filtre uygulandıktan sonra elde edilen çıktıya özellik haritası denilmektedir. Her filtreleme işlemin sonucunda farklı özellik haritası oluşmaktadır. Örneğin görüntünün giriş olarak verildiği bir çalışmada ilk evrişim katmanında görüntünün kenar özellikleri ön plana çıkarken, sonraki evrişim katmanlarında görüntünün köşeleri ve üst düzey ayrıntıları ortaya çıkabilmektedir. Şekil 3.18'de 2×2 boyutundaki bir filtrenin 4×4 boyutundaki giriş verisi üzerinde birer adım aralıkla gezdirildiği evrişim işleminin tasviri görülmektedir. Filtre boyutunun seçimi probleme göre ve tasarımcının oluşturduğu mimariye göre değişebilmektedir. Farklı katmanlarda farklı boyutlarda filtre seçimi yapılabilir.



Şekil 3.18. 4x4 boyuttaki bir giriş verisine 2x2'lik filtrenin uygulandığı evrişim işlemi

Aktivasyon Katmanı

Evrişim işleminin sonucu olarak çıktı değerleri doğrusal olmakta ve seçilen filtreye göre de çıktı değerleri negatif sonuçlar içerebilmektedir. Evrişim işlemin sonunda elde edilen çıktı değerlerine Sigmoid, ReLU, Leaky ReLU, ELU, Swish gibi doğrusal olmayan bir aktivasyon fonksiyonu uygulanmaktadır.


Derin öğrenmede kaybolan gradyan problemlerinden kaçınmak amacıyla genellikle ReLU kullanılmaktadır ve bu fonksiyonun hesaplama maliyeti de diğer aktivasyon fonksiyonlarına göre daha az olmaktadır. ReLU fonksiyonu Denklem 3.14'teki şekilde çalışmaktadır. Denklemde x giriş değerlerini, $f(x)$ ise ReLU aktivasyon fonksiyonun çıktısını temsil etmektedir.

$$f(x) = \begin{cases} x, & x > 0 \\ 0, & x \leq 0 \end{cases} \quad (3.14)$$

ReLU aktivasyon fonksiyonunda sıfırdan küçük girdi değerleri sıfıra eşitlenirken, pozitif girdi değerleri ise aynı şekilde korunmaktadır.

Havuzlama Katmanı

Evrişim katmanında çok sayıda öznetelik haritası ortaya çıkmaktadır. Havuzlama katmanı ile yüksek miktardaki özellik haritalarının boyutu düşürülmektedir. Bu işlemin sonucunda ağın hesaplama maliyeti düşmekte ve bir sonraki katmana aktarılacak verilerin boyutu azaltılmaktadır. Bu işlemin sonucundaki verilerdeki derinlik kaybolmamaktadır. Havuzlama işleminde genellikle maksimum ve ortalama işlemi kullanılmaktadır. Havuzlama işleminde belirlenen boyuttaki bir matris girdi verilerinin üzerinde gezdirilmektedir. Maksimum alma işleminde matrisin içinde kalan en büyük değer seçilirken, ortalama alma işleminde ise matrisin içinde kalan değerlerin ortalaması alınmaktadır. Şekil 3.19'da 4x4 boyutundaki giriş verisi üzerinde 2x2 boyutunda maksimum havuzlama işleminin tasviri görülmektedir.



Şekil 3.19. 4x4 boyutundaki giriş verisi üzerinde 2x2 boyutunda maksimum havuzlama işlemi


Tam Bağlı Katmanlar

Tam bağlı katmanlarda ise önceki katmandaki tüm nöronlar bu katmandaki nöronların tümüne bağlanmaktadır. Derin öğrenme mimarisine göre birden fazla tam bağlı katman kullanılabilir. Evrişim ve havuzlama katmanları sonucu elde edilen çok boyutlu öznitelik haritaları tam bağlı katmanda tek boyuta indirgenmektedir. Tam bağlı katmanlar geleneksel sinir ağlarına benzemektedir. Tam bağlı katmandaki bir nöronun çıktı değeri Denklem 3.15'teki gibi hesaplanmaktadır.

$$f_{c1} = \varphi(b + \sum_{q=1}^M w_{1,q} * o_q) \quad (3.15)$$

Denklem 3.15'te f_{c1} nöronun çıktı değerini, φ nörona uygulanan aktivasyon fonksiyonunu, M bir önceki katmandan tek boyuta düşürülmüş toplam nöron sayısını, o_q bir önceki katmandaki q . sıradaki nöronun çıktı değerini, $w_{1,q}$ bir önceki katmandaki q . sıradaki nöron ile çıktı değeri hesaplanmak istenilen nöron arasındaki ağırlık değerini temsil etmektedir. b ise bias değerini temsil etmekte ve genellikle 1 değerini almaktadır.

Sınıflandırma çalışmalarında en son katmandaki tam bağlantılı katmandaki nöronların sayısı sınıf sayısı kadar oluşturulmalıdır. Şekil 3.20'de evrişim katmanından sonra kullanılan tam bağlı katmanlar görülmektedir.



Şekil 3.20. Evrişim katmanından sonra kullanılan tam bağlı katmanlar

Softmax Katmanı

Derin Öğrenme mimarilerinde ve çok sınıflı sınıflandırma çalışmalarında da sıklıkla kullanılan Softmax aktivasyon fonksiyonu, çoklu sınıflar için lojistik regresyonun bir genellemesidir. Genel olarak sınıflandırma katmanında kullanılmaktadır. Softmax aktivasyon fonksiyonu kendisine verilen her bir girdinin belirli bir sınıfa ait olma olasılığını hesaplanmaktadır. Softmax aktivasyon fonksiyonu; 0 ile 1 arasında çıkış değeri vermekte ve tüm olasılıkların toplamı bire eşit olmaktadır. Softmax fonksiyonu denklem 3.16'deki şekilde ifade edilebilir.

$$p(x)_j = \frac{e^{x_j}}{\sum_{q=1}^K e^{x_q}} \quad (3.16)$$

Denklem 3.16'da x_j bir önceki tam bağlı katmanların çıkış değerlerini, K ise sınıf sayısını temsil etmektedir. Bu sebepten dolayı Softmax katmanından önceki tam bağlı katmanındaki nöron sayısının sınıf sayısı kadar belirlenmesi gerekmektedir.

Sınıflandırma Katmanı

Sınıflandırma çalışmalarında derin öğrenme mimarisinin son katmanıdır. Sınıflandırma katmanı, bir önceki katmanda bulunan tam bağlı katman ve çoklu sınıflandırmalar için kullanılan Softmax katmanından sonra elde edilen olasılık değerlerine göre bir sınıflandırma değeri üretmektedir. Bu değer genellikle sınıfın temsil edildiği bir sayı şeklindedir.

Sınıflandırma katmanında, çoklu sınıflandırma çalışmaları için kayıp fonksiyonu olarak genellikle çapraz entropi kaybı kullanılmaktadır. Sınıflandırma değeri 0 ile 1 arasında olan bir sınıflandırma modelinde, sınıflandırıcının başarımı çapraz entropi kaybı ile hesaplanmaktadır. Çapraz entropi kaybı Denklem 3.17'ye göre hesaplanabilmektedir.


$$kayıp = - \sum_{i=1}^M t_i * \log(s_i) \quad (3.17)$$

Denklem 3.17'de M toplam sınıf sayısını, t_i giriş verisine göre ilgili sınıfın gerçek değerini, s_i ise giriş verisine göre ilgili sınıfın derin öğrenme mimarisindeki tahmin değerini temsil etmektedir. Kayıp değerlerinin hesaplanabilmesi için tahmin değerlerinin pozitif olması gerekmektedir. Bu sebeple sınıflandırma katmanından önce 0-1 arasında olasılık değeri üreten Softmax katmanı kullanılmaktadır.

3.3. Derin Öğrenme Mimarilerinde Kullanılan Başarım Ölçütleri

Bu çalışmada, önerilen modelin başarımı 10 kat çapraz doğrulama tekniği ile değerlendirilmiştir. Bu teknik ile doğrulama sonuçlarında yanlış sonuçların elde edilmesinden kaçınılmaktadır [206]. 10 kat çapraz doğrulama tekniğinde veri seti rastgele olarak her bir sınıftaki veri miktarına eşit olacak şekilde 10 eşit parçaya bölünmektedir. Parçalara ayrılan veri setinin 9

parçası modelin eğitimi için kullanılırken geriye kalan bir parçası ise modelin başarımlı testi için kullanılmaktadır. Bu işlem veri setinin tüm parçaları için yapılmakta ve test sonuçlarından elde edilen sonuçların ortalaması alınarak sistemin genel başarımlı bulunmaktadır. Şekil 3.21’de 10 kat çapraz doğrulama tekniğine göre eğitim ve test verilerinin grafiksel modeli görülmektedir.



Şekil 3.21. 10 kat çapraz doğrulama tekniğine göre eğitim ve test verilerinin grafiksel modeli

10 kat çapraz doğrulama tekniğinde ortalama başarımlı değerleri Denklem 3.18’de gösterilen eşitlikteki gibi hesaplanmaktadır.

$$başarım = \frac{1}{10} \sum_{k=1}^{10} başarım_k \quad (3.18)$$

Mevcut çalışmalarla karşılaştırmalı değerlendirme yapabilmek için aynı başarımlı ölçütlerinin kullanılması son derece önemlidir. Mevcut çalışmaların çoğu sınıflandırmada doğruluk kriterini kullanmaktadır. Veri setinin dengeli olduğu çalışmalarda doğruluk kriterinin dikkate alınması makul bir ölçüttür. Doğruluk kriteri sınıflandırıcının doğru olarak yaptığı tahminlerin tüm tahminlere olan oranı şeklinde tanımlanmaktadır. Önerilen yöntemin doğruluğu Denklem 3.19’daki gibi hesaplanmaktadır.

$$doğruluk = \frac{GP+GN}{GP+GN+YP+YN} \quad (3.19)$$

Denklem 3.19’daki doğruluk başarımlı ölçütü hesaplamasında GP gerçek pozitiflerin sayısını, GN gerçek negatiflerin sayısını, YP yanlış pozitiflerin sayısını ve YN ise yanlış negatiflerin sayısını göstermektedir. Örneğin bir alüminyum materyali alüminyum olarak doğru bir şekilde sınıflandırılırsa bu GP olacaktır. Bir granit malzemesi yapay mermer olarak yanlış sınıflandırıldığında ise yapay mermer sınıfı için bu durum YP olacaktır. Bir alüminyum materyali, alüminyum olarak doğru bir şekilde sınıflandırılmadığında bu alüminyum sınıfı için YN olacaktır.

Benzer bir şekilde bir materyal alüminyum değilse ve bu alüminyum dışında farklı bir malzeme olarak sınıflandırılıyorsa bu *GN* olacaktır.

Her bir materyalin sınıflandırma doğruluğunun daha iyi incelenebilmesi için bu çalışmada ayrıca karışıklık matrisi de kullanılmıştır. Karışıklık matrisinde her bir malzeme sınıfı için *GP*, *GN*, *YP* ve *YN* sayıları ve malzemelerin doğru veya yanlış dahil edildikleri sınıflar ayrıca incelenebilmektedir.

Tez çalışmasındaki hedef türü analiz yaklaşımlarında doğruluk başarımlarının yanı sıra kesinlik, geri çağırma ve F1-skor değerlendirme ölçütleri de kullanılmıştır. Bu tanımlamalar aşağıdaki denklemlerde gösterilmiştir [207].

$$kesinlik = \frac{GP}{GP + YP} \quad (3.20)$$


$$geri \text{ çağırma} = \frac{GP}{GP + YN} \quad (3.21)$$

$$F1 - skor = 2 * \frac{kesinlik * geri \text{ çağırma}}{kesinlik + geri \text{ çağırma}} \quad (3.22)$$

4. UZAK MESAFEDEKİ MATERYALLERİN LAZER İŞARETLERİ İLE TANIMLANMASI

Çevremizde bulunan ve sıklıkla kullandığımız nesneler cam, metal, tahta, plastik, taş vb. çeşitli materyallerden oluşmaktadır. Çevremizdeki nesnelerin yapıldıkları malzemeleri bilmemiz bize çevremiz ile daha doğru bir şekilde etkileşim kurmamızı sağlayacaktır. Benzer bir şekilde bilgisayar destekli sistemler için de materyallerin doğru bir şekilde tanımlanması önemlidir. Örneğin otonom bir robot plastik, cam, metal veya kartondan oluşan bir bardağı kavramak için bardağın yapıldığı malzemenin cinsine göre güç kullanılmalıdır. Benzeri bir şekilde otonom bir robot veya bir araç görevini yerine getirirken beton, metal, cam benzeri malzemelerin üzerinde gittiğinin farkında olmalı ve yolun pürüzlülüğüne veya kaygan olmasına göre kendini yeniden konumlandırmalıdır.

Nesneleri oluşturan materyallerin bilgisayar görmesi ile tanımlanması önemli çalışma alanlarından. Geleneksel olarak malzeme tanımlama işlemi kamera görüntülerindeki renk, doku ve şekil bilgilerinden yola çıkılarak yapılmaya çalışılmaktadır [28]. Bu yöntemlerin en büyük dezavantajı aynı görünüme sahip farklı malzemelerin olmasıdır. Örneğin aynı görünümdeki bir bardak metal, plastik veya tahtadan yapılmış olabilir. Şekil 4.1’de aynı görünüme sahip plastik ve ahşap bardak, siyah kumaş, magnet ve granit materyalleri görülmektedir. Diğer bir dezavantaj ise kameralar çok ışıklı ortamlarda veya az ışıklı ortamlarda iyi çalışmazlar ve aynı malzemeyi bulundukları çevresel ortama göre farklı olarak görüntüleyebilmektedirler. Karanlıkta ise hiç çalışmamaktadırlar. Bu durum görüntüden malzeme tanımlanmasında zorluklara sebep olmaktadır.



Şekil 4.1. Farklı materyallerden üretilmiş bardaklar ve aynı görünüme sahip farklı materyal türleri a) Plastik bardak b) Ahşap bardak c) Siyah kumaş d) Magnet e) Granit

Malzeme tanımlamada kameralar haricinde sıcaklık, titreşim, dokunsal sensörler, kuvvet ve spektroskopi gibi çeşitli sensörler kullanılmaktadır. Bu yöntemlerin çoğu yakın temas ve özel ortamlar gerektirmektedir.

Materyal sınıflandırma çalışmalarında kullanılan kameralar ortam ışığına duyarlıdır ve görüntülerden renk, doku, geometri bilgisi alınamadığında başarısız olmaktadır. Diğer sensörler ise yakın temas gerektirmekte veya hantal yapılara sahip olabilmektedir. RGB görüntü kullanılan materyal tanımlama uygulamalarında gerçek bir materyal yerine materyalin basılı görüntüsü sisteme verilerek sistem kolaylıkla yanıltılabilir. Bu durum gerçek dünya uygulamalarında güvenlik açıklarına ve uygulamaların işlev dışı bırakılmasına sebep olabilmektedir.


Bu çalışmada yukarıda belirtilen zorluklar nedeniyle kamera kullanmak yerine ışığın malzeme ile geçici olarak etkileşime girme şeklinden faydalanılmaktadır. Örneğin, ışık yansıma ve yüzey altı saçılması yoluyla bir materyal ile etkileşime girdiğinde o materyale ait tanımlayıcı bir yansıma değerine sahip olacaktır.

Bu bölümde lazer işaretleri ve LSTM, derin LSTM, NCP derin öğrenme mimarileri kullanılarak günlük hayatta sıklıkla kullanılan 10 çeşit materyalin sınıflandırılması işlemi anlatılmaktadır. Bu amaçla yapılan çalışmada lazer ölçümlerinin teorik temelleri ve veri hazırlama metotlarına yer verilmektedir. Sonraki adımda materyallerden lazer işaretlerinin alınmasını sağlayan lazer algılayıcı sistem tasarımı ve veri seti oluşturma adımlarına yer verilmektedir. Daha sonra lazer işaretleri ile materyal tanımlama için önerilen derin öğrenme modeli, eğitim ve test aşamaları ve elde edilen sonuçlar karşılaştırmalı olarak verilmektedir.

4.1. Lazer Ölçümlerinin Teorik Temelleri

Lazer ile algılama sisteminde; hedefe bir lazer ışık demeti sürekli veya darbeli bir şekilde yansıtılmakta ve hedeften yansıyan lazer işaretleri kayıt altına alınmaktadır. Lazer işaretleri hedeften geri saçılan lazer ışığının sayısal bir temsili olmaktadır. Hedeften yansıyan işaretin gücü materyalin türüne, ortam şartlarına, cihazın tasarım elektroniğine, kullanılan lazerin dalga boyuna, hedef ile lazer sistemi arasındaki mesafeye bağlı olmaktadır.

Lazer ışığı bir materyale çarptığında materyalin yüzey pürüzlüğüne göre dağınık veya speküler yansıma yapmaktadır. Hedef materyaldeki yüzey parçacıkları lazer ışığının dalga boyundan küçükse speküler yansıma gerçekleşmekte ve materyalden yansıyan ışığın açısı lazer ışığının gelme açısına eşit olmaktadır. Bu tür yüzeyler ayna gibi parlak bir yapıya sahiptir. Hedef materyaldeki yüzey parçacıklarının yansıtılan lazer ışığının dalga boyundan büyük olduğu durumlarda, lazer ışıkları dağınık bir şekilde her yöne saçılma yapacaktır. Dağınık saçılmada hedeften saçılan lazer ışınlarının alıcıya ulaşan gücü, alıcı ile hedefin normali arasındaki açısına bağlıdır [208]. Dağınık yansımanın olduğu durumlarda yüzey altı saçılmalar da olabilmektedir. Şekil 4.2’de materyal yüzeyine çarpan lazer ışığının materyal yüzeyinden yaptığı speküler ve dağınık yansıma görülmektedir.



Şekil 4.2. Lazer ışığı ve yansımaları türleri a) pürüzsüz bir yüzeyden spekül yansıma b) Pürüzlü bir yüzeyden yüzey altı ve dağınık yansıma

Gerçek dünya şartlarında ise çok az malzeme ayna gibi spekül yansıma yapmaktadır. Çoğu materyal yapısındaki mikro dokular nedeni ile belirli bir seviyede pürüzlüdür. Bu sebeple materyalin üzerine düşen ışık, spekül ve dağınık bir yansımanın kombinasyonu şeklinde olacaktır. Materyallerin farklı yüzey ve mikro özelliklerinden dolayı, lazer ışınları farklı malzemelerde farklı yansıma yoğunluklarına sebep olacaktır.

Hedefe gönderilen ve hedeften alınan işaretin gücü arasındaki ilişki Denklem 4.1’de açıklanmaktadır [85,209,210]. Bu denklem lazer işaretinin pürüzlü bir yüzeye yansıtıldığı ve lazer ışın yarıçapının hedeften daha küçük olduğu durumlarda geçerlidir [85].

$$P_R = \frac{\pi P_T \rho}{4R^2} \eta_{Atm} \eta_{Sys} \cos(\alpha) \quad (4.1)$$

Burada P_R algılanan işaretin gücünü, P_T iletilen işaretin gücünü, ρ hedefin yansıtma katsayısını, α geliş açısını, η_{Atm} atmosferik iletim faktörünü, η_{Sys} algılayıcı sistemin iletim faktörünü ve R hedef ile cihaz arasındaki mesafeyi göstermektedir.

Denklem 4.1’e göre hedeften yansıyan lazer ışınlarının gücünü etkileyen parametreler 3 grupta ele alınabilir. Birinci gruptakiler, kısa ölçüm aralığında sabit olabilecek η_{Atm} ve η_{Sys} parametreleridir. Ölçüm esnasında bu parametrelerdeki küçük değişiklikler göz ardı edilebilir. İkinci grupta yer alan α ve R parametreleri ise ölçüm anında sağlanacak standardizasyon teknikleri ile veya ölçüm sonrasında düzeltme teknikleri ile kontrol altına alınabilecek değerlerdir. Üçüncü gruptaki ρ ise hedefteki malzemenin türüne, rengine, nemine, pürüzlülüğüne ve lazerin dalga boyuna göre değişen yansıtma katsayısıdır [16,208].

Hedef ile lazer algılayıcı sistem arasındaki mesafe kısa olduğunda, hedef ile hedeften yansıyan lazer işaretinin kaydedildiği ortamdaki η_{Atm} değeri sabit değer olarak kabul edilebilir. Lazer işaretlerini kaydetme işlemi esnasında aynı cihazın kullanıldığı varsayıldığında; η_{Sys} ve P_T değeri de sabit değer olarak kabul edilebilir. Bu durumda Denklem 4.2’deki gibi bu değerler sabit

bir K katsayı ile ifade edilirse, hedeften elde edilen lazer gücü Denklem 4.3'deki gibi ifade edilebilir.

$$K = \frac{\pi P_T}{4} \eta_{Atm} \eta_{Sys} \quad (4.2)$$

$$P_R = \rho K \frac{\cos(\alpha)}{R^2} \quad (4.3)$$

Denklem 4.3'e göre hedeften yansıyan lazerin gücü hedefin yansıtma katsayısına, hedefe yansıtılan lazer ışın demetinin hedefin yüzeyi ile normali arasındaki açısına ve hedef ile lazer alıcı/verici cihaz arasındaki mesafeye bağlıdır.

Yuan ve diğerlerinin yaptıkları çalışmaya göre; farklı lazer ışın ve algılayıcı cihazlarda düzeltme yapılabileceğinden dolayı Denklem 4.3'deki algılanan lazer gücünün uzaklık ve açı ile tamamen doğrusal olmayabileceği bildirilmiştir [16]. Buna göre hedeften elde edilen lazer gücü Denklem 4.4'teki gibi tanımlanabilir. Denklem 4.4'teki eşitlikte b cihaza göre değişebilen sabit bir terimdir.

$$P_R = \rho K \frac{\cos(\alpha)}{R^2} + b \quad (4.4)$$

4.2. Veri Hazırlama Metotları

Bu bölümde materyal tanımlama çalışmasında kullanılan veri hazırlama adımlarından çıkarma işlemi, Welch metodu ve Yule- Walker otoregresif (Auto-Regressive, AR) metodu verilmiştir.

4.2.1. Çıkarma İşlemi

Hedeften yansıyan lazer işaretleri kullanılan lazer algılayıcı sisteminin elektroniğine ve ortamdaki ışık kaynaklarına bağlı olarak gürültülü olabilmektedir. Hedeften yansıyan lazer ışığı, lazer algılayıcı sisteminde bulunan optik sistemler yardımı ile bir algılayıcının üzerine odaklanmakta ve analog dijital dönüşümü yapılarak sayısal değerler elde edilmektedir. Tasarım elektroniğine ve yazılımına bağlı olarak elde edilen işaretlerde bir taban çizgisi ve algılayıcı elektroniğin karanlık akım etkisi oluşabilmektedir.

Çalışma esnasında, lazer ışığı açıkken yapılan ölçüm ile lazer ışığı kapalı iken ardı ardına yapılan ölçümlerden elde edilen işaretler birbirinden çıkartılarak, çalışılan işaretin ortam ışığından ve cihaz gürültüsünden minimum seviyede etkilenmesi sağlanabilir. Çıkarma işlemi denklem 4.5'te verilen şekilde yapılmaktadır. Denklem 4.5'te $x(n)$ gürültüden arındırılan lazer işaretini, $s(n)$ ışık açık iken elde edilen lazer işaretini, $d(n)$ ise ışık kapalı iken elde edilen işareti ifade etmektedir.

$$x(n) = s(n) - d(n) \quad (4.5)$$

4.2.2. Welch Güç Spektral Yoğunluğu

Periodogram yönteminde ayrık Fourier dönüşümünü kullanılarak bir işaretin güç spektral yoğunluğunu (Power Spectral Density, PSD) hesaplanmaktadır [211]. Bu yöntem ile bir işareti oluşturan her bir frekansın gücü hesaplanmakta ve zaman alanındaki bir işaret, frekans alanına dönüştürülmektedir.

Bartlett yönteminde işaret birbiri ile örtüşmeyen pencerelere bölünerek periodogramlar hesaplanmakta ve ortalaması alınarak güç spektrumları bulunmaktadır.

Welch metodu ise Bartlett yönteminin geliştirilmiş halidir. Welch metodunda işaret belirlenen oranda birbiri ile örtüşecek şekilde pencerelere bölünmektedir. Her bir pencerenin periodogramlarının ortalaması alınarak PSD hesaplanmaktadır. Welch metodunda işaretin bölümlere ayrılması denklem 4.6'da belirtildiği gibi yapılmaktadır [212–214].

$$x_i(t) = \begin{cases} x(iD + t), & t = 0, 1, 2, \dots, M-1 \\ & i = 0, 1, 2, \dots, L-1 \end{cases} \quad (4.6)$$

İşaretin bölümlere ayrılması sonucu oluşan işaretin i . bölümü x_i , bölümlenmiş işaretin uzunluğu M , i . bölümün başlangıç noktası iD , toplam bölüm sayısı ise L ile gösterilmektedir. D değeri M değerine eşit olduğunda işaretler birbiri ile örtüşmemektedir. Ardışık işaretlerin birbiri ile %50 örtüşebilmesi için D değeri $M/2$ uzunluğunda seçilmelidir. Bölümlenmiş her bir işaretin spektral güç yoğunluğu Denklem 4.7'teki gibi hesaplanabilir.

$$\check{P}_i(f) = \frac{1}{MK} \left| \sum_{t=0}^{M-1} x_i(t) w(t) e^{-j2\pi f t} \right|^2 \quad (4.7)$$

$$i = 0, 1, 2, \dots, L-1$$

Denklem 4.7'de $w(t)$ pencereleme fonksiyonunu, f normalize edilmiş frekans değişkenini temsil etmektedir. Bu tez çalışmasında bölümlenmiş her bir işaretin parçası $w(t)$ ile ifade edilen Hamming penceresi ile pencerelenmektedir. Hamming penceresi işaret işlemede sıklıkla kullanılmakta ve sadece pencere uzunluğundan oluşan bağımsız değişkeni bulunmaktadır. Hamming penceresi Denklem 4.8'deki gibi tanımlanmaktadır [215].

$$w(t) = 0.54 - 0.46 \cos \frac{2\pi n}{M-1} \quad (4.8)$$

$$n = 0, 1, 2, \dots, M-1$$

Denklem 4.8'de M pencere uzunluğunu ifade etmektedir. Hamming pencereleme fonksiyonu kullanıldığında, işaretin birbiriyle örtüşmeyen merkeze yakın verilerine kıyasla, işaretin

kenarlarında örtüşen kısımlarına daha az ağırlık verilmektedir [216]. Buradaki temel düşünce $w(t)$ pencere fonksiyonunu kullanarak işareti kısaltmak ve işareti gürültüden arındırmaktır. Denklem 4.7'deki eşitlikteki K ise normalize sabiti olup Denklem 4.9'daki şekilde ifade edilir.

$$K = \frac{1}{M} \sum_{t=0}^{M-1} w^2(t) \quad (4.9)$$

Welch metoduna göre PSD tahmini Denklem 4.7'de belirtilen pencerelenmiş işaretlerin spektral güç yoğunluklarının ortalamalarına eşittir. Bu eşitlik Denklem 4.10'da gösterilmiştir.

$$P_w = \frac{1}{L} \sum_{i=0}^{L-1} \check{P}_i(f) \quad (4.10)$$

Welch metodunda, örtüşen küçük boyutlu pencerelerin peridiogramlarının ortalaması alındığından, orijinal uzunluktaki işaretin peridiogramına göre varyansı azalmaktadır. Gürültülü işaretlerde Welch metodunun kullanılması klasik peridiograma göre daha iyi sonuçlar vermektedir. Welch PSD dönüşümü ile oluşacak yeni işaretin uzunluğu Denklem 4.11'de ifade edildiği gibi hesaplanabilir. Denklemde $nfft$ PSD dönüşümünde kullanılacak ayrık Fourrrier dönüşümü noktalarının sayısını belirtmektedir.

$$N = \frac{nfft}{2} + 1 \quad (4.11)$$

4.2.3. Yule- Walker Otoregresif Güç Spektral Yoğunluğu

Otoregresif olarak bilinen Yule – Walker AR yöntemi, işareti oluşturan her bir frekans bileşeninin gücünü hesaplamakta kullanılan model tabanlı (parametrik) yöntemlerden birisidir [217]. Bu yöntem ile giriş işareti için ileri yönde tahmin hatası en aza indirilerek AR parametreleri hesaplanmaktadır. İleri tahmin hatasının minimize edilmesi en küçük kareler yöntemi ile yapılmaktadır. Yule – Walker AR yöntemine göre PSD denklem 4.12'de gösterilen eşitlikteki gibi hesaplanmaktadır.


$$\hat{P}_{YW}(f) = \frac{\sigma^2}{|1 + \sum_{k=1}^p \hat{a}_p(k) e^{-j2\pi f k}|^2} \quad (4.12)$$

Denklem 4.12'de modelleme derecesi p ile, AR parametresi tahminleri $\hat{a}$ ile, oto-kovaryans indeksi k ile, frekans ise f ile ifade edilmektedir. σ^2 ifadesi beyaz gürültünün varyansı olup, sabit bir değerdir. Bu yöntemde de Denklem 4.11'deki gibi yeni oluşan işaretin uzunluğu $nfft$ değeri ile belirlenebilmektedir.

4.3. Lazer Işık Kaynağı ve Algılayıcı Sistem Tasarımı

Çalışmada lazer ışık kaynağı ve algılayıcı sistem olarak piyasada da kolaylıkla bulunan bir lazer metre donanımı kullanılmıştır [218]. Kullanılan lazer metre modülü ideal yansıtma şartlarında 3 cm – 40 m metre arasında ölçüm yapabilmektedir. Hedef ile ışık kaynağı arasındaki mesafeyi faz farkı prensibine göre ölçen bu lazer metre modülü sürekli modda çalışmaktadır. Lazer ışığı daha düşük bir frekansta sinüs benzeri bir işaret ile genlik modülasyonu yöntemine göre modüle edilerek hedefe yansıtılmaktadır. Hedeften yansıyan işaret ile hedefe yansıtılan işaret arasındaki faz farkı hesaplanarak mesafe tespiti yapılmaktadır.


Üzerinde 32 bit Stm32 mikro denetleyici bulunan lazer metre modülünün donanım yazılımı deneysel çalışmalar için yeniden programlanmıştır [10,219]. Güncellenen donanım programı ile hedeflerden yansıyan ham lazer işaretleri 50 kHz örnekleme frekansı ile elde edilebilmektedir. Lazer modülü üzerinde bulunan STM32 mikro denetleyici 12 bit çözünürlüğünde analog dijital dönüştürücüye sahiptir ve ölçülen değerler 0- 4095 arasında değişmektedir. Lazer metre modülüne USB seri dönüştürücü modülü eklenerek elde edilen işaretlerin bilgisayar ortamına aktarılması sağlanmıştır. Yapılan bu modifikasyonlar sonucu lazer metre modülü lazer ışık kaynağı ve algılayıcı sistem olarak çalışmaktadır. Cihazdan ölçüm başına 3000 adet ham veri alınabilmektedir. Şekil 4.3'te çalışmada kullanılan lazer ışık kaynağı ve algılayıcı sistem görülmektedir.



