

KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

IMU VERİLERİYLE DERİN ÖĞRENME TABANLI HAREKET TANIMA
VE ADAPTİF KAYAN KIPLI KONTROLLÜ PROTEZ AYAK TASARIMI

DOKTORA TEZİ

Selin AYDIN FANDAKLI

MART 2024

TRABZON



KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

**IMU VERİLERİYLE DERİN ÖĞRENME TABANLI HAREKET TANIMA
VE ADAPTİF KAYAN KİPLİ KONTROLLÜ PROTEZ AYAK TASARIMI**

Selin AYDIN FANDAKLI

Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünde
"DOKTOR (ELEKTRİK MÜHENDİSLİĞİ)"
Unvanı Verilmesi İçin Kabul Edilen Tezdir.

Tezin Enstitüye Verildiği Tarih : 16 / 02 / 2024

Tezin Savunma Tarihi : 21 / 03 / 2024

Tez Danışmanı : Prof. Dr. Halil İbrahim OKUMUŞ

Trabzon 2024

ÖNSÖZ

Bu çalışma, ataletsel ölçüm birimlerinden elde edilen veri ve analiz ile desteklenen derin öğrenme tabanlı hareket tanıma ve adaptif kayan kipli kontrollü protez ayak tasarımını ele almaktadır. Bu çalışmanın temel amacı, protez ayakların kullanıcılar tarafından daha doğal ve etkili bir şekilde kullanılmasını sağlamak için yeni bir metodoloji sunmaktır. Aynı zamanda, protez ayak teknolojisinin gelecekteki gelişimine katkıda bulunmayı hedefliyor ve ilerleme ve gelişme için bir temel oluşturarak, protez ayak kullanıcılarının yaşam kalitesini artırmak için yeni ve etkili çözümler geliştirmeyi teşvik etmeyi umuyorum.

Tez çalışmam boyunca hiçbir desteğini esirgemeyen ve kıymetli bilgileriyle ve tecrübesiyle yol gösteren danışman hocam Sayın Prof. Dr. Halil İbrahim OKUMUŞ'a teşekkürü bir borç bilirim. Ayrıca, yapıcı eleştirileri ve önerileri ile tezime büyük katkıları bulunan saygıdeğer hocalarım Sayın Prof. Dr. Murat EKİNCİ'ye ve Sayın Dr. Öğr. Üyesi Hakan KAHVECİ'ye, ortak çalışmalar yürüttüğümüz Doç. Dr. Önder Aydemir'e ve Dr. Öğr. Üyesi Mehmet Öztürk'e ve tez çalışması süresinde hiçbir yardımdan kaçınmayan arkadaşlarım ve hocalarım Doç. Dr. Emre ÖZKOP'a, Doç. Dr. Ergin TÖNÜK'e, Dr. Öğr. Üyesi Zeynep HASIRCI TUĞCU'ya ve Dr. Öğr. Üyesi Ramazan Özgür DOĞAN'a, tezimin her aşamasında danıştığım kuzenim Ahmet Furkan ERDEM'e teşekkür ederim. Tez çalışmam süresince BİDEB 2228-B Yurt İçi Doktora Burs Programı kapsamında maddi olarak beni destekleyen Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK)'a teşekkür etmeyi bir borç bilirim.

Son olarak, her kararında arkamda olan, maddi ve manevi desteklerini hiçbir zaman esirgemeyen ve bugünlere gelmemde en büyük paya sahip olan annem Selma AYDIN'a, babam Bekir AYDIN'a ve kardeşlerim Seda ve Furkan AYDIN'a teşekkür eder, minnettarlığımı sunarım. Bu tez çalışmasını, doktora sürecinde zamanlarını çaldığım kızım Zeynep Asya FANDAKLI ve eşim Emre FANDAKLI'ya armağan ediyorum.

Bu tez çalışmasının bundan sonraki çalışmalara katkı sağlamasını temenni ederim.

Selin AYDIN FANDAKLI

Trabzon 2024

TEZ ETİK BEYANNAMESİ

Doktora Tezi olarak sunduğum “IMU Verileriyle Derin Öğrenme Tabanlı Hareket Tanıma ve Adaptif Kayan Kipli Kontrollü Protez Ayak Tasarımı” başlıklı bu çalışmayı baştan sona kadar danışmanım Prof. Dr. Halil İbrahim Okumuş’un sorumluluğunda tamamladığımı, verileri/örnekleri kendim topladığımı, deneyleri/analizleri ilgili laboratuvarlarda yaptığımı/yaptırdığımı, başka kaynaklardan aldığım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiğimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim. 21/03/2024

Selin AYDIN FANDAKLI

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ	III
TEZ ETİK BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	IV
ÖZET	VII
SUMMARY	VIII
ŞEKİLLER DİZİNİ.....	IX
TABLolar DİZİNİ.....	XIII
SEMBOLLER VE KISALTMALAR DİZİNİ	XIV
1. GENEL BİLGİLER	1
1.1. Giriş	1
1.2. Yürüme Analizi ile İlgili Yapılan Çalışmalar.....	4
1.3. Sınıflandırma ile İlgili Yapılan Çalışmalar	6
1.4. Robot Kontrolü ile İlgili Yapılan Çalışmalar	11
1.5. Ayak Biyomekanikliği.....	16
1.6. Ayak Anatomisi.....	18
1.6.1. Ossa Tarsi ve Ossa Metatarsi	18
1.7. Yürüyüş Analizi.....	19
1.8. Kinematik İnceleme	33
1.8.1. İleri Kinematik.....	35
1.8.2. Ters Kinematik	42
1.8.3. Protez Ayağın İleri ve Ters Kinematik Hesaplamaları.....	43
1.8.3.1. İleri Kinematik Hesaplamaları	43
1.8.3.2. Ters Kinematik Hesaplamaları	47
1.9. Protez Ayağın Mekanik Tasarımı.....	51
1.10. Referans Sinyalin Sınıflandırılması.....	59
1.10.1. Veri Toplama.....	60
1.10.1.1. Ataletsel Ölçüm Birimi.....	63
1.10.2. Öznitelik Çıkarma.....	71
1.10.3. Sınıflandırma	73
1.10.3.1. Karar Ağaçları	73

