

**T.C.
SAKARYA UYGULAMALI BİLİMLER ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**BİLGİSAYARLI GÖRÜ VE İNSAN ROBOT ETKİLEŞİMİNE
DAYALI GERİ DÖNÜŞÜM MATERYALLERİNİN
OTOMATİK AYRIŞTIRILMASI**

DOKTORA TEZİ

Kenan ERİN

Enstitü Anabilim Dalı : MEKATRONİK MÜHENDİSLİĞİ

Tez Danışmanı : Doç. Dr. Barış BORU

Haziran 2023

T.C.
SAKARYA UYGULAMALI BİLİMLER ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

BİLGİSAYARLI GÖRÜ VE İNSAN ROBOT ETKİLEŞİMİNE
DAYALI GERİ DÖNÜŞÜM MATERYALLERİNİN
OTOMATİK AYRIŞTIRILMASI

DOKTORA TEZİ

Kenan ERİN

Enstitü Anabilim Dalı : MEKATRONİK MÜHENDİSLİĞİ

Bu tez 12/06/2023 tarihinde aşağıdaki jüri tarafından oybirliği ile kabul edilmiştir.

JÜRİ	BAŞARI DURUMU
Jüri Başkanı: Prof. Dr. Devrim AKGÜN	BAŞARILI
Üye: Doç. Dr. Barış BORU	BAŞARILI
Üye: Doç. Dr. Sezgin KAÇAR	BAŞARILI
Üye: Doç. Dr. Emre DANDIL	BAŞARILI
Üye: Dr. Öğr. Üyesi Süleyman UZUN	BAŞARILI

BEYAN

Tez içindeki tüm verilerin akademik kurallar çerçevesinde tarafımdan elde edildiğini, görsel ve yazılı tüm bilgi ve sonuçların akademik ve etik kurallara uygun şekilde sunulduğunu, kullanılan verilerde herhangi bir tahrifat yapılmadığını, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunduğunu, tezde yer alan verilerin bu üniversite veya başka bir üniversitede herhangi bir tez çalışmasında kullanılmadığını beyan ederim

Kenan ERİN

12/06/2023

TEŐEKKÜR

Doktora eęitimim boyunca deęerli bilgi, deneyim ve desteęiyle her zaman yanımda olan danıőman hocam Doę. Dr. Barıő BORU'ya ve bu s¼reęte benimle birlikte ęalıőan, yardımlarını esirgemeyen B¼nyamin BİNGÖL'e en ięten teőekk¼rlerimi sunarım.

Bu tez ęalıőması T¼rkiye Bilimsel ve Teknolojik Araőtırma Kurumu (T¼BİTAK) tarafından 2211-C Öncelikli Alanlar Yurt İęi Doktora Burs programı kapsamında desteklenmiőtir. Desteklerinden dolayı T¼BİTAK BİDEB'e teőekk¼r ederim.

Ayrıca, ęalıőmalarımda bana teknik destek veren ve baőarılı sonuęlar elde etmeme katkı saęlayan ABB Robotik T¼rkiye firmasına ve orada ęalıőan deęerli m¼hendis arkadaşlarım ęaęatay ŐİMŐEK ve Cem ŐAHİNDOKUYUCU'ya Ő¼kranlarımı sunarım.

Bu ęalıőmanın maddi aęıdan desteklenmesine olanak saęlayan Sakarya Uygulamalı Bilimler Üniwersitesi Bilimsel Araőtırma Projeleri (BAP) Komisyon Baőkanlıęına (Proje No: 022-2020) teőekk¼r ederim.

Son olarak bu günlere gelmemde en b¼y¼k emeęe sahip olan annem Saniye ERİN ve babam Faysal ERİN'e sonsuz teőekk¼rlerimi sunarım.

İÇİNDEKİLER

TEŞEKKÜR	i
İÇİNDEKİLER	ii
KISALTMALAR	iv
SİMGELER	v
TABLolar LİSTESİ.....	vi
ŞEKİLLER LİSTESİ.....	vii
ÖZET.....	ix
ABSTRACT	x

BÖLÜM 1.

GİRİŞ	1
1.1. İnsan Makine Etkileşimi.....	3
1.2. Atık ayrıştırma sistemleri	5
1.3. Literatür Araştırması	5
1.3.1. Yapay zeka ve görüntü işleme tabanlı atık ayrıştırma sistemleri.....	6
1.3.2. EMG ve parmak pozisyon ölçümü ile insan makina etkileşimi.....	11
1.4. Tezin Amacı ve Önemi	13
1.5. Tezin Literatüre Katkısı.....	13

BÖLÜM 2.

ENDÜSTRİYEL ROBOTUN GİYİLEBİLİR VE TEMASSIZ SENSÖRLERLE KONTROLÜ	16
2.1. İnsan Robot Etkileşiminde Kullanılan Teknik Altyapı	17
2.2. EMG Sinyallerinin Temel Kavramları	20
2.2.1. Kas hücre yapısı ve kas aktivasyonu.....	20
2.2.2. Motor birim kavramı ve işleyişi.....	21
2.2.3. EMG sinyallerinin oluşumu ve ölçülmesi.....	22
2.2.4. EMG sinyallerinin işlenmesi ve analizi	24
2.2.5. EMG verisi için makine öğrenmesi	24
2.2.5.1. Sinyal filtreleme	25
2.2.5.2. Özellik çıkarımı ve boyut azaltımı.....	26
2.2.5.3. EMG verisinin sınıflandırılması.....	28

2.3. Parmak Pozisyon Ölçümü	34
2.3.1. Parmak pozisyon ölçüm sensörlerinin temel bileşenleri ve işleyişi.....	35
2.3.2. Parmak pozisyon ölçümü ile robot yörünge belirleme	36
2.4. Robot Kod Üretimi ve Haberleşme	39
2.5. Gerçek Zamanlı Uygulama	41

BÖLÜM 3.

YOLO TABANLI ATIK TESPİTİ.....	45
3.1. YOLO Mimarisi	45
3.1.1. YOLO eğitimi için veri seti hazırlama.....	48
3.2. 3B Kamera ile Koordinat Tespiti	52
3.2.1. Kamera kalibrasyonu	53
3.3. Atık Tespit Düzenegi	59

BÖLÜM 4.

ENDÜSTRİYEL ROBOTLA GERÇEK ZAMANLI ATIK AYRIŞTIRMA....	62
4.1. İnsan Robot Etkileşimi ile Robot Patika Takibi.....	63
4.2. Konveyör Takibi ile Robot Atık Tutma Patikasının Belirlenmesi.....	65
4.3. Gerçek Zamanlı Atık Ayrıştırma.....	67

BÖLÜM 5.

SONUÇ VE ÖNERİLER.....	69
5.1. İnsan-Robot Etkileşimi için Elde Edilen Sonuçlar.....	69
5.2. Atık Tespiti ve Kamera Ölçüm Sistemi için Elde Edilen Sonuçlar	73
5.3. Genel Değerlendirme ve Öneriler	78

KAYNAKLAR	81
------------------------	-----------

KISALTMALAR

BBA	: Bağımsız Bileşenler Analizi
ÇKA	: Çok Katmanlı Algılayıcı
DAA	: Doğrusal Ayırma Analizi
DVM	: Destek Vektör Makinaları
EEG	: Elektroensefalografi
EMG	: Elektromiyografi
EOG	: Elektrookülagrafi
ESA	: Evrimsel Sinir Ağı
HRI	: İnsan - Robot Etkileşimi
HMI	: İnsan - Makina Etkileşimi
IMU	: Atalet Ölçü Birimi
k-NN	: k- En Yakın Komşu
MAV	: Ortalama Mutlak Değer
RMS	: Karelerin Ortalama Karekökü
RO	: Rastgele Orman
ROS	: Robot İşletim Sistemi
TBA	: Temel Bileşenler Analizi

SİMGELER

b	: Bias değeri
c_x, c_y	: Kamera optik merkezi
f_x, f_y	: Kamera odak uzaklığı
N_l, N_r	: Random forest sol ve sağ düğümlerdeki eleman sayısı
P_{kl}, P_{kr}	: Random forest sol ve sağ düğümlerdeki sınıfların oranı
w	: Ağırlık değeri
X_i, Y_i	: Görüntü koordinatları
X_m	: Emg örneği
X_s, Y_s, Z_s	: Dünya koordinatları
Y_l, Y_r	: Random Forest sol ve sağ düğümlerdeki ortalama veri

TABLolar LİSTESİ

Tablo 2.1 : Myo Armband teknik özellikleri	18
Tablo 2.2 : Leap Motion teknik özellikleri	18
Tablo 2.3 : ABB IRB20 robotunun teknik özellikleri.....	19
Tablo 3.1 : Görüntü veri setinin sınıfları ve sayıları	49
Tablo 3.2 : Eğitim ve test veri setlerinin sayıları	52
Tablo 3.3 : Intel RealSense D415 kamera özellikleri	53
Tablo 3.4 : Intel realsense D415 kamera parametreleri	54
Tablo 3.5 : NVIDIA Jetson AGX Xavier bazı teknik özellikleri.....	59
Tablo 5.1 : DVM karışıklık matrisi.....	69
Tablo 5.2 : RO karışıklık matrisi	70
Tablo 5.3 : k-NN karışıklık matrisi	70
Tablo 5.4 : EMG sinyallerinin doğru sınıflandırma başarı yüzdeleri	71
Tablo 5.5 : Patika Hata Değerleri.....	72
Tablo 5.6 : Parmak pozisyonu sonuçlarının literatür ile karşılaştırılması.....	73
Tablo 5.7 : Deneysel çalışmalarda kullanılan bilgisayarın özellikleri.	74
Tablo 5.8 : YOLO-V4 model parametreleri.....	74
Tablo 5.9 : Eğitim performans sonuçları	76
Tablo 5.10 : Test veri setinden elde edilen başarı performansları	77
Tablo 5.11 : Test başarı performansları	77
Tablo 5.12 : Kamera ölçüm hata değerleri.....	78

ŞEKİLLER LİSTESİ

Şekil 1.1 : EMG ve parmak pozisyon ölçümü	4
Şekil 2.1 : Myo armband, Leap Motion controller ve IRB120 endüstriyel robot.....	17
Şekil 2.2 : İnsan robot etkileşiminin akış diyagramı	19
Şekil 2.3 : Kasılma ve gevşeme sırasında kas yapısı	21
Şekil 2.4 : 8 kanallı EMG sinyali	23
Şekil 2.5 : Makine öğrenmesi ile sınıflandırılan el hareketleri	25
Şekil 2.6 : DVM lineer sınıflandırma.....	30
Şekil 2.7 : RO sınıflandırma yapısı	32
Şekil 2.8 : k-NN sınıflandırma yapısı	33
Şekil 2.9 : EMG verisinin işlenmesinin adımları.....	34
Şekil 2.10 : Parmak pozisyon ölçümü.....	35
Şekil 2.11 : Leap Motion verisinin robota uygulanması	37
Şekil 2.12 : Oluşturulan ölçekli küp.....	38
Şekil 2.13 : Parmak ucu takibi için oluşturulan patikalar	38
Şekil 2.14 : Robot kontrol akış diyagramı	39
Şekil 2.15 : IRB120 robotunun hareket kodu üretimi	41
Şekil 2.16 : Robot patikasının belirlenmesi için kurulan deneysel düzenek.....	42
Şekil 2.17 : Senaryoda uygulanan sanal ve gerçek noktalar	42
Şekil 2.18 : Parçayı tutma işlemi	43
Şekil 2.19 : Patikayı izleme işlemi	44
Şekil 2.20 : Parçayı bırakma işlemi	44
Şekil 3.1 : YOLO - V4 mimarisi.....	46
Şekil 3.2 : TACO veri setine ait örnek görüntüler	48
Şekil 3.3 : Hazırlanan veri setinden örnek görüntüler.....	49
Şekil 3.4 : Veri seti artırımı.....	50
Şekil 3.5 : Örnek görüntü etiketleme	51
Şekil 3.6 : Görüntü etiket bilgileri	51
Şekil 3.7 : Intel RealSense D415 kamera	53
Şekil 3.8 : Kamera kalibrasyonu ve kalibrasyon deseni	54
Şekil 3.9 : Kamera kalibrasyonu sonra 3B'den 2B'ye geçiş.....	56
Şekil 3.10 : Görüntü koordinat sisteminden dünya koordinat sistemine geçiş	56
Şekil 3.11 : Kameranın θ açısı kadar döndürülmesi	57
Şekil 3.12 : Kamera ölçüm sistemi	58
Şekil 3.13 : Kamera tarafından ölçülen nesnenin pozisyonu	59
Şekil 3.14 : Kurulan deney düzeneği	60
Şekil 3.15 : Atık Tespiti Blog Diyagramı	61
Şekil 3.16 : Gerçek zamanlı atık tespiti... ..	61
Şekil 4.1 : Atık ayrıştırma sistemi.....	63
Şekil 4.2 : İnsan robot etkileşimi ile hedef nokta belirleme.....	64
Şekil 4.3 : Robot patikasının belirlenmesi adımları	65

Şekil 4.4 : Konveyör takip sistemi	66
Şekil 4.5 : Atık ayrıştırma deney düzeneği	67
Şekil 4.6 : Hareketli konveyör üzerinde atık tespiti	68
Şekil 5.1 : Leap motion ile ölçülen patika takip sonucu	72
Şekil 5.2 : Karışıklık matrisi ve performans metrikleri denklemleri	75
Şekil 5.3 : IoU Yapısı.....	76
Şekil 5.4 : Nesnelerin gerçek koordinatları ve kamera ölçüm koordinatları.....	78



BİLGİSAYARLI GÖRÜ VE İNSAN ROBOT ETKİLEŞİMİNE DAYALI GERİ DÖNÜŞÜM MATERYALLERİNİN OTOMATİK AYRIŞTIRILMASI

ÖZET

Geri dönüştürülebilir atıkların doğru bir şekilde ayrıştırılması, çevresel sürdürülebilirlik ve kaynak verimliliği açısından büyük önem taşımaktadır. Bu çalışmada, endüstriyel robot ve bilgisayar görüşü kullanılarak bir atık ayrıştırma sistemi geliştirilmiştir. Geliştirilen sistem, atıkların türlerinin belirlenmesi ve 3 boyutlu (3B) konumlarının tespit edilmesi ile robotun doğru bir şekilde ayrıştırma işlemi yapmasını sağlamaktadır. Ayrıca, insan-robot etkileşimi (HRI) ile robotun yörüngesinin planlanması, operatörlerin kolaylıkla robotu kontrol etmelerini sağlamaktadır. Bu yenilikçi sistem, geri dönüşüm süreçlerinin otomleştirilmesini ve verimliliğin artırılmasını hedeflemektedir. Aynı zamanda, atık yönetiminin çevresel etkisini azaltmayı ve endüstriyel verimliliği artırmayı amaçlamaktadır. Önerilen sistemde, atıkların türlerinin belirlenmesi için You Only Look Once (YOLO) modelleri olan YOLO-V4 ve YOLO-V4 tiny ağları kullanılmıştır. Bu modeller sayesinde elde edilen yüksek dice score başarımlarıyla (%92.65 YOLO-V4 tiny ve %95.71 YOLO-V4), atıkların türleri doğru bir şekilde tespit edilebilmiştir. Ayrıca, endüstriyel robotun hareketli bir konveyör üzerinden ayrıştırma işlemi yapabilmesi için atıkların 3B konumları da tespit edilmiştir. Intel RealSense kamera kullanılan sistemde konum ölçme sisteminin ortalama 2.52 mm hata ile ölçtüğü hesaplanmıştır. Çalışmanın bir diğer önemli aşamasında, robotun gideceği yörüngesinin planlanması için sensörler aracılığıyla gerçekleştirilen HRI kullanılmıştır. Robot yörüngesinin belirlenmesi için kullanılan sensörlerden elektromiyografi (EMG) verisinin %96.6 sınıflandırma başarısı, parmak pozisyon ölçüm sensörünün ise 2.45-2.85 mm arasında hata ile ölçüm yaptığı hesaplanmıştır. Bu yöntem, operatörlerin robot programlama bilgisine ihtiyaç duymadan, insan el hareketleriyle robot kontrolünü sağlamalarını mümkün kılmaktadır. Geliştirilen sistem, hareketli bir konveyör üzerindeki atıkların doğru bir şekilde tespit edilmesi ve endüstriyel robot aracılığıyla ayrıştırılmasını sağlamaktadır. Bu yenilikçi ayrıştırma sistemi, geri dönüşüm süreçlerini otomatikleştirerek, atık yönetimi alanında çevresel etkinin azaltılması hedeflenmektedir.

Anahtar Kelimeler: Endüstriyel robot, YOLO-V4, YOLO-V4 tiny, 3 boyutlu konum tespiti, insan-robot etkileşimi, konveyör takibi.

AUTOMATIC SEPARATION OF RECYCLING MATERIALS BASED ON COMPUTERIZED VISION AND HUMAN ROBOT INTERACTION

ABSTRACT

The correct separation of recyclable wastes is of great importance in terms of environmental sustainability and resource efficiency. In this study, a waste sorting system was developed using industrial robot and computer vision. The developed system enables the robot to perform the correct sorting process by determining the types of wastes and determining their 3D positions. In addition, planning the trajectory of the robot with human-robot interaction (HRI) allows operators to control the robot easily. This innovative system aims to automate recycling processes and increase efficiency. It also aims to reduce the environmental impact of waste management and increase industrial efficiency. In the proposed system, You Only Look Once (YOLO) models YOLO-V4 and YOLO-V4 tiny networks were used to determine the types of waste. Thanks to these models, with the high dice score performances (92.65% YOLO-V4 tiny and 95.71% YOLO-V4), the types of wastes could be determined accurately. In addition, the 3D positions of the wastes have been determined so that the industrial robot can sort through a moving conveyor. In the system using Intel RealSense camera, it has been calculated that the position measurement system measures with an average error of 2.52 mm. In another important stage of the study, HRI, which is realized through sensors, was used to plan the trajectory of the robot. It has been calculated that the electromyography (EMG) data, one of the sensors used to determine the robot trajectory, has a classification success of 96.6%, and the finger position measurement sensor measures with an error between 2.45-2.85 mm. This method makes it possible for operators to control the robot with human hand movements without the need for robot programming knowledge. The developed system ensures that the wastes on a moving conveyor are accurately detected and separated by means of an industrial robot. This innovative separation system aims to reduce the environmental impact in the field of waste management by automating the recycling processes.

Keywords: Industrial robot, YOLO-V4, YOLO-V4 tiny, 3D position detection, human-robot interaction, conveyor tracking.

BÖLÜM 1. GİRİŞ

Geri dönüştürülebilir materyallerinin ayrıştırılması günümüz dünyasının başlıca sorunlarından biridir. Özellikle plastik atıklar gün geçtikçe artmaktadır. Artan atık üretimi; hava kirliliği, su kirliliği ve ekolojik sorunları başta olmak üzere birçok problem meydana getirmektedir. Etkin bir geri dönüşüm yapılarak atıkların tekrar kazanılması ve olumsuz çevre etkilerinin azaltılması sağlanabilmektedir.

Geri dönüşüm ayrıştırma teknikleri, elle ayrıştırma ve otomatik ayrıştırma olarak ikiye ayrılmaktadır (Elrabaya, 2021). Elle ayrıştırma, genellikle insanların görsel olarak malzemeleri tanıması ve ayrıştırması olarak tanımlanmaktadır ve büyük geri dönüşüm tesisleri için uygun bir çözüm olmamaktadır. Otomatik ayrıştırma, insan müdahalesinin minimum olduğu ve geri dönüşüm malzemelerinden elde edilen verimin yüksek olduğu sistemlerdir (Cao ve Ouyang, 2019).

Otomatik ayrıştırma sistemlerinde robotların kullanılması birçok sektörde olduğu gibi bu problemin çözümü için de doğru kurgulandıklarında en olumlu sonuçları üretmektedir. Ayrıca; bilgisayarlı görme teknolojisinin gelişmesiyle birlikte robotik sektörü önemli bir ilerleme göstermiştir. Endüstriyel robot sektöründe kamera kullanılmasıyla robotun hareket edeceği yörünge optimizasyonu (Nonoyama ve diğ., 2022; Gao ve Zhang, 2022), robotlar arasında koordinasyon (Mizrahi ve diğ., 2020) ve maliyet optimizasyonu (Yun ve Rus, 2014) çalışmaları son yıllarda popüler araştırma ve ürün geliştirme konuları arasında yer almaktadır. Bu kapsamda geri dönüşüm materyallerinin ayrıştırılmasında robotlu sistemlerin kullanılması, hem maliyet hem de verimlilik açısından gelişmiş ülkelerin bu yönetime geçişini hızlandırmaktadır. Günümüzde elle çöp ayrıştırma yöntemi düşük verimlilik, zor ve sağlıksız çalışma koşulları ve bunun yanında akıllı sistemlere olan gereksinimlerden dolayı robotik ayrıştırma sistemine geçilmeye başlanmıştır.

Robotlu ayrıştırma sistemlerinde düşük maliyet, yüksek çalışma performansı en önemli kriterlerdendir. Ayrıca esnek hareket kabiliyetine sahip ve insan müdahalesine en az gereksinim gerektiren sistemlere ihtiyaç duyulmaktadır. Bu sistemleri oluşturmanın ve otomasyonu geliştirmenin önündeki en büyük engel atık ayrıştırma probleminin rastgele ve çok değişkenli ürünlerden oluşan düzensiz bir ortam olmasıdır. Bu durum, robotların atıkları doğru şekilde tanınması ve ayrıştırmasını zorlaştırmaktadır. Ancak, yapay zeka ve makine öğrenme algoritmalarının gelişmesi ile beraber, birçok farklı atık tipi doğru şekilde tespit edilip ayrıştırma işlemini yapan robotik sistemler geliştirilebilmektedir.

Atık ayrıştırma probleminin verimliliğini artırmak için bir başka husus da robotların izleyeceği yörünge planlanmasıdır (Kiyokawa ve diğ., 2022). Çeşitli sensörler ve makine öğrenmesinin beraber kullanılmasıyla HRI sistemleri geliştirilmektedir. Bu sistemler sayesinde kullanıcıların robotları daha doğal ve sezgisel bir şekilde kontrol etmesini sağlamaktadır. Bu sayede robotun gideceği patika kullanıcı tarafından belirlenerek atık ayrıştırma sürecini daha hızlı ve verimli hale getirmektedir.

Tez çalışmasının ilk bölümünde problemle ilgili temel bilgiler ve literatürde geliştirilmiş sistemler incelenecektir.

İkinci bölümde, robot patikasının belirlenmesi için geliştirilen HRI uygulaması ele alınacaktır. Uygulamada kullanılan sensörler ve bu sensörlerden veri almak için kullanılan yöntemler ayrıntılı şekilde anlatılacaktır.

Üçüncü bölümde ise geri dönüştürülebilir materyallerinin tespiti için geliştirilen yapay zeka ve görüntü işleme tabanlı uygulama incelenecektir. Bu bölümde kameradan alınan renk görüntüsü ile atığın türü, derinlik görüntüsü ile de atığın konum tespiti için kullanılan yöntemler anlatılacaktır.

Dördüncü bölümde, ikinci ve üçüncü bölümde geliştirilen uygulamalar birleştirilerek gerçek bir atık ayrıştırma sistemi prototip düzeneği ele alınacaktır. Bu bölümde hareketli bir konveyör üzerinden gelen atıklar endüstriyel robot vasıtasıyla ayrıştırılması sağlanacaktır.

Son olarak beşinci bölümde tez kapsamında elde edilen sonuçlar ayrıntılı şekilde anlatılıp mevcut literatürde sonuçlarla karşılaştırılacaktır.

1.1. İnsan – Makine Etkileşimi

İnsan - makine etkileşimi (HMI), insanlar ve makineler arasındaki etkileşimleri inceleyen bir disiplindir. HMI'nin amacı, insanların teknolojik sistemlerle etkileşimlerini kolaylaştırmak, hata yapma olasılığını azaltmak, kullanıcı memnuniyetini artırmak ve kullanıcının güvenliğini sağlamak için insan faktörlerini ve teknolojik faktörleri dikkate alan bir yaklaşım benimsemektir.


Gelişen teknolojiyle birlikte HMI'nin potansiyel uygulama alanları, oldukça artmaktadır. HMI, yapay zekâ (Iqbal ve diğ., 2011), robotik (Park and Kim, 2020), sanal gerçeklik (Wijnen ve diğ., 2020), artırılmış gerçeklik (Xue ve diğ., 2020) gibi birçok farklı teknoloji bileşenlerini içeren sektörlerin yanı sıra otomotiv, havacılık, sağlık hizmetleri, askeri ve endüstriyel ev aletleri gibi birçok farklı sektörde de kullanılmaktadır. Örneğin, otomotiv sektörü, sürücüsüz araçların geliştirilmesinde HMI teknolojilerinden yararlanmaktadır (Reuschenbach ve diğ., 2011). Bu teknoloji, sürücülerin güvenliği ve konforu için araçların algılama, analiz ve tepki verme yeteneklerini artırır. Havacılık sektörü ise, kokpitlerdeki HMI araçları ile pilotların daha iyi bir deneyim yaşamalarını ve daha etkili kararlar vermelerini sağlar (Alaimo ve diğ., 2022).

HMI'de elektromiyografi (EMG), kullanıcının kas aktivitelerini takip ederek, makinelerin insan hareketlerini ve niyetlerini anlamalarına yardımcı olabilmektedir. EMG tabanlı kontrol sistemleri, kullanıcının kas sinyallerini okuyarak bu bilgileri robot hareketlerine dönüştürür. Özellikle protezler ve robotik eldivenler gibi cihazlar, EMG sinyallerini kullanarak insan eli ve parmaklarının hareketlerini taklit edebilmektedir. Bu sayede, kullanıcılar robotik cihazları kendi kas aktiviteleriyle kontrol edebilir ve doğal bir etkileşim gerçekleştirebilirler. (Meattini ve diğ., 2018; Calderon-Cordova ve diğ., 2016).

Parmak pozisyon ölçüm sensörleri, özellikle Leap Motion Controller gibi sensörler, kullanıcıların el ve parmak hareketlerini gerçek zamanlı olarak takip ederek, bu bilgileri robotik sistemlere iletebilirler (Zhang ve diğ., 2019; Tölgyessy ve diğ., 2023). Bu sayede, robotlar insan hareketlerine uyum sağlayabilir ve insanlarla daha doğal ve sezgisel bir şekilde etkileşime geçebilirler.

HRI’de, EMG ve parmak pozisyon ölçüm tekniklerinin birleşimi, robotların insanların doğal hareket ve yeteneklerini daha iyi anlamalarına ve taklit etmelerine olanak tanır. Bu, özellikle rehabilitasyon, endüstriyel otomasyon ve oyun gibi alanlarda sıklıkla kullanılmaya başlanmıştır. Bu teknolojilerin kullanılmasıyla, insanlar ve robotlar arasındaki etkileşim daha verimli ve doğal hale gelebilir, böylece her iki tarafında çalışma kalitesi artırılabilir (Boru ve Erin, 2022). Ayrıca, robotlar aşırı sıcak, soğuk veya tehlikeli koşullarda çalışabilir, insanların bu tür risklere maruz kalmasını azaltabilir. Bu işbirliği ile daha az insan gücüne ihtiyaç duyularak uzun vadede maliyet tasarrufu sağlanabilir.

Endüstriyel otomasyon alanında, EMG ve parmak pozisyon ölçüm teknolojileri, işçilerin ve robotların işbirliğine dayalı çalışma süreçlerini geliştirebilir. İşçilerin kas sinyalleri ve parmak hareketleri, robotik sistemlerin insanlarla daha etkili bir şekilde çalışmasını sağlayarak, verimliliği ve güvenliği artırabilir. Özellikle hassas ve karmaşık görevlerde, bu teknolojiler sayesinde insanlar ve robotlar, daha uyumlu ve doğal bir etkileşim sağlayarak, üretim süreçlerini iyileştirebilirler. EMG ve parmak pozisyon ölçüm sistemi Şekil 1.1’de gösterilmiştir.



Şekil 1.1 : EMG ve parmak pozisyon ölçümü (Erin ve diğ., 2022).

1.2. Atık ayrıştırma sistemleri

Atıkların yeniden kullanılabilir hale getirilmesi küresel ısınmayı azaltmak ve doğal kaynakları kirletmemek adına uygulanması gereken en önemli adımlardan birisidir. Atık ayrıştırma sistemi atıkların geri dönüşüm tesislerinde toplanmasını, burada atık türlerine göre ayrıştırılmasını ve daha sonra tekrar kullanılmak üzere depolanması süreçlerinden oluşmaktadır. Ayrıştırma sistemleri plastik, kağıt, metal vb. atıkların geri dönüşümü için kritik bir süreçtir. Doğruluğu yüksek olan bir sistem daha iyi geri dönüşüm sağlayacaktır. Geri dönüşümü iyi yapılmış bir sistem, atıkların tekrar kullanımını ve enerji üretmeyi sağlarken kötü tasarlanmış bir sistem devletler için yüksek maliyet kaybına neden olmaktadır.

Günümüzde yapılan ayrıştırma sistemlerinde teknolojinin yetersiz kalması veya çoğu ülkede bu sistemlerde insanların çalıştırılması verimsiz bir ayrıştırmaya sebep olmaktadır (Kimyasal gelişmeler, 2015). Bu tesisler insanlar için iş kaynağı olarak görülse de sağlık açısından istenilen meslekler arasında yer almamaktadır.

Atıkların insanlar tarafından elle ayrıştırılması yavaş, ekonomik olmayan bir yöntemdir ve çalışanlar açısından iş sağlığı güvenliği tehditleri barındırmaktadır. Ayrıca bu yöntemle tehlikeli plastikleri ve plastik türü maddeleri ayırmak zor bir süreç oluşturmaktadır (Sun ve diğ., 2018). Bu gibi nedenlerle elle ayrıştırma yerine makineleşmiş ayrıştırma tesislerine olan ihtiyaç artmaktadır. Bu tür tesislerde insanların çalıştırılması etik açısından da sorun olmaktadır. Bazı ülkeler atıklarını ayırtmak için ucuz işçilik sağlanan diğer ülkelere göndermektedir. Ayrıca bu ülkelerde çocuk işçilerin çalıştırıldığı yönünde kaygılar bulunmaktadır.