Şekil 4.3. Lazer ışık kaynağı ve algılayıcı sistem

Lazer metre modülünde 1mW çıkış gücüne sahip diyot lazer bulunmaktadır. Bu lazer diyot 630-660 nm dalga boyu aralığında çalışmakta ve göz güvenliği açısından Sınıf 2 olarak sınıflandırılmaktadır. Belirtilen aralıkta dalga boyuna sahip lazer ışığı kırmızı renkte olmakta ve çıplak gözle de görülebilmektedir. Hedeften yansıyan lazer ışıklarının algılanması için modülde yüksek ışık duyarlığına sahip APD kullanılmaktadır. APD'ler fotodiyotların aksine yüksek kazanç değerlerine sahiptir. Bu da hedeften yansıyan düşük güçlü bir lazer ışığının algılanmasını mümkün kılmaktadır. APD'lerin kazançları ortamın sıcaklığından etkilenmekte ve kazançları besleme gerilimi ile doğrusal olmayan bir şekilde ayarlanabilmektedir. Algılayıcı sistemde

kullanılan APD'nin kazancı 80V – 115V arasındaki DC besleme gerilimi ile ayarlanabilmektedir[175]. Cihazda bulunan APD gerilim kazancı yazılım ile ayarlanabilmekte ve kazancı çalışma süresince sabit tutulmuştur. Algılayıcı sistemin blok şeması Şekil 4.4'teki gibidir.



Şekil 4.4. Lazer ışık kaynağı ve algılayıcı sistemin blok şeması

Algılayıcı sistemde bulunan faz kilitlemeli çevrim (Phase Lock Loop, PLL) modülü ile 200 Mhz frekansına kadar 3 farklı kanalda saat frekansı oluşturulabilmektedir [220–222]. PLL ile lazer diyot ışığı modüle edilmektedir. İstenilen frekansta modüle edilen lazer ışığı hedefe yansıtılarak hedeften yansıyan işaret ile referans işareti arasındaki faz farkı hesaplanabilmekte ve hedefin uzaklığı tespit edilebilmektedir. Yeniden programlanan algılayıcı sistemde bulunan PLL devresi devre dışı bırakılabilmekte ve hedefe modüle edilmemiş lazer ışığı da gönderilebilmektedir.

Lazer işaretleri ile materyal tanımlama çalışmasında PLL devresi devre dışı bırakılarak hedefe sürekli modda çalışan lazer ışığı yansıtılmıştır.

4.4. Materyal ve Yöntem

Bu çalışmada tek bir lazer işareti ve derin öğrenme algoritması kullanılarak materyal sınıflandırılması yapılmıştır.

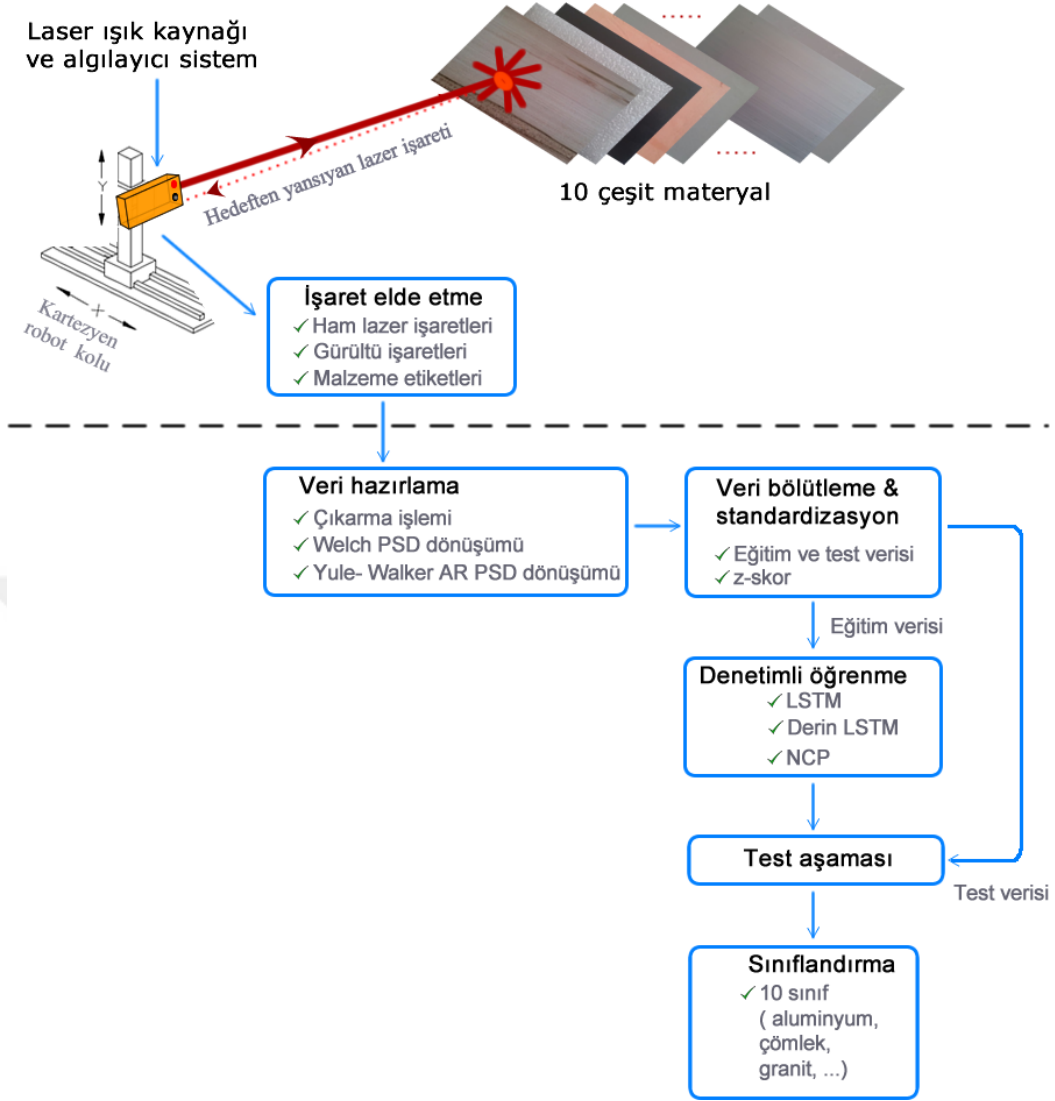
4.4.1. Sistem Tasarımı

Bu çalışmada önerilen yöntemde her bir materyal tanımlama işlemi için sadece bir adet lazer işaretinin kullanılması temel alınmıştır. Derin öğrenme ağlarının etkin bir şekilde eğitilebilmesi için yüksek sayıda veriye ihtiyaç bulunmaktadır. Bu amaçla tasarlanan deney düzeneğinde farklı hedefler sisteme sabitlenebilmekte ve tasarlanan kartezyen robot kolu kullanılarak sabit bir uzaklıktaki hedeflerin farklı noktalarından çok sayıda lazer işareti örneği alınabilmektedir. Bu şekilde her bir materyal türüne ait yeterli sayıda lazer işareti örneği elde edilebilmekte ve çalışmada önerilen derin öğrenme modelleri etkin bir şekilde eğitilebilmektedir. Şekil 4.5'te tasarlanan deney düzeneği görülmektedir.



Şekil 4.5. Tasarlanan deney düzeneği ve materyalin düzeneğe yerleştirilmesi

Materyal tanımlama çalışması iki adımdan oluşmaktadır. İlk olarak uzak mesafedeki bir materyale modüle edilmemiş sürekli moddaki bir lazer ışığı kısa süreli olarak yansıtılır ve materyalden yansıyan ham lazer işaretleri kayıt altına alınmaktadır. İkinci adımda ise lazer işareti veri hazırlama adımlarından sonra materyal tanımlaması için önerilen derin öğrenme modellerinde eğitilmektedir. Materyal tanımlama süreci Şekil 4.6'da verilmiştir.



Şekil 4.6. Önerilen hedef sınıflandırma yaklaşımı


4.4.2. Materyal Türleri

Lazer işaretleri ile materyal tanımlama çalışması için yapılan deneysel çalışmalarda Tablo 4.1’de gösterildiği gibi 6 ana materyal grubundan oluşan 10 çeşit materyal kullanılmıştır.

Tablo 4.1. Çalışmada kullanılan materyaller

Grup	Materyal
Plastik	Polietilen
Metal	Alüminyum, magnet
Kumaş	Siyah kumaş
Ahşap	İhlamur
Cam	Buzlucam, cam
Yapı malzemesi	Granit, yapay mermer, çömlek

Çalışmada önerilen derin öğrenme modellerinin eğitiminde materyal sınıfları arasında dengenin sağlanabilmesi ve eşit miktarda örnek verinin elde edilebilmesi için materyal boyutları eşit tutulmuştur. Bu amaçla her bir materyalin eni 10 cm, boyu ise 15 cm olacak şekilde dikdörtgen biçiminde kesilmiştir. Çalışmada kullanılan materyaller ve lazer işareti elde etme aşamasında materyal üzerindeki lazer ışığı Şekil 4.7’de görülmektedir.




Şekil 4.7. Deneyde kullanılan materyaller ve materyal üzerindeki örnek lazer ışığı

4.4.3. Veri Toplama Adımları

Derin öğrenme mimarisi ile 10 farklı nesnenin birbirinden yüksek başarımlı olarak ayrıştırılması için kapsamlı bir veri setine ihtiyaç duyulmaktadır. Bu amaçla aşağıda belirtilen şartlarda veri seti oluşturulmuştur.

Deneyde yapılan çalışmalar doğrudan güneş ışığı almayan laboratuvar ortamında, gündüz saatlerinde ve havanın da güneşli olduğu bir zaman diliminde yapılmıştır. Yapılan deneyde çalışmada standardizasyonun sağlanması amacıyla lazer ve hedef materyal arasında sabit 2 m mesafenin olduğu bir deney düzeneği tasarlanmıştır [223–225]. Tasarlanan sistemde lazer algılayıcı sistem Kartezyen robotun üzerine sabitlenerek materyallerin istenilen noktalarından lazer işaretleri alınabilmektedir. Veri alma işlemleri Kartezyen robot yardımı ile materyalin sağ alt tarafından başlayarak, sırası ile sağdan sola doğru ve sonrasında ise soldan sağa doğru olacak şekilde yaklaşık 5 mm aralıklarla yapılmıştır. Şekil 4.8’de Kartezyen robotun alüminyum materyalinden veri toplama süreci ve Kartezyen robotun hareket düzeni görülmektedir.



Şekil 4.8. Alüminyum materyalinden veri toplama aşaması ve ölçüm almada kullanılan Kartezyen robotun hareket düzeni a) Deney düzeneği b) Lazer ile tarama yöntemi

Lazer modülünün karanlık akım etkisi ve ortam ışıklarının etkisi ile lazer işaretleri gürültülü olabilmektedir. Bu amaçla ölçümler esnasında Kartezyen robotun her bir konumunda, lazer ışık kaynağı kapatılmış ve cihazın/ortam ışıklarının oluşturduğu gürültülü işaretler ayrıca kayıt altına alınmıştır. Bu işlemin ardından Kartezyen robotun aynı konumunda lazer ışığı açılmış ve materyalden yansıyan lazer işaretleri kayıt altına alınmıştır. Kartezyen robotun hareketi esnasında küçük boyutlu titreşimler meydana gelebilmektedir. Oluşan titreşimlerin etkisinden kaçınmak amacı ile robot kolunun hareketinden 3sn sonra ölçümlere başlanmıştır.

Ölçümler esnasında nesnelerin arkasına ışık yansıtma oranı düşük seviyede olan mat siyah renkte bir kumaş yerleştirilmiştir. Bu şekilde şeffaf olan camdan ve buzlu camdan yansıyan lazer işaretleri ölçülürken arkaplan ile etkileşimi minimum seviyede tutulmaya çalışılmıştır. Şeffaf materyallerde ölçüm esnasında arkaplanın olası yansımalarını ölçmek için, önce arkaplanın tek bir noktasından lazer ışığı açık iken ve lazer ışığı kapalı iken ölçümler yapılmıştır. Elde edilen bu işaretler referans işareti olarak kullanılmak üzere kaydedilmiş ve bu işlemin sonrasında ölçümlere başlanmıştır. Cam ve buzlu cam için ölçülen bu referans işaretleri veri hazırlama aşamasında çıkarma işleminde ayrıca kullanılmıştır.

Çalışmada; her bir materyal için 391 adet cihaz gürültü işareti, 391 adet lazer işareti ölçülmüş ve işaretler CSV dosya formatında kayıt altına alınmıştır. CSV dosyalarında bulunan veriler MATLAB programlama ortamında tek bir dosyada birleştirilmiştir. Çalışmada kullanılan 10 materyal için toplamda 3910 adet lazer işareti ve 3910 adet ortam/cihaz gürültü işareti ölçülmüştür.

Tüm deneysel çalışmalar Intel Core i7-5500U 2.40 GHz CPU, 8 GB bellek ve 2 GB NVIDIA GeForce 840M grafik kartına sahip bir bilgisayarda gerçekleştirilmiştir. Veri hazırlama ve sınıflandırma işlemlerinde MATLAB programlama ortamı ve Python programlama dili kullanılmıştır.


4.4.4. Veri Hazırlama Adımları

Materyallerden işaret elde etme işlemi sonrası, gürültülü ham lazer işaretlerinin karakteristik özelliklerinin görülebilmesi için her bir işaretin enerjisi Denklem 4.13’de verilen şekilde hesaplanmıştır. Denklem 4.13’de $s_i(n)$ i . ham lazer işaretini, N ise işaretin uzunluğunu temsil etmektedir [226]. Hesaplanan her bir enerji değeri Denklem 4.14’de verilen minimum-maksimum normalleştirme kriterine göre $[0,1]$ aralığında doğrusal olarak dönüştürülmüştür. Denklem 4.14’de e_i ham lazer işaretinin enerjisini, z_i ise normalize edilmiş veriyi, L ise toplam ölçüm sayısını ifade etmektedir. Şekil 4.10’da materyallerden yansıyan ham lazer işaretlerinin normalize edilmiş enerji değerleri görülmektedir.

$$e_i = \sum_{n=1}^N |s_i(n)|^2 \quad (4.13)$$

$$z_i = \frac{e_i - \min(e)}{\max(e) - \min(e)} \quad i = 1, 2, \dots, L \quad (4.14)$$

Şekil 4.9’da gürültülü ham lazer işaretlerinin her bir materyal türü için minimum, maksimum, ilk çeyrek, 3.çeyrek ve aykırı değerleri gösteren kutu grafiği görülmektedir. Kutu grafiği tek değişkenli verilerin incelenmesinde etkili bir yöntemdir. Kutu grafiği her bir materyalden ölçülen 391 adet ham lazer işaretinin ortalama enerji dağılımlarını göstermektedir.




Şekil 4.9. Gürültülü lazer işaretlerinin her bir materyal türü için enerji dağılımlarını gösteren kutu grafiği

Şekil 4.9'daki kutu grafiği incelendiğinde, farklı gün ve saatlerde her bir materyal için kaydedilen gürültülü lazer işaretlerinin ortalama enerjisinin genellikle aynı aralıkta olduğu görülmektedir. Lazer modülünün karanlık akım etkisi ve ortam ışıklarının sebep olduğu gürültüleri tespit etmek ve işaretleri gürültüden arındırmak için lazer ışığı açık iken yapılan her bir ölçüm noktasında öncelikle lazer ışığı kapatılarak ölçümler yapılmıştır. Gürültülü ham lazer işaretlerinden lazer ışığı kapatılarak elde edilen cihaz/ortam gürültü işaretleri çıkartılarak işaretlerdeki gürültü miktarı azaltılabilmektedir. Bu amaçla çıkarma işlemi yapılmıştır.


Çıkarma işleminden sonra cam ve buzlu cam için elde edilen lazer işaretlerinden ölçümler esnasında kaydedilen referans işaretleri (arkaplan yansıma işaretleri) de ayrıca çıkarılmıştır. Bu işlemdeki amaç, cam ve buzlu camın arkasına yerleştirilen arkaplanın bu materyallerden elde edilen lazer işaretlerine etkisini minimize etmektir. Arkaplanın yansıma işaretinden, ayrıca lazer ışığı kapalı iken ölçülen gürültü işareti de çıkarılmıştır.


Çıkarma işlemi sonucunda oluşan lazer işaretlerinin materyal türlerine göre ortalama enerji dağılımlarına bakıldığında, enerji dağılımlarında materyal türlerine göre daha belirgin ayrışmalar olduğu görülmektedir. Çıkarma işlemi sonucunda oluşan lazer işaretlerinin her bir materyal sınıfı için ortalama enerjilerinin dağılımı ve aykırı değerleri Şekil 4.10'daki kutu grafiğinde görülmektedir.



Şekil 4.10. Çıkarma işlemi sonrası lazer işaretlerinin her bir materyal türü için ortalama enerji dağılımlarını ve aykırı değerlerini gösteren kutu grafiği

Şekil 4.11’de 10 farklı materyalden yansıyan gürültülü lazer işaretleri, cihaz/ortam ışığı gürültü işaretleri ve çıkarma işleminin sonucunda elde edilen işaretlere ait birer örnek görülmektedir.





Şekil 4.11. 10 farklı materyal için ham lazer işaretleri ve gürültüsüz lazer işaretleri

Çalışmada ortam gürültüsünün ve ortam ışığının etkisini azaltmak için yapılan çıkarma işleminden sonra her bir işaretin Welch ve Yule- Walker AR modeline göre spektral güç yoğunluğu hesaplanmıştır. Güç yoğunluğu hesaplamalarında $nfft$ değeri değiştirilerek farklı boyutlarda işaretler elde edilebilmektedir. Tablo 4.2’de çalışmada kullanılan ham lazer işaretinin uzunluğu ile Welch ve Yule- Walker AR modellerine göre PSD dönüşümleri sonrası oluşan işaretlerin uzunlukları verilmiştir.

Tablo 4.2. Çalışmada kullanılan ham lazer işaretinin uzunluğu ve Welch PSD, Yule- Walker AR modellerine göre PSD dönüşümleri sonrası oluşan işaretlerin uzunlukları


İşaretin dönüşüm yöntemi	Parametre değeri ($nfft$)	İşaretin uzunluğu
Çıkarma işlemi sonrası ham lazer işareti	-	3000
Welch PSD	62	32
	124	63
Yule- Walker AR PSD	62	32
	124	63


Bu veri hazırlama adımlarının ardından, Tablo 4.2’den de görülebileceği üzere her bir materyal için 3000 noktadan oluşan ham lazer işaretlerinin yerine 32 ve 63 noktadan oluşan 2 farklı işaret türü elde edilmiştir. Bu çalışmada, farklı uzunluklardan oluşan işaret dönüşümleri Tablo 4.3’te verilen kombinasyonlarda kullanılarak önerilen derin öğrenme modellerinin başarımına etkisi incelenmiştir.

Tablo 4.3. Derin öğrenme modellerinin girişinde kullanılan işaretlerin kombinasyonları

İşaret türleri	İşaretin uzunluğu	Toplam işaret sayısı (10 materyal için)
Çıkarma işlemi sonrası ham lazer işareti	3000	3910
Welch PSD	32	3910
	63	3910
Yule- Walker PSD	32	3910
	63	3910
Welch PSD + Yule- Walker AR PSD	32 x 2	3910 x 2
Welch PSD + Yule- Walker AR PSD	63 x 2	3910 x 2


Çıkarma işleminden sonra oluşan ham lazer işaretleri kullanılarak Welch metoduna ve 4. dereceden Yule – Walker AR metoduna göre PSD hesaplandığında oluşan 32 ve 63 noktadan oluşan işaret örnekleri Şekil 4.12’de görülmektedir.





Şekil 4.12. 10 farklı materyal için çıkarma işlemi sonrasında Welch ve Yule – Walker AR metoduna göre hesaplanan PSD dönüşümlerine birer örnek

Her bir materyali temsil eden kategori etiketi Welch metoduna göre spektral güç yoğunluklarını ve Yule Walker AR metoduna göre spektral güç yoğunluklarını temsil etmektedir. Granit materyali için veri hazırlama işlemi sonrası elde edilen işaret örnekleri Şekil 4.13'te görülmektedir.



Şekil 4.13. Deneysel çalışmalarda kullanılan granit materyali, çıkarma işlemi sonrası ham lazer işareti, Welch ve Yule Walker AR methoduna göre PSD değerleri

4.4.5. Önerilen Derin Öğrenme Modelleri

Bu tez çalışmasında lazer işaretleri ile materyal türü sınıflandırması için LSTM modeli, derin LSTM modeli ve NCP modeli ile oluşturulmuş seyrek yapıdaki derin öğrenme modelleri önerilmiştir.

LSTM Modeli ve Model Parametreleri

Lazer işaretlerinden materyal tanımlama sürecini gerçekleştirmek için veri hazırlama işlemi sonrasında elde edilen bu işaretler birer özellik olarak (63 nokta uzunluğundaki 2 özellik) zaman serisi şeklinde önerilen derin öğrenme ağına girdi olarak sunulmuştur. Sınıflandırma işlemi için önerilen LSTM modelinin katmanları ve parametreleri Tablo 4.4'de verilmiştir. Çalışmadaki gizli katman sayıları, yapıları ve katmanlardaki gizli birim sayıları deneme yanılma yöntemi ile seçilmiştir.

Tablo 4.4. LSTM modelinin katmanları ve parametreleri


Katman No	Katman Türü	Özellikleri
Katman 1	Sıralı giriş katmanı	Sıralı giriş (2 x 63 boyutunda)
Katman 2	LSTM katmanı	64 gizli birim
Katman 3	Tam bağlı katman	10 gizli birim
Katman 4	Softmax katmanı	Softmax aktivasyon fonksiyonu
Katman 5	Sınıflandırma çıkış katmanı	10 sınıf

Bu çalışma için önerilen derin öğrenme modelindeki LSTM ağı; 64 gizli birim içeren bir LSTM katmanına sahiptir. Birinci katmandaki sıralı giriş katmanı, işaret gibi ardışık verileri bir sonraki katmana sıralı bir şekilde giriş olarak vermeye yaramaktadır. LSTM katmanı ise girişindeki sıralı veriler arasındaki uzun vadeli bağımlılıkları öğrenmektedir. Bu ağlar yapısı gereği uzun vadeli hafıza hücrelerine sahiptir. LSTM ağları ayrıntılı olarak 3. bölümde incelenmiştir. 64 gizli birim çıktısı olan LSTM katmanındaki verilerin Softmax katmanına aktarılabilmesi için LSTM katmanından sonra 10 gizli birimden oluşan tam bağlı katman kullanılmıştır. Bu katman önceki katmandaki verileri birbiri ile ilişkilendirerek 10 gizli birimden oluşan çıkışına aktarır. Softmax katmanı bir önceki katmandan gelen girdi değerlerinin belirli bir sınıfa ait olma olasılığını hesaplayarak sonucu bir sonraki katmana aktarmaktadır. Sınıflandırma çıkış katmanında ise ağa girilen veriye göre yapılan sınıflandırma işlemin sonucunu kategorik etiket bilgisi olarak dışarı aktarılmaktadır. LSTM modelinin eğitim aşamasında kullanılan hiper-parametreler Tablo 4.5'te verilmiştir.

Tablo 4.5. LSTM modelinin eğitim aşamasında kullanılan hiper-parametreler

Parametre adı	Parametre değeri
Maksimum eğitim tur (epoch) sayısı	1500
Veri yığını (mini-batch) boyutu	512
Öğrenme katsayısı	0,001
Optimizasyon algoritması	Adam

Sınıflandırma işlemi için önerilen LSTM modelinin parametreleri ve veri hazırlama aşamasından geçirilmiş lazer işaretlerinin ağa giriş şekli Şekil 4.14’de verilmiştir.



Şekil 4.14. Çalışmada önerilen LSTM modeli ve veri hazırlama sonrası oluşan işaretlerin giriş olarak kullanımı

Derin LSTM Modeli ve Model Parametreleri


Derin LSTM olarak adlandırılan bu modelde bir önceki LSTM modelindeki 64 gizli birimden oluşan LSTM katmanı yerine, 64 gizli birimden oluşan 2 adet LSTM katmanı art arda kullanılmıştır. Derin LSTM modelinin katmanları ve parametreleri Tablo 4.6’da verilmiştir. Derin LSTM modelinin eğitim aşamasında kullanılan hiper-parametreler önceki LSTM modelindeki hiper-parametrelerle aynı seçilmiş, sadece veri yığınının boyutu 256 olarak değiştirilmiştir.

Tablo 4.6. Derin LSTM modelinin katmanları ve parametreleri

Katman No	Katman Türü	Özellikleri
Katman 1	Sıralı giriş katmanı	Sıralı giriş (2 x 63 boyutunda)
Katman 2	LSTM katmanı	64 gizli birim
Katman 3	LSTM katmanı	64 gizli birim
Katman 4	Tam bağlı katman	10 gizli birim
Katman 5	Softmax katmanı	Softmax aktivasyon fonksiyonu
Katman 6	Sınıflandırma çıkış katmanı	10 sınıf

NCP Modeli

Veri hazırlama adımlarındaki çıkarma işlemi ve Welch PSD dönüşümü sonrası oluşan 32 nokta boyutundaki lazer işareti, NCP derin öğrenme ağına giriş olarak uygulanmaktadır. Sınıflandırma işlemi için önerilen NCP derin öğrenme mimarisinin blok şeması Şekil 4.15’de görülmektedir. Çalışmadaki inter-nöron sayısı, RNN hücre yapısındaki komut nöron sayısı ve her bir katman arasındaki bağlantı sayısı deneme yanılma yöntemi ile seçilmiştir.



Şekil 4.15. NCP derin öğrenme modelinin blok şeması


Bu çalışmada önerilen seyrek yapıdaki NCP modelinin nöron sayıları ve bağlantı konfigürasyon bilgileri Tablo 4.7’de verilmiştir. Tablo 4.7’de S_n her bir sensör nöronundan ara katmandaki inter-nöronlara bağlanan sinaps sayısını, I_n her bir inter-nöronundan komut-nöron katmanına bağlanan sinaps sayısını, R_n komut-nöronlarından kaç tanesinin RNN yapıda olduğunu sayısını ve M_n ise her bir motor-nöronuna önceki katmandan kaç tane sinaps bağlanacağını göstermektedir.

Tablo 4.7. NCP derin öğrenme modelinin parametreleri

Parametre adı	Parametre değeri
Inter-nöron sayısı	12
Komut-nöron sayısı	7
Motor-nöron sayısı	10
S_n	8
I_n	6
R_n	1
M_n	4
Toplam nöron sayısı	29
Toplam bağlantı sayısı	113

Tablo 4.7’de görüldüğü üzere ara katmanlar arasındaki bağlantı sayısı sınırlı olduğu için ağın hesaplama maliyeti benzer yapıdaki tam bağlantılı bir ağ mimarisine göre büyük oranda

düşmektedir. 10 sınıftan oluşan materyal tanımlama çalışmasında sınıflandırma olasılıklarının hesaplanabilmesi için NCP mimarisinin son katmanına Softmax katmanı eklenmiştir. Yapısı gereği Softmax katmanından önceki katmanın, sınıf sayısı kadar nörondan oluşması gerektiğinden NCP ağında motor-nöron sayısı 10 olarak seçilmiştir. Sensör nöronlarının sayısı giriş verisinin boyutuna bağlı olarak değişmektedir. NCP mimarisi ile yapılan eğitimde kullanılan hiper parametreler; maksimum eğitim tur sayısı 400, öğrenme katsayısı 0,001, optimizasyon algoritması Adam, veri yığınının boyutu ise 512 şeklinde seçilmiştir. Sınıflandırma işlemi için önerilen NCP modelinin parametreleri ve veri hazırlama aşamasından geçirilmiş lazer işaretlerinin ağa giriş şekli Şekil 4.16'da verilmiştir.



Şekil 4.16. NCP model parametreleri ve lazer işaretlerinin modele sunum şekli

4.5. Başarım Değerlendirmesi

Bu çalışmada önerilen derin öğrenme mimarilerinin sınıflandırma başarımı 3. Bölümde anlatılan 10 kat çapraz doğrulama yöntemi ile değerlendirilmiştir. 10 kat çapraz doğrulama adımlarında oluşturulan %90 eğitim ve %10 test veri setlerinin z-skorumları Denklem 4.15'te belirtilen şekilde hesaplanmış ve ardından önerilen derin öğrenme modellerinin eğitim süreci başlatılmıştır. Her bir çapraz doğrulama adımında 10 adet materyal için veri setinin yaklaşık %90'ını olan 3519 adet lazer işareti eğitim için, %10'u olan 391 adet lazer işareti ise test için kullanılmıştır.

$$v' = \frac{v - \bar{A}}{\sigma} \quad (4.15)$$

Denklem 4.15'te v normalize edilmek istenilen niteliği, $\bar{A}$ normalize edilmek istenilen niteliğin ortalamasını, σ normalize edilmesi istenilen niteliğin standart sapmasını, v' ise z-skoru hesaplanmış değerini ifade etmektedir.

Literatürde mevcut çalışmalarda başarım değerlendirme için genel olarak sınıflandırma doğruluğu kullanılmaktadır. Dengeli bir veri setinde doğruluk kriterinin kullanılması makul bir

ölçüt olduğundan bu tez çalışmasında da sınıflandırma doğruluk kriteri kullanılmıştır. Her bir malzemenin sınıflandırma doğrulunun daha iyi incelenebilmesi için bu çalışmada ayrıca karışıklık matrisi de kullanıldı. Karışıklık matrisinde her bir malzeme sınıfı için *GP*, *GN*, *YP* ve *YN* sayıları ve malzemelerin doğru veya yanlış dahil edildikleri sınıflar ayrıca incelenilmektedir. Çalışmada sınıflandırma doğruluk kriterinin yanı sıra kesinlik, geri çağırma ve F1-skor değerlendirme ölçütleri de bu çalışmada kullanılmıştır.


4.6. Bulgular ve Tartışma

Bu bölümdeki deneysel sonuçlar 4 alt başlıkta incelenmiştir. Birinci bölümde ham lazer işaretlerinin ve boyutu düşürülmüş lazer işaretlerinin LSTM ve Derin LSTM modellerindeki başarımları incelenmiştir. 2. Bölümde boyutu düşürülmüş lazer işaretlerinin NCP modelindeki başarımları incelenmiştir. 3. Bölümde çıkarma işlemi sonrası ham lazer işaretlerinin FFT değerleri hesaplanarak klasik makine öğrenmesi algoritmalarındaki sınıflandırma sonuçları da incelenmiştir. 4. Bölümde ise önerilen derin öğrenme modellerinin literatürdeki materyal tanımlama çalışmaları ile karşılaştırılması yapılmıştır.

4.6.1. LSTM ve Derin LSTM Modellerinin Sınıflandırma Sonuçlarının İncelenmesi

Bu bölümde sonuçlar iki kategori altında incelenmiştir. Bunlardan birincisi çıkarma işleminin bir sonucu olarak elde edilen ham lazer işaretlerinden materyal türü tanımlama ve ikincisi ise veri hazırlama işlemi sonrası boyutu indirgenen lazer işaretlerinden materyal türü tanımlama şeklindedir. Sınıflandırma sonuçları hem ham lazer işaretlerinin hem de boyutu indirgenmiş lazer işaretlerinin LSTM ve Derin LSTM modelleri ile tanımlanmasını içeren bulguları içermektedir. Bunun yanı sıra boyutu indirgenmiş işaretlerin LSTM ağı ile tanımlanması için farklı parametreler ve farklı katman yapıları test edilmiş ve karşılaştırmalı sonuçlar verilmiştir.