1.10.3.2. Lineer Diskriminant Analizi	74
1.10.3.3. Naïve Bayes Sınıflandırıcı	75
1.10.3.4. K-En Yakın Komşu Sınıflandırıcı	76
1.10.3.5. Destek Vektör Makineleri.....	77
1.10.3.6. Yapay Sinir Ağları	78
1.10.3.7. Derin Sinir Ağları	80
1.10.3.8. Konvolüsyonel Sinir Ağları	81
1.11. Sistemin Kontrolü.....	82
1.11.1. Oransal-İntegral-Türev Denetleyici ile Kontrol	86
1.11.2. Bulanık Mantık Denetleyici ile Kontrol	87
1.11.3. Kayan Kipli Denetleyici ile Kontrol.....	91
1.11.4. Uyarlanabilir Denetleyici ile Kontrol	92
2. YAPILAN ÇALIŞMALAR, BULGULAR VE İRDELEME.....	94
2.1. Sınıflandırma Çalışmaları.....	94
2.1.1. Makine Öğrenmesi Algoritmalarıyla Ayak Hareketlerinin Her Kişi için Ayrı Ayrı Sınıflandırılması	94
2.1.2. Ayak Hareketleri Sınıflandırmasında Yapay Sinir Ağlarının Diğer Makine Öğrenmesi Algoritmalarıyla Karşılaştırılması	97
2.1.3. Evrişimli Sinir Ağı ile Ayak Hareketlerinin Sınıflandırılması.....	103
2.1.4. 1D-ResCNN Modeli ile Ayak Hareketlerinin Sınıflandırılması	106
2.2. Kontrol Çalışmaları	117
2.2.1. PID Denetleyici Simulasyon Sonuçları	117
2.2.2. Bulanık Mantık Denetleyici Simulasyon Sonuçları	121
2.2.3. Yapay Sinir Ağları Simulasyon Sonuçları	122
2.2.4. Kayan Kipli Denetleyici Simulasyon Sonuçları.....	123
2.2.4.1. Sistem Tabanlı Kayan Kipli Denetleyici Tasarımı.....	124
2.2.5. Uyarlanabilir (Adaptif) Denetleyici Simulasyon Sonuçları	130
2.2.5.1. Sistem Tabanlı Adaptif Kayan Kipli Denetleyici Tasarımı.....	131
3. SONUÇLAR.....	134
4. ÖNERİLER.....	136
5. KAYNAKLAR	137
6. EKLER.....	152
ÖZGEÇMİŞ	

Doktora Tezi

ÖZET

IMU VERİLERİYLE DERİN ÖĞRENME TABANLI HAREKET TANIMA VE ADAPTİF KAYAN KİPLİ KONTROLLÜ PROTEZ AYAK TASARIMI

Selin AYDIN FANDAKLI

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
Elektrik-Elektronik Mühendisliği Anabilim Dalı
Danışman: Prof. Dr. Halil İbrahim OKUMUŞ
2024, 151 Sayfa, 5 Sayfa Ek

Bu araştırma, felç, sinirsel hastalıklar, ortopedik sorunlar veya travma sonucu diz altı amputasyonu geçiren bireyler için eksik uzvun yokluğunu hissettirmeyecek, kullanıcı kontrollü bir protez ayak geliştirme hedefiyle yola çıkmıştır. Tasarlanan bu protez ayak, kullanıcıların günlük yaşam aktivitelerini rahatlıkla gerçekleştirebilmelerine olanak tanıyacak şekilde hazırlanmıştır. İki serbestlik derecesine sahip olan bu protez ayak, doğal bir yürüyüşü taklit ederek, kullanıcılara hareket özgürlüğü ve doğal denge sağlamaktadır. Geliştirilen protez ayak, simetriyi koruma, doğal hareketleri taklit etme ve yürüyüşün doğal dinamiklerini yansıtırma gibi kritik özelliklere sahiptir. Eyleyiciler, denetleyiciler, algılayıcılar, bağlantı elemanları ve güç ünitesi gibi çeşitli bileşenlerden oluşan bu protez ayak, insan anatomisine uygun olarak tasarlanmıştır ve kullanıcılara geniş bir hareket aralığı sunmaktadır. Araştırmanın temelindeki veri tabanlı yaklaşım, her bireyin ihtiyaçlarına uygun olarak özelleştirilmiş protez ayak tasarımlarının oluşturulmasını mümkün kılar. Bu, ampute bireylerin yaşam kalitesini artırarak topluma daha aktif ve bağımsız katılımlarını teşvik etmeyi amaçlamaktadır. Ayrıca, bu alandaki bilimsel araştırmaların ilerlemesine katkıda bulunarak protez teknolojisinin gelişimini desteklemeyi hedeflemektedir.

Anahtar Kelimeler: 1D-ResCNN, Derin öğrenme, PID, Adaptif Kayan Kipli Denetleyici, IMU, Dorsifleksiyon, Plantarfleksiyon, İnversiyon, Eversiyon

PhD. Thesis

SUMMARY

DEEP LEARNING BASED MOTION RECOGNITION AND ADAPTIVE SLIDING MODE CONTROLLED PROSTHETIC FOOT DESIGN WITH IMU DATA

Selin AYDIN FANDAKLI

Karadeniz Technical University
The Graduate School of Natural and Applied Sciences
Electrical-Electronics Engineering Graduate Program
Supervisor: Prof. Dr. Halil İbrahim OKUMUŞ
2024, 151 Pages, 5 Pages Appendix

This research sets out with the aim of developing a user-controlled prosthetic foot that will not make the absence of the missing limb felt for individuals who have undergone below-knee amputation due to stroke, neurological diseases, orthopedic issues, or trauma. Designed to enable users to comfortably carry out their daily life activities, this prosthetic foot with two degrees of freedom mimics a natural gait, providing users with freedom of movement and natural balance. The developed prosthetic foot possesses critical features such as preserving symmetry, mimicking natural movements, and reflecting the natural dynamics of walking. Comprised of various components including actuators, controllers, sensors, connection elements, and power units, this prosthetic foot is designed in accordance with human anatomy, offering users a wide range of motion. The data-driven approach underlying the research enables the creation of customized prosthetic foot designs tailored to the needs of each individual. This aims to enhance the quality of life for amputees, thereby promoting their more active and independent participation in society. Additionally, it aims to contribute to the advancement of scientific research in this field, thereby supporting the development of prosthetic technology.