1.3. Literatür Araştırması

Günümüzde elle çöp ayrıştırma düşük verimlilik dezavantajından dolayı robotik ayrıştırma sistemine geçilmeye başlanmıştır. Robotlu ayrıştırma sistemlerinde düşük maliyet, yüksek çalışma performansı önemli kriterler olmaktadır. Atık ayrıştırma sistemi tasarımında görüntü işleme ve derin öğrenme tabanlı geliştirilen yazılımlarla parçanın türü, şekli ve konumu belirlenebilmektedir (Zhihong ve diğ., 2017; Yan ve diğ., 2019; Zhang ve diğ., 2018; Bozma ve diğ., 2002). Sistemde kullanılacak olan robotların sayısı, konveyörün hızı ve boyutu, konveyörden gelen parça sayısı ve boyutu gibi birçok değişkene bağlı olduğundan uzun ve karmaşık bir yapıdan oluşmaktadır. Bu

sebeplerden dolayı robotik ayrıştırma sisteminin tasarımı için sezgisel yapay zeka optimizasyon yöntemleri kullanılmaktadır. (Edan ve diğ., 2004; Çakar ve diğ., 2008; Daoud ve diğ., 2014)

Geri dönüşüm ayrıştırma sistemleri son yıllarda yapılan çalışmalarla literatürde geniş yer kaplamaktadır. Literatür araştırmasında atık ayrıştırmada uygulanan teknikler ve HMI ile ilgili yapılan araştırmalar ayrıntılı bir şekilde gösterilmiştir. Literatürde yapılan çalışmalar dikkate alındığında geri dönüşüm materyallerinin tespiti ve ayrıştırılmasına ilişkin yeni çalışmalar olabileceği söylenebilir. Mevcut literatürde yapılan çalışmalar kısaca şöyle özetlenebilir.

1.3.1. Yapay zeka ve görüntü işleme tabanlı atık ayrıştırma sistemleri

Tatzer ve diğ. (2005) yaptıkları çalışmada hiperspektral görüntüleme yöntemiyle atık maddelerin tespitini gerçekleştirmişlerdir. Yaptıkları deney düzeneğinde ayrıştırma işlemi için kağıt ve karton atıkları seçilmiştir. Çalışmada kameradan alınan görüntüler ön işlemden geçirilmiş ardından boyut azaltma işlemi için Temel Bileşenler Analizi (TBA) ve Doğrusal Ayırma Analizi (DAA) algoritmaları kullanılmıştır. Daha sonra elde edilen görüntülerden sınıflandırma işlemi için k- En Yakın Komşu (k-NN) algoritması kullanılmıştır. Yaptıkları çalışma sonucunda doğruluğu %90'nın üzerinde sınıflandırma başarısı elde etmişlerdir.

Scavino ve diğ. (2009) yaptıkları çalışmada konveyör üzerindeki plastik şişe atıklarının otomatik tespiti ve ayrıştırılması için prototip bir düzenek geliştirmişlerdir. Çalışmada kullandıkları donanım ve geliştirdikleri yazılım sayesinde düşük ışıkta ve şekli bozulmuş şişelerin tespitindeki zorlukları kaldırabilmektedir. Kamera ile aldıkları görüntülerden görüntü işleme yöntemi ile tanıma işlemi yapmışlardır. Görüntülerden tanıma işlemi yapılırken özellik uzayında minimum mesafe, özdüzenleyici haritalar ve sinir ağları yöntemleri kullanılmıştır. 50 tane plastik malzeme üzerinde denenmiş olan çalışmada doğruluğu %97 olarak belirlemişlerdir.

Jimoh ve diğ. (2014) yaptıkları çalışmada görüntü işleme tabanlı plastik ayırma sistemi geliştirmişlerdir. Yazarlar ilk önce kameradan elde ettikleri görüntülere morfolojik işlemler uygulayarak plastiğin şekli, alanı gibi özellikler elde edip ayrıca plastiğin çıkardığı sesten ses spektrumunu elde etmişlerdir. Daha sonra elde ettikleri görüntülerden 2 farklı yöntem ile plastiğin türünü belirlemişlerdir. Sınıflandırma

yöntemi olarak şablon eşleştirme yöntemi ve görüntülerden elde ettikleri özelliklerden bulanık mantık tabanlı sınıflandırma yapmışlardır. Deneysel çalışmada veri topladıkları 500 örnek sonunda polietilen tereftalat (PET), Yüksek yoğunluklu polietilen (HDPE), alçak yoğunluklu polietilen (LDPE) ve polipropilen (PP) türü plastik maddelerine ayırıştırma yapılmış ve sistemin doğruluğunu %88 olarak elde etmişlerdir.

Özkan ve diğ. (2015) yaptıkları çalışmada plastik geri dönüşüm malzemelerinin görüntü işleme tabanlı ayırıştırılmasını sağlamışlardır. İlk önce kameradan elde edilen görüntülerden plastik atık tespit edilmiştir. Daha sonra çeşitli görüntü işleme teknikleri ile görüntü üzerindeki gürültüler giderilmiştir. Elde edilen görüntülerden özellik çıkarımı yapılmıştır. Özellik çıkarımı için TBA, Kernel TBA , Fisher's DAA, Tekil Değer Ayırışımı (SVD), ve Laplace öz haritaları (LEMAP) olmak üzere 5 farklı algoritma ayrı ayrı kullanılmıştır. Plastik atıkları sınıflandırmak için Destek Vektör Makinaları (DVM) algoritması kullanılmış olup doğruluğu yaklaşık %90 olarak belirlenmiştir.

Roh ve diğ. (2018) yaptıkları çalışmada lazer etkileşimli plazma spektroskopisi kullanarak siyah plastik malzemelerin ayırıştırılması üzerinde çalışmışlardır. Çalışmada ilk önce spektroskopi ile elde edilen veriler üzerinde boyut azaltmak için TBA ve Bağımsız Bileşenler Analizi (BBA) algoritmaları kullanılmıştır. Boyut azaltma işleminin ardından Radyal taban fonksiyonlu yapay sinir ağı algoritması kullanılarak plastik malzemelerin sınıflandırılması sağlanmıştır. Deneysel çalışmada 400'er adet PP, polistiren (PS) ve akrilonitril bütadien stiren (ABS) türü siyah plastik malzeme kullanılmıştır. Kullanılan malzemelerinden eğitim ve test veri seti 5 katlamalı çapraz doğrulama yöntemiyle belirlenmiştir. Çalışma sonunda Radyal taban fonksiyonlu yapay sinir ağı algoritmasının bazı parametrelerinin değiştirilmesiyle doğruluğu %94.58 ve %95.83 olarak elde edilmiştir.

Chu ve diğ. (2018) yaptıkları çalışmada atık maddeleri Çok katmanlı hibrit derin öğrenme (MHS) yöntemini kullanarak sınıflandırmışlardır. Çalışma kapsamında yaygın kullanılan 40 tanesi geri dönüştürülebilir 10 tanesi ise meyve, sebze ve mutfakta kullanılan malzeme olmak üzere 50 farklı malzeme kullanmışlardır. Toplanan 50 farklı malzemedan 100'er adet RGB görüntü toplamda 5000 adet görüntüyü JPEG formatında kaydetmişlerdir. Görüntülerden malzeme tespit etmek için MHS yöntemi kullanılmış olup bu yöntem Evrişimsel Sinir Ağı (ESA) ve Çok Katmanlı Algılayıcılar (ÇKA)

yöntemlerini içermektedir. ESA yöntemi genellikle görüntüler üzerinden sınıflandırma yapan bir yöntem olup ESA yönteminden elde edilen veriler ÇKA yöntemine giriş olarak verilmiştir. ÇKA yönteminde ise ESA yönteminden gelen veriler dışında harici sensörlerden gelen verilerde kullanılmıştır. Daha sonra MHS yöntemi ve ESA yönteminin performansları karşılaştırılmıştır. MHS yönteminde doğruluk birinci ve ikinci test sonunda %98.5 ve %97.1, ESA yönteminde ise testler sonucunda doğruluğu %88.6 ve %85.9 olarak elde edilmiştir. Çalışma sonunda MHS sisteminin daha başarılı olduğunu tespit etmişlerdir.

Rani ve diğ. (2019) yaptıkları çalışmada yakın kızılötesi spektroskopi tabanlı plastik malzemelerin ayrıştırılmasını gerçekleştirmişlerdir. İlk önce spektrometreden aldıkları sinyaller üzerinde Savitzky - Golay ikinci türev yöntemini kullanarak iyileştirmeler yapmışlardır. Daha sonra sinyallerin özelliklerini çıkarmak için TBA algoritmasını kullanmışlardır. Özellikleri çıkarılan sinyalleri sınıflandırmak için Kısmi En Küçük Kareler – Ayırma Analizi (PLS-DA) algoritması kullanmışlardır. Sınıflandırma aşamasında topladıkları malzemelerin 901 tanesi eğitim 386 tanesi test için kullanılmış olup bunların rastgele ayrılması için 10 çapraz doğrulama yöntemi kullanmışlardır. Sınıflandırma sonucunda doğruluğu %100'lere ulaştığını tespit etmişlerdir.

Wang ve diğ. (2019) yaptıkları çalışmada ilk önce şişelerin bitişik, parçalanmış ve üst üste olma durumunlarını kameradan tespit ederek ayrıştırma yapmışlardır. Daha sonra şişelerin renk duruma göre 7 sınıflı ayrıştırma işlemi yapılmıştır. Sınıflandırma işleminden önce elde edilen görüntülerden özellik çıkarımını gerçekleştirmişlerdir. Özellik çıkarımı için ReliefF algoritması kullanmışlardır. Özellik çıkarımından sonra DVM algoritması ile sınıflandırma yapılmıştır. Kurdukları deneysel düzenekte 700 adet atık madde eğitim 100 adet atık madde test için kullanılmıştır. Çalışma sonunda sınıflandırma karışıklık matrisleri verilmiş olup 7 farklı renkli plastik şişe için genel sınıflandırma doğruluğunu %97.4 olarak belirlemişlerdir.

Mokled ve diğ. (2019) yaptıkları çalışmada çöp ayrıştırma sistemi için delta robotlar kullanarak optimizasyon işlemi gerçekleştirmişlerdir. Çalışmada kullanılan konveyör hızını hesaba katarak ayrıştırılacak çöp sayısını maksimum ve 2 çöp arasındaki ayrıştırma süresinin minimum yapmak için robotun gideceği patikayı optimize etmeye çalışmışlardır. Robotların gideceği patikayı konveyörün hızına bağlı olarak zamana bağlı fonksiyon şeklinde ifade etmişlerdir. Optimizasyon sonucunda geliştirdikleri

algoritmayı denemek için basit bir prototip düzenek yapmışlardır. Yaptıkları düzenekte plastik ve metal çöpler kullanılmış olup çöplerin türünü bulmak için indüktif ve kapasitif sensör kullanmışlardır. Yapılan çalışmada geliştirdikleri algoritma sayesinde robot saniyede 3 parça ayrıştırabilmektedir.

Meng ve Chu (2020) hazır olan veri seti üzerinden çöp ayrıştırma işlemi gerçekleştirmişlerdir. Yazarlar 2527 görüntü üzerinden veri artırma yöntemlerini kullanarak 10108 görüntü elde etmişlerdir. Daha sonra bu görüntüleri DVM + Yönlü Granyanlar Histogramı (YGH), Basit ESA, Kalıntı Ağı (ResNet) ve YGH + ESA yöntemleriyle karton, cam, metal, plastik, kağıt ve genel atık olmak üzere 6 farklı kategoriye ayırmışlardır. Çalışma sonunda kullandıkları yöntemleri karşılaştırıp en başarılı olarak %95.25 doğruluk ile ResNet modeli olduğunu tespit etmişlerdir.

Cao and Xiang (2020) yaptıkları çalışmada kamera ile topladıkları veri seti üzerinden çöp tespiti yapmışlardır. Topladıkları veri setini farklı veri artırma yöntemleriyle 20000 görüntüye çıkarmışlardır. Daha sonra Inception V3 modeli kullanarak atıkları; geri dönüştürülebilir atık, evsel atık, tehlikeli atık ve genel atık olmak üzere 4 kategoride sınıflandırmışlardır. Çalışma sonunda eğitim doğruluğunu %99.3, test doğruluğunu %93.2 olarak belirlemişlerdir.

Panyavaraporn ve diğ. (2021) yaptıkları çalışmada su üzerinde bulunan atıkların tespiti ve ayrıştırması için prototip bir robot tasarlamışlardır. Çalışmada 1082 görüntü üzerinden şişe, plastik ve genel atık olmak üzere 3 farklı kategoride sınıflandırma gerçekleştirmişlerdir. Tensorflow ve OpenCV kütüphanelerini kullanarak çöpleri tespit edip sınıflandırma doğruluğunu %83.25 olarak tespit etmişlerdir.

Tian ve diğ. (2021) yaptıkları çalışmada topladıkları veri seti üzerinden gerçek zamanlı atık ayırtmışlardır. Kitap, cam şişe, metal kutu, ve plastik şişe olmak üzere 4 farklı kategori için 8000 görüntü toplamışlardır. Topladıkları 8000 görüntü üzerinden 1000 tanesinin test, 7000 tanesini eğitim yapmak için kullanmışlardır. Daha sonra YOLO-V3 modeli ile kendi oluşturdukları modeli eğitmişler ve performanslarını karşılaştırmışlardır. YOLO-V3 modelinde doğruluğu %86.9 ve çalışma hızını 20ms, kendi oluşturdukları modelin doğruluğunu %86.9 ve çalışma hızını 15ms olarak tespit etmişlerdir.

Yang ve diğ. (2021) yaptıkları çalışmada TACO (Proença ve Simoes, 2020) veri seti ve YOLO-V5 kullanarak çöp ayrıştırma işlemi gerçekleştirmişlerdir. Araştırmacılar

kullandıkları TACO veri seti üzerinden 1195 görüntünün %90'ını eğitim %10'unu test için kullanmışlardır. Daha sonra 7 farklı sınıfa ayırıp doğruluğu %94.5 olarak tespit etmişlerdir.

Liu ve diğ. (2021) yaptıkları çalışmada mobil robotik manipülatör ile çöp tanıma ve ayrıştırma işlemi gerçekleştirmişlerdir. İlk önce literatürde yer alan TACO (Proença ve Simoes, 2020) veri seti üzerinden kendi oluşturdukları ve adına GarbageNet dedikleri algoritma ile çöpün tespitini gerçekleştirmişlerdir. Daha sonra mobil manipülatörün çöpü kavrayabilmesi için 3B görüntü üzerinden çöpün konumunu ve kavrama pozisyonunu tespit etmişlerdir. Çalışma sonunda kapalı alanlarda çöp toplama işleminin robotik manipülatör ile başarılı bir şekilde çalıştığını ortaya koymuşlardır.

Pan (2022) yaptığı çalışmada YOLO-V3 algoritmasının parametrelerini optimize ederek çöp veri seti üzerinden çöp tespit ederek sistemi hızlandırmaya çalışmıştır. Çalışma sonunda optimize ettiği YOLO-V3 algoritmasını YOLO, YOLO-V2 ve YOLO-V3'den daha iyi başarı ve daha hızlı sistem elde ettiğini ortaya koymuştur.

Fu ve diğ. (2021) yaptıkları çalışmada tespit edilen atığı endüstriyel robot ve RGB-D kamera kullanarak robotik ayrıştırma gerçekleştirmişlerdir. Çalışmada atığın türü ve konumunu bulmak için Robot işletim sistemi (ROS) kullanmışlardır. Daha sonra belirledikleri atığın konumunu kamera koordinat sisteminden robot koordinat sistemine dönüştürüp atığı başarılı bir şekilde ayırtmışlardır.

Cheng ve diğ. (2022) yaptıkları çalışmada kendi oluşturdukları REG adı verdikleri veri seti üzerinden çöp ayrıştırma işlemi gerçekleştirmişlerdir. Topladıkları 6694 görüntü üzerinden eğitim için 5194, doğrulama için 500 ve test için 1000 tane görüntü kullanmışlardır. Eğitim işlemi için Linux ve Nvidia GeForce RTX 2080Ti ekran kartı kullanıp sistemi python ortamında programlamışlardır. Kullandıkları veri seti üzerinden 3 farklı sınıf belirlemişlerdir. YOLO-V3 algoritması ile %83.4, YOLO-V3+VGG algoritması ile %81.1, YOLO-V3 + DenseNet algoritması ile %84.7, CenterNet+LE ile %80.48, CenterNet+Feature Fusion (Kendi önerdikleri algoritma) ile %86.34 oranında doğruluk elde etmişlerdir.

Literatürde yer alan çöp ayrıştırma sistemlerinin yanı sıra geliştirdiğimiz yöntemde çöp ayrıştırma da yer alan endüstriyel robota sensörler vasıtasıyla patika planlanması yapılmış böylece HRI gerçekleştirerek robot programlama daha esnek bir şekilde gerçekleştirilmiştir.

1.3.2. EMG ve parmak pozisyon ölçümü ile insan makina etkileşimi

Literatürde HRI üzerine elektroensefalografi (EEG) (Naveed ve diğ., 2012; Bian ve diğ., 2016; Coito ve diğ., 2016), elektrookülografi (EOG) (Tsui ve diğ., 2007) ve EMG (Artemiadis ve Kyriakopoulos, 2010) gibi sinyaller kullanılarak birçok çalışma yapılmıştır. Bu çalışmalarda insan vücudundan sensörler vasıtasıyla alınan sinyallerden gerekli öznelikler çıkarılmış ve daha sonra bu sinyaller sınıflandırılarak yorumlanmıştır.

Sueaseenak ve diğ. (2013) yaptıkları çalışmada EMG sinyallerini sınıflandırarak 12 serbestlik dereceli sanal protez kol kontrol etmişlerdir. Yazarlar yüzey elektrotları ile aldıkları sinyalleri BBA algoritması kullanarak filtrelemişlerdir. Daha sonra filtrelenmiş sinyallerle 12 farklı hareketi sınıflandırmışlardır. Çalışma sonunda BBA yönteminin sınıflandırma başarısını iyileştirdiğini gözlemlemişlerdir.

Zhang ve diğ. (2009) EMG sinyalleri ve 3B ivmeölçer sensörü kullanarak insan hareketlerini tespit ederek sanal bir zar oyunu geliştirmişlerdir. Yazarlar 18 farklı hareket için sinyal toplamış daha sonra topladıkları sinyalleri Gizli Markov Modeli (HMM) kullanarak sınıflandırmışlardır. Çalışmayı gerçek zamanlı deneyip sınıflandırma doğruluğunu %91.7 olarak tespit etmişlerdir.

Benatti ve diğ. (2015) çalışmalarında EMG sinyalleri kullanarak hareket tahmini gerçekleştirmişlerdir. Yazarlar 4 farklı kişiden aldıkları sinyaller ile 7 farklı hareket sınıflandırmaya çalışmışlardır. Çalışmada DVM algoritması kullanmış ve %90 oranında doğruluk elde etmişlerdir.

Lucas ve diğ. (2008) çalışmalarında EMG sinyallerini sınıflandırmışlardır. Topladıkları EMG sinyallerinden özellik çıkarımı için Ayrık Dalgacık Dönüşümü (DWT) algoritması, sınıflandırma için DVM algoritması kullanmışlardır. Çalışmada DWT algoritmasını kullanmadan 4.7 ± 3.7 , DWT algoritması kullanarak 11.1 ± 10.0 yanlış sınıflandırma oranı tespit etmişlerdir.

Alkan ve diğ. (2012) yüzey elektrotları kullanarak EMG sinyallerini DVM algoritması ile sınıflandırmışlardır. Yazarlar 10-katlı çapraz doğrulama yöntemiyle sınıflandırma doğruluğunu %96'dan %98'e çıkarmışlardır.

Hassan ve diğ. (2020) Myo Armband kullanarak 5 serbestlik dereceli Aideepen ROT3 isimli robot kolunu kontrol etmişlerdir. İlk olarak Myo Armband ile 6 kişiden aldıkları

EMG sinyallerinden özellik çıkarımı yapmışlardır. Daha sonra sinyalleri 3 farklı sınıflandırma algoritması ile sınıflandırıp başarı performanslarını karşılaştırmışlardır.

HRI uygulamaları ile ilgili mevcut çalışmalara bakıldığında farklı çalışmalar göze çarpmaktadır. Neto ve diğ. (2010) yaptıkları çalışmada HRI sistemi gerçekleştirmişlerdir. Uzaktan kumanda ile alınan 3B ivmeölçer verilerini yapay sinir ağları kullanarak sınıflandırmışlar ve endüstriyel robotun kontrolünü sağlamışlardır. Zhao ve diğ. (2016) yaptıkları çalışmada kızılötesi sensörlü kamera kullanarak bir HRI gerçekleştirmişlerdir. Kameradan alınan görüntülerden, robotun aktüatörlerine sinyal göndermek için kolun açılarını belirlemişlerdir. Daha sonra elde edilen açılarla robotun kontrolünü gerçekleştirmişlerdir. Kuçukyıldız ve diğ. (2017) Amyotrofik Lateral Skleroz (ALS) hastaları için akıllı tekerlekli sandalye geliştirmişlerdir. Araştırmacılar EMG, EEG ve göz hareketlerini kullanarak tekerlekli sandalye kontrolü için 3 farklı kontrol mekanizması gerçekleştirmişlerdir. Shin ve diğ. (2014) mobil robot platformunu EMG ve Atalet ölçü birimi (IMU) sensörleri ile kontrol etmişlerdir. Cao (2019) yaptığı çalışmada görüntü işleme teknikleri ile el hareketlerini tespit etmiş ve makine öğrenmesi algoritmaları ile hareketleri sınıflandırmıştır. Zhu ve Sheng (2011) yaptıkları çalışmada yaşlı insanların günlük hareketlerini tespit etmeye çalışmışlardır. İnsanların el ve ayak bileklerine yerleştirdikleri IMU sensörü ile 5 farklı hareket tespit etmişlerdir. Lu ve diğ. (2014) ivmeölçer ve EMG sensörlü giyilebilir bir cihaz tasarlamış ve cihazdan aldıkları verilerle hareket tahmini yapmışlardır. Kuang ve diğ. (2017) kameradan gelen görüntüleri sınıflandırarak 5 farklı el hareketi belirlemişlerdir. Lu ve Zhou (2019) çalışmalarında sınırlı el becerisine sahip olan veya hiç olmayan hastalar için EMG sensörlü bir insan-bilgisayar arayüz (BCI) sistemi geliştirmişlerdir. Bu hareketlerle bilgisayarın fare kontrolünü sağlamışlardır.

Yapay zeka yöntemlerinin giyilebilir teknolojilerle birlikte kullanıldığı önemli çalışmalar şu şekilde sıralanabilir. Tanaka ve diğ. (2005) elektrikli sandalyenin kontrolünü EEG sinyallerini kullanarak gerçekleştirmişlerdir. Aldıkları sinyalleri sınıflandırıp elektrikli sandalyeyi sağa sola hareket ettirmişlerdir. Mandel ve diğ. (2007) farklı bir uygulama olarak kafaya yerleştirilen IMU sensörü ile tekerlekli sandalyenin kontrolünü sağlamışlardır. Luo ve diğ. (2015) EEG sinyallerini kullanarak akıllı ev sistemi uygulaması gerçekleştirmişlerdir. Yazarlar, çalışmalarını için EEG sensörlü bir başlık kullanmışlardır. Daha sonra EEG sensöründen topladıkları verileri sınıflandırarak

evdeki televizyonu, ışığı ve klimayı kontrol etmişlerdir. Siregar ve diğ. (2021) robot kolunu Myo Armband kullanarak IMU ve EMG sensörleri ile kontrol etmişlerdir. Araştırmacılar herhangi bir sınıflandırma yöntemi kullanmadan Myo Armband üzerinde kullanıma hazır olan sınıflandırılmış sinyallerle arduino üzerinden robot kolu kontrol etmişlerdir. Tsai ve diğ. (2020) kamera kullanarak tespit ettikleri el hareketleri ile sanal fare kontrolü yapmışlardır. Yazarlar çektikleri görüntüler üzerinden 4 farklı hareket tespit edip bu hareketlerle fare kontrolü, fare tekerleği kontrolü, fare sağ ve sol tuş kontrolü olarak kullanmışlardır. Yazarlar çektikleri görüntülerin arka plan karmaşıklığına bağlı olarak ortalama %83'ün üzerinde doğruluk elde etmişlerdir. Sun ve diğ. (2020) yaptıkları çalışmada yüzey elektrotları ile aldıkları EMG sinyallerini sınıflandırmışlardır. İlk önce aldıkları sinyalleri filtrelemiş ve daha sonra öznelik çıkarımı yapmışlardır. Elde edilen sinyaller üzerinden DVM ve genelleştirilmiş regresyon sinir ağı algoritmaları ile sınıflandırmışlardır. Çalışma sonunda destek vektör makinasının daha iyi sonuçlar verdiğini gözlemlemişlerdir.

1.4. Tezin Amacı ve Önemi

Tez kapsamında yapılan otomatik ayrıştırma sisteminde amaç sadece ayrıştırılan ve enerji üretmek için yakılan atıkları geri dönüştürmek değil doğru ayrıştırılan atık yüzdesini de artırmaktır. Bu hedefe ulaşmak için mevcut sistemin iyileştirilmesi gerekmektedir. Robotların ve sensörlerin kullanılacağı bir sistem 7/24 verimli bir şekilde çalışabilir, tehlikeli atıklarla başa çıkabilir ve farklı atıkları yüksek bir oranla ayrıştırabilecektir. Ancak robotlar atıkları güvenli bir şekilde tanınması için görsel bir yardıma ihtiyaç duymaktadırlar. Bu sorunun giderilmesi içinde kamera sistemleri ve yapay zeka yöntemlerinin kullanılması gerekmektedir. Bunların sonucunda doğruluğu yüksek olan otomatik geri dönüşüm sistemleri yüksek kar elde edilen ve sağlık açısından da sorunların çözüldüğü sistem olacaktır.

1.5. Tezin Literatüre Katkısı

Tez kapsamında geliştirilen sistemde endüstriyel robot kullanılarak geri dönüştürülebilir malzemelerin ayrıştırılması sağlanmıştır. Literatürde yapılan atık ayrıştırma çalışmalarına bakıldığında genelde görüntüler üzerinden sadece derin öğrenme metodlarıyla atığın türünü belirleme uygulamalarının yapıldığı görülmektedir. Yaptığımız sistemde sadece atığın türünü değil ayrıca endüstriyel robotun çalışan bir konveyör üzerinden ayrıştırma işlemi yapabilmesi için atığın konumunun 3 boyutlu

olarak tespit edilmesi ve robotun gideceği patikanın planlanması insan-robot etkileşimi ile gerçekleştirilmiştir. Yapılan çalışmanın literatüre katkıları şu şekilde sıralanabilir;

- Yapılan çalışmanın literatüre ana katkısı robot yörüngesinin sensörler tarafından HRI ile gerçekleştirilmesidir. Bu kısımda literatürdeki HRI çalışmalarına bakıldığında genelde tek tip sensör kullanıldığı, bu nedenle elde edilen hassasiyet ve performans sonuçları özellikle yörünge planlaması uygulamaları için yeterli olamamaktadır. Bu sorunu çözmek için yapılan çalışmada literatürde ilk kez Myo armband ve Leap Motion sensör verilerinin bir arada kullanıldığı yeni bir yazılım geliştirilmiş ve endüstriyel robotun gideceği patikanın daha hassas takibi yapılmıştır. Geliştirilen yazılım sayesinde kullanıcı geleneksel robot programlama bilgisi olmadan insan hareketleriyle robotu programlayabilecektir. Bu çalışmanın literatüre bir diğer katkısı da muadillerine göre çok daha düşük maliyetli sensörler ile yüksek hassasiyetli çözüm sunmasıdır.
- Çalışmada hareketli konveyör üzerinden endüstriyel robotun atığı ayrıştırması sağlanmıştır. Bu kısımda kullanılan kamera ile atığın türü ve 3 boyutlu konumu tespit edilmiş ve robot tarafından ayrıştırılması sağlanmıştır. Literatürde yapılan çalışmalara bakıldığında genelde görüntü üzerinden veya sabit atıkların tespiti ve ayrıştırılması incelenmiştir. Hareketli konveyörden ayrıştırma işlemi yapmak literatürde karşılaşılan problemlerden birisidir. Bu problemi çözmek için konveyördeki atıklar üzerinden konveyör takibi uygulaması gerçekleştirilmiştir. Konveyöre bağlı enkoder sayesinde parçanın ilk tespit edildiği andaki konum bilgileri alınarak parçanın zaman içerisinde konumu hesaplanmıştır ve böylece robot parçaları kaçırmadan ayrıştırma işlemini kolaylıkla yapabilmektedir.
- Derin öğrenme algoritması için kullanılan TACO (Proença ve Simoes, 2020) görüntü veri setinde düzenlemeler yapılmıştır. Çalışmamıza uygun olan görüntüler belirlenmiş daha sonra kendi oluşturduğumuz veri seti ile birleştirilerek literatüre yeni bir veri seti eklenmiştir.

Bu katkılarla, sensör füzyonu ve derin öğrenme tabanlı algoritmaların etkili bir şekilde kullanılmasının geri dönüşüm için mümkün olduğu gösterilmiştir. Aşağıdaki verilen makaleler yukarıdaki katkılara dayanarak yayınlanmıştır:

- Boru, B., & Erin, K. (2022). Novel technique for control of industrial robots with wearable and contactless technologies. *Measurement*, 192, 110850.
- Erin, K., KUTLU, M. Ç., & Boru, B. (2022). Comparison of gesture classification methods with contact and non-contact sensors for human-computer interaction. *Sigma Journal of Engineering and Natural Sciences*, 40(2), 219-226.
- Erin, K., Bingöl, B., & Boru, B. (2022). YOLO–Based Waste Detection. *Journal of Smart Systems Research*, 3(2), 120-127.



BÖLÜM 2. ENDÜSTRİYEL ROBOTUN GİYİLEBİLİR VE TEMASSIZ SENSÖRLERLE KONTROLÜ

Bölüm 1'deki literatür çalışmaları incelendiğinde, HRI sistemlerinde genellikle tek tip giyilebilir sensörün kullanıldığı ve bu nedenle özellikle pozisyon ölçme uygulamaları için elde edilen hassasiyet ve performans sonuçlarının endüstriyel uygulamalarda ihtiyaç duyulan hassasiyeti sağlayamadığı görülmektedir. Bu sorunu çözmek için sunulan bu çalışmada EMG ve parmak ölçüm sensörlerinin ilk defa birlikte kullanıldığı yeni bir platform geliştirilmiş ve endüstriyel robotların hareketi ve pozisyonu çok daha yüksek hassasiyet ve performansla kontrol edilmiştir.