Deneysel çalışmalarda elde edilen ham lazer işaretlerinin uzunluğu 3000 noktadan oluşmaktadır. Ortam/cihaz gürültüsünü gidermek için lazer ışığı kapalı ve açık iken ölçümler ardı ardına alınmıştır. Veri hazırlama aşamasında bu işaretler birbirinden çıkartılarak işaretlerdeki gürültü oranı azaltılmaya çalışılmıştır. Sınıflandırma çalışmalarında ham lazer işaretleri LSTM ve Derin LSTM modellerinde ayrı ayrı eğitime tabi tutularak başarımları karşılaştırılmıştır. Ham lazer işaretlerinin eğitildiği LSTM ve Derin LSTM modellerindeki çapraz doğrulama adımlarından biri için doğruluk grafiği Şekil 4.17’de görülmektedir.




Şekil 4.17. Ham lazer işaretleri için doğruluk grafikleri a) Ham lazer işaretlerinin eğitildiği LSTM modelindeki çapraz doğrulama adımlarından biri için doğruluk grafiği b) Ham lazer işaretlerinin eğitildiği Derin LSTM modelindeki çapraz doğrulama adımlarından biri için doğruluk grafiği

Tablo 4.8’de görüleceği üzere ham lazer işaretlerinin her iki LSTM modelinde eğitim süresi yaklaşık 12 saat sürmektedir. Gürültüden arındırılmış ham lazer işaretlerinin orjinal boyutta eğitime tabi tutulması güçlü bir sistem gerektirmektedir. Bilindiği üzere derin öğrenme modellerinde yüksek boyutlu işaretleri işlemek zaman alıcı ve maliyetli olmaktadır.

Tablo 4.8. Ham lazer işaretlerinin eğitim ve test süreleri, sınıflandırma başarımları sonuçları

Derin öğrenme modeli	Eğitim süresi (sn.)	Tahmin süresi (sn.)	Geri çağırma(%)	Kesinlik (%)	F1- skor (%)	Doğruluk (%)
LSTM	40174	0,0024	73,91	74,2	74,04	74,19 ± 25.14
Derin LSTM	42707	0,0025	81,13	80,82	80,97	80,82 ± 19.37

Yüksek hesaplama maliyeti ve uzun eğitim sürelerinden dolayı ikinci yöntem olarak, gürültüden arındırılan ham lazer işaretleri Welch PSD ve Yule-Walker AR metoduna göre PSD değerleri hesaplanarak çok daha düşük boyutta (63 nokta) ve 2 farklı özellikten oluşan işaretlere dönüştürülmüştür. Ham lazer işaretinden Welch metoduna göre bir işaretin hesaplanma süresi 0,026 sn, Yule -Walker metoduna göre bir işaretin hesaplanması ise 1,0016 sn sürmüştür. Bu işlemler sonucunda elde edilen boyutu düşürülmüş lazer işaretlerinin kullanıldığı ikinci yöntemde lazer işaretleri LSTM ve Derin LSTM ağında ayrı ayrı eğitime tutularak, her iki LSTM modelinin başarımları değerlendirilmeleri de yapılmıştır. İkinci yöntemdeki boyutu düşürülmüş lazer işaretleri için LSTM ve Derin LSTM modellerindeki çapraz doğrulama adımlarından birinin doğruluk grafiği Şekil 4.18’de görülmektedir.



Şekil 4.18. Boyutu düşürülmüş lazer işaretleri için doğruluk grafikleri a) Boyutu düşürülmüş lazer işaretlerinin eğitildiği LSTM modelindeki çapraz doğrulama adımlarından biri için doğruluk grafiği b) Boyutu düşürülmüş lazer işaretlerinin eğitildiği Derin LSTM modelindeki çapraz doğrulama adımlarından biri için doğruluk grafiği

Tablo 4.9'daki sınıflandırma sonuçları incelendiğinde Welch güç yoğunluk işaretleri ve Yule-Walker güç yoğunluk işaretlerinin birlikte kullanımının LSTM derin öğrenme modelinin başarımını önemli ölçüde artırdığı görülmektedir. Bu şekildeki bir işaret dönüşümü 3000 boyutlu gürültülü ham lazer işaretlerini gürültünün etkisinden arındırmakta ve işaretin boyutunu da önemli ölçüde azaltmaktadır [227]. Düşük boyutlu işaretlerin kullanılması ise LSTM derin öğrenme modelinin işlem maliyetini ve süresini de önemli ölçüde azaltmaktadır.


Tablo 4.9. Boyutu düşürülmüş lazer işaretlerinin eğitim ve test süreleri, sınıflandırma başarımları sonuçları

	İşaretin türü			
	Welch PSD dönüşümü	Yule-Walker AR PSD dönüşümü	Welch PSD dönüşümü + Yule-Walker AR PSD dönüşümü	
İşaretin boyutu (nokta)	63	63	2 x 63	2 x 63
Derin öğrenme modeli	LSTM	LSTM	LSTM	Derin LSTM
Toplam eğitim süresi (sn.)	924	931	977	1111
Tahmin süresi (sn.)	1,2e-05	1,2e-05	1,3e-05	1,37e-05
Geri çağırma (%)	93,29	93,64	93,83	93,66
Kesinlik (%)	93,07	93,43	93,63	93,33
F1 – skor (%)	93,18	95,28	93,73	93,49
Doğruluk (%)	93,07± 1,11	93,43± 1,47	93,63 ± 1,56	93,32± 0,93

LSTM modelinde boyutu düşürülmüş lazer işaretlerinin eğitimi, ham lazer işaretlerine kıyasla sistemin başarımını ve hızını önemli ölçüde artırmıştır. Çalışmada kullanılan her 2 LSTM modelinde de veri boyutunun büyüklüğü eğitim süresini önemli oranda arttırmaktadır. Veri boyutunun indirgenmesi ile eğitim süresi eğitim tur başına 28,47 saniyeden 0,65 saniyeye düşmüş ve başarımları oranı ise %12,81 artarak %93,63'e kadar yükselmiştir. Boyutu indirgenmiş lazer

işaretlerinin eğitim süresinin ham lazer işaretlerinin eğitim süresinden yaklaşık olarak 44 kat daha hızlı olduğu görülmektedir.

Çalışmada, boyutu indirgenmiş lazer işaretlerinin birlikte kullanıldığı ve LSTM modelinin eğitim sürecindeki her bir çapraz doğrulama aşamasında ayrıntılı başarımlar değerlendirilmiştir. Çalışmada, test verileri kullanılarak önerilen LSTM modelinin tahmin doğruluğunu daha iyi anlamak için karışıklık matrisi kullanılmıştır. Test veri setinde en yüksek doğruluk başarımına sahip karışıklık matrisi Şekil 4.19’da verilmiştir.



Şekil 4.19. Çapraz doğrulama adımlarında test verisinde en yüksek başarıma sahip karışıklık matrisi

Çapraz doğrulama adımlarındaki tahmin etme sonuçları incelendiğinde en yüksek sonucun %95,91 olduğu görülmüştür. 391 test verisi içeren karışıklık matrisi incelendiğinde siyah kumaş, ıhlamur, magnet ve yapay mermerin tamamen diğerlerinden ayrıştırılabildiği görülmüştür. Tahmin sonuçlarında ise en düşük doğruluk oranının %91,30 şeklinde olduğu görülmüştür. En düşük doğruluk oranına sahip test veri setine ait karışıklık matrisi Şekil 4.20’de görülmektedir. Şekildeki karışıklık matrisi incelendiğinde, alüminyum/buzlu cam, granit/cam, granit/çömlek/polietilen materyallerinin birbirlerinin yerine tahmin edildiği görülmektedir.

Tablo 4.10 incelendiğinde LSTM derin öğrenme modelindeki LSTM katmanında gizli birim sayısının artmasıyla, sistemin ortalama doğruluk oranının ve eğitim süresinin de arttığı, 128 gizli birimde ise başarımın düşmeye başladığı görülmüştür.

4.6.2. NCP Modelinin Sınıflandırma Sonuçlarının İncelenmesi


Deneyisel çalışmalarda, NCP mimarisi kullanılarak ara katmanda bulunan farklı sayıdaki nöronlar ve nöronlara arasındaki farklı sayıdaki bağlantılar kullanılarak test edilmiştir. Welch PSD yönteminde parametre sayıları değiştirilerek farklı boyutlarda elde edilen boyutu indirgenmiş lazer işaretleri NCP ağında giriş işareti olarak kullanılmıştır. Ayrıca LSTM modelindeki çalışma ile karşılaştırma yapılabilmesi için, çıkarma işleminden sonra oluşan 3000 boyutlu lazer işaretlerine Welch PSD ve Yule-Walker AR PSD dönüşümü uygulanarak elde edilen çok daha düşük boyuttaki (32 ve 63 nokta) işaretler farklı kombinasyonlarda eğitime tabi tutulmuştur. Elde edilen sonuçlar Tablo 4.11’de verilmiştir.

Tablo 4.11. Boyutu düşürülmüş lazer işaretlerinin kullanıldığı NCP modelindeki ortalama sınıflandırma başarımları

İşaret türleri	İşaretin boyutu (nokta)	Derin öğrenme modeli	Eğitim tur sayısı	Doğruluk (%)
Welch PSD dönüşümü	63	LSTM	1500	93,07 ± 1,11
Yule-Walker AR PSD dönüşümü	63	LSTM	1500	93,43 ± 1,47
Welch PSD dönüşümü + Yule-Walker AR PSD dönüşümü	2 x 63	LSTM	1500	93,63 ± 1,56
Welch PSD dönüşümü	63	NCP	400	91,23 ± 1,32
	32	NCP	400	92,66 ± 1,50
Yule-Walker AR PSD dönüşümü	63	NCP	400	22,23 ± 1,12
	32	NCP	400	21,41 ± 1,18
Welch PSD dönüşümü + Yule-Walker AR PSD dönüşümü	2 x 63	NCP	400	90,66 ± 1,83
	2 x 32	NCP	400	91,51 ± 1,41

Tablo 4.11 incelendiğinde 32 nokta uzunluğundaki Welch güç yoğunluk işaretlerinin NCP mimarisinde kullanımının diğer olasılıklardaki işaretlerin kullanımına oranla daha başarılı sonuçlar ürettiği görülmektedir. Düşük boyuttaki bir işaretin ve NCP mimarisi ile seyrek yapıdaki bir ağının birlikte kullanımı işlem maliyetini önemli ölçüde düşürmektedir. Yule-Walker AR metoduna göre PSD değerleri hesaplanan işaretlerin eğitiminde NCP mimarisinin başarısız olduğu görülmektedir.

Yapılan deneyisel uygulamalarda Welch PSD dönüşümü ile 32 boyuta kadar düşürülmüş lazer işaretlerinin eğitildiği NCP modelindeki çapraz doğrulama adımlarında en yüksek sonucu veren sonuçlardan biri için kayıp grafiği ve doğruluk grafiği Şekil 4.21’de görülmektedir.



Şekil 4.21. Welch PSD metodu ile boyutu indirgenmiş işaretlerin NCP modelindeki kayıp ve doğruluk grafikleri a) Boyutu düşürülmüş lazer işaretlerinin eğitildiği NCP modelindeki çapraz doğrulama adımlarından biri için kayıp grafiği b) Boyutu düşürülmüş lazer işaretlerinin eğitildiği LSTM modelindeki çapraz doğrulama adımlarından biri için doğruluk grafiği

Çalışmada, test verileri kullanılarak önerilen modelin tahmin doğruluğunu daha iyi anlamak için karışıklık matrisi de kullanılmıştır. Test veri setinde en yüksek doğruluk başarımına sahip karışıklık matrisi Şekil 4.22’de görülmektedir.

Gerçek Sınıflar

Test - Karışıklık Matrisi										
Alüminyum	38		1							
Siyah kumaş		39								
Buzlu cam	3		36							
Cam				34		6				
Çömlek					38				1	
Granit				2		36			1	
İhlamur(ağşap)			1				38			
Magnet								38		1
Polietilen					1	4			34	
Yapay Mermer										39
AlüminyumSiyah kumaşBuzlu camCamÇömlekGranitİhlamur(ağşap)MagnetPolietilenYapay Mermer										
Tahmin Edilen Sınıflar										

Şekil 4.22. Test veri setinde en yüksek başarıma sahip karışıklık matrisi

Çapraz doğrulama adımlarındaki tahmin etme sonuçları incelendiğinde en yüksek sonucun %94,63 olduğu görülmektedir. Karışıklık matrisinde her satır ilgili malzemenin GP ve YN sayısını göstermektedir. 391 test verisi içeren karışıklık matrisi incelendiğinde, bir önceki bölümde çalışması yapılan LSTM modeline benzer şekilde siyah kumaş, ıhlamur ve yapay mermerin tamamen diğerlerinden ayrıştırılabildiği görülmektedir. 3 adet buzlu cam malzemesine ait verinin yanlış olarak alüminyum olarak sınıflandırıldığı, cam malzemesine ait 6 adet verinin ve polietilen

malzemesine ait 4 adet verinin ise yanlışla granit olarak sınıflandırıldığı görülebilmektedir. Tahmin sonuçlarında ise en düşük doğruluk oranının %89,51 şeklinde olduğu görülmektedir. En düşük doğruluk oranına sahip test veri setine ait karışıklık matrisi Şekil 4.23'te görülmektedir.

Test - Karışıklık Matrisi

Gerçek Sınıflar	Alüminyum	Siyah kumaş	Buzlu cam	Cam	Çömlek	Granit	İhlamur(ağşap)	Magnet	Polietilen	Yapay Mermer
Alüminyum	36		3							
Siyah kumaş		39								
Buzlu cam	9		28				2	1		
Cam				29		9		1		
Çömlek					38					1
Granit						34			5	
İhlamur(ağşap)			1				36	1		1
Magnet							1	36		2
Polietilen					1	1			37	
Yapay Mermer					2					37
	Alüminyum	Siyah kumaş	Buzlu cam	Cam	Çömlek	Granit	İhlamur(ağşap)	Magnet	Polietilen	Yapay Mermer
	Tahmin Edilen Sınıflar									

Şekil 4.23. Test veri setinde en düşük başarıma sahip karışıklık matrisi

4.6.3. Klasik Makine Öğrenimi Sınıflandırıcılarının Sınıflandırma Sonuçlarının İncelenmesi

Veri hazırlama adımında çıkarma işleminden sonra elde edilen ham lazer işaretlerinin uzunluğu 3000 noktadan oluşmaktadır. Bu şekildeki büyük boyutlu ham verilerin özellik çıkarılmadan klasik makine öğrenmesi algoritmalarında kullanılması düşük sınıflandırma doğruluklarına ve uzun eğitim süreçlerine sebep olacaktır.

Bu çalışmada önerilen derin öğrenme modellerinin yanı sıra ham lazer işaretlerinin FFT değerleri hesaplanmış ve denetimli makine öğrenme algoritmaları olan DVM, KA, DAA, NB ve KNN ile de sınıflandırma işlemi yapılmıştır. Sınıflandırma öncesi temel bileşen analizi (PCA) ile boyut azaltılması yapılmıştır. Tablo 4.12'de geleneksel makine öğrenmesi algoritmaları ile materyal tanımlama çalışmasının sonuçları görülmektedir.

Tablo 4.12. Farklı makine öğrenmesi algoritmalarının sınıflandırma başarımları

Sınıflandırıcı türü	Doğruluk (%)
DVM	59,2
KA	78,3
DAA	76,7
NB	76,6
KNN	43,2

Tablo 4.12 incelendiğinde en yüksek sınıflandırma başarımın KA ile yapılan çalışmada olduğu görülmektedir.

4.6.4. Önerilen Derin Öğrenme Modellerinin Literatürdeki Çalışmalarla Karşılaştırması

Materyal türü tanımlama sürecinde bilinmeyen bir materyal önceki bilinen materyallerle karşılaştırılmakta ve yakın olan materyal sınıfına dahil edilmektedir. Literatür incelendiğinde materyal türü tanımlama çalışmaların çoğu kamera görüntülerinin kullanımı, lazer işaretlerinin kamera görüntüleri ile kullanımı veya yardımcı bir teknoloji olarak lazer kullanımı üzerinedir.

Günlük hayatta sıklıkla kullanılan 10 çeşit materyalin tanımlandığı bu çalışmada, tanımlanmak istenilen materyal sadece bir lazer ışını ile işaretlenmiştir. Materyalden yansıyan lazer işaretleri ve LSTM, derin LSTM, NCP derin öğrenme modelleri kullanılarak materyallerin sınıflandırılması yapılmıştır. Bu çalışmaya yakın olan literatürdeki çalışmaların kısa özeti ve karşılaştırması Tablo 4.13'te verilmiştir.

Tablo 4.13 incelendiğinde TLS ile yapılan çalışmaların çoğunda lazer ve kamera birlikte kullanılmıştır. Yuan ve diğerlerinin TLS ve üzerindeki dahili kamerayı kullanarak yaptıkları sınıflandırma çalışmasında farklı özellikler ve farklı sınıflandırma algoritmaları kullanılmaktadır. Çalışmalarında bir veri kümesi için TLS ile 400 cm²'lik bir alanda birden fazla yoğunluk değerleri ve RGB görüntüsü elde edilmiştir. TLS ile yapılan diğer çalışmalarda ise lazer yardımcı teknoloji olarak kullanılmaktadır.

ToF kamera ile yeni yapılan materyal tanımlama çalışmalarında ise kısıtlı sayıdaki materyalin tespiti yapılmıştır. ToF kameralarla yapılan çalışmalarda anlık olarak yüksek miktarda veri aktarımı yapılmakta ve bu verilerin işlenmesi için yüksek miktarda hesaplama maliyetine ihtiyaç duyulmaktadır.

SPAD dizisi kullanılarak yeni yapılan materyal tanımlama çalışmasında ise 16x16 çözünürlüğündeki sensör hedef ile temas ettirilerek ölçüm yapılmaktadır. Daha az sayıda materyalin kullanıldığı bu çalışmada temas ile ölçüm yapıldığından dolayı atmosferik etkilerin oluşturduğu (nem, sis, ortam ışığı gibi) gürültülerden daha az etkilenme potansiyeline sahiptir. Bu durum ise lazer ile uzak mesafeden yapılan materyal tanımlama çalışmalarına göre avantaj sağlamaktadır.

TLS, ToF kamera ve SPAD dizisi ile yapılan çalışmalara bakıldığında materyalin birden fazla noktasına lazer ışığı yansıtılmakta ve bu noktalardan yansıyan yoğunluk değerleri aynı anda kullanılarak materyal tanımlaması yapılmaktadır. Önerilen yöntemde ise tanımlanmak istenilen materyalin sadece bir noktasına lazer ışığı yansıtılmakta ve materyalden yansıyan lazer işaretini kullanmak yeterli olmaktadır. Bu şekildeki tek bir ölçüm noktasının kullanılması daha az veri kullanımı ve daha az işlem gücü gerektirmektedir.

Tablo 4.13. Lazer işaretleri ile materyal tanımlanmasının literatürdeki çalışmalarla karşılaştırılması

Çalışma	Sınıf sayısı	Özellikler	Sınıflandırıcı	Veri türü	Veri kaynağı	Doğruluk oranı (%)
Han ve diğ. [14]	23	15 Filtre Bankası + 15 HSV değerleri	DVM	100x100 piksel RGB resim	TLS + RGB kamera	%92,4
Martino ve diğ. [18]	8	Fourier + Chirp + KL	KA	300 ToF kamera video görüntüleri	ToF kamera	%80
Hassan ve diğ. [15]	3	Materyal yansıma yoğunluğu + RGB yoğunluğu	-	133 - 343 cm ² arasındaki alandan ölçülen çok noktalı TLS	TLS + RGB kamera	-
Shen ve diğ. [17]	2	Materyal yansıma yoğunluğu	-	Çok noktalı TLS	TLS	-
Yuan ve diğ. [16]	10	Materyal yansıtma değeri + yüzey pürüzlülük değeri + HSV	Topluluk sınıflandırma	400 cm ² alandan ölçülen çok noktalı TLS + RGB resim	TLS + RGB kamera	%97,1
Yuan ve diğ. [16]	10	Materyal yansıtma değeri	KNN	400 cm ² alandan ölçülen çok noktalı TLS	TLS + RGB kamera	%77,5
Callenberg ve diğ. [19]	5	SPAD işareti	CNN	16x16 piksel SPAD işareti, aynı temas noktasından 25 tekrar	SPAD sensör	%95,04
Lang ve diğ. [21]	9	Yansıma değerleri	YSA	640x480 piksel 10 kare ToF kamera görüntüsü	Darbeleri ToF kamera	%93,3
Conde ve diğ. [23]	5	Yansıma değerleri	DVM	6 farklı frekanstaki ToF görüntüsü	ToF kamera	%78
Önerilen model	10	Ham lazer işareti	Derin LSTM	1 noktadan ölçüm yapılan yapılan lazer işareti	Lazer modülü	%80,82
Önerilen model	10	Boyutu düşürülmüş lazer işaretleri	LSTM	1 noktadan ölçüm yapılan yapılan lazer işareti	Lazer modülü	%93,63
Önerilen model	10	Boyutu düşürülmüş lazer işareti	NCP	1 noktadan ölçüm yapılan yapılan lazer işareti	Lazer modülü	%92,66

4.7. Sonuçlar

Tez çalışmasının bu bölümünde, temel seviyedeki bir lazer modülü kullanılarak uzak mesafedeki malzemelerin sınıflandırılması için LSTM, Derin LSTM ve NCP derin öğrenme modeli tasarlanmış ve bu sınıflandırıcıların başarımı doğrulanmıştır. Önerilen yöntemde materyallerden geri yansıyan lazer ışık yoğunluğuna bağlı olarak elde edilen 3000 boyutlu sayısal değerlerden oluşan ham lazer işaretleri gürültü giderme işleminin ardından Welch PSD ve Yule Walker AR PSD işaret dönüşümü sonrası 32 ve 63 boyutlu işaretlere dönüştürülmüştür. Ham lazer işaretleri yerine boyutu düşürülmüş lazer işaretlerinin kullanımı daha hızlı ve daha doğru sonuçlar

vermektedir. Bu veri hazırlama yöntemi ile derin öğrenme mimarisinin toplam işlem maliyeti de büyük oranda düşmektedir. Bunun yanında önerilen LSTM ve NCP derin öğrenme modelleri ile yüksek oranda doğru bir şekilde temassız ve uzaktan materyal sınıflandırması yapılabilmektedir. Elde edilen bu başarı ile kamera gibi ışıktan kolaylıkla etkilenen sistemlerin aksine ortam ışığından etkilenmeyen tek bir lazer ışığı ile yüksek başarımla sınıflandırma yapılabilmektedir.

Deneysel çalışmalar laboratuvar ortamında günün farklı saatlerinde yapılmış ve çalışma ortamındaki ışık miktarı değişkenlik gösterebilmiştir. Bu çalışmada kurulan deney düzeneği ile belirli bir mesafede bulunan ve günlük hayatta sıklıkla kullanılan polietilen, alüminyum, magnet, siyah kumaş, ıhlamur, buzluca, cam, granit, yapay mermer ve çömlekten işaretler alınmıştır. Materyallerden işaretlerin alınma işlemi esnasında önce lazer ışığı kapatılarak ortamdaki ışıkların veya cihazın sebep olduğu gürültülü işareti kayıt altına alınmış, sonrasında ise lazer cihazı aynı konumda iken lazer ışığı açılarak ilgili materyale yansıtılmış ve materyalden yansıyan lazer işaretleri kayıt altına alınmıştır. Bu ölçüm yöntemi ile sistemin ortam aydınlatmasına ve cihazdan kaynaklanan gürültülere karşı dayanıklılığı artırılmıştır. Ölçümler sonucunda her bir materyalden 391 adet ham ve gürültülü lazer işareti elde edilmiştir. 10 kat çapraz doğrulama tekniği ile yapılan sınıflandırma çalışmalarında Welch PSD ve Yule Walker AR PSD metodu ile boyutu indirgenmiş lazer işaretleri ve LSTM modeli kullanılarak ortalama %93,62 sınıflandırma doğruluğu elde edilmiştir.

C.Elegans nematodundan esinlenerek geliştirilen 4 katmanlı NCP modelinin giriş katmanında sensör nöronlar, ara katmanda inter ve komut-nöronlar, son çıkış katmanında ise motor nöronlar bulunmaktadır. NCP modelinin konfigürasyonu ile katmanlar arasındaki sinaps sayıları ayarlanabilmektedir. Belirlenen bağlantı sayılarına göre sinapslar bir sonraki katmandaki nöronlara rastgele bir sırayla bağlanmaktadır. Bunun yanı sıra komut-nöronlardaki RNN hücre sayısı da seçilebilmektedir. Welch PSD dönüşümü uygulanarak elde edilen 32 boyutlu indirgenmiş lazer işaretleri ile LSTM mimarisine göre çok daha az sayıdaki nöron ve nöronlar arasındaki bağlantıdan oluşan NCP modelinde ortalama %92,66 sınıflandırma başarımları elde edilmiştir. Seyrek yapıdaki NCP mimarisi LSTM gibi tamamen bağlı yapıdaki mimariye yakın başarımlar göstermektedir.

İlerleyen zamanlarda lazer teknolojisi kullanan ve kapalı alanlarda otonom sürüş yeteneğine sahip robotlara bu sistem entegre edilerek ortam haritasının çıkarılmasının yanında ortamdaki materyallerin türünün de tespiti yapılabilecektir. Tespiti yapılan bu materyallere göre robotlara farklı görevler de yüklenebilecektir. Bunun yanı sıra lazer ile materyal türü tanımlaması yapan bir robotik kavrama sisteminde, robotun materyale uygun bir şekilde pozisyon alması sağlanabilecektir. Benzer bir şekilde otonom araçlarda lazer işaretleri ile yol durumunun buzlu, yolun türünün (asfalt, toprak, çakıl taşı gibi) tespitinin yapılması ile daha güvenli sürüş sağlanabilecektir.

5. LAZER İŞARETLERİ İLE CİNSİYET BELİRLENMESİ

Erişim kontrolü yapılan uygulamalarda, pazarlama faaliyetlerinde ve biyometrik doğrulama işlemlerinde cinsiyet sınıflandırması önemli faydalar sağlayabilmektedir. Cinsiyet sınıflandırma işleminin sabıka veri tabanında, pazarlama sektöründe, biyometrik doğrulama işlemlerinde ve benzeri yerlerde kullanımı önem arz etmektedir [53]. Sadece kadınların veya erkeklerin giriş yapabileceği alanlarda otomatik cinsiyet sınıflandırması önemli faydalar sağlamaktadır. Büyük boyutlara ulaşan sabıka veri tabanında öncelikle cinsiyet sınıflandırılmasının yapılması veri tabanı üzerindeki işlem yükünü büyük bir oranda düşürecektir [228]. Bu büyük veri tabanında öncelikle cinsiyet sınıflandırmasının yapılması ile veri tabanında biyometrik karşılaştırma yapılacak kişi sayısı önemli oranda düşecek, daha hızlı ve daha doğru sonuçlar elde edilebilecektir. Bunun yanında bir alışveriş merkezinde bulunan reklam panolarında, alışveriş merkezinde bulunan kadın veya erkek sayısının ağırlığına göre ürünlerde kampanya yapılması, erkeklere veya kadınlara hitap eden ürünlerinin ön plana çıkartılması ürünlerin satış miktarında önemli oranda artışlara sebep olabilir. Benzer bir uygulama ise insan bilgisayar ara yüzlerinde kullanılabilir. Bu tür bir sistemde, kullanıcının cinsiyetine göre seslendirme, karakter veya içerik sunulabilir.

Çoğu zorlu şartlar altında insanların karşısındaki bir kişinin cinsiyetini kadın veya erkek olarak tespit etmesi kolaylıkla olmaktadır. Bilgisayarlı görüş sistemlerinde ise insanların cinsiyet tespiti halen zorlu bir görevdir.

Cinsiyet tanıma işlemi çoğunlukla yürüyüş modeline göre, yüz görüntülerine göre, sese göre ve sismik sensörler gibi farklı sensörlerden elde edilen bilgilere göre yapılabilmektedir. Literatürde cinsiyet sınıflandırma çalışmalarının ağırlıklı olarak kamera ile yapıldığı görülmektedir. Yüz görüntülerinden cinsiyet çıkarımındaki en büyük zorluklardan biri kişinin yüz ifadesinin belirli konumda tutulamaması, bir diğeri ise görüntüleme aşamasındaki zorluklardır. Kişinin kendisini saklama isteği, yüzdeki farklılıklar ve aydınlatma koşulları görüntü tabanlı yöntemin zorluklarına örnek verilebilir. Bunun yanı sıra düşük çözünürlük, düşük veya yüksek ışık koşulları, bulanık görüntüler, kısıtlı açıdaki görüntüler kamera ile yapılan cinsiyet tanımlama işlemlerinde karşılaşılan zorluklardandır. Sesle yapılan çalışmalarda ise kullanıcılardan özellikle ses kaydının yapılması gerçeği bulunmaktadır. Kamera ve sesle yapılan her iki çalışma türünde mahremiyet konusu gündeme gelebilmektedir. Bunun yanı sıra sismik sensör ile yapılan çalışmalar ise kısıtlı bir mekânda uygulanabilmekte ve uygulamanın yapılacağı mekâna çok sayıda özel sensörlerin yerleştirilmesi gerekmektedir.


Ses veya kamera ile yapılan çalışmalarda kişilerin kendini gizleme isteği sistemin en büyük zorluklarından biridir. Kişinin farklı yöntemlerle (maske, makyaj vb.) yüz ifadesini değiştirmesi veya tamamen karanlık ortamlarda bulunulması ise kamera tabanlı sistemleri devre dışı bırakacaktır.

Bu çalışmada mahremiyet, ışık koşulları, kişinin kendini gizleme isteği gibi dezavantajlara sahip kamera ile yapılan cinsiyet ayrımı yerine düşük güçlü lazer işaretleri ile cinsiyet tespiti önerilmektedir. Bu amaçla çok kısa bir süre uzak mesafedeki deneklerin koluna lazer ışığı tutulmakta, koldan yansıyan lazer işaretleri veri hazırlama işleminden sonra LSTM derin öğrenme mimarisinde eğitilerek cinsiyet sınıflandırması yapılmaktadır.

5.1. Lazer Işığının Canlı Doku ile Etkileşimi

İnsan vücudunun en büyük organı olan deri epidermis, dermis ve hipodermis olmak üzere 3 katmandan oluşmaktadır. İnsan derisinin kalınlığı ve yapısal özellikleri cinsiyete göre değişebilmektedir. Bu durum optik ölçüm sonuçlarında da değişikliğe sebep olabilmektedir. Erkek ve kadın derisinin genel kalınlığı ve onu oluşturan katmanların kalınlıkları arasında önemli farklılıklar bulunmaktadır. İnsan derisinin cinsiyete göre bilinen temel farklardan biri de erkeklerde deri kalınlığı (epidermis ve dermis tabakası) kadınlara göre daha fazladır. Branchet ve diğerlerinin bildirdiğine göre 25 -30 yaş arasındaki kadınlarda epidermis katman olarak da bilinen en dış katmandaki derinin kalınlığı yaklaşık olarak 50 μm iken, erkelerde ise bu değer 65 μm değerindedir [229]. Kadınlarda daha fazla yağ dokusu içeren hipodermis tabakası ise erkeklere oranla daha kalındır [230]. Derideki cinsiyete göre bu kalınlık farklarının olması deriden yansıyan lazer ışınlarının yoğunluğuna etkisi olmaktadır. Morvová ve diğerleri erkek ve kadınların el, alın ve üst kol bölgesini farklı dalga boylarındaki (280, 325, 400 nm) ışık ile uyarak, floresan emisyon spektrumlarını incelemiştir. Çalışmalarında floresan yoğunluğu incelenen 3 anatomik bölgenin tümünde floresan yoğunluğunun erkeklerde kadınlara göre biraz daha yüksek olmasına rağmen cinsiyete göre önemli bir farkın olmadığını bildirmişlerdir [231].