Key Words: 1D-ResCNN, Deep learning, PID, Adaptive Sliding Mode Controller, IMU, Dorsiflexion, Plantarflexion, Inversion, Eversion

ŞEKİLLER DİZİNİ

Sayfa No

Şekil 1.	SPARKy projesi. (A) SPARKy projesinin robotik ayak bileği protezinin ilk tasarımı. (B), ağırlık ve boyutun azaltıldığı SPARKy 2 prototipi. (C) iki serbestlik derecesine sahip son prototip SPARKy 3.....	13
Şekil 2.	Herr ve ekibinin tasarladığı elektrikli ayak bileği protezinin şeması	14
Şekil 3.	PANTOE 1'in CAD modeli.....	15
Şekil 4.	Bacak kemikleri	17
Şekil 5.	Ayak kemikleri.....	18
Şekil 6.	Anatomik düzlemler	20
Şekil 7.	Yürüyüşün fazları	22
Şekil 8.	Diz ve ayak bileği eklem-uzuv modeli	26
Şekil 9.	Ayak açısının zamanla değişimi	29
Şekil 10.	Ayak bileği eklem açısının zamanla değişimi	29
Şekil 11.	Gastrocnemius ve soleus kasları.....	30
Şekil 12.	Ayak bileği eklem momentinin zamanla değişimi.....	30
Şekil 13.	Ayak bileği eklemının zamanla açısal hız değişimi	31
Şekil 14.	Ayak bileği eklem gücünün zamana göre değişimi.....	31
Şekil 15.	Ayak bileği eklemi üzerindeki reaksiyon kuvvetlerinin zamanla değişimi.....	32
Şekil 16.	MATLAB GUI yürüyüş analizi simülasyon sonuçları	32
Şekil 17.	Beş noktanın x eksenine göre hızları nokta 1: vücut kütle merkezi nokta 2: kalça eklemi nokta 3:diz eklemi nokta 4: ayak bileği eklemi nokta 5: 5. metatarsal kemik.....	33
Şekil 18.	İleri ve ters kinematik şeması	34
Şekil 19.	Manipülatöre ve nesnelere eklenen koordinat sistemleri.....	35
Şekil 20.	D-H değişkenlerinin belirlenmesi.....	36
Şekil 21.	Bir manipülatöre bağlı koordinat çerçeveleri	37
Şekil 22.	$O - xyz$ referans çerçevesi ve α açısı kadar döndürüldüğünde oluşan yeni $O - x'y'z'$ çerçevesi	40
Şekil 23.	Ters kinematik çözüm yöntemleri	42
Şekil 24.	Protezin hareket eksenlerinin belirlenmesi.....	44
Şekil 25.	Protez ayağın tablodaki değerlere göre konumu	46
Şekil 26.	Verilen aralıktaki tüm θ_1 ve θ_2 değerleri için p_x, p_y, p_z konumları.....	47

Şekil 27.	Ayak protezi tahrik mekanizmasının CAD modeli.....	52
Şekil 28.	İki serbestlik dereceli protez ayak mekanizmasının prototipi A) yandan görünüm B) önden görünüm.....	53
Şekil 29.	Roadflexion foot. A) Protez ayağın iç yapısı B) Protez ayağın ön yan ve arka yandan görünüm.....	54
Şekil 30.	L16-100-35-12-P lineer motor.....	54
Şekil 31.	L16-P lineer motor Hız-Kuvvet ve Akım-Kuvvet grafiği	55
Şekil 32.	Lineer aktüatör kontrol kartı.....	56
Şekil 33.	SimMechanics'te elde edilen protez ayak mekanizması	58
Şekil 34.	Sınıflandırma temel adımları	59
Şekil 35.	ODTÜ Makine Mühendisliğindeki Biyomekanik Laboratuvarı.....	61
Şekil 36.	IMU modüllerinin veri toplamak için bağlandıkları konumları	62
Şekil 37.	LSM9DS1 kartı.....	63
Şekil 38.	Denek 1'in dorsifleksiyon hareketi sonucunda elde edilen sensör ham verileri.....	64
Şekil 39.	Denek 1'in plantar fleksiyon hareketi sonucunda elde edilen sensör ham verileri.....	65
Şekil 40.	Denek 1'in inversiyon hareketi sonucunda elde edilen sensör ham verileri.....	66
Şekil 41.	Denek 1'in eversiyon hareketi sonucunda elde edilen sensör ham verileri.....	66
Şekil 42.	Denek 1'in dorsifleksiyon hareketi sonucu üç boyutlu konumu	68
Şekil 43.	Denek 1'in laboratuvar boyunca yürüme hareketi sonucu üç boyutlu konum	68
Şekil 44.	Denek 1'in yürüme hareketi sonucu elde edilen filtrelenmiş/filtrelenmemiş ivme verilerinin zamana bağlı hız/konum grafiği	69
Şekil 45.	6. kişi 50 deneme dorsifleksiyon hareketi Gx verileri.....	69
Şekil 46.	6. kişi 50 deneme plantar fleksiyon hareketi Gx verileri	70
Şekil 47.	6. kişi 50 deneme inversiyon hareketi Gx verileri.....	70
Şekil 48.	6. kişi 50 deneme eversiyon hareketi Gx verileri	71
Şekil 49.	Ayak hareketleri sınıflandırma modeli süreci.....	79
Şekil 50.	Derin öğrenme ve makine öğrenmesi arasındaki özellik çıkarma ve sınıflandırma işleyiş karşılaştırması	80
Şekil 51.	Kontrol sistem tasarım temel aşamaları	83
Şekil 52.	DC lineer motorun eşdeğer devresi	84
Şekil 53.	DC lineer motorun parametreleri yerleştirilmiş blok diyagramı	84