Bu bölümde, Myo Armband ve Leap Motion sensörleri bir arada kullanılarak EMG sinyalleri ve el hareketi verilerinin toplanma, sinyal işleme ve endüstriyel robotların konum kontrolü için patika planlama uygulamalarına yer verilmiştir. Myo Armband sensörü, kas kasılmaları tarafından üretilen EMG sinyallerini yakalamak için kolun üst kısmına yerleştirilirken, Leap Motion sensörü, kızılötesi kameralar kullanarak el hareketlerini takip etmek için bir sabit yüzeye yerleştirilmiştir. Her iki sensor yardımı ile HRI sistemi geliştirilmiştir.

Bu iki sensörün birleştirilmesiyle, endüstriyel robotların hareket patikası tek bir sensör kullanmaktan daha yüksek hassasiyet ve doğrulukla kontrol edilmiştir. Ayrıca, bu sistem diğer mevcut çözümlere göre daha düşük maliyetli olması ile öne çıkmaktadır (Saggio ve diğ., 2010).

Genel olarak, bu çalışma, Myo Armband ve Leap Motion sensörlerinin bir kombinasyonunu kullanarak endüstriyel robotları kontrol etmek için yeni bir yaklaşım sunmaktadır. Bu yaklaşım, endüstriyel otomasyon sistemlerinin performansını artırmak, maliyetlerini düşürmek ve erişilebilirliğini artırmak için bir alternatif sunmaktadır.

2.1 İnsan Robot Etkileşiminde Kullanılan Teknik Altyapı

HRI, biyolojik sinyaller kullanarak insanların robotları kontrol etmesi veya iletişim kurması için tasarlanan sistemler olarak tanımlanmaktadır. Teknolojinin gelişmesiyle birlikte, birçok sensör bir araya getirilerek giyilebilir cihazlar geliştirilmiştir. Bu cihazlar sayesinde, insan vücudundan alınan sinyallerle elektro - mekanik sistemlere müdahale etmek mümkün olmaktadır.

Günümüzde EMG sinyalleri robotik kol ve robotik el yapımında kullanılmaktadır. Bu çalışma kapsamında insan kol kaslarından EMG sinyallerini ölçmek için 1 adet Myo Armband sensörü, robotun gideceği hareket patikasının belirlenmesi için 1 adet Leap Motion Controller sensörü ve gerçek zamanlı kontrol için ABB firmasının IRB120 model endüstriyel robotu kullanılmıştır. Kullanılan sensörler ve robot Şekil 2.1'de gösterilmiştir.



Şekil 2.1 : Myo armband, Leap Motion controller ve IRB120 endüstriyel robot

Myo Armband Thalmic Labs tarafından üretilen, EMG elektrot, ivmeölçer, jiroskop ve manyetometre bileşenlerinden oluşan düşük enerjili kablosuz bağlantı (Bluetooth Low Energy) olan giyilebilir bir bileklik cihazıdır. Myo Armband sensörünün kablosuz bağlantı ile çalışması ve firma tarafından ücretsiz verilen yazılım geliştirme kiti (SDK) sayesinde ile ham EMG verisinin alıp işlenebilmesi nedeniyle bu sensör tercih edilmiştir.

Leap Motion sensörü ise bir bilgisayara bağlanarak el hareketlerini ve parmak pozisyonlarını algılayabilen iki kızılötesi kamera içeren bir 3B sensördür. Leap motion sensörünün hassas ölçümü ve firma tarafından ücretsiz verilen SDK sayesinde parmak konumlarının alınıp işlenebilmesi nedeniyle bu sensör tercih edilmiştir.

IRB120 robotu ABB firması tarafından üretilen 6 eksenli bir endüstriyel robottur. IRB120'nin kompakt boyutu ve hafifliği sayesinde hassas ve sınırlı çalışma alanlarında bile insanlarla etkin bir şekilde çalışabilmesini sağlamaktadır. IRB120 robotunun hassasiyeti, insanlarla olan etkileşiminde potansiyel tehlike oluşturma riskini büyük ölçüde azaltmaktadır.

IRB120 robotu ABB firmasının gelişmiş kontrol sistemleri, özellikle IRC5 kompakt kontrolör ile birlikte kullanıldığında, kullanıcıların gerçek zamanlı kontrol yapmasına olanak sağlamaktadır. Bu, robotun kullanıcılarla daha etkili ve doğal bir şekilde etkileşim kurmasına olanak vermektedir. Ayrıca IRB120 robotunun python, C, java gibi yazılım programlarıyla haberleşebilmesi nedeniyle çalışma kapsamında tercih edilmiştir.

Myo Armband, Leap motion sensörlerinin ve ABB IRB120 endüstriyel robotunun teknik özellikleri Tablo 2.1, Tablo 2.2 ve Tablo 2.3'te gösterilmiştir.

Tablo 2.1 : Myo Armband teknik özellikleri

Özellikler	Parametreler
EMG Elektrodu	8 adet, kas hareketlerini ölçmek için
IMU (Inertial Measurement Unit) Sensörü	9 eksenli, elin hareketini ölçmek için
Bağlantı	Bluetooth 4.0
Pil Ömrü	Yaklaşık 1 saatte sarj edilebilir, 1 gün kullanım süresi
Uyumlu Platformlar	Windows, Mac OS X, IOS, Android
Yazılım Geliştirme Kiti	Myo Armband SDK, veri toplamak için
Boyut	114.3 x 91.44 x 48.26 mm
Ağırlık	72 gram
Frekans	200 Hz

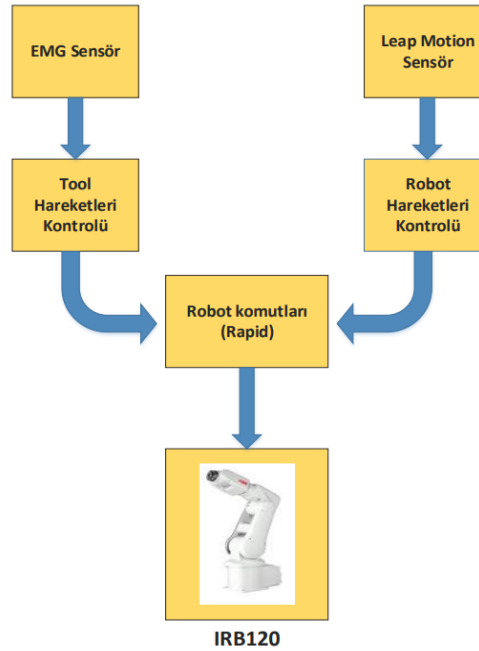
Tablo 2.2 : Leap Motion teknik özellikleri

Özellikler	Parametreler
Sensörler	IMU Sensörü , 2 adet infrared kamera
Sensör Çözünürlüğü	0.01 mm
Algılama Alanı	225x150 mm
Algılama Mesafesi	25-600 mm
Veri Aktarımı	USB 3.0
Uyumlu Platformlar	Windows, Max OS X
Boyut	80x30x12 mm
Ağırlık	45 gram

Tablo 2.3 : ABB IRB20 robotunun teknik özellikleri

Özellikler	Parametreler
Yük kapasitesi	3 kg
Çalışma yarıçapı	580 mm
Eksen sayısı	6
Hız	180°/s
Hassasiyet	±0.01 mm
Tekrarlanabilirlik	±0.03 mm
Kontrol Ünitesi	IRC5
Programlama Dili	RAPID
Bağlantı Protokolleri	Ethernet, DeviceNet, Profibus
Güç Tüketimi	0.5 Kw

IRB120 robotunu programlamak için flex pendant kontrol cihazı veya RobotStudio programı kullanılmaktadır. Bu çalışma kapsamında geliştirilen HRI, robotun kontrolünü tümüyle ele almaktadır. Yeni uygulamayla flex pendant veya robotstudio programları yerine python ve rapid programlama dilleriyle geliştirilen yazılım ile robot kontrol edilmiştir. Bu sayede Myo Armband ve Leap Motion controller sensörlerinden alınan verilerle oluşturulan komutlar kullanılarak, IRB120 robotu ve robota bağlı gripper TCP/IP iletişimi aracılığıyla gerçek zamanlı olarak kontrol edilmiştir. Geliştirilen uygulamanın akış diyagramı Şekil 2.2 'de gösterilmiştir.



Şekil 2.2 : İnsan robot etkileşiminin akış diyagramı

Bu kısımda EMG veri toplama, makine öğrenimi, el pozisyon ölçümü ve robot yörünge oluşturma aşamalarına değinilecektir. Ayrıca HRI için robot komutlarının nasıl oluşturulacağı ve endüstriyel bir robotla nasıl iletişim kurulacağı açıklanacaktır.

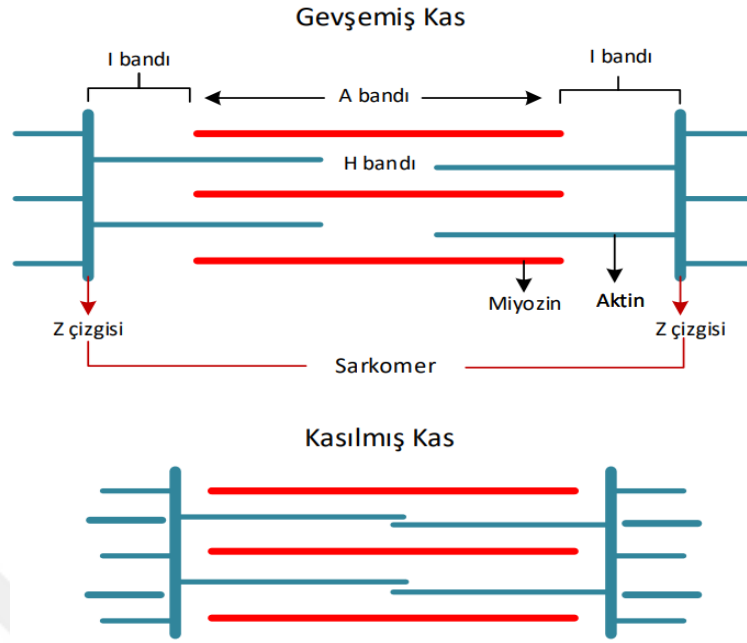
2.2. EMG Sinyallerinin Temel Kavramları

EMG, kas aktivitesinin ölçülmesinde kullanılan bir yöntemdir. Kaslardaki elektriksel aktiviteler, kasların hareketleri sırasında veya dinlenme durumunda üretilir. Kasların hareketleri sırasında, motor sinirlerinden gelen elektriksel sinyaller kas liflerine ulaşır ve kas liflerinin kasılması sonucu elektriksel aktiviteler meydana gelir (Wu ve diğ., 2013). Dinlenme durumunda ise, kaslar çok az elektriksel aktivite gösterir.

2.2.1. Kas hücre yapısı ve kas aktivasyonu

İnsan vücudunda hareketi sağlayan kas dokusunun temel yapı taşı olan kas hücreleri, aynı zamanda kas lifi olarak da bilinmektedir. Bu hücreler, kontraktıl yapıları ve proteinlerle (aktin ve miyozin) kasılma ve gevşeme yeteneğine sahiptir. Ayrıca, kasılma süreçleri sırasında enerji üretmek için mitokondri gibi organeller bulunmaktadır.

Kas kasılmasını sağlayan iki önemli protein molekülü olan aktin ve miyozin, kas hücrelerinde bulunmaktadır. Aktin ince filamentlerle, miyozin ise kalın filamentlerle temsil edilirler (Squire, 2019). Kas kasılması sırasında miyozin başları aktin filamentlerine bağlanarak kasın kısılmasını sağlar. Bu süreç kas gevşemesine kadar devam eder ve kas hücresi eski haline döner. Kasın kasılma ve gevşeme sırasındaki yapısı Şekil 2.3'de gösterilmiştir. Kasın kasılması sırasında Z çizgileri birbirine yaklaşır, I bandının boyu kısalmır, A bandının boyu değişmez ve kasın boyu kısalmırken gevşeme sırasında tam tersi işlemler gerçekleşmektedir.



Şekil 2.3 : Kasılma ve gevşeme sırasında kas yapısı

2.2.2. Motor birim kavramı ve işleyişi

Motor birim, merkezi sinir sisteminden gelen sinyalleri kasılma hareketine dönüştüren fonksiyonel birimdir (Crone ve Krarup, 2014). Bir motor birim, bir motor nöron ve o motor nöronun uyardığı kas liflerinden oluşmaktadır. Motor nöronlar, omurilikten çıkan ve kas hücrelerine giden sinir hücreleridir. Bir motor nöron, birden fazla kas lifine bağlanabilir ve motor nöronun uyarılması, uyardığı tüm kas liflerinin kasılmasına neden olmaktadır.

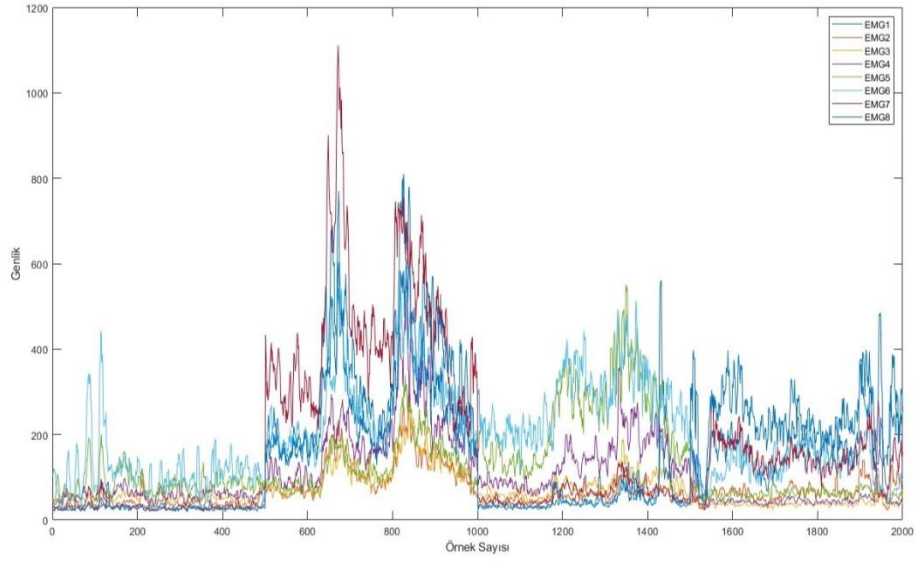
Motor nöronlar ve kas lifleri arasındaki ilişki, kas kasılmasının gücünü ve hassasiyetini etkilemektedir. Düşük motor nöron-kas lifi oranına sahip motor birimler, daha hassas hareketler ve ince motor kontrol için gereklidir. Yüksek motor nöron-kas lifi oranına sahip motor birimler ise, daha güçlü kas kasılmaları için kullanılmaktadır.

Motor birim potansiyeli (MUP), motor nöronun uyarılmasından sonra kas liflerinde oluşan elektriksel aktiviteyi temsil etmektedir. Motor nöronun uyarılması sonucu, uyardığı kas liflerinde aksiyon potansiyelleri oluşur ve bu potansiyeller EMG sinyalleri olarak kayıt edilir. MUP'ler, kas liflerinin sayısı, konumu ve kasılma özelliklerine bağlı olarak farklı şekil ve büyüklükte olabilmektedir (Yılmaz, 2019).

2.2.3. EMG sinyallerinin oluşumu ve ölçülmesi

EMG sinyalleri, elektrotlar vasıtasıyla kaslardaki elektriksel aktivitelerin kaydedilmesi ile elde edilir (Wang ve diğ., 2013). Sinyaller genlik, frekans ve süre olarak 3 bileşenden oluşmaktadır. EMG sinyallerinin genliği (voltaj değeri), kasın aktivasyon seviyesi ve kasılma gücüyle ilişkilidir. Kas aktivasyonu ve kasılma gücü arttıkça, EMG sinyalinin genliği de artmaktadır. EMG sinyallerinin frekansı genellikle 20 Hz ile 500 Hz arasında değişen değerlere sahiptir. Kas lifi tipi, aktivasyon seviyesi ve yorgunluk gibi faktörler, EMG sinyallerinin frekansını etkileyebilmektedir. EMG sinyallerinin süresi, kas aktivasyonunun ne kadar süreyle devam ettiğine işaret etmektedir. Kas aktivasyonu ve kasılma süresi uzadıkça, EMG sinyallerinin süresi de artmaktadır.

EMG sinyalleri, bir veya daha fazla elektrot kullanılarak ölçülmektedir. Elektrotlar, kaslardaki elektriksel aktiviteleri algılar ve bu aktiviteleri ölçer. Elektrotlar, kas liflerinin yüzeyine yerleştirilir ve kas lifleri kasıldığında veya gevşediğinde elektriksel aktiviteleri ölçerler (Jamal, 2012). EMG sinyallerinin toplanması 2 ana yöntemle gerçekleştirilir. İğne EMG; iğne elektrotlar kas dokusuna direkt olarak yerleştirilir. İğne EMG daha çok hassas ölçüm sağlayarak genellikle kas hastalıkları ve sinir hasarı gibi spesifik durumların teşhisinde kullanılırlar. Yüzey EMG; deri yüzeylerine yerleştirilen elektrotlar kullanarak kasların elektriksel aktivitesini ölçer. Bu elektrotlar derinin üzerinde kalır ve kas dokusuna nüfuz etmezler. Yüzey EMG, kas yorgunluğu, rehabilitasyon ve biyomekanik analiz gibi uygulamalar için uygundur ve iğne EMG'ye kıyasla daha az rahatsızlık ve risk taşımaktadır. 8 kanalla ölçülmüş EMG sinyali Şekil 2.4'te gösterilmiştir.



Şekil 2.4 : 8 kanallı EMG sinyali

EMG sinyalleri, iki tür elektriksel aktivite içerir: sinirsel aktivite ve kas aktivitesi. Sinirsel aktivite, motor sinirlerden gelen elektriksel sinyallerin kaslara ulaşmasıyla oluşur. Kas aktivitesi ise, kas liflerinin kasılması veya gevşemesi sonucu oluşmaktadır. Bu iki tür elektriksel aktivite, EMG sinyallerinin şeklini ve özelliklerini belirlemektedir (Rivera-Alvidrez ve diğ., 2010).

EMG sinyallerini ölçmek için kullanılan elektrotların kalitesi ve yerleşimi, sinyallerdeki gürültü oluşumu, kas yorgunluğu ve kastaki çeşitli varyasyonlar gibi faktörlere bağlı olarak sinyallerin değişkenliği EMG sinyallerinin yorumlanmasını etkileyecek çeşitli faktörler bulunmaktadır (Sae-lim ve diğ., 2018). EMG sinyallerini doğru yorumlamak için alınan sinyallerden özellik çıkarmak ve gürültüyü azaltmak için çeşitli sinyal işleme tekniklerini kullanmak gerekmektedir (Sharma ve diğ., 2012). Kaslardan elde edilen EMG sinyalleri, genellikle işlemek ve özellik çıkarmak için bilgisayarlı sistemlere aktarılır. Bu işlem, EMG sinyallerinin kaydedilmesi, ön işlem yapılması, analiz ve yorumlanması adımlarından oluşur.

2.2.4. EMG sinyallerinin işlenmesi ve analizi

EMG sinyalleri, öncelikle kaydedilir ve analiz için uygun bir formata dönüştürülür. Kaydedilen EMG sinyalleri daha sonra ön işlem yapılarak filtrelenir. Bu işlem, sinyaldeki istenmeyen gürültüleri gidermeye yardımcı olur. Filtreleme işlemi, EMG sinyallerinin spektral özelliklerine ve istenilen frekans bantlarına göre yapılabilir.

Ön işlem aşamasından sonra elde edilen sinyaller analiz edilir. Analiz işlemi, EMG sinyallerindeki özelliklerin belirlenmesini içerir. EMG sinyallerinin analizi için birçok parametre kullanılmaktadır. Bu parametreler sinyallerin frekansı, genliği, aktivasyon süresi gibi özellikleri olabilir. EMG sinyallerini analizinde sık kullanılan yöntemler Karelerin Ortalama Karekökü (RMS), Ortalama Mutlak Değer (MAV), Medyan Frekans (MDF) olarak gösterilebilir (Jain ve Garg, 2021; Rahim ve diğ., 2017).

EMG sinyallerinin yorumlanması aşamasında analiz sonuçlarına dikkat edilir. Analiz sonuçları, EMG sinyallerindeki özelliklerin hesaplanmasına dayanır ve kas fonksiyonlarının değerlendirilmesinde önemli bir yol oynamaktadır. EMG sinyallerinin yorumlanması, kas hastalıklarının teşhisinde (Khan ve diğ., 2019), kas yaralanmalarının tedavisinde (Vieira ve Botter, 2021) ve spor yaralanmalarının rehabilitasyonunda (Shenoy, 2010) yaygın olarak kullanılmaktadır.

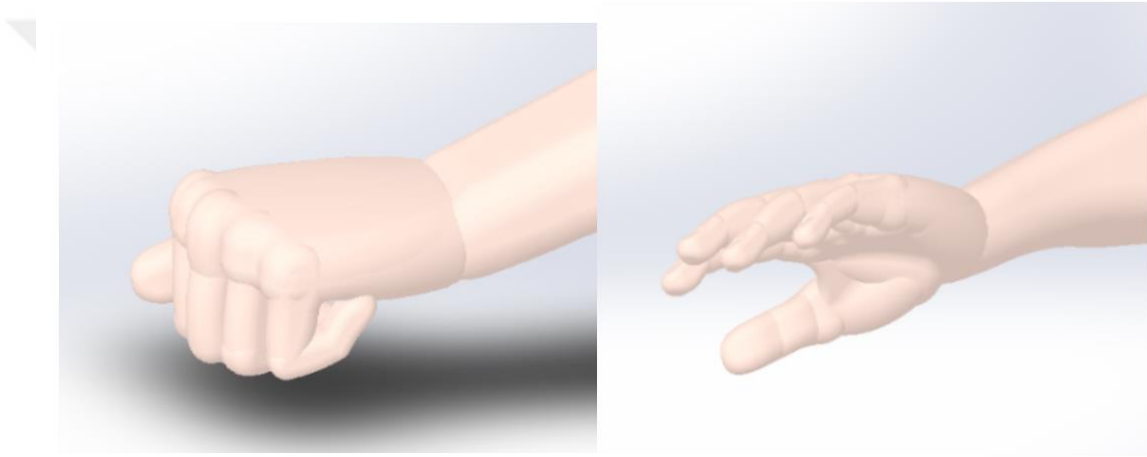
2.2.5. EMG verisi için makine öğrenmesi

Bu kısımda Myo Armband ile elde edilen EMG verilerinden özellik çıkarımı ve makine öğrenimi yöntemleri kullanılarak hareket sınıflandırılması açıklanmıştır. Çalışmada EMG verilerinin sınıflandırılmasında makine öğreniminin tercih etme sebepleri şu şekilde açıklanabilir.

İlk olarak makine öğrenimi algoritmaları daha az veri ile daha kolay eğitilebilir ve gömülü sistemlerde daha kolay uygulanabilir olması. İkinci neden ise eğitim çeşitli kişilerden alınan verilerle yapıldığı için Myo Armband tarafından sunulan ticari yazılım yerine farklı bir sensörden elde edilebilecek EMG verilerini kullanarak platformun esnek olarak geliştirilmesine izin vermesidir.

Çalışmanın ilk aşamasında metodun belirlenmesi sinyal işleme ve makine öğrenmesi için veri seti oluşturulmuştur. Bu amaçla veri setinin oluşturulmasını gerçekleştiren bir python uygulaması geliştirilmiştir. Bu uygulama sayesinde kullanıcılar istedikleri

hareket çeşidi için ham EMG verisi toplayabilmektedir. Şekil 2.5'te gösterilen elin tutma ve bırakma hareketleri için 5 farklı kişiden her hareketin 20 kez tekrar edilmesiyle 8 kanallı EMG verisi Myo Armband ile toplanmıştır. EMG verilerinin daha doğru ve hassas toplanması için kaslar stabilize olana kadar beklenmiştir. Kaslar stabil hale geldikten sonra her bir hareket için 6 örnek alınmıştır. Myo Armband'ın örnekleme frekansı ve kişilerin hareketi yapma hızına bağlı olarak 6 örnekleme alınmasının ideal olduğu belirlenmiştir. Kişiler her hareketi 20 kez tekrar etmesi ve her hareket için 6 örnekleme alınmasıyla tutma ve bırakma hareketleri için toplamda 120 EMG verisi alınmıştır.



Şekil 2.5 : Makine öğrenmesi ile sınıflandırılan el hareketleri

2.2.5.1. Sinyal filtreleme

EMG sinyallerinin işlemek için, sinyal işleme tekniklerinin kullanılması gerekmektedir. Bu sinyaller çeşitli dış etkenlerden, genellikle elektromanyetik gürültü ve biyolojik gürültü gibi istenmeyen sinyallerden etkilenebilmektedir. Bu tür gürültüler, yüksek veya düşük frekanslı parazitler olarak görülebilir ve sinyal kalitesini düşürerek sinyalin analiz edilmesini zorlaştırabilmektedir. Bu nedenle, EMG sinyallerini filtrelemek büyük önem taşımaktadır. EMG sinyallerinin filtrelenmesi için genellikle bant geçiren filtre kullanılmaktadır (Al-Mulla ve diğ., 2011). Böylelikle sinyallerin alınması ve işlenmesi sırasında oluşabilecek gürültüler azaltılmaktadır.

Gürültü azaltma tekniklerden biri de ortalama kayan filtreleme yöntemidir. Bu yöntem, EMG sinyallerinin gürültüsünü azaltmak ve daha düzgün bir sinyal elde etmek için

kullanılmaktadır. Ortalama kayan filtre basit hesaplama yapısı ve gerçek zamanlı uygulamalar için hızlı cevap vermesi nedeniyle çalışma kapsamında seçilmiştir.

Ortalama kayan filtreleme yöntemi, sinyallerin belirli bir zaman aralığındaki ortalamasının alınmasıyla gerçekleştirilir. Bu zaman aralığına "pencere boyutu" denir. Pencere boyutu genellikle birkaç milisaniye ile birkaç yüz milisaniye arasında değişir ve uygulanacak filtreleme düzeyine bağlıdır.

EMG sinyalleri, belirlenen pencere boyutu kadar bloklara ayrılır. Her blok için, blok içindeki sinyallerin ortalaması alınır ve bu ortalamaya göre blok içindeki tüm sinyaller filtrelendir. Böylece, sinyallerin belirli bir zaman aralığındaki ortalaması, sinyaldeki gürültünün azaltılmasına ve daha düzgün bir sinyal elde edilmesine yardımcı olur. Ortalama kayan filtresi denklemi denklem 2.1'de gösterilmiştir.

$$y(n) = \left(\frac{1}{N}\right) * \left(x(n) + x(n-1) + \dots + x(n-(N-1))\right) \quad (2.1)$$

Denklem 2.1'de $x(n)$ sinyalin n . örneği, N ise seçilen pencere boyutunu göstermektedir.

Denkleme göre son N örneği hesaplanarak belirli bir zaman dilimi boyunca sinyalin ortalaması alınır ve ortalamaya göre giriş sinyalinin yüksek frekanslı bileşenleri yumuşatılarak azaltılır.

2.2.5.2. Özellik çıkarımı ve boyut azaltımı

Özellik çıkarımı toplanan sinyallerden farklı özelliklere sahip veri kümeleri edinme işlemidir. Özellik çıkarımı sayesinde sinyalin farklı özellikleri sınıflandırma algoritmasına gönderilerek sınıflandırma başarısı artırılır (Phinyomark diğ., 2010; Ju ve diğ., 2013). Çalışmada Toplam EMG (IEMG) , RMS ve Dalga Formu Uzunluğu (WL) olmak üzere 3 farklı özellik çıkarımı yöntemi kullanılmıştır. Bu özellik çıkarma yöntemleri basit yapıları nedeniyle gerçek zamanlı uygulamalarda daha çok tercih edilmektedir. Kullanılan yöntemlerin denklemleri denklem 2.2 , denklem 2.3 ve denklem 2.4'de gösterilmiştir.

- IEMG: Bu yöntem elde edilen sinyalin genliğinin toplamından elde edilmektedir. IEMG hesaplama denklem 2.2'de gösterilmiştir.

$$IEMG = \sum_{m=1}^N |X_m| \quad (2.2)$$

- RMS : RMS değeri hesaplama literatürde en çok kullanılan özellik çıkarma yöntemlerinden birisidir. RMS hesaplama denklem 2.3’de gösterilmiştir.

$$\text{RMS} = \sqrt{\frac{1}{N} \sum_{m=1}^N X_m^2} \quad (2.3)$$

- WL : Ardışık iki örneğin genliğinin farkından oluşmaktadır. WL hesaplama denklem 2.4’de gösterilmiştir.

$$\text{WL} = \sum_{m=1}^N |\Delta x_m| \quad \Delta x_m = x_m - x_{m-1} \quad (2.4)$$

Yukarıda bahsi geçen 3 farklı özellik çıkarımı yöntemi ve alınan 8 kanallı EMG verisiyle beraber toplam 11 kanallı veri elde edilmiştir. Bu aşamadan sonra makine öğrenimini daha hızlı ve yüksek performanslı hale getirmek için boyut azaltma işlemi gerçekleştirilmiştir.

TBA çok değişkenli verilerde boyut azaltma işlemi için kullanılan bir veri analizi yöntemidir. Bu yöntem, değişkenleri birbirleriyle ilişkilerine göre birbirlerine bağımlı hale getiren temel bileşenleri (principal components) çıkararak, verinin boyutunu azaltır (Geethanjali, 2015).