Farklı dalga boyları ve farklı güçteki lazer ışıkları canlı dokular üzerinde farklı etkilere sebep olabilmektedir. Lazer ışınları bir doku ile temas ettiğinde yansıma, emilim, iletim ve saçılma özellikleri göstermektedir [232]. Kullanılan dalga boyuna göre bunların karışımı da olabilmektedir. Yumuşak dokularda 300-1100 nm dalga boyu arasındaki lazer ışınlarının yansıma miktarı emilim miktarına göre 10 kat daha fazla olmaktadır. Şekil 5.1’de lazer ışığının doku ile etkileşimi görülmektedir.




Şekil 5.1. Lazer ışığının doku ile etkileşimi. Doku üzerine gelen lazer ışığı, doku da lazerin ve dokunun özelliklerine bağlı olarak yansıma, emilim, saçılma ya da iletim özelliği gösterebilmektedir

5.2. Materyal ve Yöntem

Bu çalışmada tek bir lazer işareti ve derin öğrenme algoritması kullanılarak cinsiyet sınıflandırılması yapılmıştır.

5.2.1. Sistem Tasarımı

Bu bölümdeki çalışmada düşük güçlü lazer işaretleri ile insanların kolundan cinsiyet tespiti yapılmaktadır. Bu amaçla yapılan çalışmada; deneklerin koluna lazer işaretini yansıtma, koldan yansıyan işaretlerini kaydetme, veri hazırlama ve sınıflandırma işlemleri yapılmaktadır. Şekil 5.2’de lazer işaretleri ile cinsiyet tespiti yaklaşımı görülmektedir.



Şekil 5.2. Önerilen cinsiyet tespiti yaklaşımı

5.2.2. Kullanıcı Seçimi

Çalışma kapsamında 19-38 yaşları arasındaki 6 sağlıklı erkeğin ve 6 sağlıklı kadının kolundan lazer işaretleri alınmıştır. Deneysel çalışmaya başlamadan önce kullanıcılar lazer sistemi ve deney düzeneği hakkında bilgilendirilmiştir. Örnek alma esnasında deneklerin rahat edebilecekleri ve avuçları açık olacak şekilde sağ elini deney düzeneğinde belirtilen yere yerleştirmeleri istenmiştir.

5.2.3. Deney Düzeneği ve Veri Toplama

Deneysel çalışmalar, güneş ışığı almayan bir laboratuvar ortamında ve gündüz vakitlerinde yapılmıştır. Ölçümlerde kullanılan lazer algılayıcı modül ve deney düzeneği 4. bölümde ayrıntılı olarak anlatılmaktadır. Bu çalışmada kullanılan lazer ışığı modüle edilmeden sürekli modda çalışmaktadır.

Ölçümlerde lazer modülü ile deneklerin kolu arasında 2 metre mesafe bulunmaktadır. Derin öğrenme için çok sayıda örnek veri gerektiğinden, lazer modülü x ve y ekseninde hareket eden bir Kartezyen robot kolu üzerine monte edilmiş ve her bir denneğin kolunun farklı noktalarından 126 adet lazer işareti alınmıştır.

Robot kolunun hareketinin oluşturduğu titreşimlerden kaçınmak için kolun hareketinden 3 sn. sonra ölçüm alınmıştır. Her bir konum için önce lazer ışığı kapatılarak çevredeki ışıkların ve cihazın oluşturduğu gürültü ve karanlık akım etkisini bir sonraki veri hazırlama adımında gidermek için ölçüm yapılmış, hemen sonrasında ise denneğin koluna lazer ışığı yansıtılarak ölçüm yapılmıştır. Deneysel çalışma düzeneği ve ölçümler esnasında deneklerin kol pozisyonu Şekil 5.3'te görülmektedir.



Şekil 5.3. a) Deneysel çalışma düzeneği b) Deneklerin ölçüm esnasındaki pozisyonu

Denneğin kolunun sağ alt tarafından başlanarak 5mm aralıklarla önce sola doğru, sonra bir üst konumdan sağa doğru olacak şekilde bir örüntü düzeninde lazer ile ölçümler yapılmıştır. Deney düzeneği ile erkek ve kadın deneklerin kolundan toplamda 1512 adet lazer işareti elde edilmiştir.


Aynı zamanda 1512 adet lazer ışığı kapalı iken cihazın karanlık akım ve ortam ışığının oluşturduğu gürültü işaretlerinin birleşiminden oluşan gürültü işareti elde edilmiştir. Ölçüm alma esnasında erkek deneğin kol pozisyonu ve yansıtılan lazer ışığı Şekil 5.4’de görülmektedir.



Şekil 5.4. Ölçümler esnasındaki erkek deneğin kol pozisyonu ve yansıtılan lazer ışığı


5.2.4. Veri Hazırlama Adımları

Gürültülü bir işarete ve gürültünün tahmini olarak ayrı bir kanaldan erişilebilir olduğu durumlarda, gürültülü işaretten gürültünün tahminini çıkararak gürültüsüz işaretin bir tahminini elde etmek mümkün olabilmektedir [233]. Bu amaçla yapılan deneysel çalışmada lazer ışığı kapatılarak cihazın ve çevre ışığının sebep olduğu gürültü işareti kaydedilmiştir. Bu işlemin hemen ardından lazer ışığı açılarak deneklerin kolundan yansıyan lazer işareti kaydedilmiştir. Deneklerin kolundan elde edilen gürültülü lazer işaretlerinden gürültüsüz işaretler elde etmek için 4. Bölümde ayrıntılı olarak anlatılan çıkarma işlemi yapılmıştır. Şekil 5.5’te cihazın ve çevresel ışıkların oluşturduğu gürültü işareti, erkek deneğin kolundan kaydedilen lazer işareti ve çıkarma işlemi sonucu elde edilen gürültüsüz lazer işareti görülmektedir.




Şekil 5.5. Kadın ve erkek deneğin kolundan elde edilen gürültülü lazer işareti, lazer ışığı kapatılarak ölçülen gürültü işareti ve çıkarma işlemi sonucu elde edilen gürültüsüz lazer işareti

Çıkarma işlemi sonrası elde edilen ham lazer işaretlerinin normalize edilmiş enerji değerleri Denklem 4.14'te verilen şekilde hesaplanmıştır. Şekil 5.6'da 2 cinsiyet türü için hesaplanan ortalama enerji değerlerinin aykırı değerlerini gösteren kutu grafiği görülmektedir.



Şekil 5.6. Çıkarma işlemi sonrası lazer işaretlerinin her iki cinsiyet türü için ortalama enerji dağılımlarını ve aykırı değerlerini gösteren kutu grafiği

Çıkarma işleminden sonra elde edilen her bir lazer işaretinin Welch spektral güç yoğunluğu hesaplanmıştır. Welch metoduna göre PSD değerlerinin elde edilmesi 4. Bölümde ayrıntılı olarak anlatılmıştır. Welch metodunda uygun parametreler seçilerek ham lazer işaretlerinin boyutu 3000'den 63'e düşürülmüştür. Şekil 5.7'de kadın/erkek deneklere ait lazer işaretleri ve çıkarma işleminden sonra Welch metoduna göre hesaplanmış PSD değerleri görülmektedir.



Şekil 5.7. Kadın/erkek deneye ait önışlemden çıkmış lazer işaretleri ve Welch PSD dönüşümü değerleri

5.2.5. Önerilen Derin Öğrenme Mimarisi

Bu tez çalışmasında lazer işaretleri ile cinsiyet sınıflandırması için LSTM derin öğrenme modelinin kullanımı önerilmiştir. Cinsiyet sınıflandırma sürecini gerçekleştirmek için veri hazırlama işlemi sonrasında elde edilen 63 nokta uzunluğundaki işaretler zaman serisi şeklinde LSTM derin öğrenme ağına girdi olarak sunulmaktadır. Sınıflandırma işlemi için önerilen LSTM modelinin katmanları ve parametreleri Tablo 5.1'de verilmiştir. Sınıflandırma çalışmasında kullanılan boyutu düşürülmüş lazer işaretlerinin boyutu ve gizli katman sayıları deneme yanılma yöntemi ile seçilmiştir.

Tablo 5.1. Cinsiyet sınıflandırmasında önerilen LSTM modelinin katmanları ve parametreleri


Katman No	Katman Türü	Özellikleri
Katman 1	Sıralı giriş katmanı	Sıralı giriş (63 nokta boyutunda)
Katman 2	LSTM katmanı	64 gizli birim
Katman 3	Tam bağlı katman	2 gizli birim
Katman 4	Softmax katmanı	Softmax aktivasyon fonksiyonu
Katman 5	Sınıflandırma çıkış katmanı	2 sınıf

Önerilen LSTM modelinde giriş katmanında Welch metoduna göre hesaplanan 63 boyutlu PSD değerleri kullanılmaktadır. Giriş katmanından sonra sırasıyla 64 gizli birimden oluşan LSTM katmanı, 2 gizli birimden oluşan tam bağlantılı katman, Softmax katmanı ve sınıflandırma katmanı kullanılmıştır. Çalışmada kullanılan LSTM modeli için kullanılan hiper-parametreler, eğitim ve test verisi oranları Tablo 5.2'de verilmiştir.

Tablo 5.2. Önerilen LSTM modelinin eğitim aşamasında kullanılan hiper-parametreler

Parametre adı	Parametre değeri
Optimizasyon algoritması	Adam
Maksimum eğitim tur sayısı	1500
Veri yığınının boyutu	512
Öğrenme katsayısı	0,001
Eğitim verisi	Veri setinin %90'ı oranında
Test verisi	Veri setinin %10'ı oranında
Çapraz doğrulama değeri	k=10

Cinsiyet sınıflandırması için önerilen LSTM modelinin parametreleri ve veri hazırlama aşamasından geçirilmiş lazer işaretlerinin ağa giriş şekli Şekil 5.8'de verilmiştir.



Şekil 5.8. Çalışmada önerilen LSTM modeli ve veri hazırlama sonrası oluşan işaretlerin giriş olarak kullanımı


5.3. Bulgular ve Tartışma

Çalışmada, LSTM modelinin başarımlarını değerlendirmesi için çapraz doğrulama tekniği kullanılmıştır. Bu amaçla veri seti rastgele olarak 10 eşit parçaya bölünerek, her seferinde 1 bölümü test için dışarıda bırakılarak geriye kalan 9 bölüm ise modelin eğitimi kullanılmıştır. Her bir eğitim ve test işlemi sonucunda elde edilen değerlerin ortalaması alınarak sistemin ortalama başarımlarını değerleri hesaplanmıştır. Başarımlarını değerlendirmelerinde geri çağırma, kesinlik, F1-Skor ve doğruluk değerleri kullanılmıştır. Tablo 5.3’de sistemin ortalama başarımlarını değerlendirme sonuçları görülmektedir.

Tablo 5.3. Cinsiyet sınıflandırmasında önerilen LSTM modelinin başarımlarını değerleri

Parametre	Parametre değeri
Geri Çağırma	%76,163
Kesinlik	%75,874
F1-Skor	%76,018
Doğruluk	%76,2

LSTM modeli ile yapılan eğitimler sonucunda en yüksek doğrulamanın olduğu veri setine ait doğruluk grafiği ve karışıklık matrisi Şekil 5.9’da görülmektedir. Bu adımdaki doğruluk değeri %79,33 olarak ölçülmüştür. Karışıklık matrisi incelediğinde ise kadınların %78,2’sinin, erkeklerin ise %79,3’ünün doğru olarak sınıflandırıldığı görülmektedir. Yapılan eğitimler sonucunda en düşük başarımlarını oranı ise %69,91 şeklinde olmuştur.



Şekil 5.9. a) Çalışmadaki en yüksek başarıma sahip doğruluk grafiği b) Çalışmadaki en yüksek başarıma sahip karışıklık matrisi

Çalışmada ortalama eğitim ve doğrulama süresi 1512 adet örnek lazer işaretleri için 268 saniye (4 dakika 28 saniye) sürmüştür. Bu durumda 1 işaretin eğitim ve doğrulama süresi yaklaşık 0,18 saniye sürecektir. Elde edilen bu değerler gerçek zamanlı uygulamaların da geliştirilebilir olduğunu göstermektedir.

Literatür araştırmalarında düşük güçlü lazer işaretleri ile yapılan cinsiyet ayrımı çalışmasına benzer bir çalışmaya rastlanılmamıştır. Bu sebeple sistemin başarımlarını karşılaştırmak yapılamamıştır.

Morvová ve diğerlerinin yaptığı çalışmaya benzer bir şekilde bu çalışmada deneklerin kolunun alt kısmı 630-660 nm aralığında bir lazer ışığı ile uyarılmış ve koldan yansıyan ham lazer işaretleri kaydedilerek cinsiyetler arasındaki yoğunluk farkı incelenmiştir. Şekil 5.6'da çıkarma işlemi sonrası lazer işaretlerinin her iki cinsiyet türü için ortalama enerji dağılımlarını gösteren kutu grafiği incelendiğinde erkek deneklerin kolundan yansıyan işaretin yoğunluğunun kadınlara göre biraz daha fazla olduğu görülmektedir. Bu çalışma elde edilen bulgular Morvová ve diğerlerinin yaptığı çalışmayı doğrular niteliktedir.

5.4. Sonuçlar

Tez çalışmasının bu bölümünde yapılan çalışmada 2 metre uzaklıkta bulunan deneklerin koluna lazer işaretleri yansıtılarak, deneklerin kolundan yansıyan lazer işaretlerinden cinsiyet ayrımı yapılmıştır.

Deneyisel çalışmalar güneş almayan, farklı gün ve saatlerde laboratuvar ortamında yapılmıştır. Önerilen sistemde düşük güçlü bir lazer sistemi ile deneklerin kolundan elde edilen ham lazer işaretlerinden gürültülü işaretler çıkartılmakta, sonrasında büyük boyutlu ham lazer

işaretlerinin Welch metoduna göre PSD değerleri hesaplanarak boyutları düşürülmekte ve LSTM derin öğrenme modeli kullanılarak sınıflandırma yapılmaktadır. Çapraz doğrulama tekniği kullanılarak yapılan başarımlar değerlendirilmiştir. Çalışmalarında, en yüksek başarımın %79,33, en düşük başarımın %69,91, sistemin ortalama başarımının ise %76,2 olduğu görülmüştür.

Çalışmada ayrıca erkek deneklerin kolundan yansıyan işaretin yoğunluğunun kadın deneklere göre biraz daha fazla olduğu tespit edilmiştir.

Elde edilen sonuçlar mahremiyet, ışık koşulları, kişinin kendini gizleme isteği gibi dezavantajlara sahip kamera ile yapılan cinsiyet ayrımı yerine düşük güçlü lazer işaretleri ile cinsiyet ayrımının yapılabilirliğini göstermektedir. Önerilen sistemde kamera ve ses kullanılmadığı için mahremiyet problemi de olmamaktadır. Bunun yanında sismik sensör vb. bir sistem kullanılmadığı için çalışmanın yapıldığı zemine ayrıca sensör dizisi yerleştirmeye de gerek olmamaktadır.

Yapılan deneysel çalışmalarda bir lazer işareti için eğitim ve doğrulama süresinin yaklaşık 0,2 saniye olduğu görülmüştür. Bu çalışma süreleri de dikkate alındığında derin öğrenme mimarisi ile eğitim yapıldıktan sonra öğrenme transferi yapılarak düşük kapasiteli bir mikro denetleyici sisteminde de lazer işaretleri ile cinsiyet ayrımı yapılabilir. Bu sayede taşınabilir bir sistem geliştirilebilir.

6. CANLI/CANSIZ VARLIKLARIN LAZER İŞARETLERİ İLE SINIFLANDIRILMASI

Terörle mücadelede, kentsel savaş operasyonlarında ve aktif savaş ortamlarında bazı hedefler canlı insan olabilirken bazı hedefler ise manken benzeri insan yapımı sahte hedeflerden oluşabilmektedir. Bu sahte hedefler doğada bulunan farklı materyallerden üretilebilmektedir. Uzak mesafede bulunan ve kolayca ulaşılamayan durumlarda bu hedef türlerinin gerçekten bir canlıya ait olup olmadığının tespiti durumunda önemli kazanımlar sağlanabilmektedir. Uzak mesafede hareketsiz duran hedefin canlı veya yanıltma amaçlı manken benzeri bir yapı olup olmadığının tespiti kamera veya çıplak gözle yapılmaya çalışıldığında bazı zorluklarla karşılaşılması muhtemeldir. Gece karanlık ortamlarda veya duman ile gizlenmeye çalışılan bir ortamda bu her iki yöntemde başarısız olacaktır. Bilindiği üzere kameralar aşırı karanlık ortamlarda, aşırı aydınlık ortamlarda veya duman benzeri engellenmiş ortamlarda başarısız olmaktadır.

Tez çalışmasının bu bölümünde aktif savaş ortamı ve rehine operasyonu benzeri senaryolarda, uzaktaki bir hedefin canlı insan dokusu veya manken gibi cansız bir materyal olup olmadığının tespiti üzerine çalışma yapılmıştır. Bu amaçla yapılan çalışmada cansız hedefleri temsilen farklı materyallerden, canlı dokuyu temsilen ise insan derisinden elde edilen düşük güçlü lazer yansıma işaretleri kullanılarak canlı/cansız sınıflandırması yapılmıştır. Çalışmada kamera kullanımının yerine sadece lazer ışığını kullanan aktif bir ölçüm yöntemi sunulmaktadır. Lazer ışığı ile yapılan çalışmanın aydınlatma koşullarından ve atmosferik ortam koşullarından daha az etkilenme potansiyeli bulunmaktadır.


Bu bölümdeki çalışmada kullanılan canlı ve cansız hedeflerden işaret elde etme adımları, veri hazırlama adımları ve derin öğrenme mimarisinin oluşturulması anlatılmaktadır. Sonrasında ise yapılan deneysel çalışmalar ve elde edilen sonuçlar açıklanmaktadır.

6.1. Materyal ve Yöntem

Çalışmanın bu bölümünde canlı/cansız sınıflandırması için gerçekleştirilen sistemin tasarımı, materyal ve kullanıcı seçimi, veri hazırlama adımları ve derin öğrenme mimarisinin tasarımı açıklanmaktadır.

6.1.1. Sistem Tasarımı

Aktif çatışma ortamlarında da kullanılabilen manken gibi sahte hedefler ile canlı insan dokusunun tespitinin yapıldığı bu çalışma veri toplama, veri hazırlama ve sınıflandırma adımlarından oluşmaktadır. Şekil 6.1’de önerilen canlı/cansız sınıflandırma yaklaşımının blok diyagramı görülmektedir.



6.1.2. Kullanıcı Seçimi

Canlı/cansız sınıflandırması için yapılan çalışma kapsamında canlı dokuları temsilen 9 sağlıklı erkeğin kolundan lazer işaretleri alınmıştır. 20-41 yaş aralığından oluşan kullanıcılar deneysel çalışmalar öncesinde deney prosedürü hakkında bilgilendirilmiştir. Lazer modülü ile yapılan ölçümler esnasında deneklerden kollarını rahat edebilecekleri bir şekilde deney düzeneği üzerine yerleştirmeleri ve avuçlarını da açık bırakmaları istenmiştir. Ölçümler deneklerin sağ kolunun iç kısmından yapılmıştır.

6.1.3. Materyal seçimi

Cansız varlıkları temsilen çevremizde sıklıkla kullanılan alüminyum, siyah kumaş, buzluca, cam, çömlek, demir, galvaniz, granit, ıhlamur, magnet, mdf, mermer, karton, polietilen, polistiren, pvc ve yapay mermerden oluşan 17 adet materyal seçilmiştir. Deneysel çalışmada kullanılan 17 adet materyal Şekil 6.2'de görülmektedir. Çalışmada kullanılan materyaller belirli standardizasyonun sağlanabilmesi için 10x15 cm boyutlarında kesilmiştir.




Şekil 6.2. Deneysel çalışmada kullanılan cansız materyaller. Soldan sağa sırasıyla; yapay mermer, pvc, polistiren, polietilen, mermer, alüminyum, galvaniz, cam, buzluca, demir, granit, çömlek, magnet, mdf, mukavva, siyah kumaş, ıhlamur

6.1.4. Veri Toplama Adımları

Deneysel çalışmalarda kullanılan 1mW çıkış gücüne sahip lazer modülünde lazer ışığı sürekli modda ve modüle edilmeden hedefe yansıtılmıştır. Deneysel çalışmanın yapıldığı deney düzeneği ve lazer modülü ayrıntılı olarak 4. Bölümde anlatılmaktadır. Deneysel çalışmalar gündüz saatlerinde normal oda şartlarında bağlı ortam neminin 34 ± 2 olduğu laboratuvar ortamında yapılmıştır. Ölçümler esnasında hedefler ile lazer modülü arasındaki mesafe 2 m olacak şekilde sabitlenmiştir.

Çalışmada canlı varlıklar için 9 gönüllü erkeğin kolunun farklı noktalarından yaklaşık 5mm aralıklarla 130'şar adet lazer işareti örneği, cansız varlıklar için ise insanlar tarafından sıklıkla kullanılan 17 adet materyalin farklı noktalarından 391 adet lazer işareti örneği alınmıştır. Şekil 6.3'te çalışmada kullanılan bazı materyallerin ve deneklerin kolunun deney düzeneğindeki konumu görülmektedir. Her bir ölçüm öncesinde cihazdan ve gün ışığından kaynaklanan beyaz gürültülerin

tespiti için lazer ışığı kapatılarak ayrıca ölçümler yapılmıştır. Veri toplama işleminin sonunda erkek deneklerin kolundan toplam 1170 adet ve cansız varlıklardan toplam 6647 adet lazer işareti elde edilmiştir. Elde edilen lazer işaretleri ve gürültü işaretleri 3000 noktadan oluşmaktadır.




Şekil 6.3. Çalışmada kullanılan canlı ve cansız varlıkların deney düzeneğindeki konumu a) Erkek deneklerden birinin kol konumu b) Polietilen c) Çömlek d) Polistiren e) İhlamur f) galvaniz

6.1.5. Veri Hazırlama Adımları


Çalışmada canlı ve cansız dokulardan elde edilen lazer işaretlerinin sayısının eşit olabilmesi için cansız materyallerden elde edilen lazer işaretlerinden alt örnekler alınmıştır. Bu örnekleme işlemi sonucunda cansız materyallerin her birinden 69 ± 1 adet lazer işareti kullanılarak toplamda 1170 adet cansız materyale ait lazer işareti elde edilmiştir. Bu şekilde canlı ve cansız nesneler için dengeli bir veri tabanı oluşturulmuştur.

Çalışmanın ön işleme adımı canlı ve cansız varlıklardan elde edilen lazer işaretlerinden beyaz gürültüleri ayırmak için 4. Bölümde ayrıntılı olarak anlatılan çıkarma işlemi yapılmıştır. Bu adımda bir ölçüm noktasında lazer ışığı açık iken elde edilen lazer işaretinden, aynı konumda lazer ışığı kapatılarak cihaz/ortam ışığından kaynaklı olarak elde edilen gürültü işareti çıkarılmaktadır. Şekil 6.4’de erkek deneğin koluna ait lazer işaretleri, polietilen, çömlek, polistiren, ihlamur ve galvanize ait ham lazer işaretleri, beyaz gürültü ve çıkarma işlemi sonucundaki lazer işaretleri görülmektedir.




Şekil 6.4. Canlı, cansız(alüminyum), cansız(galvaniz) materyallerine ait ham lazer işaretleri, beyaz gürültü ve çıkarma işlemi sonucundaki lazer işaretleri

Canlı ve cansız varlıklardan elde edilen ham lazer işaretlerinden arka plan gürültü işaretlerinin çıkartılması işlemi sonrasında elde edilen ham lazer işaretlerinin normalize edilmiş dağılımını gösteren kutu grafiği Şekil 6.5'te verilmiştir.



Şekil 6.5. Canlı ve cansız varlıklardan yansıyan ham lazer işaretlerinin çıkarma işlemi sonrası enerji dağılımları

Çalışmada lazer işaretlerine çıkarma işleminin ardından Welch PSD dönüşümü uygulanmıştır. Bu işlem sonucunda 3000 boyutlu lazer işaretlerinin boyutu 63'e düşmektedir. Şekil 6.6'da çıkarma işlemi yapılmış lazer işaretleri ve Welch PSD dönüşümü uygulanmış lazer işaretleri görülmektedir.



Şekil 6.6. Canlı, cansız(alüminyum), cansız (ıhlamur ağacı), cansız (çömlek) materyallerine ait ön işleme yapılmış lazer işaretleri ve Welch spektral güç yoğunluğu uygulanmış lazer işaretleri


6.1.6. Önerilen Derin Öğrenme Mimarisi

Çalışmada veri hazırlama adımları sonucunda elde edilen toplam 2340 adet canlı/cansız varlığa ait lazer işaretlerini sınıflandırmak için 64 gizli birimden oluşan LSTM mimarisi önerilmektedir. Sınıflandırma işlemi için önerilen LSTM modelinin katmanları ve parametreleri Tablo 6.1'de verilmiştir.

Tablo 6.1. Canlı/cansız varlıkların sınıflandırılmasında önerilen LSTM modelinin katmanları ve parametreleri

Katman No	Katman Türü	Özellikleri
Katman 1	Sıralı giriş katmanı	Sıralı giriş (63 nokta boyutunda)
Katman 2	LSTM katmanı	64 gizli birim
Katman 3	Tam bağlı katman	2 gizli birim
Katman 4	Softmax katmanı	Softmax aktivasyon fonksiyonu
Katman 5	Sınıflandırma çıkış katmanı	2 sınıf

Canlı/cansız varlıkların sınıflandırılması için önerilen LSTM mimarisi ve veri hazırlama aşamasından geçirilmiş lazer işaretlerinin ağa giriş şekli Şekil 6.7’de verilmiştir.



Şekil 6.7. Çalışmada önerilen LSTM modeli ve veri hazırlama sonrası elde edilen işaretlerin giriş olarak kullanımı

6.2. Bulgular ve Tartışma

Canlı ve cansız varlıkların sınıflandırılması için kullanılan LSTM mimarisinde veri seti 10 eşit parçaya bölünerek her seferinde bir kesim test için geriye kalan veriler ise eğitim için kullanılmıştır. LSTM ağının eğitimi için kullanılan hiper-parametreler; maksimum eğitim tur sayısı 100, öğrenme katsayısı 0,001, optimizasyon algoritması Adam olarak belirlenmiştir. Veri yığınının boyutu ise 512 olarak seçilmiştir.

DeneySEL çalışmalardan elde edilen ham lazer işaretlerinin uzunluğu 3000 noktadan oluşmaktadır. Ortam/cihaz gürültüsünü gidermek için lazer ışınları açık ve kapalı iken ölçümler


alınmıştır. Veri hazırlama aşamasında, bu işaretler birbirinden çıkartılarak işaretlerdeki gürültü giderilmiştir. Derin öğrenme modellerinde yüksek boyutlu işaretleri işlemek zaman alıcı ve maliyetli olduğundan gürültüden arındırılan ham lazer işaretleri Welch spektral güç yoğunlukları hesaplanarak çok daha düşük boyuttaki (63 nokta) işaretlere dönüştürülmüştür. Deneysel çalışmalarda boyutu düşürülmüş lazer işaretleri 16, 32, 64, 128 gizli katmanlı LSTM ağlarında ayrı ayrı eğitime tabi tutularak başarımları karşılaştırılmıştır. Ham lazer işaretinden Welch metoduna göre bir işaretin hesaplanma süresi 0,026 sn sürmüştür.

LSTM modelinde küçültülmüş boyutlu lazer işaretlerinin eğitimi sistemin başarımının ve hızını önemli ölçüde artırmaktadır. Veri boyutunun indirgenmesi ile 64 gizli birimden oluşan LSTM ağında eğitim süresi eğitim turu başına 0,55 saniye sürmektedir. Tablo 6.2’de boyutu indirgenmiş lazer işaretlerinin ortalama sınıflandırma sonuçları, eğitim süreleri ve LSTM gizli katman sayıları verilmiştir.

Tablo 6.2. Farklı gizli birim sayısından oluşan LSTM modellerinin ortalama başarımlar ve eğitim süreleri

Gizli birim sayısı	Eğitim süresi (1 eğitim turu)	Geri Çağırma (%)	Kesinlik (%)	F1-Skor (%)	Doğruluk (%)
16	0,39 sn.	97,42 ± 4,38	97,39 ± 4,42	97,41 ± 4,40	97,39 ± 4,42
32	0,44 sn.	99,29 ± 0,81	99,27 ± 0,83	99,28 ± 0,82	99,27 ± 0,83
64	0,55 sn.	99,70 ± 0,45	99,70 ± 0,45	99,70 ± 0,45	99,70 ± 0,45
128	0,87 sn.	99,49 ± 0,44	99,49 ± 0,44	99,49 ± 0,44	99,49 ± 0,44

Ağın eğitimi sonrasında test verilerinde sınıflandırma başarımı en düşük %98,72, en yüksek %100, ortalama başarımlar ise %99,70 olarak hesaplanmıştır. Şekil 6.8’de 64 gizli katmanlı LSTM ağının en yüksek eğitim ve test başarımlarına ait karışıklık matrisi görülmektedir.



Şekil 6.8. Canlı/Cansız varlıkların sınıflandırılma başarımında en yüksek sonuçları gösteren karışıklık matrisi

6.3. Sonular

Tez alışmasının bu blmnde yapılan alışmada savař benzeri atıřma ortamlarında dřman cephe hattındaki unsurların canlılıęının tespiti gerektięinde veya biyometrik doęrulama sistemlerini kullanan kiřilerin gerek kiřiler olup olmadıęının tespiti iin belirli bir mesafeden dřk gl lazer iřaretleri ile belirlenen hedefin canlı/cansız olarak sınıflandırılması yapılmıřtır. Canlı/Cansız sınıflandırmasında insan canlılıęı ile doęada bulunan dięer materyallerin karřılařtırılması (cansız) yapılmaktadır. Bu amala gnll deneklerin kolundan ve 17 adet materyalden lazer iřaretleri elde edilmiř, elde edilen lazer iřaretleri veri hazırlama adımlarından geirilerek derin ęrenme aęlarında kullanılan LSTM mimarisi kullanılarak eęitime tabi tutulmuř ve sınıflandırma yapılmıřtır. nerilen sistem ile ortalama %99,7 oranında yksek bir bařarım elde edilmiřtir.



7. LAZER İŞARETLERİ İLE RENK ALGILAMA

Literatür incelendiğinde renk tanıma üzerine yapılan çalışmalar genellikle sabit bir ölçüm düzeneğinin olduğu kapalı bir kutu içerisine yapılandırılmış ışık kaynaklarının yerleştirilmesi ve cismin kamera görüntüsünün alınması şeklindedir. Böyle bir ölçüm düzeneğinde renk algılama işlemi 10-15 cm gibi yakın mesafeden yapılabilmektedir.