Şekil 54.	Kapalı çevrim DC lineer motor sisteminin işaret akış diyagramı.....	85
Şekil 55.	Lineer motorlar aynı yönde döndüğünde elde edilen blok diyagramı	85
Şekil 56.	PID kontrol blok diyagramı	86
Şekil 57.	Bulanık mantık denetleyici genel yapısı	88
Şekil 58.	Üçgen üyelik fonksiyonunun Simulink modeli	89
Şekil 59.	Bulanık kuralların Simulink modeli	90
Şekil 60.	Kayan kipli denetleyici faz düzlemi	92
Şekil 61.	Uyarlanabilir (Adaptif) denetleyici kontrol yapısı	93
Şekil 62.	Model referanslı adaptif kontrol genel şeması.....	93
Şekil 63.	Ayak için ham test verilerinin Karar Ağacı sınıflandırma doğruluğu SD: Sınıflandırma Doğruluğu G: Gönüllü	95
Şekil 64.	Ayak için ham test verilerinin LDA sınıflandırma doğruluğu SD: Sınıflandırma Doğruluğu G: Gönüllü	95
Şekil 65.	Ayak için ham test verilerinin Naïve Bayes sınıflandırma doğruluğu SD: Sınıflandırma Doğruluğu G: Gönüllü.....	96
Şekil 66.	Ayak için ham test verilerinin KNN sınıflandırma doğruluğu SD: Sınıflandırma Doğruluğu G: Gönüllü.....	96
Şekil 67.	Ayak için ham test verilerinin SVM sınıflandırma doğruluğu SD: Sınıflandırma Doğruluğu G: Gönüllü.....	97
Şekil 68.	Ayak için ham verilerin sınıflandırma doğruluğu (%) 1-ortalama; 2- toplam; 3-ortalama, standart sapma, çarpıklık, basıklık; 4-standart sapma, çarpıklık, kovaryans; 5- özellik sonuçlarının ortalaması.....	101
Şekil 69.	CNN modeli katmanları.....	104
Şekil 70.	CNN modeli eğitim sonuçları.....	105
Şekil 71.	Önerilen 1D-ResCNN modelinin mimarisi	107
Şekil 72.	Res-Block katmanları	108
Şekil 73.	Ayrıntılı 1D-ResCNN mimisi	109
Şekil 74.	Önerilen modelin doğruluk ve hata sonuçları.....	110
Şekil 75.	Önerilen modelin eğitim hatasının diğer modellerle karşılaştırılması.....	111
Şekil 76.	Önerilen modelin eğitim doğruluğunun diğer modellerle karşılaştırılması.....	112
Şekil 77.	Önerilen modelin validasyon hatasının diğer modellerle karşılaştırılması.....	112
Şekil 78.	Önerilen modelin validasyon hatasının diğer modellerle karşılaştırılması.....	112
Şekil 79.	Önerilen modelin eğitim doğruluğunun diğer derin öğrenme modelleriyle karşılaştırılması.....	115

Şekil 80.	Önerilen modelin validasyon doğruluğunun diğer derin öğrenme modelleriyle karşılaştırılması.....	116
Şekil 81.	Önerilen modelin eğitim hatasının diğer derin öğrenme modelleriyle karşılaştırılması.....	116
Şekil 82.	Önerilen modelin validasyon hatasının diğer derin öğrenme modelleriyle karşılaştırılması.....	116
Şekil 83.	PID denetleyicili sistemin birim basamak tepkisi.....	117
Şekil 84.	K_p , K_i ve K_d parametrelerine göre PID denetleyici karşılaştırması	117
Şekil 85.	PID6 ve PID9'un rastgele giriş tepkisinin karşılaştırılması	119
Şekil 86.	PID9'un Simulink blok diyagramı.....	119
Şekil 87.	CNN ile eğitilmiş bir modelin çıkışının PID denetleyici takibi	120
Şekil 88.	Bulanık mantık denetleyicili sistemin birim basamak tepkisi	121
Şekil 89.	Bulanık mantık denetleyicili sistemin rastgele giriş tepkisi.....	121
Şekil 90.	Sinir ağında farklı aktivasyon fonksiyonlarının karşılaştırılması a) 1.08-1.18 ms aralığı b)5.79-5.86 aralığı büyütülmüş hali.....	122
Şekil 91.	Sinir ağıyla denetlenen sistemin birim basamak tepkisi	123
Şekil 92.	Kayan kipli denetleyicili sistemin birim basamak tepkisi	124
Şekil 93.	$\lambda = 1200$, $\beta = 100$ ve $k = 40$ ve $d(t) = \sin t$ değerleri için kayan kipli denetleyici konum takibi.....	126
Şekil 94.	Kayan kipli denetleyicinin Denek 1'in dorsifleksiyon hareketi y eksenini konumunu takibi a) 5sn'lik hareket b) 0.5 s'lik kısmın büyütülmüş hal.....	127
Şekil 95.	Denek 1'in dorsifleksiyon hareketi için kontrol işareti	128
Şekil 96.	$\lambda = 1200$, $\beta = 100$, $k = 200$, $d(t) = \sin t$, $\varepsilon = 0.01$ için sinüs takibi	129
Şekil 97.	Farklı erişim yasalarına göre KKD'nin verdiği tepki a) 50s'lik sinüs takibi b)büyütülmüş hali	130
Şekil 98.	Adaptif PID konum takibi	131
Şekil 99.	Adaptif KKD konum takibi a) 1s'lik sinüs dalgası takibi b) büyütülmüş hali	133