TBA yönteminde ilk önce veri setindeki her bir özelliğin (veya değişkenin) ortalaması hesaplanır ve hesaplanan ortalamadan her bir özellik çıkarılır. Örneğin X bir veri matrisimiz olsun ve her bir sütunu bir özelliği temsil etsin, her bir özelliğin ortalaması denklem 2.5’e göre hesaplanır.

$$\mu = \frac{1}{N} \sum_{i=1}^N x_i \quad (2.5)$$

Denklem 2.5’de gösterilen N örnek sayısıdır ve x_i i’nci örnektir. Daha sonra her bir örnekten, ortalama (μ) denklem 2.6’da gösterildiği gibi çıkarılır.

$$x_i = x_i - \mu \quad (2.6)$$

Örneklerin yeni değerleri elde edildikten sonra kovaryans matrisi hesaplanır. Kovaryans matrisi, veri setindeki özellikler arasındaki korelasyonu ölçer. Kovaryans matrisi C

denklem 2.7'deki gibi hesaplanır. Denklem 2.7'deki X^T ifadesi X matrisinin transpozesidir.

$$C = \frac{1}{N-1} X^T X \quad (2.7)$$

Kovaryans matrisi hesaplandıktan sonra özdeğer ve özvektör hesaplanır. Kovaryans matrisinin denklem 2.8'de özdeğerleri ve özvektörleri hesaplanır. Burada u bir özvektör ve λ özdeğeri göstermektedir.

$$Cu = \lambda u \quad (2.8)$$

Özdeğerler ve özvektörler hesaplandıktan sonra özdeğerlerin sıralanması ve özvektörlerin seçilmesi gerekmektedir. Özdeğerler büyükten küçüğe sıralanır. En büyük özdeğerlere sahip özvektörler, veri setindeki en önemli özellikleri temsil etmektedir ve bu özvektörler ana bileşenler olarak seçilmektedir. Bu ana bileşenlerin oluşturduğu matris P matrisi olarak gösterilir.

Ana bileşenler matrisi bulunduğundan sonra yeni veri setinin oluşturulması gerekmektedir. Orijinal veri setinin ana bileşenler üzerinden projelendirilerek yeni bir veri seti oluşturulur. Her bir örneği x_i , denklem 2.9'da gösterildiği gibi ana bileşenler matrisi P ile çarpılır. Denklem 2.9'da gösterilen y_i yeni veri setinin her i 'nci örneğini göstermektedir.

$$y_i = P^T x_i \quad (2.9)$$

TBA sonrasında, yeni boyutlarda elde edilen veri, orijinal veri setindeki değişkenlerin özelliklerini korurken daha az boyutlu ve daha az gürültülü hale getirilmektedir. Bu nedenle, TBA genellikle özellik seçimi, veri görselleştirme, veri sıkıştırma, veri işleme ve veri analizi gibi birçok uygulama için kullanılır (Mishra ve diğ., 2017; Vaswani ve diğ., 2018).

2.2.5.3. EMG verisinin sınıflandırılması

Sınıflandırma yapmada amaç belirli bir probleme ait veri setinin belirli sayıda sınıfa bölünmesidir. Sınıflandırma algoritmaları verilen eğitim kümesiyle nasıl sınıflara ayrılacağını öğrenirler daha sonra sınıfı belirli olmayan veri geldiğinde hangi sınıfa ait

olduğu tahmin etmeye çalışırlar (Küçük ve diğ., 2013). Elde edilen verileri sınıflandırmak için birçok model geliştirilmiştir. Bu çalışmada 3 farklı sınıflandırma algoritması ile sınıflandırma yapılmıştır.

Destek Vektör Makinaları

DVM Cortes ve Vapnik (1995) tarafından geliştirilen makine öğrenmesi alanında sınıflandırma ve regresyon problemleri için kullanılan bir algoritmadır. DVM, doğrusal ve doğrusal olmayan sınıflandırma problemlerinde yüksek performans göstermektedir. DVM algoritması, öğrenme verileri üzerinde bir hiperdüzlem oluşturarak, verileri sınıflandırmaya çalışır. Hiperdüzlem, öğrenme verilerini sınıflandırmak için bir çizgi, düzlem veya düzlemsel olmayan bir yapı olabilir.

DVM algoritması, veri özniteliklerinin boyutuna bağlı olarak doğrusal ve doğrusal olmayan sınıflandırma problemleri için farklı yöntemler kullanır. Doğrusal DVM, verilerin doğrusal olarak ayrılabilir olduğu durumlarda kullanılır. Doğrusal olmayan DVM, verilerin doğrusal olarak ayrılamadığı durumlarda kullanılır ve özellikle çok boyutlu veriler için etkilidir.

DVM algoritması, özellikle büyük veri kümeleri için etkilidir ve genellikle yüksek boyutlu verilerde iyi sonuçlar verir (Prajapati ve Patle, 2010). DVM algoritması, sınıflandırma ve regresyon problemlerinde geniş bir uygulama yelpazesine sahiptir ve makine öğrenmesi alanında yapılan çalışmalarda sıklıkla kullanılmaktadır (Cao ve diğ., 2009).

DVM, sınıflandırma işlemi sırasında, iki farklı sınıf arasındaki boşluğu en büyük hale getirecek şekilde bir hiperdüzlem oluşturur. Bu boşluğa margin adı verilir ve DVM, bu margini maksimize etmeye çalışır. Bu, DVM algoritmasının, veriler arasındaki en iyi ayrımı bulmasını sağlar. Oluşturulan hiper düzlemler denklem 2.10'da sınıflandırma seviyesi de denklem 2.11'de gösterilmiştir.

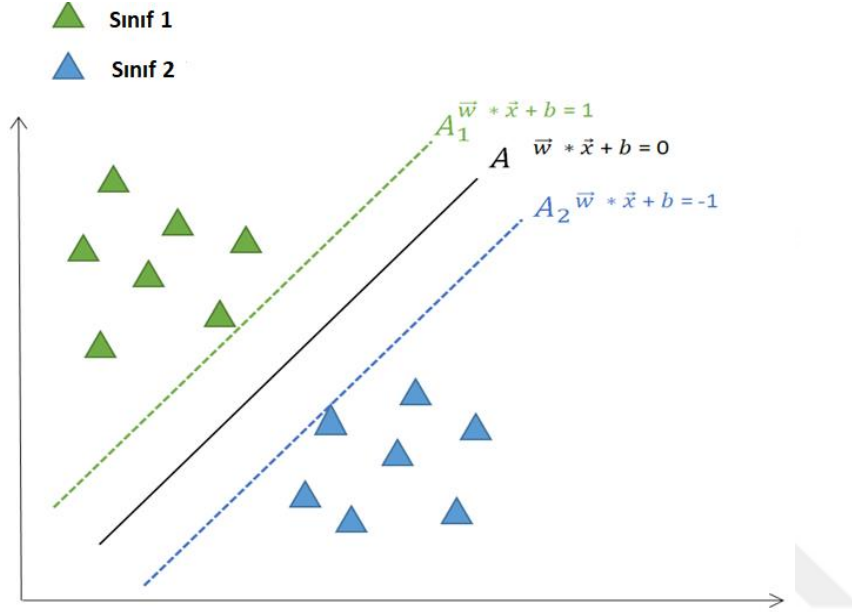
$$\vec{w} * \vec{x}_i + b = \mp 1 \quad (2.10)$$

$$f(x) = \text{sign}((w * x_i) + b) \quad (2.11)$$

En iyi düzlem için w ve b değerlerinin bulunması gerekmektedir. Şekil 2.6' da gösterilen düzlemler arasındaki mesafe denklem 2.10 kullanılarak $2 / ||w||$ olarak

bulunmaktadır. En iyi düzlem için mesafenin maksimum olması gerekmektedir. Eğer eğitilecek veriler tamamıyla lineer arıyıcı ile ayrılabilirse, denklem 2.12 en iyi düzlem olarak kullanılabilir. Denklem 2.12’de w, b ve x sırasıyla ağırlık vektörü, bias ve veriyi göstermektedir.

$$\min \frac{1}{2} \|w\|^2 \quad y_i(\bar{w} * \bar{x}_i + b \geq 1) \quad (2.12)$$



Şekil 2.6 : DVM lineer sınıflandırma

Rastgele Orman (RO) :

RO algoritması, birçok karar ağacını (decision tree) bir araya getirerek bir sınıflandırma veya regresyon problemini çözmeye çalışan bir makine öğrenmesi algoritmasıdır (Gokgoz ve Subasi, 2015). Bu ağaçlar, veri kümesindeki farklı özellikleri (features) kullanarak farklı kararlar verirler ve sonuç olarak sınıflandırma veya regresyon problemini çözmeye çalışırlar.

RO, rastgele örneklemeler ve rastgele özellik seçimleri yaparak her bir karar ağacını eğitir. Bu, her ağacın birbirinden farklı bir alt kümesindeki özelliklere odaklanarak eğitilmesini sağlar. Bu yöntem, aşırı benzeme problemini azaltmaya ve daha iyi genelleştirme yapabilmesine yardımcı olur.

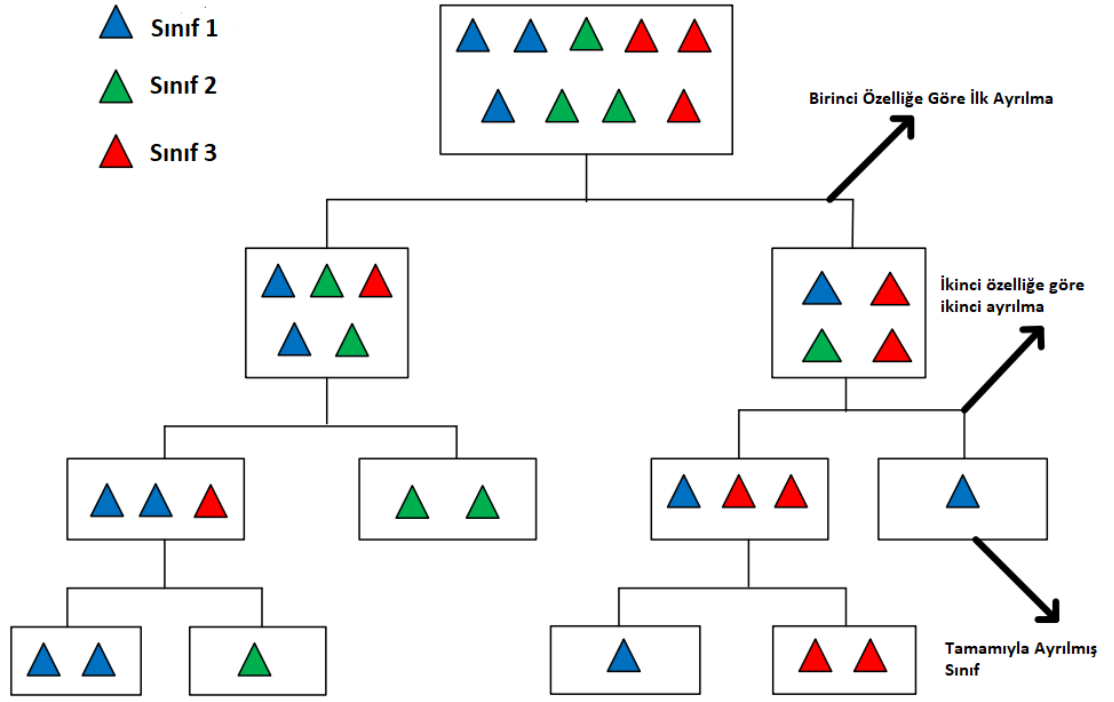
RO algoritması, her bir karar ağacının sonucuna dayalı olarak, her bir sınıf için olasılıkları hesaplar ve sonuçta, bir sınıflandırma probleminde en yüksek olasılığa sahip sınıfı, bir regresyon probleminde ise ortalama değeri tahmin eder.

RO algoritmasında veri kümesi tek bir veri sınıfı elde edene kadar düğümlere bölünür. Hangi verinin hangi dala gideceğini belirlemek için iki kriter bulunmaktadır. Bu kriterler denklem 2.13 ve 2.14’de verilen regresyon ve gini indexi olarak adlandırılır. Denklem 2.13 verilen regresyon formülü karar ağacının daha fazla bilgi sağlayacağını ve hangi özelliğin daha iyi ayırım sağlayacağını belirlenmesi için kullanılmaktadır. Denklem 2.14’te gösterilen Gini indeksi, karar ağacında her bir dalın saflığını (purity) ölçmek için kullanılan metriktir. Gini indeksi her bir dalın saflığını maksimize ederek karar ağacının doğruluğunu artırmayı sağlamaktadır.

$$Regresyon = \sum_{sol} (y_i - y_l)^2 + (y_i - y_r)^2 \quad (2.13)$$

$$Gini = N_l \sum_{k=1}^K P_{kl} (1 - P_{kl}) + N_r \sum_{k=1}^K P_{kr} (1 - P_{kr}) \quad (2.14)$$

Denklem 2.13’de verilen y_l ve y_r değerleri, sol ve sağ düğümdeki ortalama veriyi temsil etmektedir. Denklem 2.14’de verilen N_l ve N_r değerleri sırasıyla sol ve sağ düğümlerdeki veri sayısını göstermektedir. Her iki denklem de verilen P_{kl} ve P_{kr} değerleri sol ve sağ düğümlerdeki sınıfların oranını göstermektedir. RO sınıflandırmasının yapısı Şekil 2.7’de gösterilmiştir.



Şekil 2.7 : RO sınıflandırma yapısı

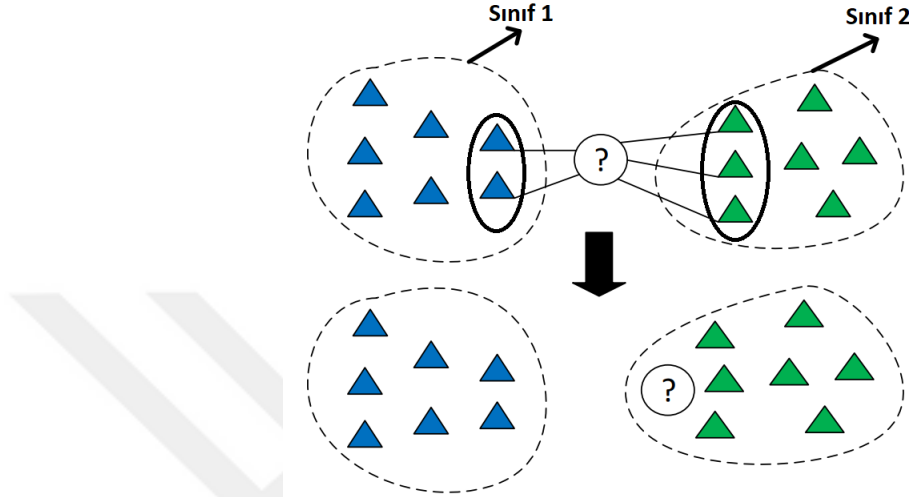
k-En Yakın Komşu

k-NN algoritması yaygın olarak kullanılan sınıflandırma algoritmalarından birisidir (Briouza ve diğ., 2022; Nia ve diğ., 2023). Basit yapısı nedeniyle birçok sınıflandırma problemi için başarılı bir şekilde kullanılmaktadır. Bu algortmada, veri kümesindeki her veri noktasını, o veri noktasına en yakın K veri noktasının sınıfına göre sınıflandırır.

k-NN algoritmasının uygulanması için ilk olarak veri seti hazırlanmalıdır. Veri seti etiketlenmiş verilerden oluşmaktadır. Bu verilerin her biri, bir dizi özellik vektörü ve bir sınıf etiketi içermektedir. Veri noktaları arasındaki uzaklık hesaplamalarında, özellik vektörleri normalleştirilir. Bu normalleştirme işlemi, özellik vektörlerinin 0 ile 1 arasında değerler almasını sağlar. Daha sonra bir veri noktasını sınıflandırmak için önce bu noktanın etrafındaki K veri noktası belirlenir. Seçilen K veri noktası, yeni veri noktasına olan uzaklığına göre sıralanır. Uzaklık hesaplama yöntemi, için genellikle öklid mesafe formülü kullanılmaktadır. Öklid mesafe formülü denklem 2.15'de gösterilmiştir. Verilen denklemde $d(x, y)$ iki örneğin (x ve y) arasındaki mesafeyi x_i ve y_i ise örneklerin i 'nci özelliklerini temsil etmektedir.

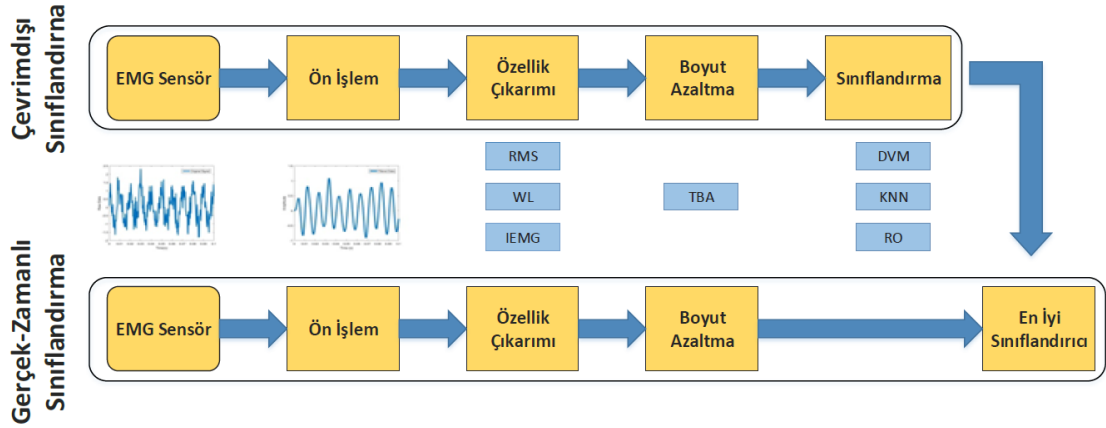
$$d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (2.15)$$

Seçilen K veri noktasının sınıf etiketleri sayılarak, en çok tekrar eden sınıf etiketi yeni veri noktasının sınıfı olarak tahmin edilir. K sayısının 5 olarak seçilerek örnek k-NN sınıflandırma algoritmasının yapısı Şekil 2.8’de gösterilmiştir.



Şekil 2.8 : k-NN sınıflandırma yapısı

EMG verileri toplanması, filtrelenmesi, özellik çıkarımı, boyut azaltılması ve en sonunda sınıflandırma işlemi gerçekleştirildikten sonra hareketler tespit edilerek HRI için hazır hale getirilmiştir. EMG verilerinin işlenmesi açıklayan akış diyagramı Şekil 2.9’da gösterilmiştir. Çalışmada toplanan veriler işlendikten sonra 3 farklı sınıflandırma algoritması ile sınıflandırılmıştır. Sınıflandırmada veri setinin %75’i eğitim %25’i ise test verisi olarak kullanılmıştır. 3 farklı sınıflandırma algoritmasıyla sınıflandırılan EMG verisinin karışıklık matrisleri ve sınıflandırma başarısı Bölüm 5’de ayrıntılı olarak verilmiştir.




Şekil 2.9 : EMG verisinin işlenmesinin adımları

2.3. Parmak Pozisyon Ölçümü

İnsan eli ve parmakları, oldukça karmaşık ve hassas yapıya sahip olan organlardır. Ellerimiz sayesinde, düşüncelerimizi ve isteklerimizi fiziksel dünyada somutlaştırabilir ve nesnelere etkileşime geçebiliriz. Bu nedenle, parmak pozisyonlarını ve hareketlerini ölçmek ve analiz etmek, insan-makine etkileşimi ve diğer alanlarda önemli bir rol oynamaktadır.

İnsan eli ve parmakları, eklemler, kaslar ve sinirler gibi birçok anatomik yapıyı içermektedir. Bu yapılar sayesinde, el ve parmaklar ince motor becerilere ve hassas hareketlere olanak tanımaktadırlar. Parmak pozisyon ölçümü, bu hareketlerin anlaşılması ve analiz edilmesi için bir yöntemdir (Sasaki ve diğ., 2009).

Parmak pozisyon ölçümünün uygulama alanları oldukça geniştir. İnsan makine etkileşimi bu ölçümlerin kullanıldığı en önemli alanlardan birisidir. Parmak pozisyonları ve hareketlerini takip ederek, kullanıcılar makinelere ve diğer teknolojilere daha doğal ve sezgisel bir şekilde etkileşim sağlayabilirler. Bu tür etkileşimler sanal gerçeklik, artırılmış gerçeklik ve oyunlar gibi alanlarda önem kazanmaktadır (Cong ve diğ., 2022). Parmak pozisyon ölçümü kişiye özel uygulamalar içinde önemli hale gelmektedir. Özellikle biyometrik kimlik doğrulama (Nishiuchi ve diğ., 2010) ve kişisel sağlık izleme uygulamalarında (Simone ve Kamper, 2005) parmak pozisyon ölçümü kullanılmaktadır. Parmak pozisyon ölçümü için kullanılan örnek uygulama Şekil 2.10'da gösterilmiştir.



Şekil 2.10 : Parmak pozisyon ölçümü (Yu ve diğ., 2015)

Parmak pozisyonu ölçümü kullanıcı deneyimini iyileştirmek ve kişiselleştirilmiş hizmetleri sunmak için önemli hale gelmektedir. Teknolojinin gelişmesiyle parmak pozisyon ölçümü önemi pek çok alanda artmaya devam edecektir.

2.3.1. Parmak pozisyon ölçüm sensörlerinin temel bileşenleri ve işleyişi

Parmak pozisyon ölçüm sensörleri, insan parmaklarının konumlarını ve hareketlerini hassas bir şekilde algılamak ve analiz etmek için tasarlanmış cihazlardır. Özellikle Leap motion gibi ticari sensörler, insan makine etkileşiminde ve diğer alanlarda kullanılmaktadırlar. Bu tür sensörlerin temel bileşenleri şunlardır:

- Kızılötesi kameralar: Kızılötesi kameralar, parmak pozisyonlarını ve hareketlerini izlemek için sensörün en önemli bileşenleridir. Bu kameralar, kızılötesi spektrumda çalışarak, insan gözüyle görülemeyen ışık dalga boylarında görüntü elde etmektedirler. Kızılötesi kameralar, genellikle birden fazla sayıda kullanılarak, el ve parmakların üç boyutlu konum bilgisini sağlamak için birlikte çalıştırılmaktadırlar (Saleh ve diğ., 2010).
- Kızılötesi LED'ler: Kızılötesi LED'ler, el ve parmakların yüzeylerini aydınlatarak, kameranın parmak pozisyonlarını ve hareketlerini daha net görmesine yardımcı olur. Kızılötesi LED'ler, insan gözü için görünmez bir ışık kaynağı sağlar ve bu sayede, parmakların ve elin yüzeyindeki yansımaları ve

gölgeleri kullanarak konum ve hareket bilgilerini elde etmeye olanak tanirlar (Zhang ve diğ., 2015).

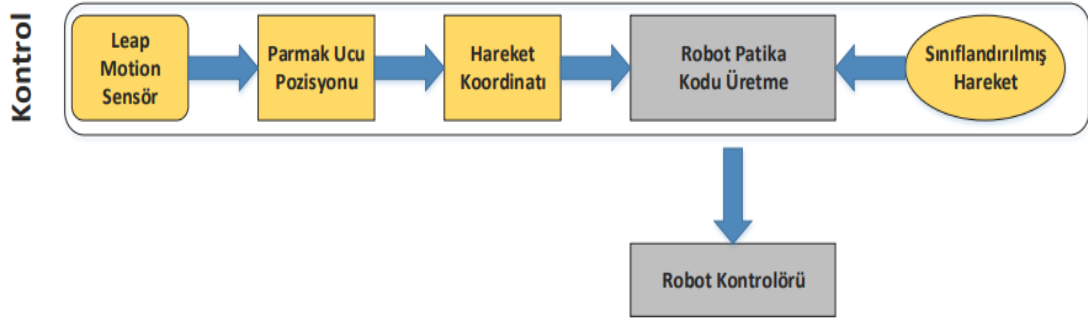
- Yazılım ve SDK: Parmak pozisyon ölçüm sensörleri, genellikle yazılım ve SDK ile birlikte kullanılmaktadır. Bu yazılım ve SDK, sensörün parmak pozisyon ölçüm verilerini işlemek, analiz etmek ve uygulamalarla entegre etmek için kullanılmaktadır. SDK, genellikle farklı programlama dilleri ve platformlar için uyumlu kütüphaneler ve araçlar içermektedir. Bu sayede, geliştiriciler, parmak pozisyon ölçüm sensörlerini kendi projelerine ve uygulamalarına kolayca entegre edebilmektedirler.

Parmak pozisyon ölçüm sensörü, kızılötesi kameralar ve LED'ler sayesinde el ve parmakların hareketleri izlemektedir. Kameradan alınan kızılötesi görüntüler, üç boyutlu koordinat sistemine dönüştürülerek el ve parmakların konum ve hareket bilgisi elde edilmektedir. Bu dönüşüm işlemi, sensörün yazılım ve algoritmaları tarafından gerçekleştirilir. Elde edilen 3 boyutlu koordinatlar, kullanıcının ellerinin ve parmaklarının gerçek zamanlı olarak takip edilmesini sağlamaktadır.

2.3.2 Parmak pozisyon ölçümü ile robot yörünge belirleme

Endüstriyel uygulamalarda robotu 3 boyutlu hareket ettirebilmek için robotun gideceği patikanın koordinatlarının belirlenmesi gerekmektedir. Bu kısımda HRI ile el konumun ölçülmesi ve robotu gideceği patikanın belirlenmesi aşamalarına yer verilmiştir.

El konumunun ölçülmesi için yapılan uygulamalarda genellikle kullanılan cihazlarda jiroskop, ivmeölçer gibi sensörler bulunmaktadır. Ancak bu sensörlerin kullanılmasında başlangıç pozisyonunun net bir şekilde ayırt edilememesi ve konumun sapması sorunları nedeniyle sistem performansı olumsuz etkilenmektedir. Geliştirilen uygulamada temassız ölçüm yapabilen çift InfraRed kameraya sahip olan Leap Motion sensörü kullanılmıştır. Geliştirilen patika belirleme ve robot sistemine uygulanması aşamalarının blok diyagramı Şekil 2.11'de gösterilmiştir.




Şekil 2.11 : Leap Motion verisinin robota uygulanması

Şekil 2.11’de görüldüğü üzere, Leap motion sensöründen alınan parmak ucu pozisyonu robot koordinat sistemine uygun hale getirilmiştir. Leap motion sensöründen parmak ucu konum değişikliği sürekli olarak izlenerek robot için hareket komutları üretilip robotun hareketi sağlanmıştır.


EMG verilerinin sınıflandırılması ile elde edilen hareketler ve Leap motion sensöründen elde edilen hareket komutları birleştirilip TCP/IP haberleşme protokolü aracılığıyla robot kontrolcüsüne gönderilmektedir. Uygulamada kolay kullanım için kullanıcının işaret parmağı kontrol noktası olarak tanımlanmıştır.

Parmak ucu pozisyonunun belirlenmesi ve ölçüm performansının ortaya çıkarılması için milimetrik yüzeylere sahip 3 boyutlu bir küp tasarlanmıştır. Oluşturulan küp Şekil 2.12 ‘de gösterilmiştir.



Şekil 2.12 : Oluşturulan ölçekli küp

Şekil 2.12’de gösterilen küp üzerinde patikayı takip etme hassasiyetinin Leap Motion ile ölçülmesi için Şekil 2.13’te gösterilen 2 farklı patika belirlenmiştir. Bu patikalar robotun doğrusal ve dairesel hareketleri yapabilmesi için doğrusal ve kavisli yollar olarak verilmiştir.

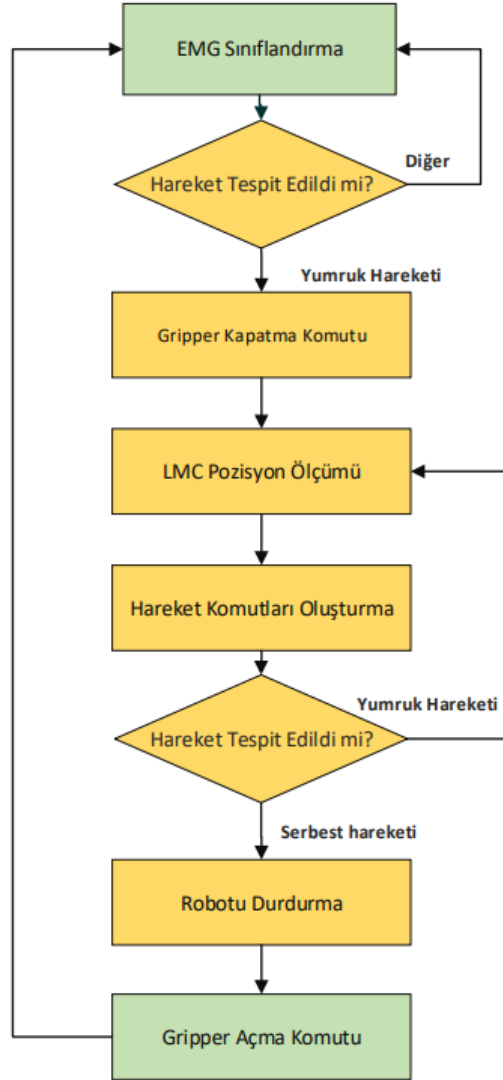


Şekil 2.13 : Parmak ucu takibi için oluşturulan patikalar

Belirlenen patikalarda 5 farklı kullanıcıdan patikaları çizmesi istenip ölçümler alınmıştır. Kullanıcıların patika takip başarı sonuçları Bölüm 5’de ayrıntılı olarak gösterilmiştir.

2.4. Robot Kod Üretimi ve Haberleşme

Bu kısımda Myo Armband ve Leap Motion sensörlerinden alınan veriler ile robotun kontrol edilmesi için gerçekleştirilen çalışmalara yer verilmiştir. Robotun hareketini sağlamak için kullanıcı tarafından gerçekleştirilen hareketler ve parmak ucu pozisyonu robot programlama diline göre hareket komutlarına dönüştürülmesi gerekmektedir. Akış diyagramı Şekil 2.14’te gösterilmektedir.