Literatürdeki diğer bir renk algılama yaklaşımında ise; 1-2 cm gibi yakın bir mesafedeki cisim sırasıyla mavi, kırmızı ve yeşil renkteki bir ışık kaynağı ile aydınlatılmaktadır. Her bir aydınlatma işlemi sonrası hedef cisimden yansıyan ışık yoğunluk değerleri kayıt altına alınarak renk tespiti yapılmaktadır.

Bu bölümdeki çalışmada ise literatürdeki çalışmalardan farklı olarak uzak mesafeden tek renkli bir lazer ışığı kullanılarak bir materyalin renk tespiti yapılmaktadır. Çalışmanın bu bölümünde renk tespiti için kullanılan lazer modülünün konfigürasyonu, materyallerden veri elde etme yöntemi, veri hazırlama yöntemleri, önerilen makine öğrenmesi algoritması verilmektedir. Sonraki aşamada ise deneysel çalışmalardan elde edilen bulgular ve sonuçlar verilmektedir.

7.1. Lazer Işık Kaynağı ve Algılayıcı Sistem Tasarımı

Çalışmanın bu bölümünde 4. bölümde ayrıntıları verilen lazer ışık kaynağı ve algılayıcı modül donanımı kullanılmıştır. Önceki bölümlerdeki hedef analiz yaklaşımlarında kullanılan lazer modülünün donanım programı renk algılama uygulaması için revize edilmiştir. Bu güncelleme işleminde lazer modülünde bulunan PLL devresi aktif hale getirilmiştir. Bu şekilde hedefe yansıtılan lazer ışığı istenilen frekansta genlik modülasyonu ile modüle edilebilmektedir.

Asıl kullanım amacı lazer metre olan bu donanımda modüle edilen lazer ışığının bir cisme çarparak geri yansıyan lazer işareti ile modüldeki referans işareti birbiri ile karşılaştırılmaktadır. Bu şekilde hedeften yansıyan ışıktaki faz kaymasının miktarı tespit edilmekte ve hedefin uzaklığı hassas bir şekilde tespit edilebilmektedir. Lazer modülünde frekans karşılaştırma işlemi heterodin devresi yardımı ile yapılmaktadır. Heterodin devresinde f_1 ve f_2 frekanslarındaki 2 işaret karıştırılarak çıkışta $f_1 - f_2$ frekansında ve $f_1 + f_2$ frekansında 2 yeni işaret elde edilmektedir. 2 işaret kullanılarak $f_1 - f_2$ frekansında yeni bir işaret elde edilmek istenildiğinde heterodin devresinin çıkışında alçak geçiren filtre (Low Pass Filter, LPF) devresi kullanılmaktadır. Şekil 7. 1’de lazer modülünde bulunan faz karşılaştırma devresinin blok diyagramı görülmektedir.



Şekil 7.1. Lazer modülünde bulunan faz karşılaştırma devresinin blok diyagramı

Şekil 7.1’deki örnekte PLL devresi aracılığı ile biri 162.5 Mhz diğeri ise 162.505 Mhz olmak üzere 2 farklı frekansta işaret üretilmektedir. Heterodin devresi ve LPF devresi ile bu 2 frekansın farkı hesaplanarak 5 kHz’lik bir referans işareti oluşturulmaktadır. Lazer ışığı ise 162.5 Mhz ile modüle edilerek hedefe yansıtılmakta ve hedeften yansıyan lazer ışıkları yüksek kazanç değerlerine sahip APD ile sayısal işaretlere dönüştürülmektedir. İkinci bir heterodin devresi ile hedeften yansıyan 162.5 Mhz frekansında modüle edilmiş lazer işareti ile 162.505 MHz frekansındaki işaretin farkı hesaplanarak mikrodenetleyiciye giriş olarak sunulmaktadır. Mesafe tespit işlemlerinde referans işareti ile hedeften yansıyan işaret arasındaki faz farkı hesaplanmaktadır.

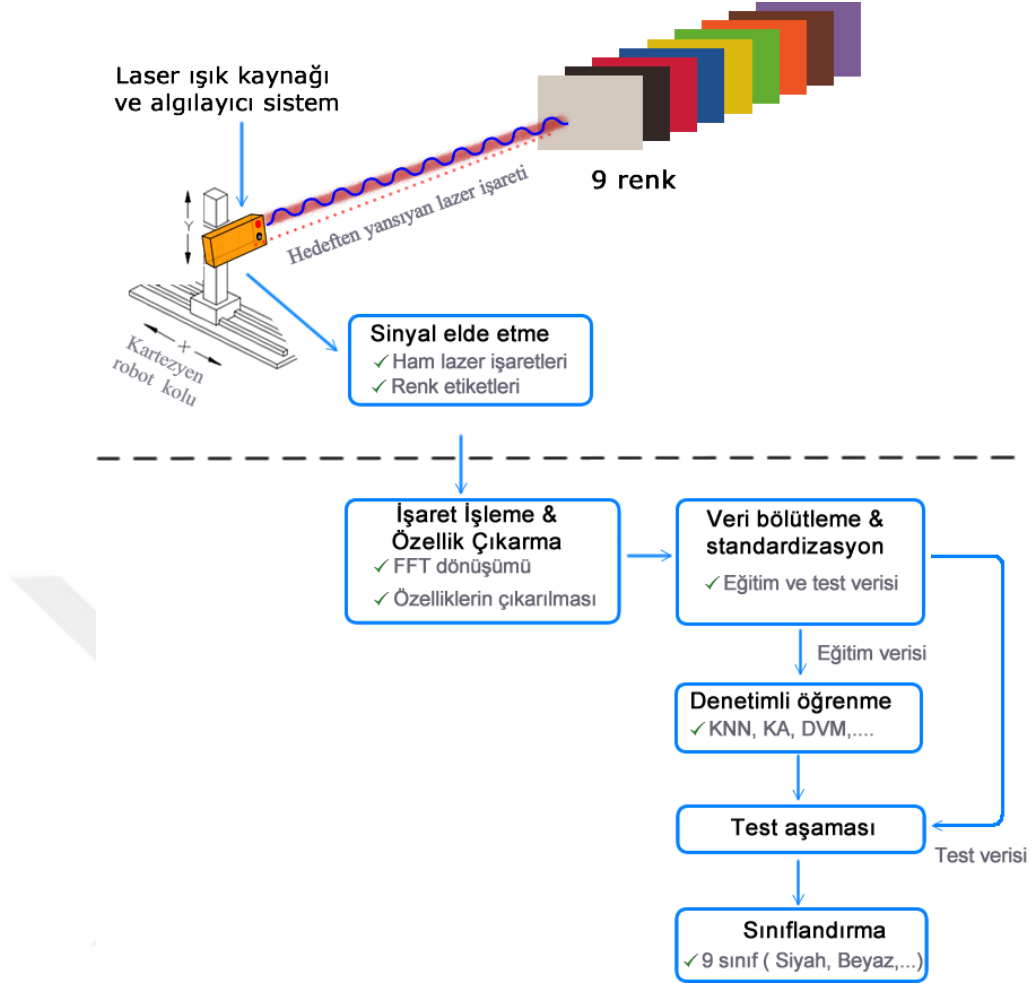
Lazer işaretleri ile hedef renginin tespit edildiği bu çalışmada PLL modülü aktif edilerek hedefe belirlenen bir frekansta modüle edilmiş lazer ışığı sürekli modda gönderilmektedir. Hedeften yansıyan lazer işaretleri heterodin devresi yardımı ile 5kHz frekansında yeni bir işarete dönüştürülerek mikro denetleyici ile kayıt altına alınmaktadır.

7.2. Materyal ve Yöntem

Bu çalışmada 3 farklı frekansta modüle edilmiş bir lazer işareti ve makine öğrenmesi algoritmaları kullanılarak uzak mesafede bulunan bir materyalin renk tespiti yapılmıştır.

7.2.1. Sistem Tasarımı

Tez çalışmasının bu bölümünde lazer işaretleri ile uzak mesafeden renk tespiti için yapılan çalışma farklı frekanslarda modüle edilmiş lazer işaretleri ile işaret elde etme, işaret önileme, özellik çıkarma ve sınıflandırma aşamalarından oluşmaktadır. Şekil 7.2’de lazer işaretleri ile renk tespiti yaklaşımının blok diyagramı görülmektedir.



Şekil 7.2. Önerilen renk tespiti yaklaşımının blok diyagramı

7.2.2. Materyal Seçimi

Çalışmada lazer işaretleri ile renk tespiti için siyah, beyaz, kırmızı, mavi, sarı, yeşil, turuncu, kahverengi ve eflatun renginden oluşan 9 adet renkli eva kâğıdı kullanılmıştır. Düzgün bir şekilde durabilmesi için 2 mm kalınlığındaki her bir eva kâğıdı 10x15 cm boyutlarında kesilerek sert bir mukavva kartona yapıştırılmıştır. Şekil 7.3'te lazer işaretleri ile renk tespiti yaklaşımında kullanılan eva kağıtları görülmektedir.



Şekil 7.3. Lazer işaretleri ile renk tespiti yaklaşımında kullanılan 9 farklı renkteki eva kağıtları

7.2.3. Deney Düzenegi ve Veri Toplama

Deneysel çalışmalar doğrudan güneş ışığı almayan, doğal ortam neminin yaklaşık %60 olduğu bir laboratuvar ortamında ve gündüz vakitlerinde yapılmıştır.

Bu çalışmada kullanılan lazer modülü üzerindeki PLL devresi yardımı ile lazer ışığı Tablo 7.1’te gösterilen frekanslarda modüle edilmektedir. Tablo 7.1’de görüldüğü üzere lazer modülünde bulunan PLL devresi yardımı ile 5 kHz frekans aralığında 2 adet işaret üretilmektedir. Modüle edilen sürekli formdaki lazer ışığı hedefe doğru yansıtılmakta ve hedeften yansıyan lazer ışıkları yüksek kazançlı APD ile lazer işaretlerine dönüştürülmektedir. Heterodin ve LPF devresi kullanılarak referans işaretinden yüksek frekanslı lazer işaretleri çıkartılarak 5 Khz frekansında yeni bir fark işareti elde edilmektedir. Lazer fark işareti mikro denetleyicide bulunan ADC ile 50 khz örnekleme frekansı ile 3000 boyutlu olarak kayıt altına alınmaktadır. Bu yöntem ile her bir ölçüm noktasından 3 farklı frekansta modüle edilmiş lazer işaretleri elde edilmektedir.

Tablo 7.1. Çalışmada kullanılan modülasyon ve referans frekansları


Sıra no	Lazer modülasyon frekansı	Referans işareti	Fark frekansı
1.	162,5 Mhz	162.505 Mhz	5 Khz
2.	191,5 Mhz	191.505 Mhz	5 Khz
3.	193,5 Mhz	193.505 Mhz	5 Khz

4. bölümde ayrıntıları verilen deney düzenegindeki Kartezyen robot kolu üzerine yerleştirilen lazer modülü ile 2 m uzaklıktaki renkli materyallerin her birinin 476 ölçüm noktasından 3 farklı modülasyon frekansındaki lazer işaretleri ardışık bir şekilde kayıt altına alınmıştır. Lazer işaretlerinin robot kolundan kaynaklanabilecek titreşimlerden etkilenmemesi için, robot kolunun konum değişikliğinden 3 sn sonra ölçüm yapılmıştır. Aynı ölçüm noktasında lazer

ışığı kapatılarak cihazdan ve ortamın gün ışığından kaynaklanabilecek gürültü işaretleri kayıt altına alınmış, ardından lazer ışığı açılarak hedeften yansıyan lazer işaretleri kayıt altına alınmıştır. Ölçümler yaklaşık 4 mm aralıklarla yapılmıştır.

7.2.4. İşaret İşleme Adımları


Farklı renklerdeki hedeflerden alınan lazer işaretlerinin frekansı heterodin ve LPF devresi yardımı ile 5 KHz frekansına dönüştürülmektedir. Cihazdan veya gün ışığından kaynaklanan gürültülerin giderilmesi için lazer ışığı açık iken hedeflerden yansıyan lazer işaretlerinden, lazer ışığı kapalı iken kayıt altına alınan cihaz/ortam gürültü işaretleri 4. Bölümde ayrıntıları verilen şekilde birbirinden çıkartılmıştır. Şekil 7.4'te çıkarma işleminden sonra siyah, beyaz ve kırmızı renkli eva kağıdının aynı ölçüm noktasından elde edilen 3 farklı modülasyon frekanslı lazer işaretleri görülmektedir. Şekil 7.4'te f_m modülasyon frekansını göstermektedir.



Şekil 7.4. Çıkarma işleminden sonra siyah, beyaz ve kırmızı renkli eva kağıdının aynı ölçüm noktasından elde edilen 3 farklı modülasyon frekanslı lazer işaretleri


Çıkarma işleminden sonra oluşan lazer işaretlerinin FFT algoritması kullanılarak ayrık Fourier dönüşümü (discrete Fourier transform, DFT) hesaplandığında elde edilen tek taraflı genlik


spektrumunda 5 KHz frekansına denk gelen genlik değerleri renk tespiti uygulamasında özellik değerleri olarak kullanılmıştır. Şekil 7.5'te FFT algoritmasına göre DFT değerlerinin hesaplanmasından sonra siyah, beyaz ve kırmızı renkteki eva kağıdının 3 farklı modülasyon frekansı için genlik değerleri görülmektedir.



Şekil 7.5. FFT algoritmasına göre DFT değerlerinin hesaplanmasından sonra siyah, beyaz ve kırmızı renkteki eva kağıdının 3 farklı modülasyon frekansı için genlik değerleri


Her bir renge ait DFT değerlerinin ayrıntılı olarak yorumlanabilmesi için Şekil 7.6'da 3 farklı modülasyon frekansı için elde edilen DFT değerlerinin kutu grafiği görülmektedir.





Şekil 7.6. 3 farklı modülasyon frekansı için elde edilen DFT değerlerinin kutu grafiği ve 3 farklı değer birleşimi ile elde edilen kutu grafiği

Şekil 7.7’te hedeflerden yansıyan lazer işaretlerinin 3 boyutlu DFT değerlerini görselleştirmek için t-dağıtılmış stokastik komşu yerleştirme (t-distributed Stochastic Neighbor Embedding, t-SNE) algoritması kullanılarak oluşturulan grafik görülmektedir. Denetimsiz bir makine öğrenmesi tekniği olan t-SNE ile çok boyutlu verilerin 2 veya 3 boyutta gösterilebileceği şekilde boyut azaltılması yapılmaktadır. Bu teknikte birbirine benzer veriler yakın noktalarda, farklı veriler ise birbirine uzak noktalarda olacak şekilde modellenmektedir.



Şekil 7.7. Farklı renklerden yansıyan lazer işaretlerine ait 3 boyutlu DFT değerlerinin t-SNE kullanılarak görselleştirilmesi


7.3. Bulgular ve Tartışma

Çalışmada, her bir modülasyon frekans değerine karşılık gelen DFT değerleri birer özellik olarak kullanılmış ve klasik makine öğrenimindeki başarımları karşılaştırılmıştır. Başarım değerlendirmeleri 10 katlı çapraz doğrulama tekniği kullanılarak yapılmıştır. Tablo 7.2’de klasik makine öğrenimi algoritmalarının başarım oranları görülmektedir.

Tablo 7.2. Klasik makine öğrenimi algoritmalarının renk tespiti uygulamasındaki başarım oranları

Sınıflandırıcılar	Kullanılan özellikler						
	f_1	f_2	f_3	$f_1 + f_2$	$f_1 + f_3$	$f_2 + f_3$	$f_1 + f_2 + f_3$
KA	89,6	90,8	90,9	90,3	91,2	90,9	90,8
DAA	89,7	90,6	90,6	90,5	90,8	90,8	90,8
NB	89,7	90,7	90,8	90,5	91,0	90,9	91,1
DVM	89,5	90,8	91,2	90,6	91,2	91,0	91,3
KNN	89,7	90,3	90,9	91,0	91,1	90,5	90,9

Tablo 7.2 incelendiğinde en yüksek başarım oranının her 3 özelliğin birlikte kullanıldığı veri setinde olduğu görülmektedir. 3 özelliğin birlikte kullanıldığı renk tespiti uygulamasında DVM algoritmasının ortalama %91,3 oranında bir başarım gösterdiği görülmektedir. DVM algoritması ile eğitim süresi ise 274,97 saniye olmuştur. Şekil 7.8’de DVM ile yapılan sınıflandırma işlemi sonucundaki karışıklık matrisi görülmektedir.



Şekil 7.8. Çalışmadaki en yüksek başarıma sahip sınıflandırıcının karışıklık matrisi

Karışıklık matrisi incelendiğinde tüm renk tayflarını içeren beyaz rengin %61,3 oranla en küçük *GP* değerine sahip olduğu görülmektedir. Karışıklık matrisinde beyaz, kırmızı ve sarı renklerinin birbirinin yerine tahmin edildiği görülmektedir. Sarı ve kırmızı renginin karışımı olan turuncu rengi ile sarı renginin birbirinin yerine tahmin edildiği görülmektedir.

Çalışmada 9 renkten oluşan veri tabanında beyaz rengine ait özellikler dışarıda bırakılarak 8 rengin tespiti klasik makine algoritmaları kullanılarak yeniden yapılmıştır. Tablo 7.3'te 8 rengin tespiti için elde edilen ortalama başarımlar görülmektedir.

Tablo 7.3. 8 rengin tespiti için elde edilen ortalama başarımlar

Sınıflandırıcılar	Kullanılan özellikler						
	f_1	f_2	f_3	$f_1 + f_2$	$f_1 + f_3$	$f_2 + f_3$	$f_1 + f_2 + f_3$
KA	97,3	97,7	98,1	97,7	97,9	98,0	97,9
DAA	97,3	97,7	97,8	97,7	97,8	97,7	97,8
NB	97,3	98,0	97,9	97,7	97,9	97,8	98,0
DVM	97,3	97,8	98,0	97,9	97,9	97,8	98,0
KNN	97,4	97,8	98,1	97,8	98,0	97,9	97,9

Tablo 7.3 incelendiğinde her bir özellik için ve sınıflandırıcı için benzer sonuçların elde edildiği görülmektedir. 8 rengin tespiti için yapılan çalışmada en yüksek ortalama başarımlar oranı %98,1 olmuştur. Şekil 7.9'da f_3 özelliğinin kullanıldığı ve KNN ile yapılan sınıflandırma işlemi sonucundaki karışıklık matrisi görülmektedir.

KNN ile 8 renk tespiti									
Gerçek Sınıflar	Kahverengi	Kırmızı	Eflatun	Mavi	Sarı	Siyah	Turuncu	Yeşil	
	99.8%					0.2%			99.8%
		99.2%			0.8%				99.2%
			99.6%					0.4%	99.6%
	0.2%			99.8%					99.8%
		2.9%			95.0%		2.1%		95.0%
						100.0%			100.0%
					6.9%		93.1%		93.1%
			1.7%					98.3%	98.3%
Tahmin Edilen Sınıflar									
									TPR
									FNR

Şekil 7.9. 8 renk tespit çalışmasında en yüksek başarıma sahip KNN sınıflandırıcısının karışıklık matrisi

Karışıklık matrisi incelendiğinde bir önceki çalışmaya benzer şekilde sarı ve turuncu renginin büyük oranda birbirinin yerine tahmin edildiği görülmektedir.

Bu çalışmada farklı renklerden oluşan hedeflere 3 farklı frekansta modüle edilmiş lazer ışığı yansıtılarak hedeflerden yansıyan lazer işaretleri kaydedilmiştir. 3 işaret türünden elde edilen genlik değerleri kullanılarak renk tespiti yapılmıştır. Bu çalışmaya yakın olan literatürdeki çalışmaların kısa özeti ve başarımlar karşılaştırması Tablo 7.4'te verilmiştir.

Tablo 7.4. Lazer işaretleri ile renk tespiti çalışmasının literatürdeki çalışmalarla karşılaştırılması

Çalışma	Renk sayısı	Özellikler	Sınıflandırıcı	Veri türü	Veri kaynağı	Doğruluk oranı (%)
Chen ve diğ. [39]	9	Hiperspektral yansıma değerleri	DAA	32 kanallı hiperspektral lazer	HSL	%91,9
Leung ve diğ. [40]	2 (25 farklı ton)	Lazer benek görüntüsü	KNN	Kırmızı ve yeşil lazer benek görüntüsü	Kamera	%55-%88
Önerilen model	9	Farklı modülasyon frekanslarındaki yansıma genlik değerleri	DVM	1 noktadan ölçüm yapılan yapılan lazer işareti	Lazer modülü	%91,3
Önerilen model	8	Farklı modülasyon frekanslarındaki yansıma genlik değerleri	DVM	1 noktadan ölçüm yapılan yapılan lazer işareti	Lazer modülü	%98,1

Tablo 7.4 incelendiğinde Chen ve diğerlerinin karanlık ortamda 32 kanallı HSL cihazı kullanarak yaptıkları çalışma lazer işaretleri ile renk algılanması çalışmasına en yakın çalışma olduğu görülmektedir [39]. Çalışmalarında en yüksek başarımları veren 3 dalga boyundaki lazer yansıma değerlerinin 32 kanalın birlikte kullanımına benzer bir sonuç verdiğini tespit etmişlerdir. 32 kanallı HSL cihazının kullanımı zor ve hassas bir kurulum gerektirmektedir. Bunun yanı sıra 32 kanalın kullanılması yüksek işlem maliyeti de getirmektedir.

7.4. Sonuçlar

Tez çalışmasının bu bölümünde 2 metre uzaklıkta bulunan farklı renkteki eva kağıtlarına 3 farklı frekansta modüle edilmiş lazer ışığı yansıtılarak, eva kağıtlarından yansıyan lazer işaretleri kayıt altına alınmıştır. Kayıt işleminden sonra ise işaret işleme, özellik çıkarma ve sınıflandırma işlemleri yapılmıştır. Her bir modülasyon frekansı için hedeflerden yansıyan lazer işaretlerinin DFT değerleri hesaplanarak, klasik makine öğrenmesi algoritmalarının eğitimi için özellik veri kümesi oluşturulmuştur.

Gündüz vakti farklı gün ve saatlerde laboratuvar ortamında yapılan deneysel çalışmalarda en yüksek sınıflandırma başarımları, 3 farklı modülasyon frekansına sahip lazer işaretlerinin DFT genlik değerlerinin birlikte kullanıldığı özellik seti ile sağlanmıştır. Çalışmada 9 renk için en yüksek

ortalama başarımları oranı %91,3 ile DVM ile gerçekleşmiştir. 8 renk için ise en yüksek başarımları oranı %98,1 olmuştur. 8 renk tespiti çalışmasında kullanılan tüm sınıflandırıcılar benzer sonuçlar vermiştir.

Elde edilen sonuçlar tek bir lazer ışığı kullanılarak uzak mesafedeki bir materyalin renginin temassız olarak yüksek bir başarımla sağlanabileceğini göstermektedir.




8. ATMOSFERİK OLAYLARIN LAZER İŞARETLERİ İLE HEDEF TANIMAYA ETKİSİ

Tez çalışmasının bu bölümünde farklı atmosferik şartların lazer işaretleri ile hedef tanıma uygulamalarındaki sınıflandırma başarısı üzerine etkisi incelenmektedir. Bu amaçla canlı/cansız varlıkların sınıflandırılması çalışması farklı nem ortamlarında ve sisli ortamda tekrarlanmış ve elde edilen sınıflandırma başarımları incelenmiştir.

Gün ışığının etkisi için ise lazer işaretleri ile uzaktan renk algılama uygulaması güneş ışığının olmadığı tamamen karanlık bir ortamda tekrarlanmış ve elde edilen sonuçlar incelenmiştir.

8.1. Ortamdaki Farklı Nem Oranlarının ve Sis Sınıflandırma Başarımına Etkisi

Aynı sıcaklıkta havada bulunabilecek maksimum su buharı miktarının mevcut su buharı oranına bağlı nem denilmektedir [234]. Sıklıkla karşılaşılan hava olaylarından bir olan sis ise çok küçük su taneciklerinden oluşmaktadır [76]. Yeryüzüne yakın yerlerde sıcaklık farkından dolayı havanın içindeki su buharının yoğunlaşması sonucu sis oluşmakta ve yatay görüş mesafesini 1 km'den daha aşağı düşürmektedir. Lazer ışıkları kullanılan dalga boyuna göre atmosferde bulunan su damlacıkları tarafından emilmekte veya saçılmaya sebep olabilmektedir. Aynı şekilde hedef materyal veya varlıkların yüzeyi nemli veya ıslak olabilmektedir. Hedeften yansıyan lazer ışık yoğunluğu ortamdaki nem oranına, hedefteki nem oranına ve kullanılan lazerin dalga boyuna göre değişebilmektedir [235,236]. Benzer durum sisli ortamlar içinde geçerli olmaktadır. Şekil 8.1'de lazer işaretleri ile hedef tespit yaklaşımında lazer ışıklarının ortamdaki sis taneciklerinden saçılması görülmektedir.



Şekil 8.1. Lazer işaretleri ile hedef tespit yaklaşımında lazer ışıklarının ortamdaki sis taneciklerinden saçılması

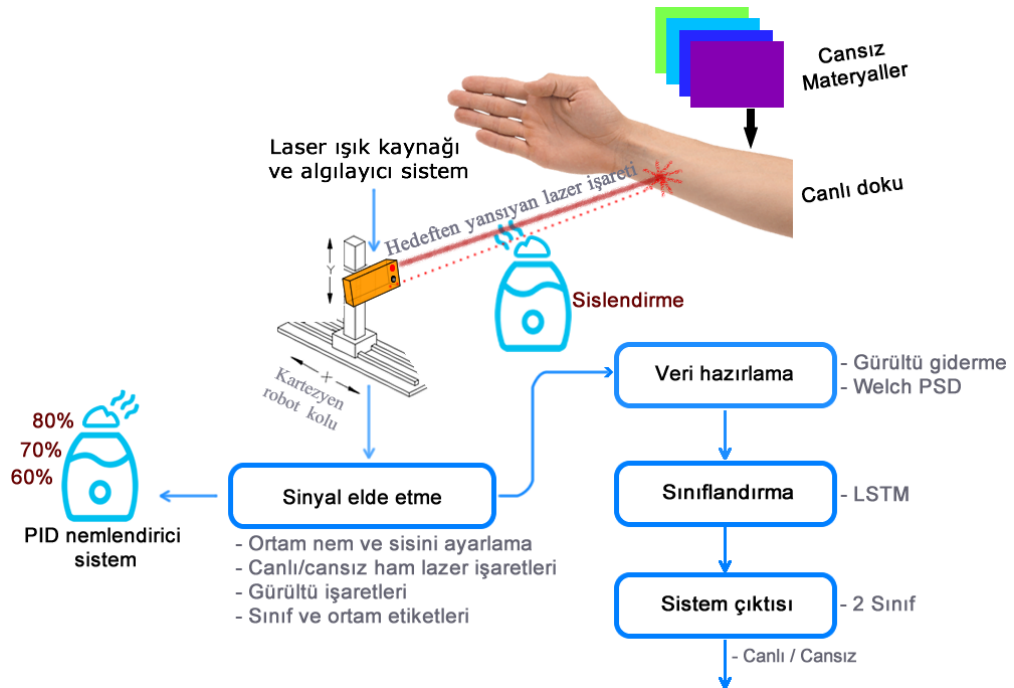
Açık alanda kullanılacak bir uzaktan algılama sisteminde, bağıl hava neminin yüksekliği veya sisin olması durumunda ortamda bulunan yüksek miktardaki küçük su parçacıkları gürültüye sebep olacak ve sistemin algılama başarımının da olumsuz etkileyebilecektir. Farklı nem aralıklarını ve sisi dikkate alan bir uzaktan tanıma sisteminin tasarlanması bu açıdan önem arz etmektedir. Bu amaçla 6.bölümde canlı/cansız varlıkların sınıflandırma çalışmasının yapıldığı laboratuvar ortamı farklı nem oranları ile nemlendirilmiş ve çalışma tekrarlanmıştır. Benzer bir çalışma da sisli ortamda yapılmıştır.

8.1.1. Materyal ve Yöntem

Çalışmanın bu bölümünde farklı bağıl nem oranları ve sis altında canlı/cansız sınıflandırması için gerçekleştirilen sistemin tasarımı, materyal ve kullanıcı seçimi, veri hazırlama adımları ve derin öğrenme mimarisinin tasarımı açıklanmaktadır.

Sistem Tasarımı

Çalışma farklı bağıl nem ortamlarındaki hedeflerden lazer işaretlerini elde etme, veri hazırlama ve sınıflandırma aşamalarından oluşmaktadır. Çalışmanın blok şeması Şekil 8.2’de görülmektedir. Çalışmada laboratuvar ortamının nemlendirilmesinde PID kontrollü ultrasonik hava nemlendirici kullanılmıştır. Çalışma kapsamında canlı/cansız hedef türlerine lazer ışığı yansıtılmakta ve hedeflerden yansıyan lazer işaretleri algılayıcı sistem ile bilgisayar sistemine aktarılmaktadır.



Şekil 8.2. Canlı/cansız varlıkların farklı nem oranlarında ve sisli ortamlarda sınıflandırma yaklaşımı

Kullanıcı ve Materyal Seçimi

Çalışma kapsamında 14 sağlıklı erkek deneğin kolundan ve 6. Bölümde de kullanılan 17 adet cansız materyalden farklı nem ortamlarında ve sisli ortamda lazer işaretleri alınmıştır. Deneysel çalışmaya katılan kullanıcıların yaş aralıkları Tablo 8.1’de görülmektedir.

Tablo 8.1. Önerilen hedef analiz çalışmasında deneysel çalışmaya katılan deneklerin yaş aralığı

Yaş	Katılımcı sayısı
18	1
19	7
20	3
22	1
23	1
40	1


Çalışma öncesi katılımcılar deney düzeneği, çalışma prosedürü ve çalışmanın amacı hakkında bilgilendirilmiştir. Çalışmalarda denekler ayakta iken rahat edebilecekleri bir konumda ve avuç içleri açık bir şekilde iken deneklerin sağ kolunun iç kısmından ölçümler yapılmıştır.

Deney Düzeneği ve Veri Toplama

Canlı/cansız varlıkların lazer işaretleri ile sınıflandırılmasında ortamdaki farklı nem oranlarının ve yoğun sisin etkisini araştırmak için yapılan ölçümlerde, ortamın sıcaklık ve bağıl nem değerleri de kayıt altına alınmıştır.


Ortamdaki bağıl nem oranını düzenlemek için PID kontrollü bir ultrasonik nemlendirici tasarlanmıştır. Bu düzenek ile laboratuvardaki bağıl nem oranı istenilen değerde sabitlenebilmektedir.

Deneysel çalışmalar gündüz vakitlerinde ortam bağıl neminin %60, %70, %80 olarak sabitlendiği laboratuvar ortamında yapılmıştır. Ortamdaki nem oranı istenilen nem oranına ulaştıktan 30 dk. sonra ölçümlere başlanmıştır. Her bir farklı nem ortamında ayrı ayrı yapılan ölçümlerde, hedeflere lazer ışığı yansıtıldıktan sonra hedeflerden yansıyan lazer işaretleri kayıt altına alınmıştır. Şekil 8.3’te deneye katılan deneklerden birinin kol pozisyonu ve mermer malzemesinin deney düzeneği üzerindeki konumu görülmektedir.