TABLÖLAR DİZİNİ

	<u>Sayfa No</u>
Tablo 1. Ayak için antropometrik veriler	25
Tablo 2. Protez ayağın D-H değişkenlerinin belirlenmesi	44
Tablo 3. İleri kinematik sonucunda elde edilen bazı konum noktaları	46
Tablo 4. Ters kinematik sonucunda elde edilen θ_1 ve θ_2 değerleri	50
Tablo 5. L16-P teknik özellikleri	55
Tablo 6. Lineer aktüatör kontrol kartı teknik özellikleri.....	57
Tablo 7. Gönüllü deneklerin fiziksel özellikleri	62
Tablo 8. LSM9DS1'in ölçüm aralığı	64
Tablo 9. Bulanık mantık denetleyicinin 49 kurallı kural tablosu.....	90
Tablo 10. F-KNN ve W-KNN özellikleri.....	98
Tablo 11. Çalışmada kullanılan sinir ağlarının özellikleri.....	98
Tablo 12. Ayak için ham eğitim verilerinin sınıflandırma doğruluğu (%)	99
Tablo 13. Ayak için ham test verilerinin sınıflandırma doğruluğu (%)	99
Tablo 14. Alt bacak için ham eğitim verilerinin sınıflandırma doğruluğu (%)	100
Tablo 15. Farklı sinir ağlarının karşılaştırma sonuçları (%)	101
Tablo 16. Naïve Bayes, SVM, KNN ve YSA karşılaştırma sonuçları (%).....	102
Tablo 17. Ayak hareketleri sınıflandırmasında EMG ve IMU verilerinin karşılaştırılması.....	102
Tablo 18. Derin öğrenme modeli eğitim parametreleri.....	106
Tablo 19. Epoch değerlerinin sonuçlar üzerindeki etkisi.....	110
Tablo 20. Önerilen modelin literatürdeki diğer çalışmalarla karşılaştırılması.....	114
Tablo 21. Önerilen modelin literatürdeki diğer derin öğrenme modelleriyle karşılaştırılması.....	115
Tablo 22. Farklı PID parametrelerine göre geçici tepke parametrelerinin karşılaştırılması.....	118

SEMBOLLER VE KISALTMALAR DİZİNİ

M_t	: hareketli birimin toplam kütlesi (kg)
F_t	: hareketli üniteye etki eden net kuvvet (N)
$\frac{dv(t)}{dt}$	: ivme (m/s ²)
$v(t)$	: zamana bağlı hız (m/s)
F_e	: elektriksel olarak üretilen kuvvet (N)
F_l	: zıt yönde oluşan yük kuvveti (N)
F_d	: toplam sürtünme kuvveti (N)
α	: hıza bağlı olarak değişen viskoz sürtünme katsayısı
F_c	: Coulomb sürtünme kuvveti
F_s	: cisim durgun iken maruz kalınan statik sürtünme kuvveti
e_b	: indüklenen zıt elektromotor kuvvet (V)
$R_b + R_f$	: endüvi direnci (Ω)

HARS	: İnsan Aktivitesi Tanıma ve Segmentasyon
EMG	: Elektromiyografi
LDA	: Lineer Diskriminant Analizi
KNN	: K-En Yakın Komşu
LTD	: Logaritmik Zaman Domeni
TTD	: Geleneksel Zaman Domeni
HAR	: İnsan Aktivite Tanıma
CNN	: Evrişimli Sinir Ağları
PCA	: Temel Bileşenler Analizi
SVM	: Destek Vektör Makineleri
DBN	: Derin İnanç Ağı
YSA	: Yapay Sinir Ağları

IMU	: Ataletsel Ölçüm Birimi
MLP	: Çok Katmanlı Algılayıcı
LSTM	: Uzun Kısa Süreli Bellek
BiLSTM	: Çift Yönlü Uzun Kısa Süreli Bellek
RFC	: Rasgele Orman Sınıflandırıcısı
RNN	: Tekrarlayan Sinir Ağı
DP	: Dorsifleksiyon-Plantarfleksiyon
IE	: Inversiyon-Eversiyon
PID	: Oransal-İntegral-Türev Denetleyici
BMD	: Bulanık Mantık Denetleyici
KKD	: Kayan Kipli Denetleyici
	: hareketli birimin toplam kütlesi (kg)

1. GENEL BİLGİLER

1.1. Giriş

Ampütasyon, omurilik yaralanması ve travmatik beyin yaralanması sonucu beyin ile ekstremiteler arasındaki bağlantının kesilmesi sonucu sağlıklı uzuv işlevini yerine getiremeyen bir fonksiyonel kayıp olarak tanımlanmaktadır [1]. Beslenemeyen uzvun kesildiği, tarihsel olarak kaydedilmiş en eski cerrahi işlemlerden biridir. Son yıllarda, iyi huylu ve kötü huylu kemik hastalıkları, doğal afetler, trafik kazaları, doğum kusurları, periferik damar hastalıkları gibi bir dizi belirsiz ve beklenmedik faktör nedeniyle alt ekstremiteler amputasyonları artmaktadır [2]. Her yıl Amerika Birleşik Devletleri'nde toplam 185.000 amputasyon gerçekleşmekte olup, bu amputasyonların %85'i alt ekstremitelerde meydana gelmektedir. 2005 yılında uzuv kaybı yaşayan insan sayısı 1,6 milyon olarak belirlenmiş ve gelecek yıllara dair tahminlere göre, 2050 yılında bu sayının 3,6 milyona ulaşması beklenmektedir [3,4,5]. Almanya'da ise 2005 ile 2015 yılları arasında yatarak tedavi gören tüm alt ekstremiteler amputasyonlu vakaları kapsayan bir çalışma, 2015 yılında 55.595 alt ekstremiteler amputasyonu tespit etmiştir. Bu oran, diğer Avrupa ülkeleriyle kıyaslandığında oldukça yüksek bir seviyededir [6]. Alt ekstremiteler amputasyonlarıyla ilgili bir araştırmaya göre, dünya genelinde her yıl bir milyondan fazla amputasyon gerçekleşmekte olup, en sık görüleni diz altı amputasyonlarıdır [7]. Periferik arter hastalığından kaynaklanan ekstremiteler kan akışının kısıtlanması, tüm alt ekstremiteler amputasyonlarının en önemli nedenlerinden biridir [8]. Ülkemizde, özellikle damar sorunları sebebiyle alt ekstremiteler amputasyon ameliyatı geçiren yaşlı bireylerin sayısında bir artış gözlemlenirken, aynı zamanda iş kazaları, trafik kazaları ve terör olayları nedeniyle genç yaşta yapılan amputasyon sayısında da artış görülmektedir. Bu genç bireylerin çoğunluğu ise diz altı amputasyonu ameliyatı geçirmiştir.