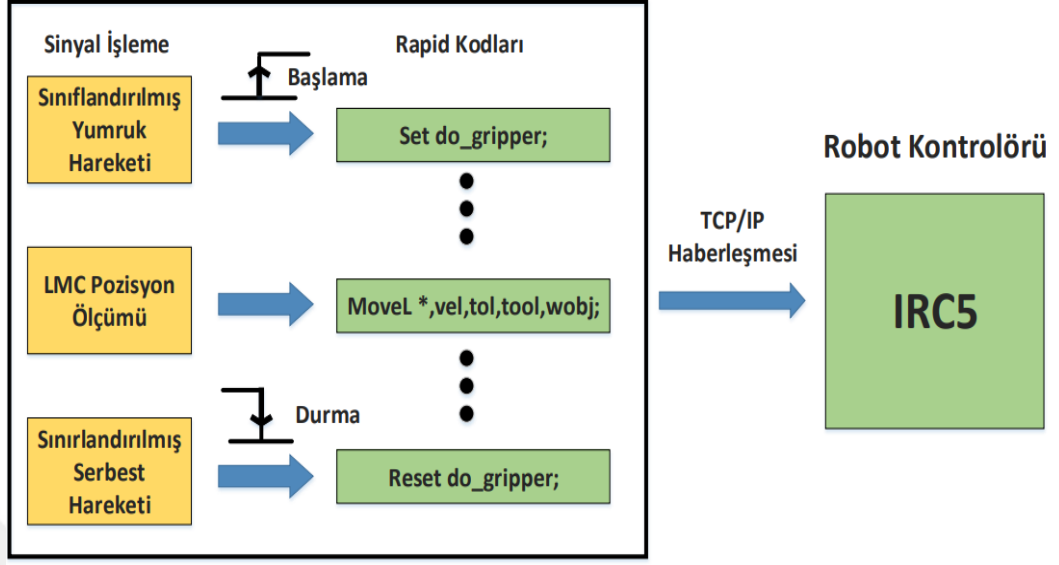
Şekil 2.14 : Robot kontrol akış diyagramı

Şekil 2.14'te görülüşü gibi, oluşturulan kontrol senaryosu geređi, robot kontrol komutları oluşturulurken ilk önce EMG sınıflandırmasında yumruk hareketini tespit edilmesi gerekmektedir. Yumruk hareketi tespit edildiğinde, parçayı tutma komutu robota gönderilmektedir ve parça tutma işlemi gerçekleştirilmektedir. El serbest hareketi tespit edilene kadar yani el tutma hareketi olduđu süre boyunca Leap Motion sensöründen alınan parmak ucu pozisyon bilgileri robota hareket komutları olarak gönderilmektedir ve böylece robot parmak hareketlerini takip etmektedir. El serbest hareketi tespit edildiđi anda robotun hareketi durdurulur ve robota parçayı bırak komutu gönderilerek robotun taşıdığı parça belirlenen noktaya bırakılmaktadır.

Geliştirilen uygulamanın gerçekleştirilmesi için ABB firmasının IRB120 endüstriyel robotu kullanılmıştır. IRB120 robotu kontrolcü olarak IRC5 robot bilgisayarını kullanmaktadır. Bu kontrolcü RAPID programlama diliyle yazılan komutları içermektedir. Uygulamada robotun parçayı tutma işlemi pnömatik olarak kontrol edilen manyetik bir gripper vasıtasıyla gerçekleştirilmiştir. Gripper'ın tutma ve bırakma işlemleri EMG sinyallerinin sınıflandırılmasıyla oluşan hareketleri sonucunda gripper'ı kontrol eden selenoid valfin "24V" ve "0V" olmasıyla gerçekleştirilmiştir. Bu amaçla Şekil 2.15'te gösterilen ilgili robot çıkışına bağlanan selenoid valfin kontrolü için "set" ve "reset" komutları robota gönderilmektedir. Robotun patika takibi için Leap motion ile tespit edilen parmak pozisyonu Şekil 2.15'te gösterilen "move..." komutu içerisinde noktalar olarak robota aktarılmaktadır. Tüm bu işlemler için TCP/IP haberleşme protokolü kullanılmaktadır.

Şekil 2.15'te gösterilen "*" hedef nokta koordinatı, Leap motion sensörünün orijin noktasına göre ölçülen işaret parmak ucu pozisyonudur. Tüm endüstriyel robotlar işlenen parça ve çalışma ortamına bağlı olarak hareket komutlarının daha kolay programlanmasını sağlayan workobject sanal koordinat sistemine sahiptir. Kullanıcının kullanım kolaylığı ve robot tarafından tutulması, bırakılması gereken noktalar ile kullanıcı önünde bunlar için oluşturulan sanal noktaların uyarlanması için Leap motion koordinat sistemiyle ve workobject koordinat sistemlerinin orijin noktaları ve yönelimleri örtüşecek şekilde konumlandırılmıştır. Bu şekilde Leap Motion tarafından tespit edilen pozisyonlar herhangi bir dönüşüme veya rotasyona gerekmeden robota gönderilerek robot hareket ettirilmektedir.


Robot Patika Kod Oluşturma




Şekil 2.15 : IRB120 robotunun hareket kodu üretimi

2.5. Gerçek Zamanlı Uygulama

Bu kısımda HRI için çalışmanın ilerleyen bölümlerinde ihtiyaç duyulan tutma ve bırakma hareketlerini içeren bir endüstriyel senaryo geliştirilmiştir. Senaryoda kullanıcının, IRB120 robotu çalışma alanındaki belirlenmiş bir başlangıç noktasından metal nesneyi alarak konveyörün başlangıcına bırakılması planlanmıştır. Kullanıcı bu çalışmayı yaparken geliştirilen HRI sistemi devreye alınmış ve kullanıcıdan sadece Myo Armband'ı takarak parmak ve yumruk hareketleriyle robotu uzaktan kontrol etmesi istenmiştir. Pnömatik olarak kontrol edilen manyetik gripper robot kontrolüne gelen dijital giriş çıkış ile kontrol edilmektedir. Bu şekilde insan robot etkileşiminde kullanıcı tarafından gerçekleştirilen sanal tut-bırakma işlemi robot kolunda gerçek olarak gerçekleştirilmektedir. Tüm ekipmanlarla gerçekleştirilen deneysel düzenek Şekil 2.16'da gösterilmiştir. Yapılan senaryoda gerçek ve sanal tut-bırak noktaları, koordinat düzlemleri Şekil 2.17'de gösterilmiştir.




Şekil 2.16 : Robot patikasının belirlenmesi için kurulan deneysel düzenek




Şekil 2.17 : Senaryoda uygulanan sanal ve gerçek noktalar

Şekil 2.18, Şekil 2.19 ve Şekil 2.20’de sırasıyla kullanıcı tarafından gerçekleştirilen gerçek zamanlı parçayı alma, patikayı izleme, parçayı bırakma işlemleri ve bunların robot tarafından takip edilmesi gösterilmektedir. Bu işlemler bilgisayar ekranındaki grafik arayüzünden anlık olarak takip edilmektedir. Şekil 2.18’de kullanıcı elini sanal tutma noktasına getirir ve yumruğunu sıkarak tutma hareketi yapar, bu sırada insan robot etkileşim sistemi robota tut komutu gönderir. Aynı zamanda gerçek tutma noktasında robotun parçayı aldığı görülmektedir.


Şekil 2.19’da kullanıcının işaret parmağını hareketiyle robota hareket komutları gönderildiği ve aynı zamanda robotun kullanıcı tarafından gösterilen konumu takip ettiği görülmektedir. Şekil 2.20’de kullanıcının sanal bırakma noktası gittiğinde elini açarak bırakma komutunu robota gönderdiği ve aynı zamanda robotun gerçek bırakma noktasına gittiği ve parçayı bıraktığı görülmektedir. Robotun tutma ve bırakma işlemleri sadece sınıflandırılan 2 hareket ile gerçekleştirilmektedir. Yanlış hareket algılandığında veya hareket algılanmadığında robota komut gönderilmediği için robot çalışmayı durdurmaktadır. Ayrıca ABB robotta SafeMove özelliği etkinleştirilmiş, çalışma alanı yazılımsal olarak sınırlandırılmış ve diğer güvenlik önlemleri alınmıştır.



Şekil 2.18 : Parçayı tutma işlemi



Şekil 2.19 : Patikayı izleme işlemi



Şekil 2.20 : Parçayı bırakma işlemi

BÖLÜM 3. YOLO TABANLI ATIK TESPİTİ

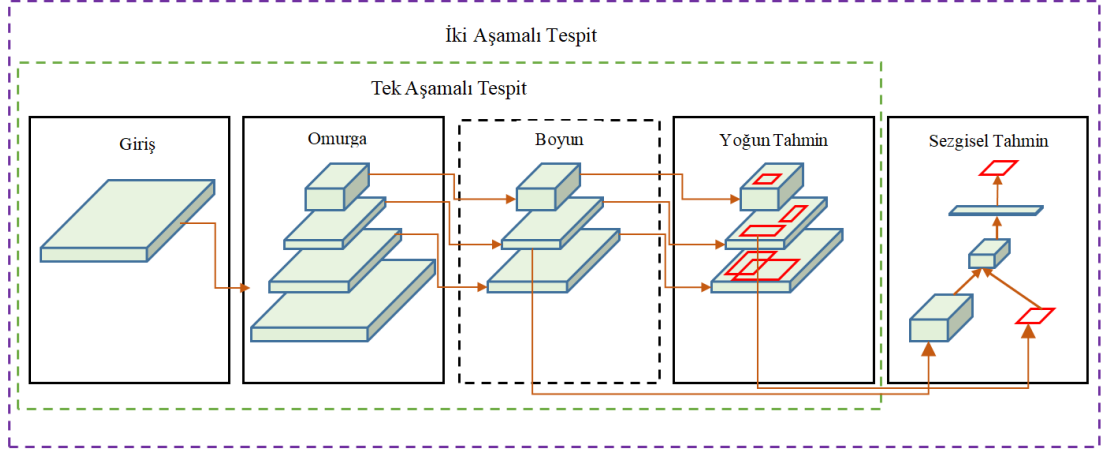
Bu bölümde tez kapsamında yapılan bilgisayar görüşü tabanlı atık tespiti detaylı olarak anlatılacaktır. Atık tespiti için derin öğrenme algoritmalarından olan YOLO algoritması kullanılmıştır. Bu algoritmanın kullanılma nedeni çalışma performansının oldukça yüksek olmasıdır. YOLO algoritması ile tespit edilen atığın daha sonra bir manipülatör ile ayrıştırılması için atığın konumun 3 boyutlu olarak bilinmesi gerekmektedir. Bu problemin çözümünde derinlik kamerası olan Intel RealSense kamerasıyla alınan derinlik görüntüsünden atığın konumu tespit edilmiştir. Atığın tespiti ve konumunun bilinmesinden sonra HRI sistemi ile robotik manipülatör vasıtasıyla ayrıştırılması Bölüm 4 'te anlatılacaktır.

3.1. YOLO Mimarisi

Günümüzde derin öğrenme ve bilgisayarlı görü alanında büyük ilerlemeler kaydedilmiştir. Bu teknolojiler özellikle video analitik (Lu ve Yuan, 2020), güvenlik kameraları, otonom araçlar (Fanthony ve diğ., 2011) ve akıllı şehirler (Zhi-Xian ve Zhang, 2022) gibi uygulamalarda, gerçek zamanlı nesne algılama ve sınıflandırma sistemleri büyük önem taşımaktadır. YOLO algoritması, bu ihtiyaca yönelik olarak geliştirilmiş gerçek zamanlı nesne algılama sistemlerinin en popüler ve başarılı örneklerindedir.

Bu kısımda, YOLO' nun sürümlerinden olan YOLO-V4 ve YOLO-V4 tiny ağlarının temel özellikleri incelenecektir. Gerçek zamanlı nesne tespit algoritmalarından biri olan YOLO-V4 modeli YOLO-V1 (Redmon ve diğ., 2016), YOLO-V2 (Redmon ve Farhadi, 2017) ve YOLO-V3'ün (Redmon ve Farhadi, 2018) daha gelişmiş bir versiyonudur. YOLO serisi algoritmalar sürekli iyileştirilerek başarımları artırılmaya

çalışılsa da algılama prensipleri aynıdır (Hu ve diğ., 2021). YOLO-V4'ün temel mimarisi Şekil 3.1'de gösterilmiştir.



Şekil 3.1 : YOLO - V4 mimarisi

Şekil 3.1'de gösterilen YOLO-V4 mimari yapısı incelendiğinde giriş (input), omurga, (backbone), boyun (neck) , yoğun tahmin (dense prediction), sezgisel tahmin (sparse prediction) olmak üzere beş ana bölüme ayrılmaktadır.

- Giriş: Bu kısımda YOLO-V4, bir görüntüyü alarak bu görüntüyü modelin geri kalanına iletmek için ön işleme yapar. İlk olarak, görüntü boyutunu sabit bir boyuta yeniden ölçeklendirir (genellikle 416x416 veya 608x608 piksel). Ardından, görüntüyü normalize eder ve bazı veri artırma teknikleri uygular. Bu işlemler, modelin daha iyi sonuçlar üretmesine yardımcı olur.
- Omurga: Bu kısım görüntünün özelliklerini öğrenmek ve modelin başarısını artırmak için kullanılır. Omurga genellikle CSPDarknet53 olarak adlandırılan ve görüntünün semantik ve düşük seviyeli özelliklerini öğrenen bir yapıdır. CSPDarknet53 görüntülerin hem düşük hem de yüksek seviyeli özelliklerini öğrenir. Darknet53, 53 katmanlı bir yapıdır ve daha önceki YOLO-V3 modelinde de kullanılmaktadır. Darknet53 hafif ve hızlı olmasıyla bilinir ve ResNet gibi diğer popüler mimarilere kıyasla daha az karmaşıktır. CSPNet, Cross Stage Hierarchy Network teknolojisini ifade etmektedir. CSPNet, özellik haritalarını iki gruba ayıran, daha sonra bu grupları birleştiren ve öğrenme sürecini iyileştiren bir yapıdır. CSPDarknet53, YOLO-V4 modelinin omurga ağı

olarak kullanıldığında, modelin daha hızlı ve doğru nesne algılama performansı sağlamasına yardımcı olmaktadır.

- Boyun: Bu kısım omurga kısmında öğrenilen özelliklerin daha iyi kullanılmasına yardımcı olur ve farklı ölçeklerde özellikleri birleştirir. YOLO-V4'te kullanılan boyun, PAnet (Path Aggregation Network) ve BiFPN (Bidirectional Feature Pyramid Network) gibi yapıları içerir. Bu yapılar farklı ölçeklerdeki özellik haritalarını birleştirerek ve yoğunlaştırarak modelin daha doğru ve hızlı tahminler yapmasını sağlar.
- Yoğun Tahmin: Bu kısımda nesne sınıfı, koordinatlar ve sınırlayıcı kutu boyutları için tahmin yapılmaktadır. YOLO-V4'te özellik haritaları ve boyun çıktıları, yoğun tahmin katmanına iletilir, burada modelin son çıktısı oluşturulur. Bu katmanlar, nesnelerin sınıflandırılması ve sınırlayıcı kutular tahmin edilmesi için kullanılır.
- Sezgisel Tahmin: Bu kısım modelin öğrenme sürecini hızlandırmak ve doğruluğunu artırmak için kullanılır. Bu yöntem, modelin sadece nesnelerin bulunduğu yerlerde yoğun tahminlere odaklanmasını sağlar. Bu, modelin yalnızca belirli alanlarda çalışarak hesaplama gücünden tasarruf etmesini ve böylece daha hızlı ve doğru tahminler yapmasını sağlar. Sezgisel tahmin, yoğun tahmin katmanlarını daha verimli hale getiren ve modelin dikkatini önemli alanlara yönlendiren yöntemdir.

YOLO-V4 tiny YOLO-V3'ün basitleştirilmiş bir versiyonudur. Bu model gerçek zamanlı nesne tanıma süreçleri için hızlı eğitim, tanıma ve tespit işlemleri sunmak üzere tasarlanmıştır (Dewi ve diğ., 2022; Wang ve diğ., 2022).

YOLO-V4 tiny modeli nesne tanıma alanında son derece etkili ve verimli bir çözüm sunmaktadır. YOLO prensibi, bir görüntüyü tek bir aşamada tüm nesneleri tanıyacak şekilde analiz etmeyi amaçlamaktadır. YOLO-V4 tiny, bu prensibi kullanarak gerçek zamanlı uygulamalar için hızlı ve doğru nesne tanıma yetenekleri sunmaktadır. YOLO-V4 tiny'nin temel amacı, yüksek hızda nesne tanıma yaparken aynı zamanda düşük hesaplama gücüne ihtiyaç duymasıdır. Bu nedenle YOLO-V4 tiny'nin daha küçük ağ yapısıyla YOLO-V4'e kıyasla daha hafif ve daha hızlı çalışır. Bu özelliği sınırlı kaynaklara sahip sistemlerde gerçek zamanlı uygulamalar için ideal hale getirir. YOLO-V4 tiny'nin ağ yapısı, farklı boyutlardaki özellik haritalarını birleştirerek nesne tespitini

gerçekleştirir. Ağ, birden fazla ölçekli özellik haritasını kullanarak nesnelerin çeşitli özelliklerini farklı seviyelerde yakalar. Bu, nesnelerin farklı boyutlarını ve özelliklerini doğru bir şekilde tanımlamak için daha iyi bir özellik çıkarımı sağlar. Genelde daha küçük ve tekli sınıflandırıcıları kullanırken, daha büyük ve daha karmaşık nesnelere tanımlamak için birden fazla ölçekli sınıflandırıcıları kullanır. Böylece çeşitli boyutlardaki nesnelerin doğru bir şekilde tanınmasını sağlar. YOLO-V4 tiny modeli, yüksek hızlı ve gerçek zamanlı nesne tanıma uygulamaları için optimize edilmiş güçlü bir çözüm sunar. Düşük hesaplama gücüne ihtiyaç duyulan sistemlerde etkin bir şekilde çalışabilirken, yüksek doğruluk ve performans sağlama kabiliyetine sahiptir. Bu nedenle, YOLO-V4 tiny, akıllı atık yönetimi gibi uygulamalarda hızlı ve verimli atık tespitini desteklemek için kullanılabilir önemli bir algoritmadır.

3.1.1 YOLO eğitimi için veri seti hazırlama


Veri hazırlama aşamasında eğitim için kullanılacak görüntü veri seti toplanmıştır. Toplanan verilerin yetersiz görülmesinden dolayı TACO (Proença ve Simoes, 2020) veri seti de kullanılarak daha büyük yeni bir veri seti oluşturulmuştur. TACO veri setinden kullanılan görüntüler Şekil 3.2’de gösterilmiştir. TACO veri seti, doğadaki atık görüntülerinden oluşan bir veri setidir. Tropik sahillere Londra sokaklarına kadar çok farklı ortamlarda farklı görüntülerden oluşmaktadır. Bu veri seti içerisindeki bütün görüntüler nesne tespiti algoritmalarında kullanılacak şekilde etiketlenmiş ve bölümlere ayrılmıştır. Bu veri seti içerisindeki görüntüler, insanların doğada çektiği görüntüleri web sitesine yüklemeye imkan sağladığı için sürekli olarak artmaktadır.



Şekil 3.2 : TACO veri setine ait örnek görüntüler

Çalışmada karton, metal, cam ve plastik sınıflarına ait nesnelere odaklanıldığı için TACO veri setinden sadece bu görüntüler seçilerek kullanılmıştır. Görüntülerin sayısını

artırmak amacıyla başka görüntülerde çekilerek kullanılmıştır. Yazarlar tarafından hazırlanan veri setindeki örnek görüntüler Şekil 3.3'te gösterilmiştir.



Şekil 3.3 : Hazırlanan veri setinden örnek görüntüler

Bu veri seti hazırlanırken tıpkı TACO veri setinde olduğu gibi doğada farklı yerlerde bulunan farklı görüntülerin fotoğrafları çekilerek etiketlemeleri yapılmıştır. Ardından TACO veri seti ile birleştirilerek karton, metal, cam ve plastik sınıflarından oluşan daha büyük yeni bir veri seti oluşturulmuştur.

Çalışmada kullanılmak amacıyla oluşturulan yeni veri seti içerisindeki görüntüler rastgele olacak şekilde eğitim ve test veri seti olarak ayrıştırılmıştır. Yeni veri seti içerisinde bulunan görüntülerin sınıflara göre dağılımları ile her bir sınıftan kaç adet görüntünün eğitim ve test de kullanıldığı Tablo 3.1'de gösterilmiştir.

Tablo 3.1 : Görüntü veri setinin sınıfları ve sayıları

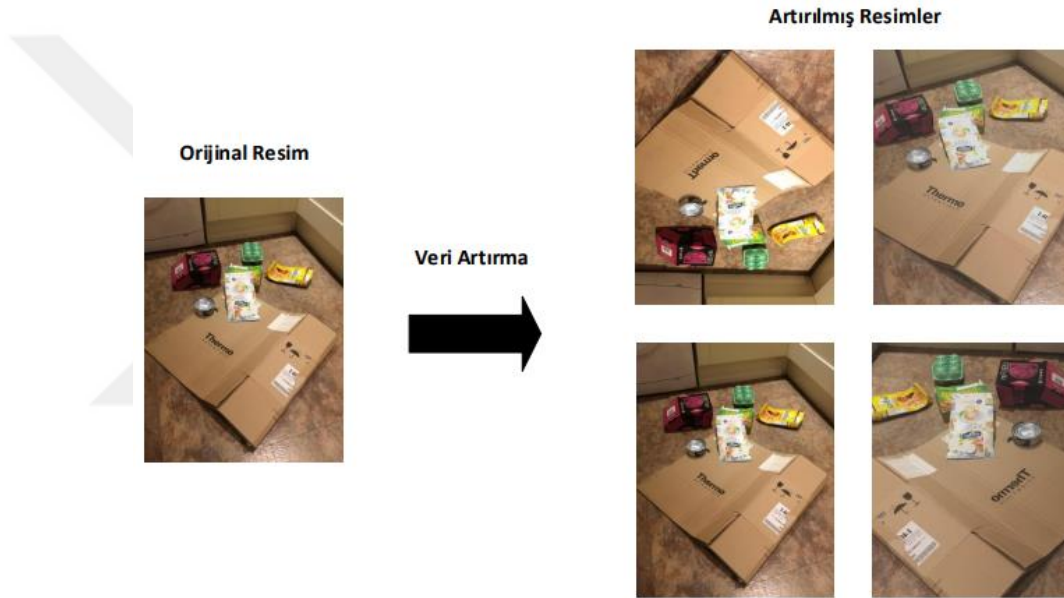
Sınıf	Veri	Sayı	Toplam
Karton	Eğitim	552	678
	Test	126	
Metal	Eğitim	332	395
	Test	63	
Cam	Eğitim	378	498
	Test	120	
Plastik	Eğitim	324	402
	Test	78	

Çalışmada toplamda 1973 adet görüntü kullanılmıştır. Görüntülerin yaklaşık, %80'i eğitim (1586 adet görüntü) ve %20'si test (387 adet görüntü) veri seti olacak şekilde kullanılmıştır.

Eğitim veri seti tespit edilecek nesnelerin farklı açılardan, farklı boyutlarda, çeşitli ışık koşullarında ve arka planlarda temsil edilmesi gereken çeşitli örnekler içermelidir. Bu,

eğitilecek modelin genelleme yeteneğini artırarak gerçek ortam koşullarında daha iyi performans göstermesine yardımcı olur.

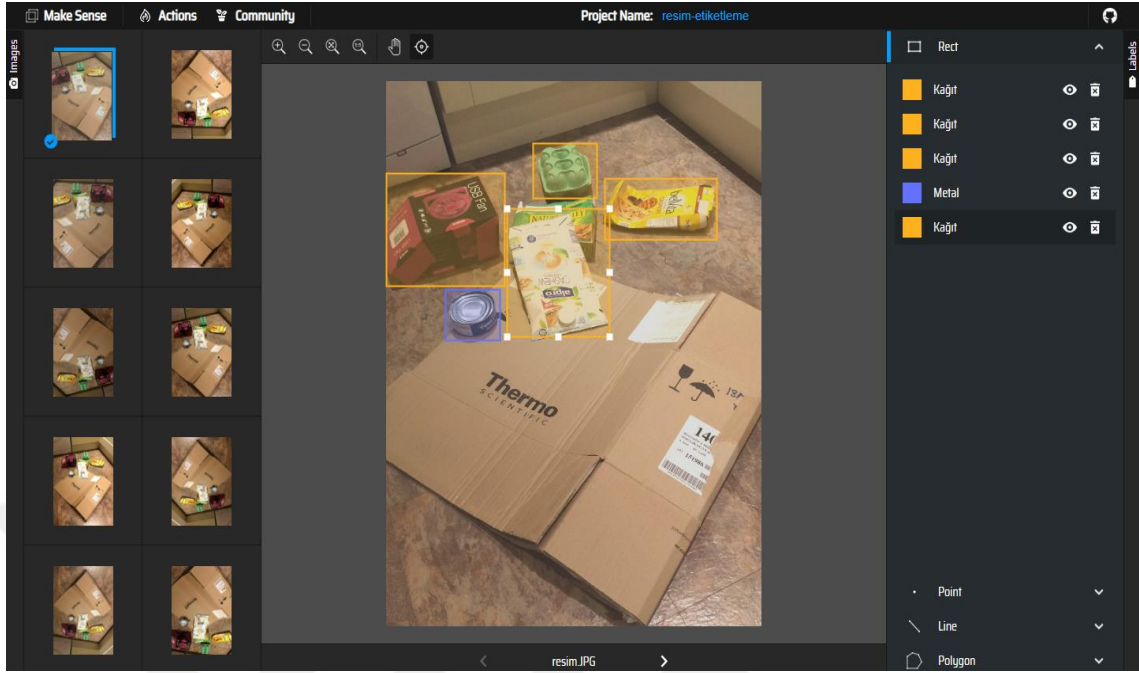
Derin öğrenme modellerinde veri sayısı büyük bir etkidir. Veri ne kadar çok olursa model o kadar iyi performans sergilemektedir. Bu sebepten dolayı veri setinin büyütülmesi gerekmektedir. Çalışma kapsamında hazır bulunan veri seti üzerine kendi oluşturduğumuz veri setini ekleyerek yeni bir seti veri oluşturulmuştur. Oluşturulan veri seti görüntü işleme teknikleri ile blur ekleme, gürültü ekleme gibi deformasyonlara uğratarak modelin zor şartlarda bile daha iyi performans sergilenmesi sağlanmıştır. Bununla beraber yatay da aynalama, dikeyde aynalama işlemi uygulanmıştır. Veri artırma teknikleri ile veri seti artırma Şekil 3.4’de gösterilmiştir.



Şekil 3.4 : Veri seti artırımı

Veri toplama işleminden sonra veri etiketleme işlemine geçilmektedir. Veri etiketleme, her görüntüdeki nesnelerin sınıf etiketlerini ve sınırlayıcı kutularını (bounding box) belirlemeye yönelik işlemdir. YOLO-V4 de etiketleme yapacak uygun bir araç kullanılması gerekmektedir. Programda ilk önce YOLO-V4 uyumlu etiketleme formatını (genellikle Pascal VOC veya YOLO formatları) seçilmektedir. Yaptığımız çalışmada etiketleme formatı için YOLO formatı seçilmiştir. Bu format etiketlerin sınıf adlarını ve sınırlayıcı kutu koordinatlarıyla birlikte metin dosyasında saklanmasını sağlamaktadır. Bütün ön işlemler yapıldıktan sonra toplanan tüm görüntülerin her birini açarak, üzerindeki etiketleme yapılmıştır. Her nesne için bir sınıf etiketi ve nesnenin etrafına sınırlayıcı kutu çizilmiştir. Eğitimin başarılı olması için etiketleme işleminin

dođru bir řekilde yapılması gerekmektedir. Yapılan etiketleme işleminde ait örnek Şekil 3.5'te gösterilmiştir.



Şekil 3.5 : Örnek görüntü etiketleme

Görüntü etiketleme için Makesense.ai isimli web sitesi kullanılmış ve tüm görüntüler bu ortamda etiketlenmiştir. Etiketleme işlemi bittikten sonra her bir görüntü için “.txt” uzantılı görüntülerin etiket bilgilerini içeren dosya oluşturulmaktadır. Şekil 3.5'te gösterilen görüntü için oluşturulan “.txt” uzantılı görüntü etiket bilgileri Şekil 3.6'da gösterilmiştir.

Dosya	Düzen	Biçim	Görünüm	Yardım
0	0.225552	0.285489	0.292324	0.119874
0	0.419033	0.190852	0.128286	0.085174
0	0.742902	0.249211	0.300736	0.173502
2	0.708202	0.395899	0.126183	0.091483
0	0.501052	0.370662	0.195584	0.208202
1	2	3	4	5

Şekil 3.6 : Görüntü etiket bilgileri

Şekil 3.6’da 5 satır ve 5 sütunlu bir etiket oluşturulmuştur. Bu şekilde her bir satır etiketlenen nesnelere, 1. sütun etiketlenen nesnenin bağlı olduğu sınıfı, 2. sütun nesnenin x_ merkezini, 3. sütun nesnenin y_ merkezini, 4. sütun nesnenin genişliğini ve 5. sütun nesnenin yüksekliğini göstermektedir. Burada verilen koordinatlar görüntünün boyutlarına göre 0-1 arasında normalize edilmiş değerlerdir.

Eğitime başlamadan önce toplanan veri seti eğitim ve test seti olmak üzere 2 gruba ayrılmıştır. Toplam verinin %80’i eğitim ve %20’si test veri seti olarak ayrılmış ve sayılar Tablo 3.2’de gösterilmiştir.

Tablo 3.2 : Eğitim ve test veri setlerinin sayıları

Veri	Sayı
Eğitim	1586
Test	387

YOLO-V4 ve YOLO-V4 tiny modellerinin eğitim sonuçları ve başarı performansları Bölüm 5’de ayrıntılı olarak gösterilmiştir.

3.2. 3B Kamera İle Koordinat Tespiti

YOLO ile tespit edilen atığın bir manipülatör vasıtasıyla ayrıştırılabilmesi için öncelikle atığın koordinatının 3 boyutlu olarak tespit edilmesi gerekmektedir. Kamera ile konum tespitinde yapılan çalışmalar incelendiğinde stereo derinlik kameraları kullanıldığı görülmektedir (Li ve diğ., 2008; Carfagni ve diğ., 2019; Keselman ve diğ., 2017). Stereo derinlik kameraları 3B görüntüleme ve derinlik algılama için kullanılan özel bir kamera türüdür. Bu kameralar, iki ayrı kamera sensörü ve lens kullanarak, insan gözü gibi iki farklı perspektiften görüntü yakalamaktadır. Stereo derinlik kameralarından alınan, bu iki görüntü analiz edilerek ve kamera arasındaki farklılıklar belirlenerek, nesnelerin derinlik bilgisi elde edilmektedir. Bu sebeple stereo kameralar birçok uygulama ve endüstride kullanılmaktadır (Zin ve diğ., 2021).