Şekil 8.3. Çalışmada kullanılan canlı ve cansız varlıkların deney düzeneğindeki konumu

Sisin canlı/cansız varlıkların sınıflandırılması üzerindeki etkisini tespit ölçmek için de ölçümler yapılmıştır. Bu amaçla ölçümler esnasında hedef ile lazer modülünün arasına ultrasonik nemlendirici ile sürekli olarak su buharı püskürtülmüştür. Oluşturulan bu deneysel ortamda da her deneğin koluna ve her bir materyale lazer ışığı yansıtılarak, hedeflerden yansıyan lazer işaretleri kayıt altına alınmıştır. Şekil 8.4’de sisli ortamda yapılan bir ölçüm örneği görülmektedir.



Şekil 8.4. Sisli ortamda yapılan ölçüm örneği

Her bir nem ve sisli ortam için ayrı ayrı 14 erkek deneğin kolunun farklı noktalarından 272’şer adet lazer işareti ve 17 adet materyalin farklı noktalarından ise 400’er adet lazer işareti örneği alınmıştır. Ölçümler hedeflerin sol alt tarafından başlanarak yaklaşık 5 mm aralıklarla sağdan sola ve soldan sağa doğru olacak şekilde sırasıyla alınmıştır. Ölçüm sisteminin ortam ışığına duyarlılığını ortadan kaldırmak amacı ile her bir ölçüm öncesinde lazer ışığı kapatılarak ortam ışığının ve cihazın olduğu gürültüler de kayıt altına alınmıştır.

Veri toplama işleminin sonunda her bir nem ortamı ve sisli ortam için, 14 erkek deneğin kolundan ve diğer cansız varlıklardan elde edilen lazer işaretlerinin sayısı Tablo 8.2’de verilmiştir. Tabloda aynı zamanda 6. Bölümde yapılan çalışmadaki bağıl nemin $\%34 \pm 2$ olduğu doğal laboratuvar ortamında bu çalışmada olmayan farklı kişilerden oluşan 9 erkek denekten ve bu çalışmada da kullanılan 17 adet cansız varlıktan elde edilen lazer işaretlerinin sayısı da görülmektedir.

Tablo 8.2. Farklı ortam türlerinde canlı/cansız varlıklardan elde edilen işaret sayısı

Ortam türü	Hedef türü	Lazer işareti sayısı	Ortam/cihaz gürültü işareti sayısı
Doğal ortam (%34 ± 2 bağıl nem)	Canlı	1170	1170
	Cansız	6647	6647
%60 bağıl nem	Canlı	3808	3808
	Cansız	6800	6800
%70 bağıl nem	Canlı	3808	3808
	Cansız	6800	6800
%80 bağıl nem	Canlı	3808	3808
	Cansız	6800	6800
Sisli ortam	Canlı	3808	3808
	Cansız	6800	6800


Veri Hazırlama Adımları ve Derin Öğrenme Mimarisinin Seçimi

Sınıflandırma çalışmalarında her bir sınıfa ait eşit miktarda eğitim verisinin kullanılması durumunda sınıflandırıcının herhangi bir sınıfa ait yanlış sonuçlar üretmesinin önüne geçilebilmektedir. Çalışmada kullanılan işaret sayısının eşitlenmesi amacıyla, Tablo 8.2’de verilen materyallere ait işaretler alt örnekleme yoluyla seçilmiştir. Cansız işaretlerin örnekleme sonucu oluşan yeni işaret sayıları Tablo 8.3’te görülebilir.

Tablo 8.3. Cansız varlıklardaki işaretlerin örnekleme sonucu oluşan yeni işaret sayıları


Ortam türü	Hedef türü	Lazer işareti sayısı	Ortam/cihaz gürültü işareti sayısı
Doğal ortam (%34 ± 2 bağıl nem)	Canlı	1170	1170
	Cansız	1170	1170
%60 bağıl nem	Canlı	3808	3808
	Cansız	3808	3808
%70 bağıl nem	Canlı	3808	3808
	Cansız	3808	3808
%80 bağıl nem	Canlı	3808	3808
	Cansız	3808	3808
Sisli ortam	Canlı	3808	3808
	Cansız	3808	3808

Örnekleme işleminin ardından, her bir nem oranında ve sisli ortamda hedeflerden yansıyan lazer işaretlerinden gürültü işaretleri çıkartılarak ortam ışığı/cihaz gürültüsü ortadan kaldırılmaya çalışılmıştır. Şekil 8.5’te doğal laboratuvar ortamında (%34 ± 2), %60, %70, %80 bağıl nem ortamında ve sisli ortamda canlıyı temsilen erkek deneğin kolundan ve cansız varlığı temsilen ıhlamurdan alınan lazer işaretleri, gürültü işaretleri ve çıkarma işlemi sonucunda elde edilen işaretler görülmektedir.



Şekil 8.5. Farklı ortam koşullarında canlı, cansız(ıhlamur) materyallerine ait ham lazer işaretleri, beyaz gürültü ve çıkarma işlemi sonucundaki lazer işaretleri


Farklı ortam koşullarında erkek deneklerden ve çeşitli materyallerden elde edilen lazer işaretlerinin geneli hakkında fikir sahibi olunabilmesi için çıkarma işlemi sonrasında her bir nem ortamında ve sisli ortamda elde edilen lazer işaretlerinin normalize edilmiş enerjisi Denklem 4.14’de verildiği şekilde hesaplanmıştır. Şekil 8.6’da doğal laboratuvar ortamında ($\%34 \pm 2$), %60, %70, %80 nemli ortamda ve sisli ortamdaki çıkarma işlemi sonrasında elde edilen ham lazer işaretlerinin normalize edilmiş enerji dağılım grafiği sınıflar bazında görülmektedir.



Şekil 8.6. Doğal laboratuvar ortamında, %60, %70, %80 nemli ortamda ve sisli ortamdaki çıkarma işlemi sonrasında elde edilen ham lazer işaretlerinin normalize edilmiş enerji dağılım grafiği

Farklı nem oranlarının olduğu ortamların ve sisli ortamların canlı/cansız varlıkların lazer işaretleri ile sınıflandırma başarımına etkisinin incelendiği bu çalışmada, 6. Bölümde doğal laboratuvar ortamında yapılan canlı/cansız varlıkların sınıflandırılması çalışmasıyla aynı koşullarda yapılması ve karşılaştırma yapılabilmesi amacıyla veri hazırlama süreçleri aynı tutulmuştur. Bu yaklaşımla lazer işaretlerinden gürültü işaretlerinin çıkarılması sonrasında elde edilen lazer işaretlerine Welch PSD dönüşümü uygulanmıştır. Dönüşüm işlemi sonrası işaretlerin boyutu 63 noktaya düşmüştür. Şekil 8.7’de doğal laboratuvar ortamında, %60, %70, %80 nem oranlarında ve sisli ortamdaki canlıdan ve ıhlamurdan yansıyan lazer işaretlerine çıkarma

işleminden sonra elde edilen ham lazer işaretlerine Welch PSD dönüşümü uygulanması sonucu oluşan işaretler görülmektedir.



Şekil 8.7. Doğal laboratuvar ortamında, %60, %70, %80 nem oranlarında ve sisli ortamdaki canlıdan ve ıhlamurdan yansıyan lazer işaretlerine çıkarma işleminden sonra elde edilen ham lazer işaretlerine Welch PSD dönüşümü uygulanması sonucu oluşan işaretler

Atmosferik etkilerin canlı/cansız varlıkların sınıflandırma başarımına etkisinin incelendiği bu bölümde 6. Bölümde yapılan doğal nem ortamındaki çalışma ile karşılaştırma yapılabilmesi için bu çalışmada önerilen mimari kullanılmıştır. Bu mimaride bir sıralı giriş katmanı, 64 gizli birimden oluşan LSTM katmanı, 2 birimden oluşan tam bağlı katman, Softmax katmanı ve sınıflandırma

katmanı bulunmaktadır. Önerilen derin öğrenme mimarisinin eğitimi için kullanılan hiper parametreler bir önceki çalışmada belirtilen şekliyle kullanılmıştır.

8.1.2. Bulgular ve Tartışmalar

Atmosferik ortam etkilerinin lazer işaretleri ile hedef sınıflandırma başarımına etkisinin incelendiği bu çalışmada, bağıl hava neminin %34 olduğu doğal laboratuvar koşullarında, yapay nemlendirme ile bağıl nem oranının %60, %70, %80 olarak ayarlandığı laboratuvar koşullarında ve ölçüm ortamının sisli olduğu laboratuvar koşullarında canlı/cansız varlıkların sınıflandırılması yapılmıştır. Ölçümler esnasında ortam neminin ± 2 oranında saptığı görülmüştür.


10 kat çapraz doğrulama yönteminin kullanıldığı bu çalışmada veri seti 10 eşit parçaya bölünerek başarımlar değerlendirilmiştir. Bu amaçla 10 eşit parçaya bölünen veri setinin 9 bölümü ağı eğitimi için, 1 bölümü ise test işlemi için kullanılmış ve elde edilen başarımların ortalaması alınarak sistemin ortalama başarımları bulunmuştur.

Çalışma kapsamında her bir ortamda elde edilen veri seti 3 farklı şekilde kullanılarak canlı/cansız sınıflandırma yaklaşımının başarımlar karşılaştırmaları yapılmıştır. BSınıflandırma çalışmasının birinci yönteminde her bir bağıl nem oranı için ve sisli ortam için ayrı ayrı yapılmıştır. Bu yöntemde ağı eğitimi parametrelerinde eğitim tur sayısı 100 seçilmiştir. Tablo 8.4’de 10 kat çapraz doğrulama yöntemi ile yapılan sınıflandırma çalışmasında her bir nem ortamına ait başarımlar oranları görülmektedir.

Tablo 8.4. 10 kat çapraz doğrulama tekniği ile her bir bağıl nem oranı ve sisli ortam için yapılan Canlı/Cansız sınıflandırmasının ortalama başarımları

Ortam türü	Geri Çağırma (%)	Kesinlik (%)	F1-Skor (%)	Doğruluk (%)
Doğal ortam (Önceki çalışma)	99.70 $\pm$ 0,45	99.70 $\pm$ 0,45	99.70 $\pm$ 0,45	99.70 $\pm$ 0,45
%60 bağıl nem	99,73 $\pm$ 0,26	99,72 $\pm$ 0,27	99,73 $\pm$ 0,26	99,72 $\pm$ 0,27
%70 bağıl nem	99,53 $\pm$ 0,27	99,53 $\pm$ 0,27	99,53 $\pm$ 0,27	99,53 $\pm$ 0,27
%80 bağıl nem	99,71 $\pm$ 0,25	99,71 $\pm$ 0,25	99,71 $\pm$ 0,25	99,71 $\pm$ 0,25
Sisli ortam	99,09 $\pm$ 0,48	99,08 $\pm$ 0,49	99,09 $\pm$ 0,48	99,08 $\pm$ 0,49
Ortalama Başarımlar	99,52	99,51	99,52	99,51

Tablo 8.4 incelendiğinde önerilen veri hazırlama adımlarının ve derin öğrenme mimarisinin farklı nem oranlarının olduğu ortamlarda yüksek bir başarımlar oranı göstermekle beraber sisli ortamdaki başarımların yaklaşık 1 puan düştüğü görülmektedir. Sisli ortamda en düşük başarımlar oranı %98,55 şeklinde olmuştur. Sisli ortamda en düşük başarımlara ait doğruluk grafiği ve test verileri için karışıklık matrisi Şekil 8.8’de görülmektedir.



a)

Test - Karışıklık Matrisi

	Cansız	Canlı	
Gerçek Sınıflar	371 48.8%	2 0.3%	99.5% 0.5%
	9 1.2%	379 49.8%	97.7% 2.3%
	97.6% 2.4%	99.5% 0.5%	98.6% 1.4%
	Cansız	Canlı	Tahmin Edilen Sınıflar

b)


Şekil 8.8. Sisli ortamda en düşük başarıma ait doğruluk grafiği ve test verileri için karışıklık matrisi

Sınıflandırma çalışmasının 2. yönteminde farklı bağıl nem ortamlarında ve sisli ortamda alınan veriler birleştirilmiştir. 10 kat çapraz doğrulama işlemi bu yöntem için de uygulanmıştır. Bu yöntemde ise ağırlıklı eğitim parametrelerinde eğitim tur sayısı 35 olarak seçilmiştir. Bu yöntemde elde edilen başarımlar Tablo 8.5'te görülmektedir.

Tablo 8.5. Farklı bağıl nem ortamlarında ve sisli ortamda alınan verilerin birleştirilmesi ile yapılan canlı/cansız sınıflandırmasının başarımları

Ortam türü	Geri Çağırma (%)	Kesinlik (%)	F1-Skor (%)	Doğruluk (%)
Birleştirilmiş farklı ortam verileri	99,48 ± 0,17	99,48 ± 0,17	99,50 ± 0,06	99,48 ± 0,17

Farklı bağıl nem ortamlarında alınan verilerin ve sisli ortamda alınan verilerin birleştirilmesi ile yapılan sınıflandırma çalışmasında eğitim tur sayısı daha az tutulmasına rağmen başarımların birinci yöntemle hemen hemen aynı olduğu görülmektedir. Bu yöntemde en düşük başarımlar oranı %99,21 olmuştur. Şekil 8.9'da birleştirilmiş verilerle yapılan eğitim işleminde en düşük başarıma ait doğruluk grafiği ve test verileri için karışıklık matrisi görülmektedir.



Şekil 8.9. Birleştirilmiş verilerle yapılan eğitim işleminde en düşük başarıma ait doğruluk grafiği ve test verileri için karışıklık matrisi

Sınıflandırma çalışmasının 3. yönteminde ise nemli ortamdaki veya sisli ortamdaki veri grubu önerilen derin öğrenme mimarisinin sadece eğitimi için kullanılırken, geriye kalan diğer nem ortamlarındaki ve sisli ortamdaki veriler ise test verisi olarak kullanılmaktadır. Örneğin doğal laboratuvar ortamında elde edilen lazer işaretlerinin %90'ı eğitim için kullanılmakta, geriye kalan %10 doğal ortam lazer işaretleri, %60, %70, %80 oranındaki bağıl nem ortamından ve sisli ortamdan elde edilen lazer işaretlerinin tamamı ise test verisi olarak kullanılmaktadır. Bir sonraki aşamada ise diğer ortam işaretlerinden birisi eğitim için kullanılırken geriye kalan lazer işaretleri ise test için kullanılmaktadır. Bu yöntem ile elde edilen başarımlar Tablo 8.6'da görülmektedir.

Tablo 8.6. 10 kat çapraz doğrulama tekniği ile her bir bağıl nem oranı ve sisli ortam için yapılan canlı/cansız sınıflandırmasının ortalama başarımları

Eğitim verisi	Test verisi başarımlar oranları (%)					
	Doğal ortam	%60 bağıl nem	%70 bağıl nem	%80 bağıl nem	Sisli ortam	Ortalama Başarımlar
Doğal ortam (Önceki çalışma)	99,49	91,58	93,29	92,48	92,4	92,44
%60 bağıl nem	98,03	99,91	98,32	99,93	98,58	99,19
%70 bağıl nem	97,65	98,95	99,65	99,66	97,28	98,89
%80 bağıl nem	89,91	99,02	97,62	99,54	95,31	97,87
Sisli ortam	99,53	99,24	98,1	99,62	99,42	99,1

Eğitim verisi
 Test verisi

Tablo 8.6 incelendiğinde örnek sayısı az olan doğal ortamdaki lazer işaretlerinin eğitim verisi olarak kullanıldığı durumda, kendi veri grubu içerisinde %100'e yakın doğrulama başarımları göstermesine rağmen önerilen sistemdeki sınıflandırıcının diğer ortam türlerindeki başarımları

en düşük %91,58 olmaktadır. Örnek sayısı diğer ortam türleri ile eşit olan %60 bağıl nem ortamındaki lazer işaretlerinin eğitim verisi olarak kullanıldığı durumda önerilen sistemdeki sınıflandırıcının diğer ortam türlerindeki en düşük başarımlar oranı %98,03 olmaktadır. Bu yöntemdeki en yüksek ortalama başarımlar oranı %60 bağıl nem ortamında elde edilen lazer işaretlerinin eğitim verisi olarak kullanılması ile elde edilmiştir.

8.1.3. Sonuçlar

Tez çalışmasının bu bölümünde yapılan çalışmada nemli ve sisli ortamların lazer işaretleri ile hedef sınıflandırması başarımlarına etkisi incelenmiştir. Doğal nem oranının %34 olduğu ve yapay nemlendirme ile nem oranının %60, %70 ve %80 olarak ayarlandığı bir laboratuvar ortamında, her bir nem oranı için farklı nesne türlerinden ve insanların kolundan lazer işaretleri elde edilmiş ve elde edilen işaretler geliştirilen derin öğrenme ağına eğitilmiştir. Benzer bir çalışmada sisli ortam için tekrarlanmıştır.

Çalışmada önerilen sistemin farklı bağıl nem ortamlarındaki başarımların ortalama %99,51 oranında olduğu görülmüştür. Elde edilen sonuçlar neticesinde, önerilen sistemin neme karşı duyarlı olmadığı ve sistemin belirli bir mesafedeki varlıkları canlı/cansız olarak sınıflandırmasının mümkün olduğu görülmüştür.

8.2. Gün Işığının Sınıflandırma Başarımlarına Etkisi

Gün ışığı, gündüz vakitlerinde yapılan lazer ölçümlerinde önemli miktarda gürültüye sebep olabilmektedir. Hedeflerden yansıyan lazer ışığı lazer algılayıcı modülü tarafından sayısal işaretlere dönüştürülmektedir. Gündüz vakitlerinde yapılan ölçümlerde APD algılayıcı hem hedeften yansıyan lazer ışınlarını hem de etraftan saçılan güneş ışınlarını algılamaktadır. Güneş ışınlarının çevredeki nesnelerden ve havadaki aerosollardan saçılması sonucu APD algılayıcıya ulaşan fotonlar ve lazer ışığının hedefe çarpıp tekrar APD algılayıcıya ulaşan fotonlar farklı kaynaklardan olmasına rağmen APD algılayıcıda aynı şekilde algılanmaktadır.


Çalışmanın bu bölümünde gün ışığının renk tespiti uygulamasına olan etkisi incelenmektedir. Bu amaçla 7. Bölümde gündüz vakitlerinde laboratuvar ortamında yapılan renk tespiti uygulaması gece vakti tamamen karanlık bir ortamda tekrarlanarak, gün ışığının sınıflandırma başarımlarına etkisi incelenmektedir.

8.2.1. Materyal ve Yöntem

Gün ışığının renk tespiti uygulamasına etkisinin incelenmesi için yapılan bu çalışmada 9 renkten oluşan eva kağıtlarından farklı günlerde ve gece vakitlerinde tamamen karanlık bir ortamda lazer işaretleri elde edilmiştir. Lazer işaretleri ile ölçümler yapıldığında doğal ortam nemi %58-


%68 aralığında olmuştur. Deneysel çalışmalar esnasında pencereler ışık geçirmeyen siyah bir perde ile kapatılmış ve ölçümler esnasında da ortam ışıklandırması kapatılmıştır.

Önceki bölümdeki çalışmaya benzer şekilde her bir renkli materyalin 476 noktasından lazer işareti ve ayrıca lazer ışığı kapatılarak ortam/cihaz gürültü işareti kayıt altına alınmıştır. Cihaz gürültüsünün giderilmesi amacı ile lazer işaretlerinden cihaz gürültü işaretleri çıkartılmış ve ardından sınıflandırıcıda kullanılmak üzere her 3 modülasyon frekansındaki lazer işaretlerinin DFT değerleri hesaplanarak 3 boyutlu özellik veri kümesi oluşturulmuştur. Şekil 8.10'da çıkarma işleminden sonra siyah, beyaz ve kırmızı renkli eva kağıdının aynı ölçüm noktasından elde edilen 3 farklı modülasyon frekanslı lazer işaretleri görülmektedir.




Şekil 8.10. Karanlık ortamda yapılan renk tespiti çalışmasında çıkarma işleminden sonra siyah, beyaz ve kırmızı renkli eva kağıdının aynı ölçüm noktasından elde edilen 3 farklı modülasyon frekanslı lazer işaretleri


Şekil 8.11'de FFT algoritmasına göre DFT değerlerinin hesaplanmasından sonra siyah, beyaz ve kırmızı renkteki eva kağıdının 3 farklı modülasyon frekansı için genlik değerleri görülmektedir.



Şekil 8.11. Karanlık ortamda yapılan renk tespiti çalışmasında FFT algoritmasına göre DFT değerlerinin hesaplanmasından sonra siyah, beyaz ve kırmızı renkteki eva kağıdının 3 farklı modülasyon frekansı için genlik değerleri


Her bir renge ait DFT değerlerinin ayrıntılı olarak yorumlanabilmesi için Şekil 8.12’de 3 farklı modülasyon frekansı için elde edilen DFT değerlerinin kutu grafiği görülmektedir.





Şekil 8.12. Karanlık ortamda yapılan renk tespiti çalışmasında, 3 farklı modülasyon frekansı için elde edilen DFT değerlerinin kutu grafiği

Şekil 8.13'te hedeflerden yansıyan lazer işaretlerinin 3 boyutlu DFT değerlerinin t-SNE algoritması ile görselleştirildiği grafik görülmektedir.



Şekil 8.13. Karanlık ortamda yapılan renk tespiti çalışmasında farklı renklerden yansıyan lazer işaretlerine ait 3 boyutlu DFT değerlerinin t-SNE kullanılarak görselleştirmesi

8.2.2. Bulgular ve Tartışmalar

Atmosferik ortam etkilerinin lazer işaretleri ile hedef sınıflandırma başarımına etkisinin incelendiği bu çalışmada, gündüz vakitlerinde ve gece tamamen karartılmış bir ortamda farklı renklerden oluşan eva kağıtlarının renk tespiti yapılmıştır. 10 kat çapraz doğrulama tekniği


kullanılarak yapılan renk tespiti çalışmalarında gece ve gündüz vakitlerinde elde edilen veri seti 3 farklı şekilde kullanılarak başarımlar karşılaştırmaları yapılmıştır.

Birinci yöntemde gündüz vakti aydınlık ortamda elde edilen veri seti ve gece vakti karanlık ortamda elde edilen veri seti ayrı ayrı kullanılarak KA, DAA, NB, DVM ve KNN sınıflandırıcı algoritmalarında eğitilerek renk tespiti yapılmıştır. Tablo 8.7’de 10 kat çapraz doğrulama yöntemi ile yapılan renk tespiti çalışmasında gündüz aydınlık ve gece karanlık ortamdaki başarımlar oranları görülmektedir. Gündüz vakti aydınlık ortamda yapılan renk tespiti uygulamasında en yüksek başarımlar değerini veren f_1, f_2 ve f_3 modülasyon frekanslarına karşılık gelen DFT değerleri gece karanlık ortamda yapılan çalışmada da özellik olarak kullanılmıştır.

Tablo 8.7. 10 kat çapraz doğrulama tekniği ile her bir bağıl nem oranı ve sisli ortam için yapılan Canlı/Cansız sınıflandırmasının ortalama başarımları

Sınıflandırıcı	Gündüz aydınlık ortam başarımlar değerleri	Gece karanlık ortam başarımlar değerleri
KA	90,8	88,0
DAA	90,8	86,9
NB	91,1	88,6
DVM	91,3	88,7
KNN	90,9	88,7

Tablo 8.7 incelendiğinde her iki ortam verileri için de DVM’lerinin yüksek başarımlar oranı sağladığı görülmektedir. Gece karanlık ortamda DVM ile yapılan renk tespit çalışmasında test verileri için karışıklık matrisi Şekil 8.14’de görülmektedir.



Şekil 8.14. Karanlık ortamda test verileri için en yüksek başarıma ait karışıklık matrisi


Şekil 8.14'deki karışıklık matrisi incelendiğinde, gece karanlık ortamda yapılan renk tespiti sonuçlarının gündüz aydınlık ortamda yapılan renk tespiti sonuçları ile benzer sonuçlar verdiği görülmektedir. Her iki ortam türünde de tüm renkleri içinde barındıran beyaz rengin diğer renklerin yerine tahmin edildiği görülmektedir. Benzer bir şekilde sarı renginin de turuncu renginin yerine tahmin edildiği görülmektedir. Turuncu rengi sarı ve kırmızı renklerinin karışımından elde edilmektedir. Bir benzer durum da eflatun renginde görülmektedir. Eflatun rengi ve yeşil rengi birbirinin yerine tahmin edilmektedir. Her iki rengin karışımında mavi tonu bulunmaktadır.

Sınıflandırma çalışmasının 2. yönteminde gündüz vakti aydınlık ortamdan ve gece vakti karanlık ortamdan alınan veriler birleştirilmiştir. 10 kat çapraz doğrulama tekniğinin de kullanıldığı bu yöntemde elde edilen başarımlar Tablo 8.8'de görülmektedir.

Tablo 8.8. Gündüz vakti aydınlık ortamdan ve gece vakti karanlık ortamdan alınan verilerin birleştirilmesi ile yapılan renk tespiti uygulamasının başarımları

Sınıflandırıcı	Birleştirilmiş farklı ortam verileri ile başarımlar (%)
KA	89,1
DAA	88,6
NB	89,3
DVM	89,4
KNN	89,2

Gündüz aydınlık ortamda ve gece karanlık ortamda alınan verilerin birleştirilmesi ile yapılan renk tespiti uygulamasındaki başarımların birinci yöntemdeki başarımlarına yakın olduğu görülmektedir. Şekil 8.15'te birleştirilmiş verilerle yapılan eğitimde test verileri için karışıklık matrisi görülmektedir. Karışıklık matrisi incelendiğinde bir önceki yöntemle benzer sonuçlar verildiği görülmektedir.




Şekil 8.15. Birleştirilmiş verilerle yapılan eğitimde test verileri için karışıklık matrisi

Sınıflandırma çalışmasının 3. yönteminin birinci adımında gündüz aydınlık ortamda elde edilen veriler kullanılarak DVM ile eğitim yapılırken, gece karanlık ortamda alınan veriler ise test verisi olarak kullanılmaktadır. İkinci adımda ise gece karanlık ortamda elde edilen veriler kullanılarak DVM ile eğitim yapılırken, gündüz aydınlık ortamda alınan veriler ise test verisi olarak kullanılmaktadır. Bu yöntem ile test verileri için elde edilen başarımlar Tablo 8.9’da görülmektedir.

Tablo 8.9. Gündüz aydınlık ortamda elde edilen verilerin ve gece karanlık ortamda elde edilen verilerden bir grubun eğitim ve diğer grubun ise test verisi olarak kullanılması sonucu oluşan başarımlar

Sınıflandırıcı	Eğitim verisi	Test verisi	Ortalama başarımlar (%)
DVM	Gündüz aydınlık ortam verileri	Gece karanlık ortam verileri	%86,7
DVM	Gece karanlık ortam verileri	Gündüz aydınlık ortam verileri	%90,1

Tablo 8.9 incelendiğinde gece karanlık ortamda alınan verilerin eğitim verisi olarak kullanılması durumunda daha başarılı sonuçlar verdiği görülmektedir. Şekil 8.16’da gündüz aydınlık ortam eğitim verileri kullanılarak elde edilen sonuçlar için karışıklık matrisi ve gece karanlık ortam verilerinin eğitim için kullanıldığı durumdaki karışıklık matrisi görülmektedir.



Şekil 8.16. Gündüz aydınlık ortamda elde edilen verilerin ve gece karanlık ortamda elde edilen verilerden bir grubun eğitim ve diğer grubun ise test verisi olarak kullanılması sonucu elde edilen karışıklık matrisleri

8.2.3. Sonuçlar

Tez çalışmasının bu bölümünde gün ışığının renk tespiti üzerindeki etkisi incelenmiştir. Bu amaçla gündüz vakti aydınlık ortamda elde edilen lazer işaretleri ve gece karanlık ortamda elde edilen lazer verileri ayrı ayrı kullanılarak renk tespiti yapılmıştır. 2. aşamada her iki ortam için elde edilen veriler birleştirilerek renk tespiti yapılmıştır. 3. aşamanın birinci adımında gündüz aydınlık ortamda elde edilen veriler eğitim için kullanıldığında gece karanlık ortamda elde edilen veriler ise test verisi olarak kullanılmıştır. 3. aşamanın ikinci adımında gece karanlık ortamda elde edilen

veriler eğitim için kullanıldığında gündüz aydınlık ortamda elde edilen veriler ise test verisi olarak kullanılmıştır.

Tüm eğitim senaryolarına bakıldığında tüm renk tayflarını içeren beyaz rengi ile diğer renklerin birbirinin yerine tahmin edildiği görülmektedir. Benzer şekilde sarı renginin ve turuncu renginin, eflatun renginin yeşil renginin birlerinin yerine tahmin edildiği görülmektedir. Sarı ve kırmızı renginin karışımı ile turuncu rengi elde edilebilmektedir. Aynı şekilde yeşil renginin karışımında ve eflatun renginin karışımında mavi renk bulunmaktadır.

Yapılan deneysel sonuçlarda gece karanlık ortamda elde edilen verilerin eğitim verisi olarak kullanılması durumunda gündüz aydınlık ortamda elde edilen veriler ile başarılı bir şekilde renk tespitinin yapılabildiği görülmektedir. Benzer bir şekilde gece veya gündüz şartlarında lazer işaretleri ile renk tespiti yaklaşık %90 başarı oranı ile tespit edilebilmektedir.



9. SONUÇLAR VE ÖNERİLER

Bu tez çalışmasında lazer işaretleri ve yapay zeka kullanılarak çeşitli hedef analiz yaklaşımları önerilmiştir. Bu amaçla bir lazer metre donanımı yeniden programlanarak hedeflerden yansıyan lazer işaretlerinin kaydedilmesine olanak sağlanmıştır. Çeşitli hedef analiz yaklaşımları için lazer işaretlerinden oluşan bir veri setinin oluşturulmasına ihtiyaç bulunmaktadır. Bu amaçla bir deney düzeneği oluşturulmuştur. Bu çalışmada kurulan deney düzeneği ile belirli bir mesafede bulunan farklı hedef türlerinden lazer işaretleri alınmıştır. Hedef türlerinden işaret elde edilme işlemi esnasında önce lazer ışığı kapatılarak ortam ışıklarının veya cihazın sebep olduğu gürültülü işaretler kayıt altına alınmış, sonrasında ise lazer cihazı aynı konumda iken lazer ışığı açılarak ilgili hedef türüne yansıtılmış ve hedeften yansıyan lazer işaretleri kayıt altına alınmıştır. Bu ölçüm yöntemi ile sistemin ortam aydınlatmasına ve cihazdan kaynaklanan gürültülere karşı dayanıklılığı artırılmıştır.