Ekstremitelerin kaybolan yapı ve işlevleri, protez, ortez gibi rehabilitasyon yardımcıları ile değiştirilebilmektedir. Geçmişte kullanılan mekanik pasif protezler sadece temel fonksiyonu sağlayabiliyordu [9]. Bu tez çalışmasında, ayağın hareketiyle alınan sinyallerin işlenerek kendisini kontrol edebilen bir akıllı protez tasarlanmıştır. Bu tasarım, adını tasarımcının kızının adı olan Asya'dan alarak 'Asyaprofoot' olarak adlandırılmıştır. 'Pro' eki, protez anlamına gelirken, 'foot' kelimesi İngilizcede ayak anlamına gelmektedir.

Bu proje, ayak uzvunu kaybeden bireyler için uzvun yerini tutmaya yardımcı olmayı amaçlamaktadır.

Projenin başarıya ulaşması için belirlenen kriterler aşağıda sıralanmıştır:

- Protezin, ihtiyaca yönelik olarak iki serbestlik derecesinde hareket gerçekleştirebilecek şekilde mekanik olarak tasarlanması.
- Ayak ve ayak bileği biyomekaniğinin detaylı bir şekilde incelenmesi ve yürüyüş analizi yapılması, bu analiz sonucunda ayak hareketlerinin belirlenmesi.
- Verilerin toplanması ve analizinin gerçekleştirilmesi için uygun yöntemlerin kullanılması.
- Sistemin denetimini gerçekleştirecek olan kontrol teorisinin belirlenmesi ve uygulanması.
- Kontrol edilen sistemin optimize edilmesi için gerekli düzeltmelerin yapılması ve sistem performansının artırılması.

Bu kriterler, projenin başarıyla tamamlanabilmesi ve tasarlanan akıllı protezin etkili bir şekilde çalışabilmesi için önemli adımları içermektedir. Her bir adımın titizlikle ve doğru bir şekilde uygulanması, projenin hedeflerine ulaşmasına katkı sağlayacaktır.

Projede ilk olarak, literatürde ihtiyaca yönelik olarak belirlenen dört ayak hareketini gerçekleştirebilen ayak protezi, Solidworks programı kullanılarak mekanik olarak tasarlandı. Tasarım, mafsallar ve lineer motorlardan oluşan bileşenlerle bir araya getirilerek bağlantıları gerçekleştirildi.

İkinci aşamada, ayak biyomekaniği ve yürüyüş analizi konularında yapılan araştırmalar, üniversitenin sınırlı imkânları nedeniyle ODTÜ Makine Mühendisliği laboratuvarına gidilerek gerçekleştirildi. Burada, gerekli deneyler ve analizler yapılarak veriler toplandı. Bu veriler, sınıflandırma işlemlerine tabi tutularak detaylı bir analiz sürecinden geçirildi.

Üçüncü aşamada, sistemin kontrolü üzerine çalışmalar yapıldı ve uygun kontrol teorileri belirlendi. Bu kontrol teorileri, birbirleriyle karşılaştırılarak en uygun kontrolcü belirlendi. Bu aşamada sistemin sağlıklı bir şekilde çalışabilmesi için gerekli olan kontrol mekanizmaları titizlikle incelendi ve uygulandı. Bu adımların tamamlanmasıyla birlikte, projenin başarıyla ilerlemesi ve tasarlanan akıllı protezin işlevselliğinin artırılması hedeflenmiştir.

Dördüncü aşamada belirlenen kontrol teorisinin bir optimizasyon yöntemiyle iyileştirilmesi sağlandı ve bu sayede uzvunu kaybeden kişiler için optimum protez ayak tasarımı tamamlanmış oldu. Bu aşama, kontrol teorisinin daha etkili ve hassas bir şekilde çalışabilmesi için gerekli düzeltmelerin yapılması ve sistemin performansının artırılması üzerine odaklandı. Bu optimizasyon süreci, tasarlanan protez ayak sisteminin daha güvenilir, kullanıcı dostu ve işlevsel hale gelmesine katkı sağladı. Böylece, projenin başlangıç hedeflerine ulaşması adına önemli bir adım atılmış oldu.

Protezler, hastalık veya travma sonucu doğuştan veya sonradan uzuv kaybı yaşayan amputasyon geçirmiş bireylerin, eksik vücut parçalarının yerine kullanılan yapay cihazlardır. Protez araştırmalarının temel hedefi, kullanıcıların eksik olan uzuvlarını hissetmeyecekleri, rahat ve etkili bir şekilde kullanabilecekleri cihazlar geliştirmektir. Klinik yürüyüş analizi, protez ayak tasarımı ve aktüatör seçiminde kullanılan en önemli araçlardan biridir ve insan hareketinin analizinden elde edilen verilere dayanır.

Alt ekstremitedeki deformasyonlar, insan hareketlerini ve psikolojisini daha fazla etkilediği için, araştırmacıların üst ekstremitte yaralanmalarından daha fazla ilgisini çekmiş ve bu alandaki araştırmaların önemini artırmıştır [10]. Alt ekstremitte protezleriyle ilgili çalışmalar son yirmi yılda önemli bir ivme kazanmıştır. Bu çalışmaların odak noktası, protezlerin hem işlevselliğini hem de estetiğini artırmak üzerinedir. İkinci Dünya Savaşı'ndan bu yana, vücut hasarı görmüş uzuvların yapay organlarla yeniden işlevselliğe kavuşturulması amacıyla çeşitli çalışmalar yapılmıştır. Bu süre zarfında, protez teknolojisi önemli ölçüde gelişmiş, malzeme teknolojileri ve mühendislik yaklaşımları kullanıcıların yaşam kalitesini artırmak amacıyla iyileştirilmiştir. Estetik açıdan, protez tasarımlarında doğal uzvun anatomisine daha yakın ve kullanıcıya uyumlu modeller geliştirilmiştir. Ayrıca, protezlerin hareket kabiliyeti, denge ve kullanım kolaylığı gibi faktörler üzerine odaklanan birçok araştırma yapılmıştır. Literatürdeki çalışmalar yürüyüş analizi, sınıflandırma ve robot kontrolü olmak üzere üç ana başlık altında ele alınmıştır.