Tez kapsamında yapılan çalışmada tespit edilen atığın konumunu bulmak için Intel RealSense D415 derinlik kamerası kullanılmıştır. Intel RealSense kamerası piyasadaki benzer özellikli kameralara göre yüksek hassasiyetli ve ucuz olması, ayrıca üretici firmanın kullanıcılarına sağladığı ücretsiz SDK sebebiyle tez çalışmasında tercih edilmiştir. Kullanılan kamera Şekil 3.7’de gösterilmiştir.



Şekil 3.7 : Intel RealSense D415 kamera

D415 kamerası derinlik algılama teknolojisi sayesinde nesnelerin uzaklığı ve boyutu ölçülebilmektedir. Bu kamera özellikle robotik, sanal gerçeklik ve artırılmış gerçeklik uygulamaları, yüz tanıma ve nesne takibi gibi uygulamaların yaygın olarak kullanılmaktadır. D415 kamerasının bazı özellikleri Tablo 3.3'te gösterilmiştir.

Tablo 3.3 : Intel RealSense D415 kamera özellikleri

Özellik	Parametreler
Sensör	Derinlik Sensörü
Derinlik Çözünürlüğü	1280x720 (maksimum)
RGB Çözünürlüğü	1920x1080 (maksimum)
Derinlik Çerçeve Hızı	30, 60, 90 fps (maksimum)
RGB çerçeve hızı	30 fps (maksimum)
Minimum derinlik mesafesi	0.3m
SDK uyumluluğu	Intel RealSense SDK 2.0

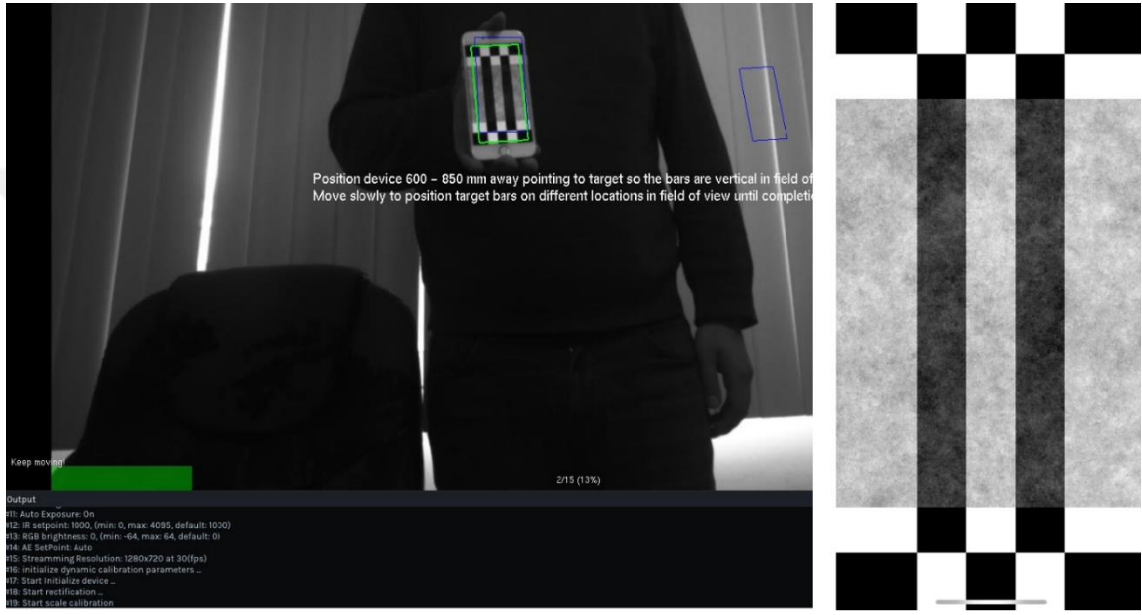
3.2.1. Kamera kalibrasyonu

Stereo kameralarda kamera kalibrasyonu için, iki veya daha fazla kameranın birbirine göre konum ve oryantasyonlarının hesaplanması gerekmektedir. Özellikle 3B görüntü işleme ve derinlik hesaplamada kullanılmaktadır. 3B kamera kalibrasyonu, kameranın dünya koordinatlarından görüntü koordinatlarına geçişini belirleyen parametrelerin belirlenmesi sürecidir. Bu süreç iç ve dış kalibrasyon olmak üzere iki adımdan oluşmaktadır.

İç Kalibrasyon: Bu adımda kameranın optik merkezi ve odak uzunluğu parametreleri belirlenmektedir. Kamera kalibrasyonunu gerçekleştirmek için iç matrisinin hesaplanması gerekmektedir. Kamera iç matrisi, kameranın temel optik ve geometrik özelliklerini temsil eden bir matristir. İç matris denklem 3.1'de gösterilmiştir.

$$K = \begin{bmatrix} f_x & 0 & c_x \\ 0 & f_y & c_y \\ 0 & 0 & 1 \end{bmatrix} \quad (3.1)$$

Denklem 3.1’de gösterilen matristerde ' f_x ' kameranın yatay odak uzaklığını, ' f_y ' kameranın dikey odak uzaklığını, ' c_x, c_y ' kameranın optik merkezi olarak kabul edilen noktanın piksel cinsinden konumunu göstermektedir. Kamera iç matrisi, gerçek dünya koordinatlarından görüntü koordinatlarına dönüşüm yapmak için kullanılmaktadır. Bu matris, kamera kalibrasyonu sırasında hesaplanmaktadır. Intel Realsense kamerasıyla mesafe ölçmeden önce kameranın yazılımı olan ' Dynamic Calibrator Toolbox ' ile kamera kalibrasyonu gerçekleştirilmiştir. Yapılan kalibrasyon işlemi Şekil 3.8’de gösterilmiştir.



Şekil 3.8 : Kamera kalibrasyonu ve kalibrasyon deseni

Kamera kalibrasyon işlemi sırasında kameraya telefonda Şekil 3.8’de verilen kamera kalibrasyon deseni gösterilmiş ve kalibrasyon işlemi başarıyla gerçekleştirilmiştir. Kalibrasyon işlemi ile kamera parametreleri belirlenmiş ve yazılımsal olarak kameraya aktarılmıştır. Kalibrasyon sonrasında bulunan değerler Tablo 3.4’de gösterilmiştir.

Tablo 3.4 : Intel realsense D415 kamera parametreleri

Parametre	Değeri
f_x	615.84
f_y	615.33
c_x	316.24
c_y	234.22

Dış Kalibrasyon : Bu adımda, kameranın dünya koordinatlarına göre konumu ve yönelimi belirlenmektedir. Dış kalibrasyon matrisi R , kameranın dünya koordinatlarındaki dönüşünü göstermektedir. Bu matris dönüş matrisi olarak ifade edilir ve kameranın dünya koordinatlarındaki yönelimini belirler.

Dönüş matrisi, genellikle Euler açıları veya bir dönüş vektörü kullanılarak belirlenir. Euler açıları, bir nesnenin etrafındaki üç ana dönüş eksenindeki dönüşleri temsil eder; roll (x - eksen etrafında dönüş), pitch (y -ekseni etrafında dönüş) ve yaw (z -ekseni etrafında dönüş).

Eğer θ_x , θ_y , θ_z roll, pitch ve yaw açıları kabul edilirse dönüş matrisi R denklem 3.2'deki gibi gösterilir.

$$R = R_z(\theta_z) R_y(\theta_y) R_x(\theta_x) \quad R = \begin{bmatrix} r_{11} & r_{12} & r_{13} \\ r_{21} & r_{22} & r_{23} \\ r_{31} & r_{32} & r_{33} \end{bmatrix} \quad (3.2)$$

Denklem 3.2 de gösterilen R_x , R_y ve R_z x , y , ve z eksenleri etrafındaki dönüş matrisleridir.

Dış kalibrasyon vektörü t , kameranın dünya koordinatlarındaki konumunu temsil etmektedir. Bu vektör denklem 3.3'de gibi çeviri vektörü olarak ifade edilmektedir. Burada t_x , t_y ve t_z kameranın dünya koordinatlarındaki x , y ve z konumlarını göstermektedir.

$$t = \begin{bmatrix} t_x \\ t_y \\ t_z \end{bmatrix} \quad (3.3)$$

Tüm kalibrasyon süreci projeksiyon matrisi ile gösterilmektedir. Projeksiyon matrisi, 3B dünya koordinatlarını 2B görüntü koordinatlarına dönüştürmektedir. Projeksiyon matrisi denklem 3.4'de gösterilmiştir.

$$P = K[R|t] \quad (3.4)$$

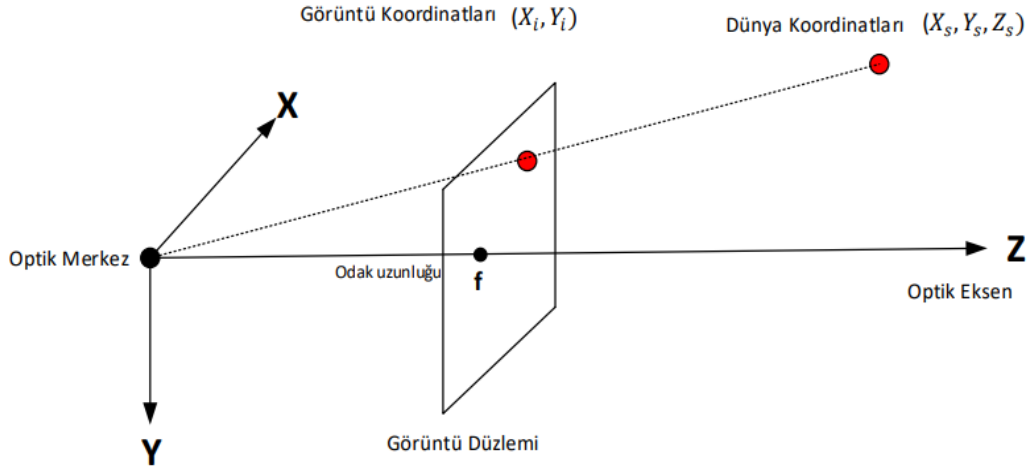
Denklem 3.4'de gösterilen K , R ve t matrisleri denklem 3.1, denklem 3.2 ve denklem 3.3'de ifade edilmiştir. 3 matris denklem 3.4'de yerine yazılırsa 3B koordinatından 2B koordinatına geçiş formülü Şekil 3.9'de gösterilmiştir. Şekil 3.9'da gösterilen X_i , Y_i değerleri 2B görüntü koordinatlarını gösterirken X_s , Y_s ve Z_s dünya koordinatlarını göstermektedir.

$$\begin{bmatrix} X_i \\ Y_i \\ 1 \end{bmatrix} = \begin{bmatrix} f_x & 0 & c_x \\ 0 & f_y & c_y \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} r_{11} & r_{12} & r_{13} & t_x \\ r_{21} & r_{22} & r_{23} & t_y \\ r_{31} & r_{32} & r_{33} & t_z \end{bmatrix} \begin{bmatrix} X_s \\ Y_s \\ Z_s \\ 1 \end{bmatrix}$$

\downarrow 2B Görüntü Koordinatları \downarrow İç Kalibrasyon \downarrow Dış Kalibrasyon \downarrow 3B Dünya Koordinatları

Şekil 3.9 : Kamera kalibrasyonu sonra 3B'den 2B'ye geçiş

Kamera kalibrasyonunun ardından belirlenen parametreler görüntü koordinat sisteminden gerçek dünya koordinat sistemine geçişin sağlanması gerekmektedir. Görüntü koordinat sisteminde gerçek dünya koordinat sistemine geçiş Şekil 3.10'da gösterilmiştir.



Şekil 3.10 : Görüntü koordinat sisteminden dünya koordinat sistemine geçiş


Şekil 3.10'da gösterilen görüntü koordinatları 2B (X_i, Y_i) olarak verilmiştir. Daha sonra (X_i, Y_i) koordinatlarından 3B gerçek dünya koordinatları olan (X_s, Y_s, Z_s) koordinatlarına geçiş gösterilmiştir. Yapılan dönüşüm işlemleri denklem 3.5 ve 3.6'da gösterilmiştir. Denklemlerde gösterilen Z_s parametresi görüntünün derinliği belirtmektedir ve Intel RealSense kamerasıyla elde edilmektedir.

$$X_s = Z_s * \frac{X_i - c_x}{f_x} \quad (3.5)$$

$$Y_s = Z_s * \frac{Y_i - c_y}{f_y} \quad (3.6)$$


Eğer kamera koordinat sistemi ana koordinat sistemi ile aynı değilse koordinat dönüşüm işlemi yapılması gerekmektedir. Örneğin Şekil 3.11'deki gibi kameranın X ekseninde θ kadar döndürüldüğünü Y ve Z eksenleri boyunca da ötelendiğini varsayarsak oluşacak yeni 3B koordinatlar denklem 3.7'de gösterilmiştir. Dönüşüm sonrası elde edilen X' , Y' ve Z' yeni koordinatları temsil etmektedir.

$$\begin{bmatrix} X' \\ Y' \\ Z' \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 \\ 0 & \cos\theta & \sin\theta \\ 0 & -\sin\theta & \cos\theta \end{bmatrix} \begin{bmatrix} X_{kam} \\ Y_{kam} \\ Z_{kam} \end{bmatrix} + \begin{bmatrix} 0 \\ Y_{öteleme} \\ Z_{öteleme} \end{bmatrix} \quad (3.7)$$




Şekil 3.11 : Kameranın θ açısı kadar döndürülmesi

Kamera koordinat dönüşüm işlemlerinden sonra Intel RealSense kamerasının 3 boyutlu pozisyon ölçmek için Şekil 3.12'de gösterilen örnek 3B kamera ölçüm sistemi oluşturulmuştur.



Şekil 3.12 : Kamera ölçüm sistemi

Şekil 3.12’de oluşturulan sistemde 3B küpün yüzeyleri milimetrik kağıtlarla kaplanmış ve ölçümün doğru olup olmadığı gözlemlenmiştir. Şekilde kamera görüş alanında belirli bir pozisyonda bir nesne yerleştirilip kameranın ölçtüğü pozisyon ile nesnenin gerçek pozisyonları gözlemlenmiş ve kameranın milimetrik hatalarla pozisyon ölçtüğü belirlenmiştir. Kamera tarafından ölçülen nesnenin pozisyonu Şekil 3.13’te gösterilmiştir. Şekil 3.12’de verilen koordinat sistemi baz alındığında nesnenin koordinatları (X,Y,Z) eksenlerinde sırasıyla (-30mm, -73mm, 376 mm) olduğu tespit edilmiştir.



Şekil 3.13 : Kamera tarafından ölçülen nesnenin pozisyonu

Şekil 3.12’de gösterilen milimetrik ölçüm küpü ile kameranın ölçüm doğruluğu için 10 farklı konuma nesnelere eklenmiş olup bu nesnelere hem gerçek konumları hemde kamera ile ölçülen konumları belirlenerek ve kameranın ölçme doğruluğu hesaplanmıştır. Kamera ölçüm performansı sonuçları Bölüm 5’de ayrıntılı olarak sunulmuştur.


3.3. Atık Tespit Düzenegi

YOLO derin öğrenme algoritması ile atığın türünün belirlenmesinin, ardından kamera ile 3B ölçüm işlemlerinin yapılmasından sonra gerçek zamanlı olarak atığın tespit edilmesi için prototip düzenek kurulmuştur. Bu düzenekte algoritmanın hızlı bir şekilde çalışması için NVIDIA Jetson AGX Xavier kartı kullanılmıştır. Jetson AGX Xavier, NVIDIA’nın özel tensör çekirdekleri ile donatılmıştır. Bu çekirdekler, derin öğrenme algoritmaları için özel tasarlanmış olup, yapay sinir ağlarının işlem hızını ve enerji verimliliğini artırmaktadır. Bu sayede, nesne tespiti uygulamalarının gerçek zamanlı ve düşük gecikmeli çalışmasına olanak sağlamaktadır. NVIDIA Jetson AGX Xavier kartının teknik özellikleri Tablo 3.5’te gösterilmiştir.

Tablo 3.5 : NVIDIA Jetson AGX Xavier bazı teknik özellikleri

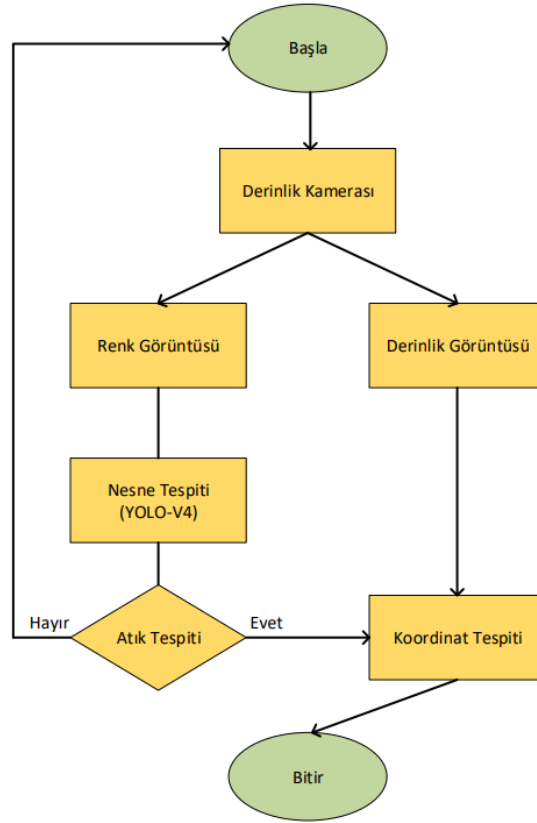
Özellikler	Parametreler
İşlemci	8 adet ARMv8.2 64-bit CPU
GPU	Nvidia Volta Mimarisi, 512 Tensor Cores
Bellek	16 GB 256 – bit LPDDR4x
AI Performansı	30 TOPS

Kurulan düzende python ortamında kameradan alınan görüntüler üzerinde pyrealsense2, OpenCV ve YOLO-V4 derin öğrenme algoritması kullanılarak metal, karton, cam ve plastik olmak üzere 4 farklı atığın tespiti yapılmıştır. Çalışma kapsamında kurulan deney düzeneği Şekil 3.14’te gösterilmiştir.



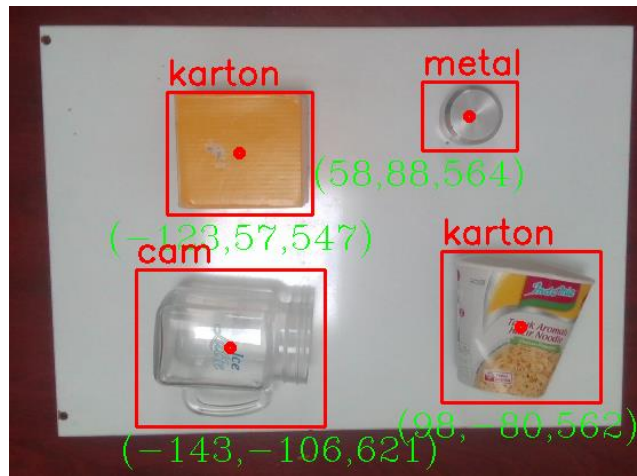
Şekil 3.14 : Kurulan deney düzeneği

Kurulan deney düzeneğinde Bölüm 4 ‘de anlatılacak robotik manipülatör ile ayrıştırma işlemi için örnek bir uygulama gerçekleştirilmiştir. Bu uygulamada birden fazla atığın tespiti ve ayrıştırma işlemi için 3 boyutlu koordinatları tespit edilip sistemin başarılı bir şekilde çalıştığı gözlemlenmiştir. Kurulan deney düzeneğini çalışma blok diyagramı Şekil 3.15’te gösterilmiştir. Şekil 3.15’te gösterilen blok diyagrama bakıldığında kameradan aynı anda hem derinlik görüntüsü hem de renk görüntüsü alınmaktadır. Bunu nedeni YOLO derin öğrenme algoritmasında atık tespit edilebilmesi için renk görüntüsüne ihtiyaç duyulmaktadır. YOLO algoritmasıyla tespit edilen atığın 3 boyutlu konumunun tespit edilebilmesi içinde derinlik görüntüsü kullanılmaktadır.



Şekil 3.15 : Atık Tespiti Blog Diyagramı

Kurulan düzenek sonucu tespit edilen atıklar Şekil 3.16’da gösterilmiştir. Şekil 3.16’da gösterilen 4 farklı atık robot tarafından ayrıştırma işlemi yapabilmesi için tespit edilen atıklar çerçeve içerisine alınmış ve merkez koordinatları 3 boyutlu olarak hesaplanmıştır. Yapılan çalışma sonucunda eğitilen modeller ve ayrıntılı sonuçları Bölüm 5’de anlatılmıştır.



Şekil 3.16 : Gerçek zamanlı atık tespiti

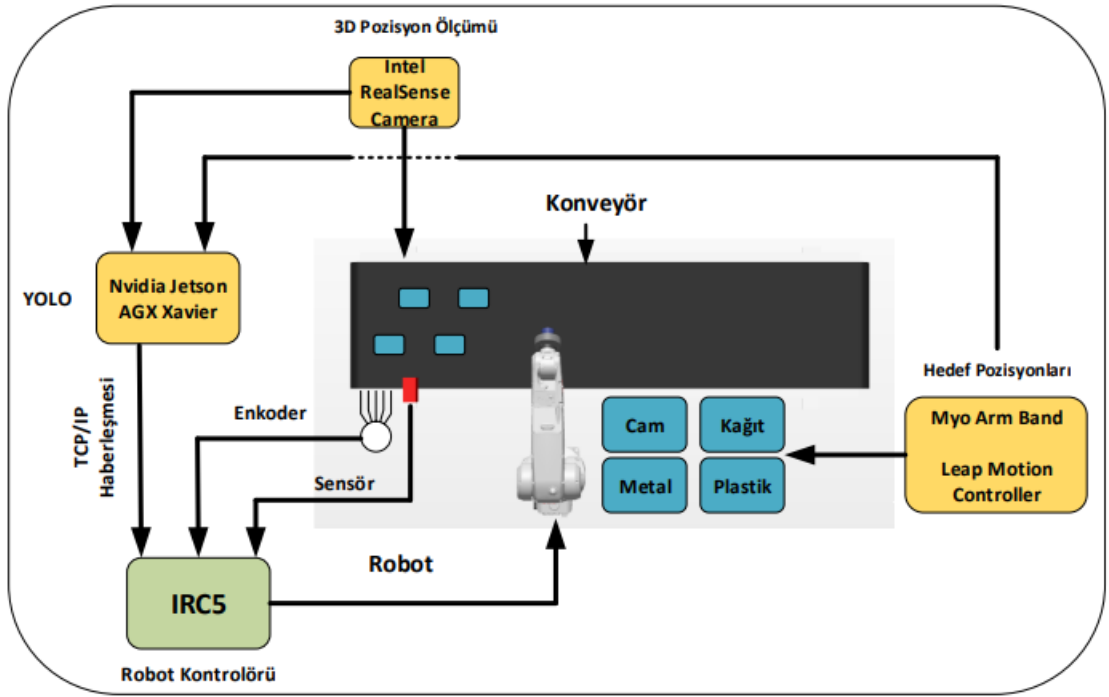
BÖLÜM 4. GERÇEK ZAMANLI ATIK AYRIŞTIRMA UYGULAMASI

Endüstriyel atık ayrıştırma, atık yönetiminin çevresel etkisini azaltma ve verimliliği artırmak için son yıllarda gelişmekte olan alanların başında gelmektedir. Atık ayrıştırma sistemleri, endüstriyel robot kollarının geliştirilmesi ve görüntü işleme algoritmalarının daha verimli hale gelmesiyle beraber yapılan uygulamalarla atıklar ayrıştırılabilmektedir.

Otomatik atık ayrıştırma, zor bir uygulama olmakla beraber, farklı atıkların tespit edilip ayrıştırılması için bir takım zorluklar mevcuttur (Kiyokawa ve diğ., 2022). Geliştirilen robot teknolojileri sayesinde, otomatik ayrıştırma sistemlerinin zorlukları ortalıktan kaldırılmaktadır (Gundupalli ve diğ., 2021).

Atık ayrıştırma süreci, genellikle bir konveyör bant ve endüstriyel robot kollarla gerçekleştirilmektedir. Yapay zeka tabanlı algoritmalarla robotik ayrıştırma sistemleri ile katı atıkların ayrıştırılması sağlanmış ve bu sayede atık arıtma tesislerinde kullanılmaya başlanmıştır (Wilts ve diğ., 2021).


Tezin amacı Bölüm 1’de belirtildiği üzere atık ayrıştırma işlemlerinin esnek, hızlı ve konforlu bir şekilde gerçekleştirilebildiği bir uygulama geliştirmektir. Bu kısımda tez kapsamında gerçekleştirilen insan robot etkileşimi ve derin öğrenme ile atık tespitinin ardından endüstriyel robot kol ile gerçek zamanlı atık ayrıştırma uygulamasına değinilecektir. Yapılan atık ayrıştırma uygulamasının şeması Şekil 4.1’de gösterilmiştir



Şekil 4.1 : Atık ayrıştırma sistemi

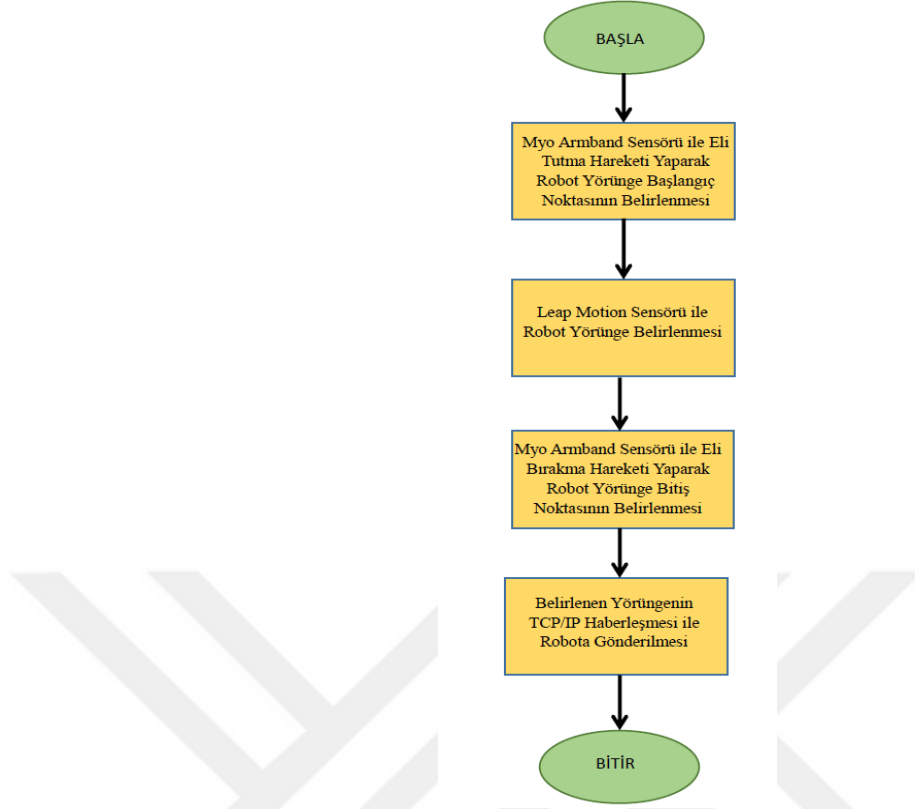
4.1 İnsan-Robot Etkileşimi ile Robot Patika Tespiti

Yapılan çalışma klasik ayrıştırma işlemlerinden farklı olup, HRI yapılarak kullanıcıların sisteme aktif olarak müdahale edebilmesi sağlanmıştır. Çalışmanın birinci kısmında Myo Armband ve Leap Motion sensörleri vasıtasıyla Bölüm 2’ de ayrıntıları verilen bir HRI uygulaması geliştirilmiştir. Bu HRI uygulamasıyla robot programlama bilgisi olmadan operatör tarafından robotun atıkları tuttuktan sonra bırakacağı noktalar ve gideceği patika belirlenmektedir. Yapılan HRI sistemi ile patika planlaması Şekil 4.2’de gösterilmiştir.



Şekil 4.2 : İnsan robot etkileşimi ile hedef nokta belirleme

Şekil 4.2’de gösterilen sistemde kullanıcı robotun gideceği patikayı planlamak için Myo Armband ve Leap Motion sensörlerini kullanmaktadır. Kullanıcı, robot “home” pozisyonunda beklerken Myo Armband sensörünü giyerek eliyle tutma hareketini yapmaktadır. Tutma hareketi makine öğrenmesi ile tespit edildiği anda robotun eksenleri çalışır hale gelmektedir ve oluşturulacak patikanın başlangıç noktası belirlenmektedir. Daha sonra robotun gideceği patika Leap Motion sensörü vasıtasıyla işaret parmağı ucu pozisyonunun hareketleriyle 3B olarak oluşturulmaktadır. Kullanıcı atıkların bırakılacağı 4 farklı noktayı belirledikten sonra Myo Armband ile elini bırakma hareketini yapmaktadır ve bu şekilde patikaların bitiş noktaları belirlenmektedir. Kullanıcı tarafından yapılan tutma hareketi ve bırakma hareketi arasında belirlenen noktalar patika olarak robot kontrolörüne TCP/IP haberleşmesi ile gönderilmektedir. Yapılan bu uygulamanın blok diyagramı Şekil 4.3’te gösterilmiştir.



Şekil 4.3 : Robot patikasının belirlenmesi adımları


4.2. Konveyör Takibi ile Robot Atık Tutma Patikasının Belirlenmesi

Konveyör takibi, endüstriyel robotların hareketli bir konveyör üzerinden gelen parçaları anlık olarak takip ederek parçaları tutması için geliştirilmiş bir teknolojidir. Bu teknoloji yüksek hassasiyet, tekrarlanabilirlik ve parça izleme doğruluğunun gerekli olduğu uygulamalarda yaygın olarak kullanılmaktadır (Luo ve Liao, 2017).