Tez çalışmanın ilk hedef analiz yaklaşımında, temel seviyedeki bir lazer modülü kullanılarak uzak mesafedeki malzemelerin sınıflandırılması için LSTM, Derin LSTM ve NCP ile derin öğrenme mimarisi tasarlanmış ve bu sınıflandırıcıların başarımı doğrulanmıştır. Önerilen yöntemde materyallerden geri yansıyan lazer ışık yoğunluğuna bağlı olarak elde edilen 3000 boyutlu sayısal değerlerden oluşan ham lazer işaretleri gürültü giderme işleminin ardından Welch PSD ve Yule Walker AR dönüşümü sonrası 32 ve 63 boyutlu işaretlere dönüştürülmüştür. Bu veri hazırlama yöntemi ile derin öğrenme mimarisinin toplam işlem maliyeti büyük oranda düşmektedir. Bunun yanında önerilen NCP modeli sayesinde az sayıdaki nöron ve az sayıdaki nöronlar arasındaki bağlantı ile yüksek oranda doğru bir şekilde temassız ve uzaktan malzeme sınıflandırması yapılabilmektedir.

Tez çalışmanın ikinci hedef analiz yaklaşımında, lazer işaretleri ile cinsiyet tespiti yapılmaktadır. Bu hedef analizi yaklaşımında kameraya dayalı geleneksel cinsiyet ayırım yöntemi yerine düşük güçlü lazer ışıkları ile cinsiyet tespiti önerilmektedir. Bu amaçla deneklerin kolundan lazer işaretleri alınarak, LSTM derin öğrenme mimarisinde eğitilmiş ve sistemin başarımlarının doğrulanması yapılmıştır.

Tez çalışmasının 3. hedef analiz yaklaşımında, savaş benzeri çatışma ortamlarında düşman cephe hattındaki unsurların canlılık tespitinin gerektiği durumlar için veya biyometrik doğrulama sistemlerini kullanan kişilerin gerçek kişiler olup olmadığının tespitinin gerektiği durumlar için lazer işaretleri ile belirlenen hedeflerin canlı/cansız olarak sınıflandırılması yapılmaktadır. Bu amaçla gönüllü erkek deneklerin kolundan ve 17 adet materyalden lazer işaretleri elde edilmiş, elde edilen lazer işaretleri işaret işleme adımlarından geçirildikten sonra önerilen LSTM derin öğrenme mimarisi kullanılarak eğitime tabi tutulmuş ve sınıflandırma yapılmıştır.

Tez çalışmasının 4. hedef analiz yaklaşımında ise lazer işaretleri ve makine öğrenmesi yöntemleri ile belirlenen bir hedefin rengi tespit edilmektedir. Bu amaçla farklı renklerden oluşan eva kağıtlarından toplanan lazer işaretleri önışleme, özellik çıkarma ve eğitim aşamalarından geçirilerek renk tespiti yapılmaktadır.

Tez çalışmasının 5. yaklaşımında ise farklı nem ortamları, sis, gün ışığı, karanlık ortam gibi farklı atmosferik şartların hedef analiz yaklaşımı üzerindeki başarıma etkisi incelenmiştir. Yapılan çalışmalarda önerilen sistemin neme karşı dayanıklı olduğu, sisten ise %1 seviyesinde bir etkileneceğinin olduğu görülmektedir. Benzer şekilde gün ışığının hedef analiz yaklaşımı üzerindeki etkisi incelenmiştir. Tamamen karanlık bir ortamda elde edilen verilerle eğitilen bir sistemin gün ışığında da başarılı sonuçlar ürettiği tespit edilmiştir.

Hedef analiz yaklaşımlarında elde edilen başarılı sonuçlar, kamera gibi ışıktan kolaylıkla etkilenen sistemlerin aksine ortam ışığından etkilenmeyen tek bir lazer ışığı ile hedeflerin analiz edilebileceğini göstermektedir. Önerilen sistemin işlem maliyetinin düşük olması sayesinde herhangi bir uygulamaya kolaylıkla adapte edilebilir. Yapılan deneysel çalışmalar neticesinde belirli bir mesafede bulunan hedeflerin lazer işaretleri ile tespitinin mümkün olduğu sonucuna ulaşılmıştır.

Lazer işaretlerinin materyal ile cihaz arasındaki mesafeye, cihazın iç donanımına ve yazılımına, materyalin normali ile lazerin açısına göre değiştiği bilinmektedir. Materyalin normali ile lazer cihazının arasındaki açı yansıyan yoğunluk değerlerinde farklılıklar oluşturacaktır ve bu durumda da sınıflandırma başarımları olumsuz etkilenebilecektir. Lazer cihazı ile materyal arasındaki mesafe ve açığı dikkate alan çalışmalara ihtiyaç bulunmaktadır.

İlerleyen zamanlarda önerilen sistemin başarımlarını daha da yükseltmek için öğrenme verisi artırılabilir ve sistemin doğrudan güneş ışığı altında, karlı ve yağmurlu ortamlardaki başarımları üzerine çalışma yapılabilir.

Lazer teknolojisi kullanan ve kapalı alanlarda otonom sürüş yeteneğine sahip robotlara bu sistem entegre edilerek ortam haritasının çıkarılmasının yanında ortamdaki hedef türlerinin de tespiti yapılabilir. Tespiti yapılan bu materyallere göre robotlara farklı görevler de yüklenebilecektir.

KAYNAKLAR

- [1] Singh M, Arora AS. A Novel Face Liveness Detection Algorithm with Multiple Liveness Indicators. *Wireless Personal Communications* 2018;100:1677–87. <https://doi.org/10.1007/S11277-018-5661-1/FIGURES/9>.
- [2] Matthew P, Anderson M. Novel categorisation techniques for liveness detection. *Proceedings - 2014 8th International Conference on Next Generation Mobile Applications, Services and Technologies, NGMAST 2014* 2014;153–8. <https://doi.org/10.1109/NGMAST.2014.51>.
- [3] Fei J, Xia Z, Yu P, Xiao F. Adversarial attacks on fingerprint liveness detection. *Eurasip Journal on Image and Video Processing* 2020;2020:1–11. <https://doi.org/10.1186/S13640-020-0490-Z/TABLES/7>.
- [4] Maiman TH. Stimulated Optical Radiation in Ruby. *Nature* 1960 187:4736 1960;187:493–4. <https://doi.org/10.1038/187493a0>.
- [5] Sumpf B. Wavelength stabilized high-power diode lasers — Devices and applications. 2016 International Conference Laser Optics (LO), IEEE; 2016, p. R3-3-R3-3. <https://doi.org/10.1109/LO.2016.7549713>.
- [6] Kawamura Y. Applications of III-V Semiconductors for Mid-infrared Lasers. *Molecular Beam Epitaxy*, Chichester, UK: John Wiley & Sons Ltd; 2019, p. 169–74. <https://doi.org/10.1002/9781119354987.ch10>.
- [7] Douplik A, Saiko G, Schelkanova I, Tuchin V V. The response of tissue to laser light. *Lasers for Medical Applications: Diagnostics, Therapy and Surgery*, Woodhead Publishing; 2013, p. 47–109. <https://doi.org/10.1533/9780857097545.1.47>.
- [8] Berkovic G, Shafir E. Optical methods for distance and displacement measurements. *Advances in Optics and Photonics* 2012;4:441. <https://doi.org/10.1364/AOP.4.000441>.
- [9] Kaushal H, Kaddoum G. Applications of Lasers for Tactical Military Operations. *IEEE Access* 2017;5:20736–53. <https://doi.org/10.1109/ACCESS.2017.2755678>.
- [10] Olgun N, Türkoğlu İ. Lazer İşaretleri ile Otomatik Hedef Tanıma. *Sakarya University Journal of Computer and Information Sciences* 2018;1:1–10.
- [11] Lutzmann P, Göhler B, van Putten F, Hill CA. Laser vibration sensing: overview and applications. In: Kamerman GW, Steinvall O, Bishop GJ, Gonglewski JD, Lewis KL, Hollins RC, et al., editors. *Electro-Optical Remote Sensing, Photonic Technologies, and Applications V*, 2011, p. 818602. <https://doi.org/10.1117/12.903671>.
- [12] Sun L, Du J, Xie Z, Xu Y. Auxiliary Features from Laser-Doppler Vibrometer Sensor for Deep Neural Network Based Robust Speech Recognition. *Journal of Signal Processing Systems* 2018;90:975–83. <https://doi.org/10.1007/s11265-017-1287-x>.
- [13] Wojtkowska M, Kedzierski M, Delis P. Validation of terrestrial laser scanning and artificial intelligence for measuring deformations of cultural heritage structures. *Measurement* 2020;167:108291. <https://doi.org/10.1016/j.measurement.2020.108291>.
- [14] Han KK, Golparvar-Fard M. Appearance-based material classification for monitoring of operation-level construction progress using 4D BIM and site photologs. *Automation in Construction* 2015;53:44–57. <https://doi.org/10.1016/j.autcon.2015.02.007>.
- [15] Hassan MU, Akcamete-Gungor A, Meral C. Investigation of Terrestrial Laser Scanning Reflectance Intensity and RGB Distributions to Assist Construction Material Identification. *Lean and Computing in Construction Congress - Volume 1: Proceedings of the Joint Conference on Computing in Construction*, Edinburgh: Heriot-Watt University; 2017, p. 507–15. <https://doi.org/10.24928/JC3-2017/0312>.
- [16] Yuan L, Guo J, Wang Q. Automatic classification of common building materials from 3D terrestrial laser scan data. *Automation in Construction* 2020;110:103017. <https://doi.org/10.1016/j.autcon.2019.103017>.
- [17] Shen Y, Wang J, Wei S, Zheng D, Ferreira VG. Accurate extraction of brick shapes in

- masonry walls from dense terrestrial laser scanning point cloud. *Measurement: Journal of the International Measurement Confederation* 2019;146:254–67. <https://doi.org/10.1016/j.measurement.2019.05.086>.
- [18] Martino F, Patruno C, Mosca N, Stella E. Material recognition by feature classification using time-of-flight camera. *Journal of Electronic Imaging* 2016;25:061412. <https://doi.org/10.1117/1.jei.25.6.061412>.
 - [19] Callenberg C, Shi Z, Heide F, Hullin MB. Low-cost SPAD sensing for non-line-of-sight tracking, material classification and depth imaging. *ACM Transactions on Graphics (TOG)* 2021;40. <https://doi.org/10.1145/3450626.3459824>.
 - [20] Su S, Heide F, Swanson R, Klein J, Callenberg C, Hullin M, et al. Material Classification Using Raw Time-of-Flight Measurements. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, vol. 2016- December, IEEE Computer Society; 2016, p. 3503–11. <https://doi.org/10.1109/CVPR.2016.381>.
 - [21] Lang S, Zhang J, Cai Y, Zhu X, Wu Q. Classification of materials using a pulsed time-of-flight camera. *Machine Vision and Applications* 2021;32:30. <https://doi.org/10.1007/s00138-020-01163-5>.
 - [22] Kim J, Lim H, Ahn SC, Lee S. RGBD Camera Based Material Recognition via Surface Roughness Estimation. *Proceedings - 2018 IEEE Winter Conference on Applications of Computer Vision, WACV 2018* 2018;2018-January:1963–71. <https://doi.org/10.1109/WACV.2018.00217>.
 - [23] Conde MH. A Material-Sensing Time-of-Flight Camera. *IEEE Sensors Letters* 2020;4. <https://doi.org/10.1109/LSSENS.2020.3005042>.
 - [24] Lu Q, Lee S, Chen L. Image-driven fuzzy-based system to construct as-is IFC BIM objects. *Automation in Construction* 2018;92:68–87. <https://doi.org/10.1016/j.autcon.2018.03.034>.
 - [25] Liu C, Gu J. Discriminative illumination: Per-pixel classification of raw materials based on optimal projections of spectral BRDF. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 2014;36:86–98. <https://doi.org/10.1109/TPAMI.2013.110>.
 - [26] Son H, Kim C, Hwang N, Kim C, Kang Y. Classification of major construction materials in construction environments using ensemble classifiers. *Advanced Engineering Informatics* 2014;28:1–10. <https://doi.org/10.1016/j.aei.2013.10.001>.
 - [27] Dimitrov A, Golparvar-Fard M. Vision-based material recognition for automated monitoring of construction progress and generating building information modeling from unordered site image collections. *Advanced Engineering Informatics* 2014;28:37–49. <https://doi.org/10.1016/j.aei.2013.11.002>.
 - [28] Bian P, Li W, Jin Y, Zhi R. Ensemble feature learning for material recognition with convolutional neural networks. *Eurasip Journal on Image and Video Processing* 2018;2018:1–11. <https://doi.org/10.1186/s13640-018-0300-z>.
 - [29] Bell S, Upchurch P, Snavely N, Bala K. Material Recognition in the Wild With the Materials in Context Database 2015:3479–87.
 - [30] Wu C, Zhang F, Wang B, Liu KJR. mSense. *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies* 2020;4:2020. <https://doi.org/10.1145/3411822>.
 - [31] Dhekne AM. Wireless sensing: Material identification and localization. 2019.
 - [32] Windau J, Shen WM. An inertia-based surface identification system. *Proceedings - IEEE International Conference on Robotics and Automation* 2010:2330–5. <https://doi.org/10.1109/ROBOT.2010.5509310>.
 - [33] Liu H, Song X, Bimbo J, Seneviratne L, Althoefer K. Surface material recognition through haptic exploration using an intelligent contact sensing finger. *IEEE International Conference on Intelligent Robots and Systems* 2012:52–7. <https://doi.org/10.1109/IROS.2012.6385815>.
 - [34] Baglio S, Cantelli L, Giusa F, Muscato G. Intelligent prodder: Implementation of measurement methodologies for material recognition and classification with humanitarian

- demining applications. *IEEE Transactions on Instrumentation and Measurement* 2015;64:2217–26. <https://doi.org/10.1109/TIM.2014.2386917>.
- [35] Erickson Z, Xing E, Srirangam B, Chernova S, Kemp CC. Multimodal material classification for robots using spectroscopy and high resolution texture imaging. *IEEE International Conference on Intelligent Robots and Systems, Institute of Electrical and Electronics Engineers Inc.*; 2020, p. 10452–9. <https://doi.org/10.1109/IROS45743.2020.9341165>.
 - [36] Xiong NN, Shen Y, Yang K, Lee C, Wu C. Color sensors and their applications based on real-time color image segmentation for cyber physical systems. *Eurasip Journal on Image and Video Processing* 2018;2018:1–16. <https://doi.org/10.1186/S13640-018-0258-X/FIGURES/6>.
 - [37] Muniraj M, Dhandapani V. Underwater image enhancement by combining color constancy and dehazing based on depth estimation. *Neurocomputing* 2021;460:211–30. <https://doi.org/10.1016/J.NEUCOM.2021.07.003>.
 - [38] Manninen H, Paakki M, Hopia A, Franzén R. Measuring the green color of vegetables from digital images using image analysis. *LWT - Food Science and Technology* 2015;63:1184–90. <https://doi.org/10.1016/J.LWT.2015.04.005>.
 - [39] Chen B, Shi S, Gong W, Sun J, Chen B, Du L, et al. True-Color Three-Dimensional Imaging and Target Classification Based on Hyperspectral LiDAR. *Remote Sensing* 2019, Vol 11, Page 1541 2019;11:1541. <https://doi.org/10.3390/RS11131541>.
 - [40] Leung TS, Jiang S, Kirkpatrick SJ, Wang RK, Duncan DD, Kulesz-Martin M, et al. Classifying hidden colors behind an opaque layer with the acoustically modulated laser speckle contrast technique. *Optics Express*, Vol 21, Issue 17, Pp 20197–20209 2013;21:20197–209. <https://doi.org/10.1364/OE.21.020197>.
 - [41] Milovanovic B, Tomovic V, Djekic I, Miocinovic J, Solowiej BG, Lorenzo JM, et al. Colour assessment of milk and milk products using computer vision system and colorimeter. *International Dairy Journal* 2021;120:105084. <https://doi.org/10.1016/J.IDAIRYJ.2021.105084>.
 - [42] Goñi SM, Salvadori VO. Color measurement: comparison of colorimeter vs. computer vision system. *Journal of Food Measurement and Characterization* 2017;11:538–47. <https://doi.org/10.1007/s11694-016-9421-1>.
 - [43] Minz PS, Saini CS. RGB camera-based image technique for color measurement of flavored milk. *Measurement: Food* 2021;4:100012. <https://doi.org/10.1016/J.MEAFOO.2021.100012>.
 - [44] Nguyen CN, Vo VT, Cong Ha N. Developing a computer vision system for real-time color measurement – A case study with color characterization of roasted rice. *Journal of Food Engineering* 2022;316:110821. <https://doi.org/10.1016/J.JFOODENG.2021.110821>.
 - [45] Minz PS, Saini CS. Comparison of computer vision system and colour spectrophotometer for colour measurement of mozzarella cheese. *Applied Food Research* 2021;1:100020. <https://doi.org/10.1016/J.AFRES.2021.100020>.
 - [46] Heng C, Shen H, Wang F, Chen Y. Calibrated color measurement of cashmere using a novel computer vision system. *Measurement* 2021;185:109991. <https://doi.org/10.1016/J.MEASUREMENT.2021.109991>.
 - [47] Yang PK, Chen JC, Chuang YH. Improvement on reflective color measurement using a tri-color LED by multi-point calibration. *Optics Communications* 2007;272:320–4. <https://doi.org/10.1016/J.OPTCOM.2006.11.051>.
 - [48] Saracoglu ÖG, Altural H. Color Regeneration from Reflective Color Sensor Using an Artificial Intelligent Technique. *Sensors* 2010, Vol 10, Pages 8363–8374 2010;10:8363–74. <https://doi.org/10.3390/S100908363>.
 - [49] Qiu K, Chen W, Zhou H, Wang C, Cui Z. Evaluation of the color measurement based on a microscopic hyperspectral imaging system. *Color Research & Application* 2021;46:1205–17. <https://doi.org/10.1002/COL.22663>.
 - [50] Li S, Pandharipande A. LED-based color sensing and control. *IEEE Sensors Journal*

- 2015;15:6116–24. <https://doi.org/10.1109/JSEN.2015.2453408>.
- [51] Ali S, Wu Z, Zhou M, Du G, Li X, Pengcheng F. Human identification using sensors data based on 3D gait area. *Proceedings - 2014 International Conference on Cyberworlds, CW 2014*, Institute of Electrical and Electronics Engineers Inc.; 2014, p. 285–92. <https://doi.org/10.1109/CW.2014.46>.
 - [52] Anchal S, Mukhopadhyay B, Kar S. Predicting gender from footfalls using a seismic sensor. *2017 9th International Conference on Communication Systems and Networks, COMSNETS 2017*, Institute of Electrical and Electronics Engineers Inc.; 2017, p. 47–54. <https://doi.org/10.1109/COMSNETS.2017.7945357>.
 - [53] Nayak JS, Indiramma M. An approach to enhance age invariant face recognition performance based on gender classification. *Journal of King Saud University - Computer and Information Sciences* 2021. <https://doi.org/10.1016/j.jksuci.2021.01.005>.
 - [54] Mustafa A, Meehan K. Gender Classification and Age Prediction using CNN and ResNet in Real-Time. *2020 International Conference on Data Analytics for Business and Industry: Way Towards a Sustainable Economy, ICDABI 2020*, Institute of Electrical and Electronics Engineers Inc.; 2020, p. 1–6. <https://doi.org/10.1109/ICDABI51230.2020.9325696>.
 - [55] Do TD, Nguyen VH, Kim H. Real-time and robust multiple-view gender classification using gait features in video surveillance. *Pattern Analysis and Applications* 2020;23:399–413. <https://doi.org/10.1007/s10044-019-00802-6>.
 - [56] Sengupta S, Yasmin G, Ghosal A. Classification of male and female speech using perceptual features. *8th International Conference on Computing, Communications and Networking Technologies, ICCCNT 2017*, Institute of Electrical and Electronics Engineers Inc.; 2017, p. 1–7. <https://doi.org/10.1109/ICCCNT.2017.8204065>.
 - [57] Qadri SAA, Gunawan TS, Wani T, Alghifari MF, Mansor H, Kartiwi M. Comparative Analysis of Gender Identification using Speech Analysis and Higher Order Statistics. *2019 IEEE 6th International Conference on Smart Instrumentation, Measurement and Application, ICSIMA 2019*, Institute of Electrical and Electronics Engineers Inc.; 2019, p. 1–6. <https://doi.org/10.1109/ICSIMA47653.2019.9057296>.
 - [58] Bales D, Tarazaga PA, Kasarda M, Batra D, Woolard AG, Poston JD, et al. Gender Classification of Walkers via Underfloor Accelerometer Measurements. *IEEE Internet of Things Journal* 2016;3:1259–66. <https://doi.org/10.1109/JIOT.2016.2582723>.
 - [59] Zhang X, Javed S, Dias J, Werghi N. Person Gender Classification on RGB-D Data With Self-Joint Attention. *IEEE Access* 2021;9:166303–13. <https://doi.org/10.1109/ACCESS.2021.3135428>.
 - [60] Nixon MS, Carter JN. Automatic recognition by gait. *Proceedings of the IEEE* 2006;94:2013–24. <https://doi.org/10.1109/JPROC.2006.886018>.
 - [61] Kwon B, Lee S. Joint Swing Energy for Skeleton-Based Gender Classification. *IEEE Access* 2021;9:28334–48. <https://doi.org/10.1109/ACCESS.2021.3058745>.
 - [62] Zhang D, Wang Y. Using multiple views for gait-based gender classification. *26th Chinese Control and Decision Conference, CCDC 2014*, IEEE Computer Society; 2014, p. 2194–7. <https://doi.org/10.1109/CCDC.2014.6852532>.
 - [63] Russel NS, Selvaraj A. Gender discrimination, age group classification and carried object recognition from gait energy image using fusion of parallel convolutional neural network. *IET Image Processing* 2021;15:239–51. <https://doi.org/10.1049/ipr2.12024>.
 - [64] Dileep MR, Danti A. Human Age and Gender Prediction Based on Neural Networks and Three Sigma Control Limits. *Applied Artificial Intelligence* 2018;32:281–92. <https://doi.org/10.1080/08839514.2018.1451217>.
 - [65] Debnath SBC. TTW life sign detection by means of CW X-band radar, homeland security and rescue applications. *2017 USNC-URSI Radio Science Meeting (Joint with AP-S Symposium), USNC-URSI 2017*, Institute of Electrical and Electronics Engineers Inc.; 2017, p. 89–90. <https://doi.org/10.1109/USNC-URSI.2017.8074911>.

- [66] Zhang H, Zhang L, Gao Q, Xiao Y, Hong H, Zhu X. Body Movement Cancellation Based on Hybrid Radar-Webcam Sensing System. IEEE MTT-S 2019 International Microwave Biomedical Conference, IMBioC 2019 - Proceedings, Institute of Electrical and Electronics Engineers Inc.; 2019. <https://doi.org/10.1109/IMBIOC.2019.8777873>.
- [67] JalaliBidgoli F, Moghadami S, Ardalan S. A Compact Portable Microwave Life-Detection Device for Finding Survivors. IEEE Embedded Systems Letters 2016;8:10–3. <https://doi.org/10.1109/LES.2015.2489209>.
- [68] Wu CW, Huang ZY. Using the phase change of a reflected microwave to detect a human subject behind a barrier. IEEE Transactions on Biomedical Engineering 2008;55:267–72. <https://doi.org/10.1109/TBME.2007.910680>.
- [69] Scalise L, Morbiducci U, Melis M De. A laser Doppler approach to cardiac motion monitoring: effects of surface and measurement position. SPIE Proceedings, vol. 6345, 2006, p. 63450D-63450D – 11. <https://doi.org/10.1117/12.693151>.
- [70] Scalise L, Morbiducci U. Non-contact cardiac monitoring from carotid artery using optical vibrocardiography. Med Eng Phys 2008;30:490–7. <https://doi.org/10.1016/j.medengphy.2007.05.008>.
- [71] De Melis M, Morbiducci U, Scalise L. Identification of cardiac events by Optical Vibrocardiography: Comparison with Phonocardiography. Annual International Conference of the IEEE Engineering in Medicine and Biology - Proceedings, 2007. <https://doi.org/10.1109/IEMBS.2007.4352949>.
- [72] Yufu Qu, Tao Wang, Zhigang Zhu. Remote audio/video acquisition for human signature detection. 2009 IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops, IEEE; 2009, p. 66–71. <https://doi.org/10.1109/CVPRW.2009.5204294>.
- [73] Marchionni P, Scalise L, Antonioli L, nobile S, Carnielli VP. Non-contact procedure to measure heart and lung activities in preterm pediatric patients with skin disorders. In: Longo L, editor. Laser Florence 2017: Advances in Laser Medicine, vol. 10582, SPIE; 2018, p. 20. <https://doi.org/10.1117/12.2316345>.
- [74] Takano C, Ohta Y. Heart rate measurement based on a time-lapse image. Medical Engineering and Physics 2007;29:853–7. <https://doi.org/10.1016/j.medengphy.2006.09.006>.
- [75] Ozana N, Margalith I, Beiderman Y, Kunin M, Campino GA, Gerasi R, et al. Demonstration of a Remote Optical Measurement Configuration That Correlates with Breathing, Heart Rate, Pulse Pressure, Blood Coagulation, and Blood Oxygenation. Proceedings of the IEEE 2015;103:248–62. <https://doi.org/10.1109/JPROC.2014.2385793>.
- [76] Rasshofer RH, Spies M, Spies H. Influences of weather phenomena on automotive laser radar systems. Advances in Radio Science 2011;9:49–60. <https://doi.org/10.5194/ars-9-49-2011>.
- [77] Kijima D, Kushida T, Kitajima H, Tanaka K, Kubo H, Kubo H, et al. Time-of-flight imaging in fog using multiple time-gated exposures. Optics Express, Vol 29, Issue 5, Pp 6453-6467 2021;29:6453–67. <https://doi.org/10.1364/OE.416365>.
- [78] Muraji T, Tanaka K, Funatomi T, Mukaigawa Y. Depth from phasor distortions in fog. Optics Express, Vol 27, Issue 13, Pp 18858-18868 2019;27:18858–68. <https://doi.org/10.1364/OE.27.018858>.
- [79] Kutila M, Pyykonen P, Holzhuter H, Colomb M, Duthon P. Automotive LiDAR performance verification in fog and rain. IEEE Conference on Intelligent Transportation Systems, Proceedings, ITSC 2018;2018-November:1695–701. <https://doi.org/10.1109/ITSC.2018.8569624>.
- [80] Colomb M, Hirech K, André P, Boreux JJ, Lacôte P, Dufour J. An innovative artificial fog production device improved in the European project “FOG.” Atmospheric Research 2008;87:242–51. <https://doi.org/10.1016/J.ATMOSRES.2007.11.021>.
- [81] Heinzler R, Schindler P, Seekircher J, Ritter W, Stork W. Weather Influence and Classification with Automotive Lidar Sensors. 2019 IEEE Intelligent Vehicles Symposium

- (IV), vol. 2019- June, IEEE; 2019, p. 1527–34. <https://doi.org/10.1109/IVS.2019.8814205>.
- [82] Heinzler R, Piewak F, Schindler P, Stork W. CNN-Based Lidar Point Cloud De-Noising in Adverse Weather. *IEEE Robotics and Automation Letters* 2020;5:2514–21. <https://doi.org/10.1109/LRA.2020.2972865>.
- [83] Li Y, Duthon P, Colomb M, Ibanez-Guzman J. What Happens for a ToF LiDAR in Fog? *IEEE Transactions on Intelligent Transportation Systems* 2021;22:6670–81. <https://doi.org/10.1109/TITS.2020.2998077>.
- [84] Nolet C, Poortinga A, Roosjen P, Bartholomeus H, Ruessink G. Measuring and Modeling the Effect of Surface Moisture on the Spectral Reflectance of Coastal Beach Sand. *PLOS ONE* 2014;9:e112151. <https://doi.org/10.1371/JOURNAL.PONE.0112151>.
- [85] Suchocki C, Katzer J. Terrestrial laser scanning harnessed for moisture detection in building materials – Problems and limitations. *Automation in Construction* 2018;94:127–34. <https://doi.org/10.1016/J.AUTCON.2018.06.010>.
- [86] Jin J, Verbeurgt J, de Sloover L, Stal C, Deruyter G, Montreuil AL, et al. Support vector regression for high-resolution beach surface moisture estimation from terrestrial LiDAR intensity data. *International Journal of Applied Earth Observation and Geoinformation* 2021;102:102458. <https://doi.org/10.1016/J.JAG.2021.102458>.
- [87] Light. Plant Factory, Elsevier; 2016, p. 115–28. <https://doi.org/10.1016/B978-0-12-801775-3.00007-X>.
- [88] Starr Cecie, Evers CA, Starr Lisa. *Biology : concepts and applications*. 6th ed. Belmont CA: Thomson Brooks/Cole; 2006.
- [89] Abadal G, Alda J, Agustí J. Electromagnetic Radiation Energy Harvesting – The Rectenna Based Approach. *ICT - Energy - Concepts Towards Zero - Power Information and Communication Technology* 2014. <https://doi.org/10.5772/57118>.
- [90] Haken H. *Laser Theory*. Laser Theory 1983. <https://doi.org/10.1007/978-3-642-45556-8>.
- [91] Einstein A. The Quantum Theory of Radiation. *Physikalische Zeitschrift* 1917;18:121.
- [92] Yan J, Takayama N. Fundamentals of laser processing. *Micro and Nanoscale Laser Processing of Hard Brittle Materials* 2020;17–35. <https://doi.org/10.1016/B978-0-12-816709-0.00002-1>.
- [93] Peter W. Milonni, Joseph H. Eberly. *Laser Physics*. 2nd ed. ohn Wiley & Sons, Incorporated; 2010.
- [94] Ertem RU. Investigation Of The Effect Of The Laser Welding Parameters Change On Welding Seam For Stainless Steel. *Journal of Engineering and Natural Sciences* 2013;31:583–93.
- [95] Ronald D. Schaeffer. Laser beam’s wavelength determines its ‘color’ | Micro manufacturing 2013. <http://mic-mfg.com/content/laser-beam’s-wavelength-determines-its-‘color’> (accessed March 12, 2018).
- [96] Xuan H, Igarashi H, Ito S, Qu C, Zhao Z, Kobayashi Y. High-Power, Solid-State, Deep Ultraviolet Laser Generation. *Applied Sciences* 2018;8:233. <https://doi.org/10.3390/app8020233>.
- [97] Nasim H, Jamil Y. Diode lasers: From laboratory to industry. *Optics and Laser Technology* 2014;56:211–22. <https://doi.org/10.1016/j.optlastec.2013.08.012>.
- [98] Shemshad J, Aminossadati SM, Kizil MS. A review of developments in near infrared methane detection based on tunable diode laser. *Sensors and Actuators B: Chemical* 2012;171–172:77–92. <https://doi.org/10.1016/J.SNB.2012.06.018>.
- [99] Shukla P, Lawrence J, Zhang Y. Understanding laser beam brightness: A review and new prospective in material processing. *Optics & Laser Technology* 2015;75:40–51. <https://doi.org/10.1016/J.OPTLASTEC.2015.06.003>.
- [100] Min J, Wan H, Carlson BE, Lin J, Sun C. Application of laser ablation in adhesive bonding of metallic materials: A review. *Optics & Laser Technology* 2020;128:106188.

<https://doi.org/10.1016/J.OPTLASTEC.2020.106188>.