Bu çalışmalar, protez kullanıcılarının günlük yaşam aktivitelerini daha etkili bir şekilde sürdürebilmelerini sağlamak ve aynı zamanda estetik açıdan daha tatmin edici bir deneyim yaşamalarını amaçlamaktadır. İleri teknoloji ve multidisipliner yaklaşımlarla, alt ekstremitte protezleri alanındaki gelişmeler gelecekte daha da önemli hale gelmeye devam edecektir [11].

1.2. Yürüme Analizi ile İlgili Yapılan Çalışmalar

Ng ve Chizeck, belden aşağısı felçli deneklerin kalça, diz ve ayak bileğinden topladıkları sensör verilerini kullanarak bir sistem modeli tanımlamış ve bulanık model tanımlama yöntemlerini uygulayarak sistemin beş ayrı yürüyüş fazını tespit etmiştir. Bu çalışmada, deri yoluyla kişiye implante edilen elektrotlar aracılığıyla felçli kasların bilgisayar kontrollü elektriksel uyarımı gerçekleştirilmiştir [12].

Pappas ve arkadaşları, 10 sağlıklı ve 6 yürüme bozukluğu olan bireyden jiroskoplardan elde ettikleri ayağın açısal hız bilgileri ile kuvvete duyarlı dirençle ayağın tabana uyguladığı kuvvet bilgilerini kullanarak bir yürüme fazı saptama sistemi geliştirmişlerdir. Bu sistem, hem iç hem de dış ortamlarda hem düz hem de düzensiz yüzeylerde sağlıklı bireyler için %99'un üzerinde, yürüme bozukluğu olan bireyler için ise %96'nın üzerinde bir başarı elde etmiştir [13].

Palmer'ın 2002 yılında gerçekleştirdiği doktora tez çalışmasında, hız kamerası ve kuvvet plakası kullanılarak 10 sağlıklı denek üzerinde her biri 3 ila 9 arasında değişen denemeler yapılmıştır. Bu denemelerde, yavaş, normal ve hızlı yürüyüş durumlarında kontrollü plantarfleksiyon, kontrollü dorsifleksiyon ve güçlendirilmiş plantar fleksiyon verileri toplanmıştır. Bu veriler, ayak bileği eklemının sagittal düzlemdeki fonksiyonunu karakterize etmek amacıyla incelenmiştir [14].

Schache ve arkadaşları, yüksek hızlı kameralar ve kuvvet plakası kullanarak 3.5 ila 8.95 m/s arasındaki 4 farklı hızda koşan 8 kişiden veri topladılar. Bu çalışmada, koşu hızının alt ekstremitte eklem kinetiği üzerindeki etkisini incelediler ve elde ettikleri verilere göre, ayak bileği torkunun 2.94 Nm/kg'den 4 Nm/kg'a yükseldiğini bildirdiler. Bu sonuçlar, koşu hızının ayak bileği eklemındaki kinetik değişimlere nasıl etki ettiği konusunda önemli bir anlayış sağlamaktadır [15].

Luo ve Stefanyshyn'ın yaptığı çalışmada, yüksek hızlı kameralar ve kişilere iştirilmiş işaretleyiciler kullanılarak 13 denekten bir eğri boyunca koşma ile ilgili kinematikler kaydedilmiştir. Ayrıca, kuvvet plakası tarafından ölçülen zemin reaksiyon kuvvetleri hesaba katılarak ters dinamiklerle bağlantıların torkları tahmin edilmiştir. Bu çalışmada, eklem kinetiği ve kinetiğinin frekans alanı özelliklerinin analizi yapılmış ve bir protezin taklit etmesi gereken sistem olan ayak bileği eklem uyumunun dinamik analizi incelenmiştir. Bu analizler, koşu sırasında ortaya çıkan kinematik ve kinetik değişimleri anlamak ve protez tasarımında uygunluğu değerlendirmek için önemli bir temel oluşturmaktadır [16].

Atalet sensör tabanlı yürüyüş tanıma konusundaki ilk araştırmalarda, Mäntyjärvi ve arkadaşları 2005 yılında 36 test kişisinden yavaş, normal ve hızlı hızlarda 20 metre yürümelerini istedi. Deneyi beş gün arayla iki kez gerçekleştirerek toplamda 108 gerçekçi deneme elde ettiler. Yürüyüş sırasında kişilerin giydikleri ivmeölçerleri kullanarak elde edilen sonuçlar, kişilerin yürüyüş özelliklerine göre ayırt edilebileceğini gösterdi. Bu çalışma, atalet tabanlı sensörlerin yürüyüş tanıma alanında kullanılabilirliğini gösteren önemli bir örnektir [17].

Rong ve arkadaşları 2007 yılında yaptıkları ilk çalışmada, 35 sağlıklı kişiden üç hafta boyunca 30 metrelik bir çizgi üzerinde yürümelerini istedi ve bu süre zarfında ivmeölçerlerle üç boyutlu hızlanma verilerini topladı. Diğer bir çalışmalarında ise, 21 sağlıklı kişiden normal hızlarda yürümelerini istediler. Elde edilen sonuçlar, kullanıcıları yürüme hızlarına göre tanıma olasılığını doğrulayan kimlik tespiti için potansiyel sundu. Araştırmacılar, yürüme hızındaki doğal değişikliklerden kaynaklanan sorunları ortadan kaldırmak ve verileri işlemek için ön işleme adımları geliştirmek için çalışmalar yaptılar. Bu çalışmalar, yürüyüş tabanlı kimlik tespiti konusunda daha etkili yöntemlerin geliştirilmesine katkı sağlamaktadır [18, 19].