Konveyör takibi bir dizi sensör veya bilgisayar görüşü sistemi kullanılarak gerçekleştirilmektedir. Sensörler veya bilgisayar görüşü, konveyör bandı üzerindeki parçaların yerini belirlemekte ve elde edilen bilgiyi robota göndermektedir. Parça takibi sırasında robot yörüngesini ayarlayarak hareketli parçayı takip edebilir, parça üzerinde işlem yapabilir veya parçayı belirli bir noktaya bırakabilmektedir.

Konveyör takibinde ilk iş bir sensör veya kamera vasıtasıyla parçanın konumunun belirlenmesi aşamasıdır. Parçanın konumunun belirlenmesinden sonra robot kontrolörü ile konveyör bandının senkronizasyonunun sağlanması gerekmektedir. Bu sayede robot kontrolörü, parçaların ne zaman ve hangi konumda alınacağını belirlemektedir.


Tez kapsamında yapılan çalışmada konveyör üzerinden gelen atıklar için konveyör takibi uygulaması yapılmıştır. Şekil 4.4'te gösterilen sistemde konveyörün motoruna bağlı enkoder ile konveyörün hızı ve atıkların zaman içerisinde ilerledikleri mesafe hesaplanmaktadır. Bu hız ve mesafe bilgisi robot kontrolörüne gönderilip konveyör bilgisinin sürekli olarak izlenmesi sağlanmaktadır. Konveyöre bağlı senkronizasyon sensörü konveyör üzerindeki hareket eden atıkları izlemekte ve atık geçtiği anda sinyal üretmektedir. Bu sinyal, robot kontrolörüne iletilmekte ve nesnenin o anki konumunu ve zamanlamasını belirlemek için kullanılmaktadır. Robot kontrolörü, enkoder ve senkronizasyon sensöründen gelen verileri işleyerek hareket halinde olan atıkların konumlarını belirlemektedir. Bu bilgiler, robotun doğru zamanda ve doğru yere hareket etmesini sağlamak için kullanılmaktadır. Robotun izleyeceği patika, konveyör hızına ve nesnenin konumuna göre sürekli olarak ayarlanmaktadır. Bu sayede robotun hareketli nesneyi doğru zamanda ve doğru yerde yakalamasını ve ayrıştırmasını sağlamaktadır. Konveyör takibi için ABB firmasına ait DSCQ2000 konveyör takibi kartı kullanılmıştır. Bu kart konveyör üzerinde bulunan senkronizasyon sensörü ve konveyörü hareket ettiren motorun enkoderi ile haberleşmektedir.



Şekil 4.4 : Konveyör takip sistemi

4.3. Gerçek Zamanlı Atık Ayırıştırma

Bu kısımda ayrıntıları Bölüm 3’de anlatılan atık tespiti için kullanılan YOLO-V4 algoritması, python ortamında yazılmış ve Nvidia Jetson AGX Xavier kartına yüklenmiştir. Intel RealSense kamerası ile tespit edilen atığın türü ve 3 boyutlu konumu jetson kart üzerinden robota TCP/IP haberleşmesi ile ethernet üzerinden gönderilmiştir. Ayırıştırma için kurulan prototip deney düzeneği Şekil 4.5’te gösterilmiştir.




Şekil 4.5 : Atık ayırıştırma deney düzeneği

Çalışmada ABB firmasına ait IRB1200 endüstriyel robotu kullanılmıştır. Bu robot IRC5 kontrolörü tarafından kontrol edilmektedir. Konveyör üzerinden atıklar senkronizasyon sensörü tarafından tespit edildiğinde konveyör takibi başlamaktadır. Sensörden gelen atık parça tespit bilgisi IRC5 kontrolörü üzerinde ethernet ile Jetson AGX Xavier kartına gelmektedir. Kameradan alınan ilk pozisyon Jetson AGX Xavier tarafından robota iletilmektedir. Daha sonra IRC5 kontrolörü üzerinden enkoder ile alınan mesafe hesaplanıp robotun parçayı tutması için uygun patika oluşturulup parçanın konveyörden alınması işlemi gerçekleştirilmektedir.

Her senkronizasyon sensöründen gelen sinyal ile atık robot tarafından konveyör takip kartı ile hafızaya alınıp robot parçaların o anki gelen konum bilgisiyle birlikte

enkoderden atığın gittiği mesafeyi hesaplayıp her parça için patika oluşturmaktadır. Konveyör üzerinden gelen atıkların tespit edilmesi Şekil 4.6'da gösterilmiştir.



Şekil 4.6 : Hareketli konveyör üzerinde atık tespiti

BÖLÜM 5. SONUÇ VE ÖNERİLER

Bu tez çalışması kapsamında, endüstriyel robot kullanılarak geri dönüştürülebilir malzemelerin ayrıştırılması için prototip düzenek geliştirilmiştir. Çalışmada elde edilen sonuçlar iki bölümde incelenmiştir. Çalışmanın birinci bölümünde HRI ile yapılan patika belirleme aşamasında sınıflandırılan hareketlerin doğruluğu ve patika hatası tespit edilmiştir. İkinci bölümünde YOLO algoritması ile elde edilen atık tespit doğruluğu ve 3B kamera ölçüm sisteminin ölçüm hatası belirlenmiştir. Bu bölümde Bölüm 2 ve Bölüm 3'te ayrıntıları anlatılan sistemlerin sonuçları ayrıntılı olarak verilmiş ve gelecek çalışmalar için önerilerde bulunulmuştur.

5.1. İnsan-Robot Etkileşimi için Elde Edilen Sonuçlar

Bu bölümde robotun yörüngesi sensörler tarafından HRI ile belirlenmiştir. İnsan robot etkileşimi için Myo Armband ve Leap Motion sensörlerinin bir arada kullanıldığı yeni bir yazılım geliştirilmiş ve endüstriyel robotun gideceği yörünge daha hassas bir şekilde hesaplanmıştır.

Çalışmada Myo Armband ile alınan EMG verileri 5 farklı kullanıcı tarafından belirlenen “tutma” ve “bırakma” el hareketleri için DVM, RO ve k-NN olmak üzere 3 farklı sınıflandırma algoritması ile sınıflandırılmıştır. 3 farklı sınıflandırma sonucu hesaplanan karışıklık matrisleri Tablo 5.1, Tablo 5.2 ve Tablo 5.3'te gösterilmiştir.

Tablo 5.1 : DVM karışıklık matrisi

	Sınıflandırılan Hareketler	Tutma	Bırakma
Kullanıcı 1	Tutma	115	5
	Bırakma	3	117
Kullanıcı 2	Tutma	116	4
	Bırakma	5	115
Kullanıcı 3	Tutma	117	3

Tablo 5.1 (devam) : SVM karışıklık matrisi

	Sınıflandırılan Hareketler	Tutma	Bırakma
Kullanıcı 4	Bırakma	6	114
	Tutma	115	5
Kullanıcı 5	Bırakma	6	114
	Tutma	114	6
	Bırakma	7	113

Tablo 5.2 : RO karışıklık matrisi

	Sınıflandırılan Hareketler	Tutma	Bırakma
Kullanıcı 1	Tutma	118	2
	Bırakma	3	117
Kullanıcı 2	Tutma	116	4
	Bırakma	5	115
Kullanıcı 3	Tutma	115	5
	Bırakma	2	118
Kullanıcı 4	Tutma	116	4
	Bırakma	6	114
Kullanıcı 5	Tutma	117	3
	Bırakma	3	117

Tablo 5.3 : k-NN karışıklık matrisi

	Sınıflandırılan Hareketler	Tutma	Bırakma
Kullanıcı 1	Tutma	117	3
	Bırakma	7	113
Kullanıcı 2	Tutma	115	5
	Bırakma	6	114
Kullanıcı 3	Tutma	115	5
	Bırakma	2	118
Kullanıcı 4	Tutma	114	6
	Bırakma	6	114
Kullanıcı 5	Tutma	113	7
	Bırakma	7	113

Üç farklı sınıflandırma algoritması ile sınıflandırılan EMG sinyallerinin karışıklık matrisleri verilmiştir. Her kullanıcıdan hareketleri 20 kez tekrar etmesi istenmiş ve her tekrarda 6 örnek toplanmıştır. Toplamda her kullanıcıdan 120 EMG verisi alınmıştır.

Sınıflandırma sonucunda elde edilen karışıklık matrislerinden algoritmaların doğru sınıflandırma yüzdeleri Tablo 5.4’de gösterilmiştir.

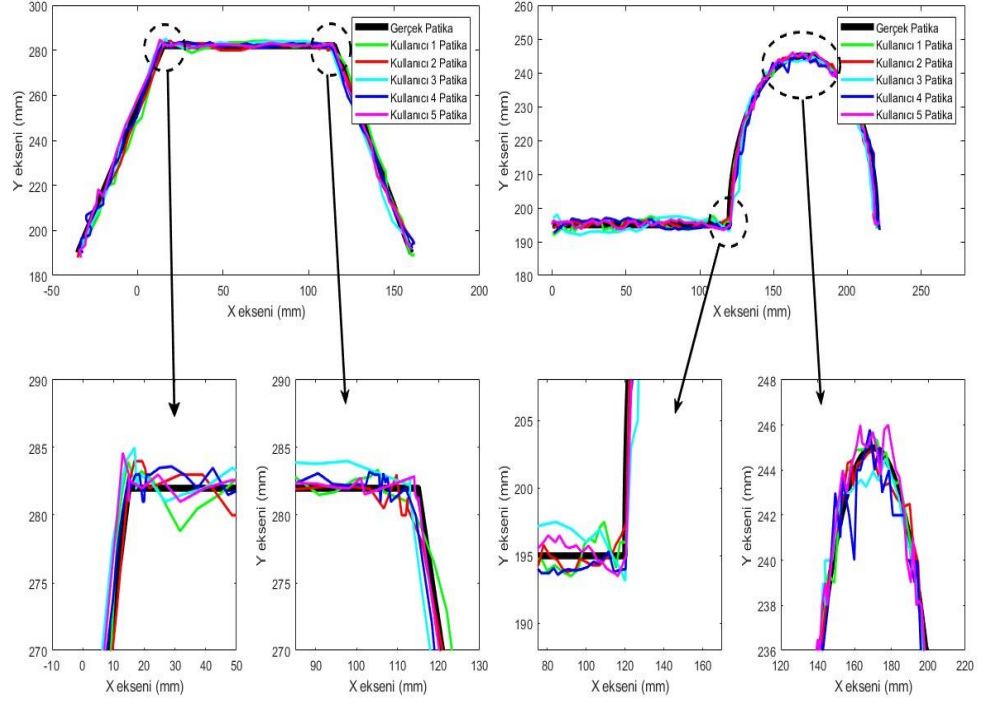
Tablo 5.4 : EMG sinyallerinin doğru sınıflandırma başarı yüzdeleri

	Tutma	Bırakma	Ortalama
DVM	%96.1	%95.5	%95.8
RO	%97	%96.8	%96.9
k-NN	%95.6	%95.3	%95.45

Tablo 5.4’te sunulan RO sınıflandırma algoritması “tutma” el hareketi için %97, “bırakma” el hareketi için %96.8 ve ortalama sınıflandırma başarısı olarak %96.9 oranında doğruluğa sahiptir. Doğru sınıflandırma başarı oranları hesaplandıktan sonra RO algoritması gerçek zamanlı uygulama için sınıflandırıcı olarak seçilmiştir.

EMG sinyallerinin sınıflandırdıktan sonra, insan-robot etkileşiminin ikinci kısmı olarak Leap Motion sensörü ile parmak pozisyon ölçümü uygulamasına geçilmiştir. Bölüm 2’de ayrıntıları verilen sistemin başarı performansını ölçmek için Şekil 2.9’da gösterilen 3 boyutlu ölçüm küpü oluşturulmuştur. Oluşturulan ölçüm küpünde 5 farklı kullanıcıdan 2 farklı patikayı takip etmeleri istenmiştir.

Kullanıcılardan 2 farklı patikayı 20 kez tekrar edilmesi istenmiştir. Şekil 5.1’te görüldüğü gibi kullanıcıların ellerindeki titreşimlere rağmen patikanın izlenmesinde büyük bir sapma olmadığı görülmektedir. Yine Şekil 5.1’te görüldüğü üzere hata oranının en büyük olması beklenen köşe ve dairesel dönüşlerde sapsmalar çok sınırlı olmaktadır. Bu sonuçlar geliştirilen uygulamanın yüksek hassasiyetli ve performanslı çalıştığını göstermektedir.



Şekil 5.1 : Leap motion ile ölçülen patika takip sonucu

Şekil 5.1’te yörünge takibinden sonra, sonuçların daha hassas bir şekilde değerlendirilmesi için patika takip hatası hesaplanmış ve her kullanıcının hata değerleri sayısal olarak Tablo 5.5’te gösterilmiştir. Tablo 5.5’te görüldüğü üzere kullanıcıların hata değerleri 1.57 mm ile 4.12 mm arasında değişmektedir. Her bir patika için elde edilen ortalama hata değerleri tablonun son satırında patika 1 için 2.85 mm ve patika 2 için 2.45 mm olarak gösterilmiştir. Bu hata değerleri parmağın titreşimi ve pratik uygulamadaki hatalarını içermektedir.

Tablo 5.5 : Patika Hata Değerleri

	Patika 1 (mm)	Patika 2 (mm)
Kullanıcı 1	3.36	1.57
Kullanıcı 2	2.44	2.25
Kullanıcı 3	3.07	4.12
Kullanıcı 4	2.97	2.57
Kullanıcı 5	2.37	1.76
Ortalama	2.85	2.45

Tablo 5.5’te gösterilen hata deęerleri literatürde yapılan benzer parmak pozisyon ölçüm sensörleriyle yapılan çalışmalar karşılaştırıldığında yaptığımız ölçüm sisteminin hatasının daha iyi olduğu görülmektedir. Sonuçların literatür ile karşılaştırılması Tablo 5.6’da gösterilmiştir.

Tablo 5.6 : Parmak pozisyonu sonuçlarının literatür ile karşılaştırılması

Literatür	Patika takip hatası
Korayem ve dię. (2021)	9.55 mm
Curiel- Razo ve dię. (2016)	12 mm
Valentini ve Pezzuti (2017)	4-5 mm
Önerilen Çalışma	2.45 mm

Sonuç olarak yapılan HRI sisteminde el hareketlerinin sınıflandırılmasında %96.9 doğruluk ve patika takip hatası da 2.45 mm olarak hesaplanmıştır.

5.2. Atık Tespiti ve Kamera Ölçüm Sistemi için Elde Edilen Sonuçlar

Çalışmanın ikinci bölümünde hareketli konveyör üzerinden endüstriyel robotun atığı ayrıştırması sağlanmıştır. Bu bölümde kullanılan kamera ile atığın türü ve 3 boyutlu konumu tespit edilmiş ve robot tarafından ayrıştırılmıştır.

Çalışmada, yapay zekâ temelli geliştirilen yazılım ile endüstriyel robotlar kullanılarak gerçek zamanlı atık tespit ve ayrıştırma sistemi yapılmıştır. Hazırlanan deney ortamında önerilen sistemde farklı atıklarla testler yapılarak sistemin kararlı ve doğru çalıştığı gözlemlenmiştir. Sistemin doğru ve kararlı çalışması başta yapay zeka algoritması ile atık tespiti ve bu işlemin gerçek zamanlı olarak gerçekleşmesi işlemlerine bağlıdır. Ayrıca atıkların gerçek zamanlı olarak hızlı bir şekilde tanınması, koordinatlarının belirlenmesi ve robot kolun ilgili nesneyi alarak bulunması gereken kutuya atması işlemlerini koordine eden gömülü sistemin bulunduğu kontrol biriminin yeteri derecede hızlı çalışması ile mümkün olmaktadır.

Çalışmada nesnelerin gerçek zamanlı olarak tespit edilebilmesi için bu alanda en başarılı algoritmalarından biri olan Bölüm 3’de detayları anlatılan YOLO derin öğrenme algoritmasının iki farklı türü kullanılmıştır. Bu algoritmalar, YOLO-V4 ve YOLO-V4 tiny modelleridir. Kullanılan YOLO modelleri özellikleri Tablo 5.7’de gösterilen yüksek kapasiteli bilgisayar üzerinde gerçekleştirilmiştir.

Tablo 5.7 : Deneysel çalışmalarda kullanılan bilgisayarın özellikleri.

Cihaz	Yapılandırma
İşletim sistemi	Ubuntu 16.04 LTS
İşlemci	Intel Xeon E5-2698 v4 @ 2.30GHz (18 Core)
CUDA Core/version	2496 / 8.0
GPU	NVIDIA P100
Çerçeveler	Pytorch, Keras, Tensorflow
Derleyiciler	Python IDE

Eğitimde kullanılan Bölüm 3’de gösterilen veri seti görüntüleri, 416×416×3 çözünürlüğünde görseller kullanılmıştır. Eğitim 1000 adımda (epoch) tamamlanmıştır. Her bir adımda 62 iterasyon kullanılmıştır. Algoritmada kullanılan parametreler Tablo 5.8’de verilmiştir.

Tablo 5.8 : YOLO-V4 model parametreleri

Parametreler	Değerleri
Öğrenme Oranı (Learning Rate)	0.00261
Adım (Epoch)	1000
Optimize Edici (Optimizer)	Adam
Grup Boyutu (Batch Size)	32
Alt Bölümler (Subdivisions)	16
Momentum Değeri	0.949
Azalma (Decay)	0.0005
Aktivasyon Fonksiyonu	Mish
Giriş Görüntü Boyutu	[416,416,3]
Veri Artırma	Yatay, dikey , 90-180 ve 270 derece döndürme

Yapay zekâ modelinin eğitimi tamamlandıktan sonra test verileri ile test edilmektedir. Test edilen modelin performans metriklerini belirlemek amacıyla farklı performans metrikleri kullanılmıştır.

GP (Gerçek Pozitif - True Positive): Gerçekte pozitif olan bir görüntünün doğru bir şekilde pozitif olarak tahmin edilmesine denir. Örneğin; metal görüntüsünün, metal olarak tahmin edilmesidir.

GN (Gerçek Negatif – True Negative): Gerçekte negatif olan bir görüntünün doğru bir şekilde negatif olarak tahmin edilmesine denir. Örneğin; metal görüntüsünün, karton, cam ya da plastik olmadığını tahmin edilmesidir.

YP (Yanlış Pozitif - False Positive): Gerçekte negatif olan bir görüntünün yanlış bir şekilde pozitif olarak tahmin edilmesine denir. Örneğin; metal görüntüsünün, karton, cam ya da plastik sınıflarından biri olduğu tahmin edilir (Aslında yanlış bir tahminde bulunulur).

YN (Yanlış Negatif – False Negative): Gerçekte pozitif olan bir görüntünün yanlış bir şekilde negatif olarak tahmin edilmesine denir. Örneğin; metal görüntüsü olan bir nesnenin, karton, cam ya da plastik olduğunu tahmin etmektedir.

Çalışmada kullanılan karışıklık matrisi ve performans metrikleri Şekil 5.2’de tablo şeklinde özet olarak gösterilmektedir.

		Tahmin Edilen Sınıf		
		Pozitif	Negatif	
Gerçek Sınıf	Pozitif	Gerçek Pozitif	Yanlış Negatif	Duyarlılık $\frac{GP}{GP+YN}$
	Negatif	Yanlış Pozitif	Gerçek Negatif	Özgüllük $\frac{GN}{GN+YP}$
		Kesinlik $\frac{GP}{GP+YP}$	Negatif Öngörü Değeri $\frac{GN}{GN+YN}$	Doğruluk $\frac{GP+GN}{GP+GN+YP+YN}$

Şekil 5.2 : Karışıklık matrisi ve performans metrikleri denklemleri

Ortalama Hassasiyet (AP), sınıflandırma modelinin kesinlik-hassasiyet eğrisi altındaki alanı ifade etmektedir. AP hesaplama formülü denklem 5.1’de gösterilmiştir.

$$AP = \int_0^1 P(y)dy \quad (5.1)$$

Ortalama Hassasiyetlerin Ortalaması (mAP), farklı sınıflar için hesaplanan AP değerlerinin ortalamasını ifade etmektedir. mAP hesaplama formülü denklem 5.2’de

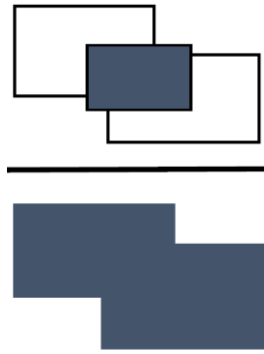
gösterilmiştir. Denklem 5.2'deki n her bir sınıfı, N ise toplam sınıf sayısını göstermektedir.

$$mAP = \frac{\sum_n^N AP_n}{N} \quad (5.2)$$

F1 – puanı, 0-1 arasında değer alan ve modelin sınıflandırma performansını gösteren puandır. Eğitilen model 1'e ne kadar yakınsa modelin gerçek pozitifleri tespit etme yeteneği o kadar yüksektir. F1-puanı hesaplama formülü Denklem 5.3'de gösterilmiştir.

$$F1 - Puanı = 2 * \frac{Kesinlik * Duyarlılık}{Kesinlik + Duyarlılık} \quad (5.3)$$

Alan Birleşme Oranı (IoU), her bir sınırlayıcı kutu için tahmin edilen sınırlayıcı kutu ile gerçek sınırlayıcı kutu arasındaki örtüşmeyi ölçmek için kullanılan metriktir. IoU yapısı Şekil 5.3'de gösterilmiştir.

$$IoU = \frac{Kesişme Alanı}{Birleşme Alanı} =$$


Şekil 5.3 : IoU Yapısı

Model eğitimleri esnasında elde edilen doğruluk (accuracy), doğrulama doğruluğu (validation accuracy), kayıp (loss) ve doğrulama kaybı (validation loss) sonuçları Tablo 5.9'da gösterilmiştir. Tablo 5.9'da gösterilen eğitim performans sonuçlarına bakıldığında YOLO-V4 modelinin YOLO-V4 tiny modeline göre doğruluğunun yüksek kaybının daha düşük olduğu görülmektedir.

Tablo 5.9 : Eğitim Performans sonuçları

Model	Doğruluk	Doğrulama Doğruluğu	Kayıp	Doğrulama Kaybı
YOLO-V4 tiny	0.9265	0.9296	0.7984	0.7565
YOLO-V4	0.9571	0.9587	0.7798	0.7307

Eğitim sonunda elde edilen model, yapay zekanın daha önce hiç görmediği test görüntüleri ile testler gerçekleştirilmiş olup elde edilen başarımların performans sonuçları Tablo 5.10’da gösterilmiştir.

Tablo 5.10 : Test veri setinden elde edilen başarımların performansları

Model	Sınıflar	GP	GN	AP(%)
YOLOv4-Tiny	Karton	547	131	84
	Metal	276	120	62
	Cam	397	101	92
	Plastik	305	97	90
	Karton	558	120	87
YOLOv4	Metal	294	102	68
	Cam	412	86	96
	Plastik	339	63	95

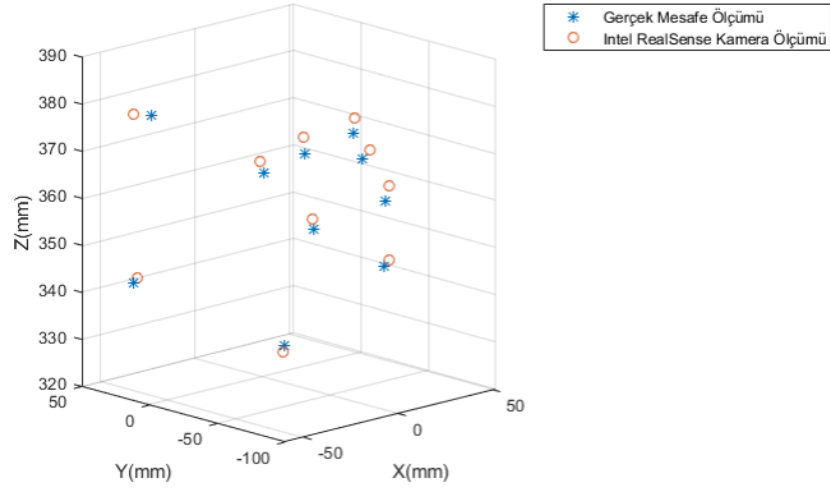
Tablo 5.10’den anlaşılacağı üzere genel olarak YOLO-V4 algoritması sonucunda elde edilen performans başarımları YOLO-V4 tiny’e göre oldukça başarılı olduğu görülmektedir. Özellikle YOLO-V4’ün GP ve GN değerlerinin yüksek olması bu algoritmanın nesnelere o derece başarılı bir şekilde doğru tespit ettiğini göstermektedir.

Tablo 5.11 : Test başarımların performansları

Models	Duyarlılık	Keskinlik	F1	IoU(%)	mAP(%)
YOLO-V4 tiny	0.91	0.63	0.74	74.56	81.56
YOLO-V4	0.90	0.91	0.92	78.36	86.5

Tablo 5.11’de YOLO modellerinin test başarımların performans sonuçları görülmektedir. Elde edilen sonuçlara bakıldığında eğitilen YOLO-V4 modelin atık ayrıştırma sisteminde kullanılabilir olduğu görülmektedir.

YOLO ile atık tespitinin ardından tespit edilen atığın 3 boyutlu konumunun tespit edilmesi için Intel RealSense kamerası kullanılmış ve ölçüm başarısını hesaplamak için Şekil 3.10’da gösterilen ölçüm küpü oluşturulmuştur. Bölüm 3’de ayrıntılı anlatılan kamera ölçüm sisteminde nesnelere, kamera vasıtasıyla ne kadar hassas ölçüldüğünü belirlemek için kamera görüş açısında 10 farklı konumda nesnelere konulmuş olup ve hepsinin gerçek koordinatları ve kameranın ölçtüğü koordinatlar hesaplanmıştır. Kamera ölçüm sisteminde eklenen cisimlerin gerçek koordinatları ve kameranın ölçtüğü koordinatlar Şekil 5.4’de gösterilmiştir.



Şekil 5.4 : Nesnelerin gerçek koordinatları ve kamera ölçüm koordinatları

Yapılan ölçümler sonrasında cisimlerin hatalı ölçüm miktarları hesaplanmış olup Tablo 5.12’de gösterilmiştir. Tablo 5.12’ de gösterilen değerlere bakıldığında kameranın ortalama 2.52 mm hata ile ölçtüğü hesaplanmış olup tez kapsamında yapılan çalışma için tolere edilebilecek bir hata oranına sahip olduğu tespit edilmiştir.

Tablo 5.12 : Kamera ölçüm hata değerleri

Kamera Eksenleri	Hata Değerleri
X eksen	3.17 mm
Y eksen	2.16 mm
Z eksen	2.23 mm
Ortalama	2.52 mm

5.3. Genel Değerlendirme ve Öneriler

Genel olarak tez kapsamında geliştirilen sistemde endüstriyel robot kullanılarak geri dönüştürülebilir malzemelerin ayrıştırılması için bir prototip düzenek oluşturulmuştur. Bu prototip düzenek üzerinde insan-robot etkileşimi ile atıkların bırakılacağı konumu belirlemek ve robotun patikasını planlamak için yeni bir yazılım geliştirilmiştir. Myo Armband ve Leap Motion sensörlerini içeren bu yazılımda EMG verileri kullanılarak el hareketleri olan “tutma” ve “bırakma” hareketleri sınıflandırılmıştır. Verilerin sınıflandırılmasında DVM, RO ve k-NN algoritmaları kullanılmış ve RO algoritması %96.9 ile en yüksek sınıflandırma başarısını göstermiştir.

Robot patikasının belirlenmesi için Leap Motion sensörü kullanarak parmak pozisyon ölçümü gerçekleştirilmiştir. Parmak pozisyon ölçüm sonucunda robotun gideceği patika 2.44 – 2.85 mm arasında hata ile belirlenebilmektedir.

Çalışmanın diğer kısmında, hareketli konveyör üzerinden endüstriyel robotun atığı ayrıştırması gerçekleştirilmiş, YOLO-V4 VE YOLO-V4 tiny derin öğrenme modelleri kullanılmıştır. YOLO-V4 gerçekleştirilen testler sonucunda daha yüksek performans gösterdiği hesaplanmıştır.

Bu tez çalışmasında, geliştirilen prototip düzenek ve kullanılan yazılımların, geri dönüşüm tesislerini optimize etme ve hızlandırma potansiyeli olduğu gösterilmiştir. Ayrıca tez çalışması, gerçek zamanlı atık tespit ve ayrıştırma sistemleri, insan-robot etkileşimi ve yapay zeka algoritmaların endüstriyel robotik uygulamalarına entegrasyonu konularına önemli katkılar sağlamıştır. Sonuç olarak, bu çalışmanın, endüstriyel atık yönetimi ve robotik teknolojileri alanlarında önemli bir referans olabileceği düşünülmektedir.

İlerleyen çalışmalarda mevcut sistemi geliştirmeye yönelik birtakım iyileştirmeler olacağı öngörülmektedir:

- Yazılım Geliştirme : Mevcut yazılım EMG verilerini kullanarak el hareketlerini sınıflandırmaktadır. Ancak, yazılımın doğruluğunun artırılması ve farklı hareketleri sınıflandırma yeteneğini iyileştirilmesi gerekmektedir. Bunun için daha fazla veri toplanması, farklı veri ön işleme tekniklerinin uygulanması ve daha gelişmiş sınıflandırma algoritmalarının uygulanması planlanmaktadır.
- Patika Planlama : Leap motion sensörü kullanılarak parmak pozisyonlarından elde edilen verilerle robotun gideceği patika belirlenmektedir. Ancak belirlenen hata oranları dikkate alındığında, yörünge belirleme doğruluğunun artırılması önemli olacaktır. Bu sebeple, yüksek hassasiyet gerektiren gelecek çalışmalarda daha gelişmiş sensör teknolojileri veya başka bir veri işleme tekniği geliştirilmesi planlanmaktadır.
- Atık Ayrıştırma Sistemi : Yapılan sistemde hareketli konveyör üzerinden endüstriyel robotun atık ayrıştırması sağlanmıştır. Tez kapsamında atık tespiti için YOLO-V4 ve YOLO-V4 tiny modelleriyle eğitim sağlanmıştır. Daha doğru

ve daha hızlı atık tespiti için farklı derin öğrenme modellerinin geliştirilmesi planlanmaktadır.