- [101] Books J, Sign R. Handbook of Solid-State Lasers Abstract: Solid-state crystalline raman lasers continue to evolve as practical and efficient laser solid-state laser; Raman laser; stimulated Raman scattering; visible laser; infrared Raman lasers - Handbook of Solid-St. 2017.
- [102] Mahamood RM. Laser Basics and Laser Material Interactions 2018;11–35. https://doi.org/10.1007/978-3-319-64985-6_2.
- [103] Guo J, Li J, Kou H. Chemical preparation of advanced ceramic materials. Modern Inorganic Synthetic Chemistry 2011;429–54. <https://doi.org/10.1016/B978-0-444-53599-3.10019-8>.
- [104] Duley WW. Lasers, Gas. Encyclopedia of Physical Science and Technology 2003;399–408. <https://doi.org/10.1016/B0-12-227410-5/00368-9>.
- [105] Biswas DJ, Padma Nilaya J. Repetitive transversely excited gas laser pulsers. Progress in Quantum Electronics 2002;26:1–63. [https://doi.org/10.1016/S0079-6727\(01\)00013-1](https://doi.org/10.1016/S0079-6727(01)00013-1).
- [106] Steen W, Mazumder J. Laser material processing. 2010.
- [107] Shankarling GS, Jarag KJ. Laser dyes. Resonance 2010 15:9 2010;15:804–18. <https://doi.org/10.1007/S12045-010-0090-9>.
- [108] Silfvast WT. Lasers. Encyclopedia of Physical Science and Technology 2003;267–81. <https://doi.org/10.1016/B0-12-227410-5/00363-X>.
- [109] Mehta SK, Jain A, Jain D. Semiconductor Lasers: Basics and Technology. Springer Proceedings in Physics 2015;160:115–32. https://doi.org/10.1007/978-81-322-2000-8_5.
- [110] Li L. The advances and characteristics of high-power diode laser materials processing. Optics and Lasers in Engineering 2000;34:231–53. [https://doi.org/10.1016/S0143-8166\(00\)00066-X](https://doi.org/10.1016/S0143-8166(00)00066-X).
- [111] Davis CC. Semiconductor lasers. Lasers and Electro-optics, Cambridge: Cambridge University Press; 2014, p. 301–60. <https://doi.org/10.1017/CBO9781139016629.013>.
- [112] Ripley PM. The physics of diode lasers. Lasers in Medical Science 1996 11:2 1996;11:71–8. <https://doi.org/10.1007/BF02133204>.
- [113] Wen B, Ban D. High-temperature terahertz quantum cascade lasers. Progress in Quantum Electronics 2021;80:100363. <https://doi.org/10.1016/J.PQUANTELEC.2021.100363>.
- [114] Koch SW, Hofmann MR. Semiconductor Lasers. Encyclopedia of Modern Optics, vol. 1–5, Elsevier; 2018, p. 462–8. <https://doi.org/10.1016/B978-0-12-803581-8.10103-1>.
- [115] Heidari E, Dalir H, Ahmed M, Sorger VJ, Chen RT. Hexagonal transverse-coupled-cavity VCSEL redefining the high-speed lasers. Nanophotonics 2020;9:4743–8. <https://doi.org/10.1515/NANOPH-2020-0437/MACHINEREADABLECITATION/RIS>.
- [116] Moon S, Yun Y, Lee M, Kim D, Choi W, Park JY, et al. Top-emitting 940-nm thin-film VCSELs transferred onto aluminum heatsinks. Scientific Reports 2022 12:1 2022;12:1–7. <https://doi.org/10.1038/s41598-021-04625-6>.
- [117] Sliney DH, Dennis JE. Safety concerns about laser pointers. Journal of Laser Applications 2012;6:159. <https://doi.org/10.2351/1.4745352>.
- [118] Smalley PJ. Laser safety: Risks, hazards, and control measures. Laser Therapy 2011;20:95–106. <https://doi.org/10.5978/ISLSM.20.95>.
- [119] Wang Q, Tan Y, Mei Z. Computational Methods of Acquisition and Processing of 3D Point Cloud Data for Construction Applications. Archives of Computational Methods in Engineering 2020;27:479–99. <https://doi.org/10.1007/S11831-019-09320-4/TABLES/6>.
- [120] Wojtanowski J, Zygmunt M, Kaszczuk M, Mierczyk Z, Muzal M. Comparison of 905 nm and 1550 nm semiconductor laser rangefinders' performance deterioration due to adverse environmental conditions. Opto-Electronics Review 2014 22:3 2014;22:183–90. <https://doi.org/10.2478/S11772-014-0190-2>.

- [121] Raj T, Hashim FH, Huddin AB, Ibrahim MF, Hussain A. A Survey on LiDAR Scanning Mechanisms. *Electronics* 2020, Vol 9, Page 741 2020;9:741. <https://doi.org/10.3390/ELECTRONICS9050741>.
- [122] Fang W, Huang X, Zhang F, Li D. Intensity correction of terrestrial laser scanning data by estimating laser transmission function. *IEEE Transactions on Geoscience and Remote Sensing* 2015;53:942–51. <https://doi.org/10.1109/TGRS.2014.2330852>.
- [123] FARO. FARO Focus Laser Scanner | FARO n.d. <https://www.faro.com/en/Products/Hardware/Focus-Laser-Scanners> (accessed April 1, 2022).
- [124] Combination of FARO scanner data and ZEB-REVO scanner data for as-built documentation | Laserscanning Europe n.d. <https://www.laserscanning-europe.com/en/news/combination-faro-scanner-data-zeb-revo-scanner-data-built-documentation> (accessed April 8, 2022).
- [125] Azure Kinect DK Windows karşılaştırması | Microsoft Docs n.d. <https://docs.microsoft.com/tr-tr/azure/kinect-dk/windows-comparison> (accessed April 4, 2022).
- [126] pmd 3D Sensing Family – pmdtechnologies ag n.d. <https://pmdtec.com/en/pmd-3d-sensing-family/> (accessed April 4, 2022).
- [127] Wang C-C, Trivedi SB, Jin F, Stepanov S, Chen Z, Khurgin J, et al. Human life signs detection using high-sensitivity pulsed laser vibrometer. *IEEE Sensors Journal* 2007;7:1370–6. <https://doi.org/10.1109/JSEN.2007.905041>.
- [128] Wang C, Trivedi S, Kutcher S, Rodriguez P, Jin F. Non-Contact Human Cardiac Activity Monitoring Using a High Sensitivity Pulsed Laser Vibrometer 2011:6–7.
- [129] Fercher AF. Optical coherence tomography. *Journal of Biomedical Optics* 1996;1:157. <https://doi.org/10.1117/12.231361>.
- [130] Rodriguez P, Trivedi S, Jin F, Wang C-C, Stepanov S, Elliott G, et al. Pulsed-laser vibrometer using photoelectromotive-force sensors. *Applied Physics Letters* 2003;83:1893–5. <https://doi.org/10.1063/1.1606882>.
- [131] Wang CC, Trivedi S, Jin F, Swaminathan V, Rodriguez P, Prasad NS. High sensitivity pulsed laser vibrometer and its application as a laser microphone. *Applied Physics Letters* 2009;94:051112. <https://doi.org/10.1063/1.3078520>.
- [132] Yazdanfar S, Kulkarni MD, Izatt JA. High resolution imaging of in vivo cardiac dynamics using color Doppler optical coherence tomography. *Optics Express* 1997;1:424. <https://doi.org/10.1364/OE.1.000424>.
- [133] Renishaw. İnterferometrik sistemler nasıl çalışır? n.d. <http://www.renishaw.com.tr/tr/interferometrik-sistemler-nasil-calisir--38612> (accessed March 14, 2018).
- [134] Gümüş ÖF. İnterferometre (Girişim Ölçer) Nedir? n.d. [http://www.elektrikport.com/teknik-kutuphane/interferometre-\(girisim-olcer\)-nedir/17218#ad-image-0](http://www.elektrikport.com/teknik-kutuphane/interferometre-(girisim-olcer)-nedir/17218#ad-image-0) (accessed March 15, 2018).
- [135] Vohl D. Algorithmes de compression d’images hyperspectrales astrophysiques. Université Laval, 2013.
- [136] Tabatabai H, Oliver DE, Rohrbaugh JW, Papadopoulos C. Novel Applications of Laser Doppler Vibration Measurements to Medical Imaging. *Sensing and Imaging: An International Journal* 2013;14:13–28. <https://doi.org/10.1007/s11220-013-0077-1>.
- [137] Lutzmann P, Göhler B, Hill CA, Putten F van. Laser vibration sensing at Fraunhofer IOSB: review and applications. *Optical Engineering* 2016;56:031215. <https://doi.org/10.1117/1.OE.56.3.031215>.
- [138] Devroye L, Györfi L, Lugosi G. A Probabilistic Theory of Pattern Recognition. vol. 31. New York, NY: Springer; 1996. <https://doi.org/10.1007/978-1-4612-0711-5>.
- [139] Wong YF, Ng HT, Leung KY, Chan KY, Chan SY, Loy CC. Development of fine-grained pill identification algorithm using deep convolutional network. *Journal of Biomedical*

- Informatics 2017. <https://doi.org/10.1016/j.jbi.2017.09.005>.
- [140] Pathak AR, Pandey M, Rautaray S. Application of Deep Learning for Object Detection. *Procedia Computer Science* 2018;132:1706–17. <https://doi.org/10.1016/j.procs.2018.05.144>.
 - [141] Ren S, He K, Girshick R, Sun J. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 2017;39:1137–49. <https://doi.org/10.1109/TPAMI.2016.2577031>.
 - [142] Betul A, Gurses OA, Oktay AB, Gurses A. Automatic Detection, Localization and Segmentation of Nano-Particles with Deep Learning in Microscopy Images 2019. <https://doi.org/10.1016/j.micron.2019.02.009>.
 - [143] Wang S, Yang DM, Rong R, Zhan X, Xiao G. Pathology Image Analysis Using Segmentation Deep Learning Algorithms. *The American Journal of Pathology* 2019. <https://doi.org/10.1016/j.ajpath.2019.05.007>.
 - [144] Wang D, Chen J. Supervised speech separation based on deep learning: An overview. *IEEE/ACM Transactions on Audio Speech and Language Processing* 2018. <https://doi.org/10.1109/TASLP.2018.2842159>.
 - [145] Hinton G, Deng L, Yu D, Dahl G, Mohamed AR, Jaitly N, et al. Deep neural networks for acoustic modeling in speech recognition: The shared views of four research groups. *IEEE Signal Processing Magazine* 2012. <https://doi.org/10.1109/MSP.2012.2205597>.
 - [146] Wu Y, Schuster M, Chen Z, Le Q V., Norouzi M, Macherey W, et al. Google's Neural Machine Translation System: Bridging the Gap between Human and Machine Translation. *ArXiv Preprint ArXiv:160908144* 2016.
 - [147] Peris Á, Casacuberta F. Online learning for effort reduction in interactive neural machine translation. *Computer Speech and Language* 2019. <https://doi.org/10.1016/j.csl.2019.04.001>.
 - [148] Kratzwald B, Ilić S, Kraus M, Feuerriegel S, Prendinger H. Deep learning for affective computing: Text-based emotion recognition in decision support. *Decision Support Systems* 2018. <https://doi.org/10.1016/j.dss.2018.09.002>.
 - [149] yasmina D, Hajar M, Hassan AM. Using YouTube Comments for Text-based Emotion Recognition. *Procedia Computer Science* 2016;83:292–9. <https://doi.org/10.1016/j.procs.2016.04.128>.
 - [150] Chatterjee A, Gupta U, Chinnakotla MK, Srikanth R, Galley M, Agrawal P. Understanding Emotions in Text Using Deep Learning and Big Data. *Computers in Human Behavior* 2019. <https://doi.org/10.1016/j.chb.2018.12.029>.
 - [151] Chen H, Engkvist O, Wang Y, Olivecrona M, Blaschke T. The rise of deep learning in drug discovery. *Drug Discovery Today* 2018. <https://doi.org/10.1016/j.drudis.2018.01.039>.
 - [152] LeCun Y, Bengio Y, Hinton G. Deep learning. *Nature* 2015;521:436–44. <https://doi.org/10.1038/nature14539>.
 - [153] Hinton GE, Salakhutdinov RR. Reducing the Dimensionality of Data with Neural Networks. *Science* (1979) 2006;313:504–7. <https://doi.org/10.1126/science.1127647>.
 - [154] Angermueller C, Pärnamaa T, Parts L, Stegle O. Deep learning for computational biology. *Molecular Systems Biology* 2016;12:878. <https://doi.org/10.15252/MSB.20156651>.
 - [155] Libbrecht MW, Noble WS. Machine learning in genetics and genomics. *Nat Rev Genet* 2015;16:321. <https://doi.org/10.1038/NRG3920>.
 - [156] Xin Y, Kong L, Liu Z, Chen Y, Li Y, Zhu H, et al. Machine Learning and Deep Learning Methods for Cybersecurity. *IEEE Access* 2018;6:35365–81. <https://doi.org/10.1109/ACCESS.2018.2836950>.
 - [157] Cover TM, Hart PE. Nearest Neighbor Pattern Classification. *IEEE Transactions on Information Theory* 1967;13:21–7. <https://doi.org/10.1109/TIT.1967.1053964>.
 - [158] Fayed HA, Atiya AF. A novel template reduction approach for the K-nearest neighbor method. *IEEE Transactions on Neural Networks* 2009;20:890–6.

- <https://doi.org/10.1109/TNN.2009.2018547>.
- [159] Larrañaga P, Calvo B, Santana R, Bielza C, Galdiano J, Inza I, et al. Machine learning in bioinformatics. Briefings in Bioinformatics 2006;7:86–112. <https://doi.org/10.1093/BIB/BBK007>.
 - [160] Vapnik VN. The Nature of Statistical Learning Theory. Springer New York; 2000. <https://doi.org/10.1007/978-1-4757-3264-1>.
 - [161] Patle A, Chouhan DS. SVM kernel functions for classification. International Conference on Advances in Technology and Engineering (ICATE), IEEE; 2013, p. 1–9.
 - [162] Panja S, Chatterjee A, Yasmin G. Kernel Functions of SVM: A Comparison and Optimal Solution. Communications in Computer and Information Science, vol. 955, Springer, Singapore; 2019, p. 88–97. https://doi.org/10.1007/978-981-13-3140-4_9.
 - [163] Kavzoğlu T, Çölkesen İ. Destek vektör makineleri ile uydu görüntülerinin sınıflandırılmasında kernel fonksiyonlarının etkilerinin incelenmesi . Harita Dergisi 2010;76:73–82.
 - [164] Li H, Liang Y, Xu Q. Support vector machines and its applications in chemistry. Chemometrics and Intelligent Laboratory Systems 2009;95:188–98. <https://doi.org/10.1016/J.CHEMOLAB.2008.10.007>.
 - [165] Hsu CW, Lin CJ. A comparison of methods for multiclass support vector machines. IEEE Transactions on Neural Networks 2002;13:415–25. <https://doi.org/10.1109/72.991427>.
 - [166] Raschka S. Naive Bayes and Text Classification I - Introduction and Theory. ArXiv 2014;abs/1410.5329.
 - [167] Misra S, Li H. Noninvasive fracture characterization based on the classification of sonic wave travel times. Machine Learning for Subsurface Characterization, Elsevier; 2019, p. 243–87. <https://doi.org/10.1016/B978-0-12-817736-5.00009-0>.
 - [168] McCallum A, Nigam K. A comparison of event models for naive bayes text classification. AAAI-98 workshop on learning for text categorization, vol. 752, Citeseer; 1998, p. 41–8.
 - [169] Amor N ben, Benferhat S, Elouedi Z. Qualitative Classification with Possibilistic Decision Trees. Modern Information Processing 2006:159–69. <https://doi.org/10.1016/B978-044452075-3/50014-5>.
 - [170] Quinlan JR. Induction of decision trees. Machine Learning 1986 1:1 1986;1:81–106. <https://doi.org/10.1007/BF00116251>.
 - [171] Vaibhaw, Sarraf J, Pattnaik PK. Brain-computer interfaces and their applications. An Industrial IoT Approach for Pharmaceutical Industry Growth: Volume 2 2020:31–54. <https://doi.org/10.1016/B978-0-12-821326-1.00002-4>.
 - [172] Subasi A. Machine learning techniques. Practical Machine Learning for Data Analysis Using Python 2020:91–202. <https://doi.org/10.1016/B978-0-12-821379-7.00003-5>.
 - [173] Mohanty N, John ALS, Manmatha R, Rath TM. Shape-based image classification and retrieval. Handbook of Statistics 2013;31:249–67. <https://doi.org/10.1016/B978-0-444-53859-8.00010-2>.
 - [174] Marsalli M. McCulloch-Pitts Neurons (Overview) n.d. <http://www.mind.ilstu.edu/curriculum/modOverview.php?modGUI=212> (accessed October 30, 2018).
 - [175] Olgun N, Türkoğlu İ. Lazer İşaretleri ile Otomatik Hedef Tanıma. Sak Univ J Comput Inf Sci 2018;1:1–10.
 - [176] Abraham A. Artificial Neural Networks. Handbook of Measuring System Design, Chichester, UK: John Wiley & Sons, Ltd; 2005. <https://doi.org/10.1002/0471497398.mm421>.
 - [177] Öztemel E. Yapay Sinir Ağları. İstanbul: Papatya Yayıncılık Eğitim; 2012.
 - [178] Smolensky P. Information Processing in Dynamical Systems: Foundations of Harmony Theory. Parallel Distributed Processing: Explorations in the Microstructure of Cognition, Vol.

1: Foundations, Cambridge, MA, USA: MIT Press; 1986, p. 194–281.

- [179] Liu R, Yang B, Zio E, Chen X. Artificial intelligence for fault diagnosis of rotating machinery: A review. *Mechanical Systems and Signal Processing* 2018;108:33–47. <https://doi.org/10.1016/J.YMSSP.2018.02.016>.
- [180] Salakhutdinov R, Hinton G. Deep Boltzmann Machines n.d.
- [181] Fischer A, Igel C. Training restricted Boltzmann machines: An introduction. *Pattern Recognition* 2014;47:25–39. <https://doi.org/10.1016/J.PATCOG.2013.05.025>.
- [182] Hinton GE, Osindero S, Teh Y-W. A Fast Learning Algorithm for Deep Belief Nets. *Neural Computation* 2006;18:1527–54. <https://doi.org/10.1162/neco.2006.18.7.1527>.
- [183] O'Connor P, Neil D, Liu SC, Delbruck T, Pfeiffer M. Real-time classification and sensor fusion with a spiking deep belief network. *Frontiers in Neuroscience* 2013;0:178. <https://doi.org/10.3389/FNINS.2013.00178/ABSTRACT>.
- [184] Lopes N, Ribeiro B, Gonçalves J. Restricted Boltzmann Machines and Deep Belief Networks on multi-core processors. *Proceedings of the International Joint Conference on Neural Networks* 2012. <https://doi.org/10.1109/IJCNN.2012.6252431>.
- [185] Bengio Y. Learning Deep Architectures for AI. *Foundations and Trends® in Machine Learning* 2009;2:1–127. <https://doi.org/10.1561/22000000006>.
- [186] Lee H, Ekanadham C, Ng A. Sparse deep belief net model for visual area V2. In: Platt J, Koller D, Singer Y, Roweis S, editors. *Advances in Neural Information Processing Systems*, vol. 20, Curran Associates, Inc.; 2007.
- [187] Vincent P, Larochelle H, Lajoie I, Bengio Y, Manzagol P-A. Stacked Denoising Autoencoders: Learning Useful Representations in a Deep Network with a Local Denoising Criterion. *Journal of Machine Learning Research* 2010;11:3371–408.
- [188] Wang W, Huang Y, Wang Y, Wang L. Generalized autoencoder: A neural network framework for dimensionality reduction. *IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops* 2014:496–503. <https://doi.org/10.1109/CVPRW.2014.79>.
- [189] Zhang JS, Xiao XC. Predicting chaotic time series using recurrent neural network. *Chinese Physics Letters* 2000;17:88–90. <https://doi.org/10.1088/0256-307X/17/2/004>.
- [190] Kalchbrenner N, Blunsom P. Recurrent continuous translation models. *EMNLP 2013 - 2013 Conference on Empirical Methods in Natural Language Processing, Proceedings of the Conference, Association for Computational Linguistics; 2013*, p. 1700–9.
- [191] Cho K, Van Merriënboer B, Gulcehre C, Bahdanau D, Bougares F, Schwenk H, et al. Learning phrase representations using RNN encoder-decoder for statistical machine translation. *EMNLP 2014 - 2014 Conference on Empirical Methods in Natural Language Processing, Proceedings of the Conference, 2014*, p. 1724–34. <https://doi.org/10.3115/v1/d14-1179>.
- [192] Mikolov T, Karafiát M, Burget L, Honza J, Cernocký J, Khudanpur S. Recurrent neural network based language model. 2010.
- [193] Bengio Y, Simard P, Frasconi P. Learning Long-Term Dependencies with Gradient Descent is Difficult. *IEEE Transactions on Neural Networks* 1994. <https://doi.org/10.1109/72.279181>.
- [194] Greff K, Srivastava RK, Koutník J, Steunebrink BR, Schmidhuber J. LSTM: A Search Space Odyssey 2015. <https://doi.org/10.1109/TNNLS.2016.2582924>.
- [195] Jiao Y, Deng Y, Luo Y, Lu BL. Driver sleepiness detection from EEG and EOG signals using GAN and LSTM networks. *Neurocomputing* 2020;408:100–11. <https://doi.org/10.1016/j.neucom.2019.05.108>.
- [196] Lu Y, Wang H, Qi Y, Xi H. Evaluation of classification performance in human lower limb jump phases of signal correlation information and LSTM models. *Biomedical Signal Processing and Control* 2021;64:102279. <https://doi.org/10.1016/j.bspc.2020.102279>.
- [197] Hosny M, Zhu M, Gao W, Fu Y. A novel deep LSTM network for artifacts detection in microelectrode recordings. *Biocybernetics and Biomedical Engineering* 2020;40:1052–63.

<https://doi.org/10.1016/j.bbe.2020.04.004>.

- [198] Swapna G, Soman KP, Vinayakumar R. Automated detection of diabetes using CNN and CNN-LSTM network and heart rate signals. *Procedia Computer Science*, vol. 132, Elsevier B.V.; 2018, p. 1253–62. <https://doi.org/10.1016/j.procs.2018.05.041>.
- [199] Lechner M, Hasani R, Amini A, Henzinger TA, Rus D, Grosu R. Neural circuit policies enabling auditable autonomy. *Nature Machine Intelligence* 2020 2:10 2020;2:642–52. <https://doi.org/10.1038/s42256-020-00237-3>.
- [200] Corsi AK, Wightman B, Chalfie M. A Transparent window into biology: A primer on *Caenorhabditis elegans*. *WormBook*, WormBook; 2015, p. 1–31. <https://doi.org/10.1895/WORMBOOK.1.177.1>.
- [201] Yan G, Vértés PE, Towlson EK, Chew YL, Walker DS, Schafer WR, et al. Network control principles predict neuron function in the *Caenorhabditis elegans* connectome. *Nature* 2017 550:7677 2017;550:519–23. <https://doi.org/10.1038/nature24056>.
- [202] Hasani R, Lechner M, Amini A, Rus D, Grosu R. Liquid Time-constant Networks 2020. <https://doi.org/10.48550/arxiv.2006.04439>.
- [203] LeCun Y, Boser B, Denker JS, Henderson D, Howard RE, Hubbard W, et al. Backpropagation Applied to Handwritten Zip Code Recognition. *NEURAL COMPUTATION* 1989;1:541–51. <https://doi.org/10.1162/neco.1989.1.4.541>.
- [204] Lecun Y, Bottou L, Bengio Y, Haffner P. Gradient-based learning applied to document recognition. *Proceedings of the IEEE* 1998;86:2278–324. <https://doi.org/10.1109/5.726791>.
- [205] Hubel DH, Wiesel TN. Receptive fields and functional architecture of monkey striate cortex. *The Journal of Physiology* 1968;195:215–43. <https://doi.org/https://doi.org/10.1113/jphysiol.1968.sp008455>.
- [206] Fushiki T. Estimation of prediction error by using K-fold cross-validation. *Statistics and Computing* 2011;21:137–46. <https://doi.org/10.1007/s11222-009-9153-8>.
- [207] Kiran R, Kumar P, Bhasker B. Oslcfrit (organic simultaneous LSTM and CNN Fit): A novel deep learning based solution for sentiment polarity classification of reviews. *Expert Systems with Applications* 2020;157:113488. <https://doi.org/10.1016/j.eswa.2020.113488>.
- [208] Carrea D, Abellan A, Humair F, Matasci B, Derron M-H, Jaboyedoff M. Correction of terrestrial LiDAR intensity channel using Oren–Nayar reflectance model: An application to lithological differentiation. *ISPRS Journal of Photogrammetry and Remote Sensing* 2016;113:17–29. <https://doi.org/10.1016/j.isprsjprs.2015.12.004>.
- [209] Suchocki C, Damińska-Suchocka M, Katzer J, Janicka J, Rapiński J, Stałowska P. Remote Detection of Moisture and Bio-Deterioration of Building Walls by Time-Of-Flight and Phase-Shift Terrestrial Laser Scanners. *Remote Sensing* 2020;12:1708. <https://doi.org/10.3390/rs12111708>.
- [210] Jelalian A v. Laser Radar Systems. *Electronics and Aerospace Systems Conference (EASCON'80)*, 1992, p. 546–54.
- [211] Zhao L, He Y. Power Spectrum Estimation of the Welch Method Based on Imagery EEG. *Applied Mechanics and Materials* 2013;278–280:1260–4. <https://doi.org/10.4028/WWW.SCIENTIFIC.NET/AMM.278-280.1260>.
- [212] Gupta HR, Mehra R. Power Spectrum Estimation using Welch Method for various Window Techniques. *International Journal of Scientific Research Engineering & Technology* 2013;2:389–92.
- [213] Kumar Rahi P, Mehra R, Scholar M, Professor A. Analysis of Power Spectrum Estimation Using Welch Method for Various Window Techniques. *International Journal of Emerging Technologies and Engineering* 2014;2:106–9.
- [214] Rao KD, Swamy MNS. *Spectral Analysis of Signals*. Digital Signal Processing, Singapore: Springer Singapore; 2018, p. 721–51. https://doi.org/10.1007/978-981-10-8081-4_12.
- [215] Antoniou A. *Digital Signal Processing: Signals, Systems, and Filters*. New York: McGraw-

Hill; 2006.

- [216] Vishwajeet, Singh D, Deepak KK. Investigation of heart rate variability with the help of Welch periodogram in Indian young adults based on body physique. *Smart Healthcare for Disease Diagnosis and Prevention* 2020;51–7. <https://doi.org/10.1016/B978-0-12-817913-0.00008-0>.
- [217] Alkan A, Yilmaz AS. Frequency domain analysis of power system transients using Welch and Yule-Walker AR methods. *Energy Conversion and Management* 2007;48:2129–35. <https://doi.org/10.1016/j.enconman.2006.12.017>.
- [218] industrial continuous measurement Laser Distance Transducer China Manufacturer n.d. <https://www.jrt-measure.com/industrial-laser-distance-sensor/57156437.html> (accessed May 21, 2022).
- [219] Амохин И. Laser tape reverse engineering 2018. https://github.com/iliasam/Laser_tape_reverse_engineering (accessed October 31, 2018).
- [220] Silicon Labs. Si5351a/b/c-b I2C-Programmable Any-Frequency Cmos Clock Generator + Vcxo Features Applications Description. 2018.
- [221] Demirdelen T, Tan A, İnci M, Köroğlu T, Büyük M, Terciyanlı A, et al. Şebekeye Bağlı Sistemler İçin Üç Faz ve Tek Faz PLL'lerin Performans Değerlendirmesi. 5 Enerji Verimliliği ve Kalitesi Sempozyumu -EVK 2013 2013:5–9.
- [222] Si5351A/B/C-B Datasheet - Silicon Labs | DigiKey n.d. <https://www.digikey.com/en/datasheets/silicon-labs/silicon-labs-si5351-b> (accessed May 21, 2022).
- [223] Olgun N, Türkoğlu İ. Classification of Live/Lifeless Assets with Laser Beams in Different Humidity Environments. 8th International Symposium on Digital Forensics and Security, ISDFS 2020, 2020. <https://doi.org/10.1109/ISDFS49300.2020.9116314>.
- [224] Olgun N, Türkoğlu İ. Classification of Live / Lifeless Assets from Long Distance with Laser Signals by Using Deep Learning Network. 4th International Conference on Engineering Technology and Innovation (ICETI), Skopje, North Macedonia: 2020, p. 20–6.
- [225] Olgun N, Türkoğlu İ. Defining Objects with Laser from a Long Distance via Deep Learning Networks. 10th International Symposium on Intelligent Manufacturing and Service Systems (IMSS'19), Sakarya,Turkey: 2019, p. 1401–11.
- [226] Chaparro LF, Akan A. Discrete-Time Signals and Systems. *Signals and Systems Using MATLAB*. 3rd ed., Academic Press; 2019, p. 487–557. <https://doi.org/10.1016/b978-0-12-814204-2.00020-x>.
- [227] Lee ET, Eun HC. Structural Damage Detection by Power Spectral Density Estimation Using Output-Only Measurement. *Shock and Vibration* 2016;2016. <https://doi.org/10.1155/2016/8761249>.
- [228] Juefei-Xu F, Verma E, Savvides M. Deepgender2: A generative approach toward occlusion and low-resolution robust facial gender classification via progressively trained attention shift convolutional neural networks (PTAS-CNN) and deep convolutional generative adversarial networks (DCGAN). *Advances in Computer Vision and Pattern Recognition*, vol. PartF1, Springer London; 2017, p. 183–218. https://doi.org/10.1007/978-3-319-61657-5_8.
- [229] Branchet MC, Boissic S, Frances C, Robert AM. Skin Thickness Changes in Normal Aging Skin. *Gerontology* 1990;36:28–35. <https://doi.org/10.1159/000213172>.
- [230] Sjöström L, Smith U, Krotkiewski M, Björntorp P. Cellularity in different regions of adipose tissue in young men and women. *Metabolism* 1972;21:1143–53. [https://doi.org/10.1016/0026-0495\(72\)90109-6](https://doi.org/10.1016/0026-0495(72)90109-6).
- [231] Morvová Jr. M, Jeczko P, Šikurová L. Gender differences in the fluorescence of human skin in young healthy adults. *Skin Research and Technology* 2018;24:599–605. <https://doi.org/https://doi.org/10.1111/srt.12471>.
- [232] Gülsoy M. Lazerlerin Tıptaki Uygulamaları n.d.

- [233] Vaseghi S v. Advanced Digital Signal Processing and Noise Reduction. Chichester, UK: John Wiley & Sons, Ltd; 2001. <https://doi.org/10.1002/0470841621>.
- [234] Aliç E, Kaşka Ö, Bor O. Nem Ölçerlerin Endüstrideki Yeri. Teknik Bilimler Dergisi 2019;9:8–16.
- [235] Bretagne E, Dassonville P, Caron G. Spherical target-based calibration of terrestrial laser scanner intensity. Application to colour information computation. ISPRS Journal of Photogrammetry and Remote Sensing 2018;144:14–27. <https://doi.org/10.1016/j.isprsjprs.2018.06.014>.
- [236] Tan K, Chen J, Zhang W, Liu K, Tao P, Cheng X. Estimation of soil surface water contents for intertidal mudflats using a near-infrared long-range terrestrial laser scanner. ISPRS Journal of Photogrammetry and Remote Sensing 2020;159:129–39. <https://doi.org/10.1016/j.isprsjprs.2019.11.003>.