- Optimizasyon ve Entegrasyon : Tez kapsamında geliştirilen prototip düzenek ve geliştirilen yazılımların geri dönüşüm tesislerinde atık ayrıştırmanın hızlandırma potansiyelini ortaya koymuştur. Gelecek çalışmalarda birden fazla robotun entegrasyonu ile görev dağılımı algoritmalarıyla sistemi optimize etme ve farklı atık türlerinin tespit edilerek sistemi daha verimli hale getirilmesi planlanmaktadır.



KAYNAKLAR

- Alaimo, A., Esposito, A., Faraci, P., Orlando, C., & Valenti, G. D. (2022). Human Heart-Related Indexes Behavior Study for Aircraft Pilots Allowable Workload Level Assessment. *IEEE Access*, 10, 16088-16100.
- Alkan, A., & Günay, M. (2012). Identification of EMG signals using discriminant analysis and SVM classifier. *Expert systems with Applications*, 39(1), 44-47.
- Al-Mulla, M. R., Sepulveda, F., & Colley, M. (2011). A review of non-invasive techniques to detect and predict localised muscle fatigue. *Sensors*, 11(4), 3545-3594.
- Artemiadis, P. K., & Kyriakopoulos, K. J. (2010). EMG-based control of a robot arm using low-dimensional embeddings. *IEEE transactions on robotics*, 26(2), 393-398.
- Benatti, S., Casamassima, F., Milosevic, B., Farella, E., Schönle, P., Fateh, S., ... & Benini, L. (2015). A versatile embedded platform for EMG acquisition and gesture recognition. *IEEE transactions on biomedical circuits and systems*, 9(5), 620-630.
- Bian, Y., Wang, X., Zhao, L., & Cui, S. (2016, October). A new control system for space robot based on brain-computer interfaces. In *2016 IEEE Advanced Information Management, Communicates, Electronic and Automation Control Conference (IMCEC)* (pp. 232-236). IEEE.
- Bochkovskiy, A., Wang, C. Y., & Liao, H. Y. M. (2020). *Yolov4: Optimal speed and accuracy of object detection*. arXiv preprint arXiv:2004.10934.
- Boru, B., & Erin, K. (2022). Novel technique for control of industrial robots with wearable and contactless technologies. *Measurement*, 192, 110850.
- Bozma, H. I., Yalçın, H. (2002). Visual processing and classification of items on a moving conveyor: a selective perception approach. *Robotics and Computer-Integrated Manufacturing*, 18(2), 125-133.
- Briouza, S., Gritli, H., Khraief, N., Belghith, S., & Singh, D. (2022, March). Emg signal classification for human hand rehabilitation via two machine learning techniques: knn and svm. In *2022 5th International Conference on Advanced Systems and Emergent Technologies (IC_ASET)* (pp. 412-417). IEEE.
- Calderon-Cordova, C., Ramírez, C., Barros, V., Quezada-Sarmiento, P. A., & Barba-Guamán, L. (2016, December). EMG signal patterns recognition based on

- feedforward Artificial Neural Network applied to robotic prosthesis myoelectric control. *In 2016 Future Technologies Conference (FTC)* (pp. 868-875). IEEE.
- Cao, B., Zhan, D., & Wu, X. (2009, April). Application of svm in financial research. *In 2009 International Joint Conference on Computational Sciences and Optimization* (Vol. 2, pp. 507-511). IEEE.
- Cao, C., & Ouyang, Q. (2019). 2D rotation-angle measurement utilizing least iterative region segmentation. *Sensors*, 19(7), 1634.
- Cao, L., & Xiang, W. (2020, June). Application of convolutional neural network based on transfer learning for garbage classification. *In 2020 IEEE 5th Information Technology and Mechatronics Engineering Conference (ITOEC)* (pp. 1032-1036). IEEE.
- Cao, W. (2019). Application of support vector machine algorithm based gesture recognition technology in human-computer interaction. *Informatica*, 43(1).
- Carfagni, M., Furferi, R., Governi, L., Santarelli, C., Servi, M., Ucheddu, F., & Volpe, Y. (2019). Metrological and critical characterization of the Intel D415 stereo depth camera. *Sensors*, 19(3), 489.
- Cheng, X., Hu, F., Song, L., Zhu, J., Ming, Z., Wang, C., ... & Ruan, Y. (2022). A Novel Recyclable Garbage Detection System for Waste-to-energy Based On Optimized CenterNet With Feature Fusion. *Journal of Signal Processing Systems*, 1-10.
- Chu, Y., Huang, C., Xie, X., Tan, B., Kamal, S., Xiong, X. (2018). Multilayer hybrid deep-learning method for waste classification and recycling. *Computational Intelligence and Neuroscience*, 2018.
- Coito, A., Michel, C. M., Van Mierlo, P., Vulliemoz, S., & Plomp, G. (2016). Directed functional brain connectivity based on EEG source imaging: methodology and application to temporal lobe epilepsy. *IEEE Transactions on Biomedical Engineering*, 63(12), 2619-2628.
- Cong, G. (2022, June). Research on fingertip positioning and human-computer interaction technology based on stereo vision. *In Proceedings of the 2022 2nd International Conference on Control and Intelligent Robotics* (pp. 117-121).
- Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine learning*, 20, 273-297.
- Crone, C., & Krarup, C. (2013). Neurophysiological approach to disorders of peripheral nerve. *Handbook of clinical neurology*, 115, 81-114.
- Curiel-Razo, Y. I., Icasio-Hernández, O., Sepúlveda-Cervantes, G., Hurtado-Ramos, J. B., & González-Barbosa, J. J. (2016). Leap motion controller three dimensional verification and polynomial correction. *Measurement*, 93, 258-264.

- Çakar, T., Köker, R., Demir, H. İ. (2008). Parallel robot scheduling to minimize mean tardiness with precedence constraints using a genetic algorithm. *Advances in Engineering Software*, 39(1), 47-54.
- Daoud, S., Chehade, H., Yalaoui, F., Amodeo, L. (2014). Efficient metaheuristics for pick and place robotic systems optimization. *Journal of Intelligent Manufacturing*, 25(1), 27-41.
- Dewi, C., Chen, R. C., Jiang, X., & Yu, H. (2022). Deep convolutional neural network for enhancing traffic sign recognition developed on Yolo V4. *Multimedia Tools and Applications*, 81(26), 37821-37845.
- Edan, Y., Berman, S., Boteach, E., Mendelson, E. (2004). Distributed multi-robot assembly/packaging algorithms. *Intelligent Automation & Soft Computing*, 10(4), 349-357.
- Elrabaya, D. T. D. (2021). Can the new waste morphology method predict sorting plants operational and financial challenges? A case study in Sharjah. *Environmental Research, Engineering and Management*, 77(2), 19-36.
- Erin, K., KUTLU, M. Ç., & Boru, B. (2022). Comparison of gesture classification methods with contact and non-contact sensors for human-computer interaction. *Sigma Journal of Engineering and Natural Sciences*, 40(2), 219-226.
- Fanthony, I. V., Husin, Z., Hikmarika, H., Dwijayanti, S., & Suprpto, B. Y. (2021, October). YOLO Algorithm-Based Surrounding Object Identification on Autonomous Electric Vehicle. In *2021 8th International Conference on Electrical Engineering, Computer Science and Informatics (EECSI)* (pp. 151-156). IEEE.
- Fu, H., Xu, D., & Wu, J. (2021, October). Robotic Arm Intelligent Grasping System for Garbage Recycling. In *2021 China Automation Congress (CAC)* (pp. 6821-6826). IEEE.
- Gao, Y., & Zhang, Y. (2022). Path Optimization of Welding Robot Based on Ant Colony and Genetic Algorithm. *Journal of Applied Mathematics*, 2022.
- Geethanjali, P. (2015). Comparative study of PCA in classification of multichannel EMG signals. *Australasian physical & engineering sciences in medicine*, 38, 331-343.
- Gokgoz, E., & Subasi, A. (2015). Comparison of decision tree algorithms for EMG signal classification using DWT. *Biomedical Signal Processing and Control*, 18, 138-144.
- Gundupalli, S. P., Shukla, R., Gupta, R., Hait, S., & Thakur, A. (2021). Optimal Sequence Planning for Robotic Sorting of Recyclables From Source-Segregated Municipal Solid Waste. *Journal of Computing and Information Science in Engineering*, 21(1).

- Hassan, H. F., Abou-Loukh, S. J., & Ibraheem, I. K. (2020). Teleoperated robotic arm movement using electromyography signal with wearable Myo armband. *Journal of King Saud University-Engineering Sciences*, 32(6), 378-387.
- Hu, X., Liu, Y., Zhao, Z., Liu, J., Yang, X., Sun, C., ... & Zhou, C. (2021). Real-time detection of uneaten feed pellets in underwater images for aquaculture using an improved YOLO-V4 network. *Computers and Electronics in Agriculture*, 185, 106135.
- Iqbal, A., Shafie, A. A., Khan, M. R., Alias, M. F., & Radhi, J. (2011). HRI for Interactive Humanoid Head Amir-II for Visual Tracking and Servoing of Human Face. *International Journal of Robotics and Automation (IJRA)*, 2(3), 220-231.
- Jain, R., & Garg, V. K. (2021). Review of EMG Signal Classification Approaches Based on Various Feature Domains. *Matter: International Journal of Science and Technology*, 6(3), 123-143.
- Jamal, M. Z. (2012). Signal acquisition using surface EMG and circuit design considerations for robotic prosthesis. *Computational Intelligence in Electromyography Analysis-A Perspective on Current Applications and Future Challenges*, 18, 427-448.
- Jimoh, K., Ajayi, A., Ayilara, O. (2014). Intelligent model for manual sorting of plastic wastes. *International Journal of Computer Applications*, 101(7).
- Ju, Z., Ouyang, G., Wilamowska-Korsak, M., & Liu, H. (2013). Surface EMG based hand manipulation identification via nonlinear feature extraction and classification. *IEEE Sensors Journal*, 13(9), 3302-3311.
- Keselman, L., Iselin Woodfill, J., Grunnet-Jepsen, A., & Bhowmik, A. (2017). Intel realsense stereoscopic depth cameras. *In Proceedings of the IEEE conference on computer vision and pattern recognition workshops* (pp. 1-10).
- Khan, M. U., Aziz, S., Bilal, M., & Aamir, M. B. (2019, August). Classification of EMG signals for assessment of neuromuscular disorder using empirical mode decomposition and logistic regression. *In 2019 International Conference on Applied and Engineering Mathematics (ICAEM)* (pp. 237-243). IEEE.
- Kimyasal Gelişmeler, (2015), Plastik Geri Dönüşümü Nasıl Yapılır. . <http://www.kimyasalgelismeler.com/sectorler/geri-donusum-teknolojisi/plastik-geri-donusumu-nasil-yapilir.html>. Son Erişim Tarihi : 30 Aralık 2022
- Kiyokawa, T., Takamatsu, J., & Koyanaka, S. (2022). Challenges for Future Robotic Sorters of Mixed Industrial Waste: A Survey. *IEEE Transactions on Automation Science and Engineering*. 1-18.
- Korayem, M. H., Madihi, M. A., & Vahidifar, V. (2021). Controlling surgical robot arm using leap motion controller with Kalman filter. *Measurement*, 178, 109372
- Kuang, D., Yang, C., Wang, M., & Peng, G. (2017, October). An improved approach for gesture recognition. *In 2017 Chinese Automation Congress (CAC)* (pp. 4856-4861). IEEE.

- Küçük, H., Tepe, C., & Eminoğlu, İ. (2013, April). Classification of EMG signals by k-Nearest Neighbor algorithm and Support vector machine methods. *In 2013 21st Signal Processing and Communications Applications Conference (SIU)* (pp. 1-4). IEEE.
- Kucukyildiz, G., Ocak, H., Karakaya, S., & Sayli, O. (2017). Design and implementation of a multi sensor based brain computer interface for a robotic wheelchair. *Journal of Intelligent & Robotic Systems*, 87(2), 247-263.
- Li, J., Zhao, H., Jiang, T., & Zhou, X. (2008). Development of a 3D high-precise positioning system based on a planar target and two CCD cameras. *In Intelligent Robotics and Applications: First International Conference, ICIRA 2008 Wuhan, China, October 15-17, 2008 Proceedings, Part II 1* (pp. 475-484). Springer Berlin Heidelberg.
- Liu, J., Balatti, P., Ellis, K., Hadjivelichkov, D., Stoyanov, D., Ajoudani, A., & Kanoulas, D. (2021, July). Garbage collection and sorting with a mobile manipulator using deep learning and whole-body control. *In 2020 IEEE-RAS 20th International Conference on Humanoid Robots (Humanoids)* (pp. 408-414). IEEE.
- Lucas, M. F., Gaufriau, A., Pascual, S., Doncarli, C., & Farina, D. (2008). Multi-channel surface EMG classification using support vector machines and signal-based wavelet optimization. *Biomedical Signal Processing and Control*, 3(2), 169-174.
- Lu, Q., & Yuan, Y. (2020). Improved YOLO algorithm for object detection in traffic video. *In Communications, Signal Processing, and Systems: Proceedings of the 8th International Conference on Communications, Signal Processing, and Systems* (pp. 1647-1655). Springer Singapore.
- Lu, Z., Chen, X., Li, Q., Zhang, X., & Zhou, P. (2014). A hand gesture recognition framework and wearable gesture-based interaction prototype for mobile devices. *IEEE transactions on human-machine systems*, 44(2), 293-299.
- Lu, Z., & Zhou, P. (2019). Hands-free human-computer interface based on facial myoelectric pattern recognition. *Frontiers in neurology*, 10, 444.
- Luo, Z., Han, S., & Duan, F. (2015, December). The development of a smart house system based on Brain-Computer Interface. *In 2015 IEEE International Conference on Robotics and Biomimetics (ROBIO)* (pp. 1012-1017). IEEE.
- Luo, R. C., & Liao, C. H. (2017, July). Robotic conveyor tracking with dynamic object fetching for industrial automation. *In 2017 IEEE 15th International Conference on Industrial Informatics (INDIN)* (pp. 369-374). IEEE.
- Mandel, C., Rofer, T., & Frese, U. (2007, June). Applying a 3dof orientation tracker as a human-robot interface for autonomous wheelchairs. *In 2007 IEEE 10th International Conference on Rehabilitation Robotics* (pp. 52-59). IEEE.

- Meattini, R., Benatti, S., Scarcia, U., De Gregorio, D., Benini, L., & Melchiorri, C. (2018). An sEMG-based human–robot interface for robotic hands using machine learning and synergies. *IEEE Transactions on Components, Packaging and Manufacturing Technology*, 8(7), 1149-1158.
- Meng, S., & Chu, W. T. (2020, February). A study of garbage classification with convolutional neural networks. *In 2020 Indo–Taiwan 2nd International Conference on Computing, Analytics and Networks (Indo-Taiwan ICAN)* (pp. 152-157). IEEE.
- Mishra, S. P., Sarkar, U., Taraphder, S., Datta, S., Swain, D., Saikhom, R., ... & Laishram, M. (2017). Multivariate statistical data analysis-principal component analysis (PCA). *International Journal of Livestock Research*, 7(5), 60-78.
- Mizrahi, D., Zuckerman, I., & Laufer, I. (2020). Using a stochastic agent model to optimize performance in divergent interest tacit coordination games. *Sensors*, 20(24), 7026.
- Mokled, E., Chartouni, G., Kassis, C., Rizk, R. (2019). Parallel Robot Integration and Synchronization in a Waste Sorting System. *In Mechanism, Machine, Robotics and Mechatronics Sciences* (pp. 171-187). Springer, Cham.
- Naveed, K., Iqbal, J., & ur Rehman, H. (2012, October). Brain controlled human robot interface. *In 2012 International Conference of Robotics and Artificial Intelligence* (pp. 55-60). IEEE.
- Neto, P., Pires, J. N., & Moreira, A. P. (2010). High-level programming and control for industrial robotics: using a hand-held accelerometer-based input device for gesture and posture recognition. *Industrial Robot: An International Journal*. 37(2):137-147
- Nia, N. G., Kaplanoglu, E., & Nasab, A. (2023, April). EMG-Based Hand Gestures Classification Using Machine Learning Algorithms. *In SoutheastCon 2023* (pp. 787-792). IEEE.
- Nishiuchi, N., Komatsu, S., & Yamanaka, K. (2010). Biometric verification using the motion of fingers: a combination of physical and behavioural biometrics. *International Journal of Biometrics*, 2(3), 222-235.
- Nonoyama, K., Liu, Z., Fujiwara, T., Alam, M. M., & Nishi, T. (2022). Energy-efficient robot configuration and motion planning using genetic algorithm and particle swarm optimization. *Energies*, 15(6), 2074.
- Özkan, K., Ergin, S., Işık, Ş., & Işıklı, İ. (2015). A new classification scheme of plastic wastes based upon recycling labels. *Waste Management*, 35, 29-35.
- Pan, Z. (2022, February). Research on Improved Yolo on Garbage Classification Task. *In 2022 IEEE International Conference on Electrical Engineering, Big Data and Algorithms (EEBDA)* (pp. 951-953). IEEE.
- Panyavaraporn, J., Chaimongkol, N., Limsomnuek, N., Wasayangkul, W., Charoenwattana, N., & Horkaew, P. (2021, May). Dual Mode Controlled Water

- Surface Garbage Collecting Robot by using Embedded Deep Learning. *In 2021 18th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-CON)* (pp. 14-17). IEEE.
- Park, H., & Kim, D. (2020). An open-source anthropomorphic robot hand system: HRI hand. *HardwareX*, 7, e00100.
- Phinyomark, A., Hirunviriya, S., Nuidod, A., Phukpattaranont, P., & Limsakul, C. (2011). Evaluation of EMG feature extraction for movement control of upper limb prostheses based on class separation index. *In 5th Kuala Lumpur International Conference on Biomedical Engineering 2011: (BIOMED 2011)* 20-23 June 2011, Kuala Lumpur, Malaysia (pp. 750-754). Springer Berlin Heidelberg.
- Prajapati, G. L., & Patle, A. (2010, November). On performing classification using SVM with radial basis and polynomial kernel functions. *In 2010 3rd International Conference on Emerging Trends in Engineering and Technology* (pp. 512-515). IEEE.
- Proença, P. F., & Simoes, P. (2020). *Taco: Trash annotations in context for litter detection*. arXiv preprint arXiv:2003.06975.
- Rahim, M. A., Rasool, G., & Ahmad, N. (2017). EMG-controlled transradial prostheses-an investigation into machine learning techniques. *International Journal of Computer Applications*, 174(3), 1-8.
- Rani, M., Marchesi, C., Federici, S., Rovelli, G., Alessandri, I., Vassalini, I., Bontempi, E. (2019). Miniaturized Near-Infrared (MicroNIR) Spectrometer in Plastic Waste Sorting. *Materials*, 12(17), 2740.
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You only look once: Unified, real-time object detection. *In Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 779-788).
- Redmon, J., & Farhadi, A. (2017). YOLO9000: better, faster, stronger. *In Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 7263-7271).
- Redmon, J., & Farhadi, A. (2018). *Yolov3: An incremental improvement*. arXiv preprint arXiv:1804.02767.
- Reuschenbach, A., Wang, M., Ganjineh, T., & Gohring, D. (2011, April). iDriver-human machine interface for autonomous cars. *In 2011 Eighth International Conference on Information Technology: New Generations* (pp. 435-440). IEEE.
- Rivera-Alvidrez, Z., Kalmar, R. S., Ryu, S. I., & Shenoy, K. V. (2010, August). Low-dimensional neural features predict muscle EMG signals. *In 2010 Annual International Conference of the IEEE Engineering in Medicine and Biology* (pp. 6027-6033). IEEE.

- Roh, S. B., Park, S. B., Oh, S. K., Park, E. K., Choi, W. Z. (2018). Development of intelligent sorting system realized with the aid of laser-induced breakdown spectroscopy and hybrid preprocessing algorithm-based radial basis function neural networks for recycling black plastic wastes. *Journal of Material Cycles and Waste Management*, 20(4), 1934-1949.
- Sae-lim, W., Phukpattaranont, P., & Thongpull, K. (2018, July). Effect of electrode skin impedance on electromyography signal quality. In *2018 15th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-CON)* (pp. 748-751). IEEE.
- Saggio, G., Bocchetti, S., Pinto, C. A., & Orengo, G. (2010, November). Wireless data glove system developed for HMI. In *2010 3rd International Symposium on Applied Sciences in Biomedical and Communication Technologies (ISABEL 2010)* (pp. 1-5). IEEE.
- Saleh, M., Takahashi, K., Amit, Y., & Hatsopoulos, N. G. (2010). Encoding of coordinated grasp trajectories in primary motor cortex. *Journal of Neuroscience*, 30(50), 17079-17090.
- Sasaki, A., Hashimoto, H., Yokota, S., & Ohyama, Y. (2009). Finger pose estimation based on anatomical motion constraints. *SICE Journal of Control, Measurement, and System Integration*, 2(6), 357-364.
- Scavino, E., Wahab, D. A., Hussain, A., Basri, H., Mustafa, M. M. (2009). Application of automated image analysis to the identification and extraction of recyclable plastic bottles. *Journal of Zhejiang University SCIENCE A*, 10(6), 794-799.
- Sharma, S., Kumar, G., Kumar, S., & Mohapatra, D. (2012). Techniques for feature extraction from EMG signal. *International Journal of Advanced Research in Computer Science and Software Engineering*, 2(1).
- Shenoy, S. (2010). EMG in sports rehabilitation. *British Journal of Sports Medicine*, 44(Suppl 1), i10-i10.
- Shin, S. O., Kim, D., & Seo, Y. H. (2014, November). Controlling mobile robot using imu and emg sensor-based gesture recognition. In *2014 Ninth International Conference on Broadband and Wireless Computing, Communication and Applications* (pp. 554-557). IEEE.
- Simone, L. K., & Kamper, D. G. (2005). Design considerations for a wearable monitor to measure finger posture. *Journal of NeuroEngineering and Rehabilitation*, 2(1), 1-10.
- Siregar, B., Sitompul, O. S., & Zarlis, M. (2021, March). Development of electromyography signal function to control robot arm working adaptively in the reverse direction of the human arm movement. In *IOP Conference Series: Materials Science and Engineering* (Vol. 1115, No. 1, p. 012010). IOP Publishing.

- Sueaseenak, D., Chanwimalueang, T., Pintavirooj, C., & Sangworasil, M. (2013). An accurate forearm EMG signal classification method using two-channel electrode. *IEEE transactions on electrical and electronic engineering*, 8(4), 328-338.
- Sun, L., Zhao, C., Yan, Z., Liu, P., Duckett, T., Stolkin, R. (2018). A novel weakly-supervised approach for RGB-D-based nuclear waste object detection. *IEEE Sensors Journal*, 19(9), 3487-3500.
- Sun, Y., Xu, C., Li, G., Xu, W., Kong, J., Jiang, D., ... & Chen, D. (2020). Intelligent human computer interaction based on non redundant EMG signal. *Alexandria Engineering Journal*, 59(3), 1149-1157.
- Squire, J. (2019). The actin-myosin interaction in muscle: Background and overview. *International Journal of Molecular Sciences*, 20(22), 5715.
- Tanaka, K., Matsunaga, K., & Wang, H. O. (2005). Electroencephalogram-based control of an electric wheelchair. *IEEE transactions on robotics*, 21(4), 762-766.
- Tatzer, P., Wolf, M., Panner, T. (2005). Industrial application for inline material sorting using hyperspectral imaging in the NIR range. *Real-Time Imaging*, 11(2), 99-107.
- Tian, Z., Sun, D., Yu, C., Li, J., Ma, G., & Xia, H. (2021, July). Garbage Classification Algorithm Based on Deep Learning. In *2021 40th Chinese Control Conference (CCC)* (pp. 8199-8203). IEEE.
- Tölgyessy, M., Dekan, M., Rodina, J., & Duchoň, F. (2023). Analysis of the Leap Motion Controller Workspace for HRI Gesture Applications. *Applied Sciences*, 13(2), 742.
- Tsai, T. H., Huang, C. C., & Zhang, K. L. (2020). Design of hand gesture recognition system for human-computer interaction. *Multimedia tools and applications*, 79(9), 5989-6007.
- Tsui, C. S. L., Jia, P., Gan, J. Q., Hu, H., & Yuan, K. (2007, December). EMG-based hands-free wheelchair control with EOG attention shift detection. In *2007 IEEE International Conference on Robotics and Biomimetics (ROBIO)* (pp. 1266-1271). IEEE.
- Valentini, P. P., & Pezzuti, E. (2017). Accuracy in fingertip tracking using leap motion controller for interactive virtual applications. *International Journal on Interactive Design and Manufacturing (IJIDeM)*, 11, 641-650.
- Vaswani, N., Chi, Y., & Bouwmans, T. (2018). Rethinking PCA for modern data sets: Theory, algorithms, and applications [scanning the issue]. *Proceedings of the IEEE*, 106(8), 1274-1276.
- Vieira, T. M., & Botter, A. (2021). The accurate assessment of muscle excitation requires the detection of multiple surface electromyograms. *Exercise and Sport Sciences Reviews*, 49(1), 23-34.

- Wilts, H., Garcia, B. R., Garlito, R. G., Gómez, L. S., & Prieto, E. G. (2021). Artificial intelligence in the sorting of municipal waste as an enabler of the circular economy. *Resources*, 10(4), 28.
- Wang, J., Gao, Z., Zhang, Y., Zhou, J., Wu, J., & Li, P. (2022). Real-time detection and location of potted flowers based on a ZED camera and a YOLO V4-tiny deep learning algorithm. *Horticulturae*, 8(1), 21.
- Wang, J., Tang, L., & Bronlund, J. E. (2013). Surface EMG signal amplification and filtering. *International Journal of Computer Applications*, 82(1).
- Wang, Z., Peng, B., Huang, Y., & Sun, G. (2019). Classification for plastic bottles recycling based on image recognition. *Waste management*, 88, 170-181.
- Wijnen, L., Lemaignan, S., & Bremner, P. (2020, March). Towards using virtual reality for replicating HRI studies. In *Companion of the 2020 ACM/IEEE International Conference on Human-Robot Interaction* (pp. 514-516).
- Wu, Y., Martínez, M. Á. M., & Balaguer, P. O. (2013). *Overview of the Application of EMG Recording in the Diagnosis and Approach of Neurological Disorders* (Vol. 10, p. 5772). London, UK: IntechOpen.
- Xue, C., Qiao, Y., & Murray, N. (2020, August). Enabling human-robot-interaction for remote robotic operation via augmented reality. In *2020 IEEE 21st International Symposium on A World of Wireless, Mobile and Multimedia Networks (WoWMoM)* (pp. 194-196). IEEE.
- Yan, S., Yao, L., Zhang, Y. (2019, October). Design of Industrial Robot Sorting System Based on Smart Camera. In *2019 International Conference on Artificial Intelligence and Advanced Manufacturing (AIAM)* (pp. 652-655). IEEE.
- Yang, G., Jin, J., Lei, Q., Wang, Y., Zhou, J., Sun, Z., ... & Wang, W. (2021, October). Garbage Classification System with YOLOV5 Based on Image Recognition. In *2021 IEEE 6th International Conference on Signal and Image Processing (ICSIP)* (pp. 11-18). IEEE.
- Yılmaz, G.(2019). *Contamination of the EEG by Postural Activity of Temporalis Muscle: Single Motor Unit Approach to Evaluate the Extent of Muscle Interference*. (Doktora tezi). Koç Üniversitesi, Biomedical sciences and Engineering, İstanbul.
- Yu, N., Xu, C., Wang, K., Yang, Z., & Liu, J. (2015, June). Gesture-based telemanipulation of a humanoid robot for home service tasks. In *2015 IEEE International Conference on Cyber Technology in Automation, Control, and Intelligent Systems (CYBER)* (pp. 1923-1927). IEEE.
- Yun, S. K., & Rus, D. (2014). Distributed coverage with mobile robots on a graph: locational optimization and equal-mass partitioning. *Robotica*, 32(2), 257-277.
- Zakria, Z., Deng, J., Kumar, R., Khokhar, M. S., Cai, J., & Kumar, J. (2022). Multiscale and direction target detecting in remote sensing images via modified YOLO-v4.

IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 15, 1039-1048.

- Zin, T. T., Htet, Y., Akagi, Y., Tamura, H., Kondo, K., Araki, S., & Chosa, E. (2021). Real-time action recognition system for elderly people using stereo depth camera. *Sensors*, 21(17), 5895.
- Zhang, C., Tabor, J., Zhang, J., & Zhang, X. (2015, September). Extending mobile interaction through near-field visible light sensing. In *Proceedings of the 21st Annual International Conference on Mobile Computing and Networking* (pp. 345-357).
- Zhang, X., Chen, X., Wang, W. H., Yang, J. H., Lantz, V., & Wang, K. Q. (2009, February). Hand gesture recognition and virtual game control based on 3D accelerometer and EMG sensors. In *Proceedings of the 14th international conference on Intelligent user interfaces* (pp. 401-406).
- Zhang, Y., Li, L., Ripperger, M., Nicho, J., Veeraraghavan, M., Fumagalli, A. (2018, January). Gilbreth: A conveyor-belt based pick-and-sort industrial robotics application. In *2018 Second IEEE International Conference on Robotic Computing (IRC)* (pp. 17-24). IEEE
- Zhang, X., Zhang, R., Chen, L., & Zhang, X. (2019, April). Natural gesture control of a delta robot using Leap Motion. In *Journal of Physics: Conference Series* (Vol. 1187, No. 3, p. 032042). IOP Publishing.
- Zhao, L., Liu, Y., Wang, K., Liang, P., & Li, R. (2016, June). An intuitive human robot interface for tele-operation. In *2016 IEEE International Conference on Real-time Computing and Robotics (RCAR)* (pp. 454-459). IEEE.
- Zhihong, C., Hebin, Z., Yanbo, W., Binyan, L., Yu, L. (2017, July). A vision-based robotic grasping system using deep learning for garbage sorting. In *2017 36th Chinese Control Conference (CCC)* (pp. 11223- 11226). IEEE.
- Zhi-Xian, Z., & Zhang, F. (2022). Image real-time detection using lse-yolo neural network in artificial intelligence-based internet of things for smart cities and smart homes. *Wireless Communications and Mobile Computing*, 2022.
- Zhu, C., & Sheng, W. (2011). Wearable sensor-based hand gesture and daily activity recognition for robot-assisted living. *IEEE Transactions on Systems, Man, and Cybernetics-Part A: Systems and Humans*, 41(3), 569-573.