Osaka Üniversitesi'nde bir araştırma grubu, yürüyüş tanıma konusunda kapsamlı bir araştırma gerçekleştirdi ve atalet sensörüne dayalı olarak 744 kişiden alınan verilerle dünyanın en büyük veri setini sağladılar. Yapılan araştırmada, yürüyüş tanıma performansı açısından ivmenin, açışal hızdan daha iyi çalıştığını ve normalleştirilmiş mesafenin normalleştirilmemiş mesafeden daha iyi sonuçlar elde ettiğini gösterdiler. Bu bulgular, yürüyüş analizi ve tanıma teknolojilerinde ivme ve mesafe normalizasyonunun önemini vurgulamaktadır. Elde edilen bu büyük veri seti, yürüyüş tanıma algoritmalarının daha geniş ve çeşitli bir veri yelpazesinde test edilmesine olanak sağlayarak alandaki araştırmalara önemli katkıda bulunmaktadır [20,21].

2014 yılında Seel ve arkadaşlarının yaptığı çalışmada, doğrusal olmayan en küçük kareler teknikleriyle insan hareketi analizi gerçekleştirmek üzere, 40 yaşında transfemoral amputasyonlu bir erkek denek üzerinde üst bacak, alt bacak ve ayağa takılan 6 IMU (Ataletsel Ölçüm Birimi) ile 60 Hz ölçüm hızında yürüyüş deneyleri yapılmıştır. Bu deneylerde, IMU'lara dayalı eklem açısı hesaplama yöntemleri kullanılmıştır. Bu çalışma, IMU teknolojisinin kullanımıyla ampute bireylerin yürüyüş analizlerinin gerçekleştirilmesine yönelik bir örneği temsil etmektedir [22].

San-Segundo ve diğerlerinin yaptığı çalışmada, 30 gönüllüden akıllı telefon atalet sinyalleri toplanarak halka açık bir veri seti kullanılmıştır. Bu çalışmada, yürüme, oturma, ayakta durma, yatma, merdiven çıkma ve merdiven inme gibi 6 farklı aktiviteyi tanımak amacıyla bir İnsan Aktivitesi Tanıma ve Segmentasyon (HARS) sistemi önerilmiştir. Önerilen HARS sistemi, atalet sinyallerini kullanarak çeşitli insan aktivitelerini tanımak ve bu aktiviteleri zaman içinde doğru bir şekilde segmente etmek için geliştirilmiştir. Segmentasyon hatası oranının %0,5'ten az olacak şekilde düşürüldüğü belirtilmiştir. Bu, sistemin aktiviteleri tanıma ve sinyalleri etkili bir şekilde bölme konusunda başarılı olduğunu gösterir. Akıllı telefonlar gibi taşınabilir cihazların içerdikleri sensörlerin kullanılması, günlük aktiviteleri izlemek ve analiz etmek için yaygın bir ve etkili bir yaklaşım olabilir [23].

1.3. Sınıflandırma ile İlgili Yapılan Çalışmalar

Parkka ve arkadaşları, sadece ivmeölçerleri kullanarak 16 gönüllüden geniş ve gerçekçi bir veri kütüphanesi oluşturmak için veri topladı. Bu verileri kullanarak, özellik çıkarımı ve 12-kat çapraz doğrulamanın ardından özel bir karar ağacını, otomatik olarak oluşturulan karar ağacını ve yapay sinir ağını kullanarak oturma, ayakta durma, yürüme, koşma, bisiklete binme gibi günlük aktiviteleri başarıyla sınıflandırdılar. Otomatik olarak oluşturulan karar ağacı için % 86 ile en yüksek genel sınıflandırma doğruluğu elde edildi. Bu sonuçlar, sensörlerin kullanılmasıyla birçok günlük aktivitenin iyi bir doğrulukla tanınabileceğini göstermektedir [24].

2016 yılında, Wu ve arkadaşları, atalet sensörleri ile elde ettikleri verilerden dengesiz bir veri seti oluşturarak insan aktivitesi tanıma çalışması gerçekleştirdi. Bu çalışmada, sınıf dengesizliğine çözüm bulmak amacıyla karma çekirdek tabanlı ağırlıklı bir aşırı öğrenme makinesi (MK-WELM) önerilmiş ve başarılı sonuçlar elde edilmiştir. Bu yöntem, dengesiz veri setlerinde etkili bir şekilde çalışabilen bir model geliştirilmesini sağlayarak aktivite tanıma performansını artırmıştır [25].

Quraishi ve arkadaşları tarafından gerçekleştirilen çalışmada, 15 erkek ve 5 kadın gönüllü üzerinde dorsifleksiyon, plantarifleksiyon, adduksiyon ve abduksiyon gibi ayak hareketlerinin elektromiyografiye (EMG) dayalı kontrolü gerçekleştirildi. Bu amaçla, Lineer Diskriminant Analizi (LDA), K-En Yakın Komşu (KNN) ve Naive Bayes olmak üzere üç

farklı sınıflandırıcı kullanıldı. Sınıflandırıcılar, hem logaritmik aktarılan zaman alanı özellikleri (LTD) hem de geleneksel zaman alanı özellikleri (TTD) açısından değerlendirildi. Yapılan değerlendirmeler sonucunda, en yüksek performansın LDA sınıflandırıcı ve LTD kullanılarak elde edildiği belirlendi. Ortalama %97,23 sınıflandırma doğruluğu ile EMG sinyalleri üzerinden ayak hareketlerinin kontrolünde etkili bir yöntemin geliştirildiği sonucuna varıldı [26].

Zebin ve arkadaşları, İnsan Aktivite Tanıma (HAR) için 12 sağlıklı gönüllüden elde ettikleri yürüme, merdiven inme, merdiven çıkma, oturma, ayağa kalkma ve uzanma gibi hareketlere ait 3 boyutlu ivmeölçer ve 3 boyutlu jiroskop verilerini kullanarak Evrişimli Sinir Ağları (CNN) uygulamışlardır. Çalışmada, evrişim katmanlarının sayısı ve çekirdek boyutu gibi çeşitli hiperparametrelerin CNN modeli üzerindeki etkisini incelemişlerdir. Elde edilen sonuçlar, bu çalışmanın %97.01 sınıflandırma doğruluğu oranıyla, geleneksel makine öğrenimi yöntemleri olan SVM ve Çok Katmanlı Algılayıcı (MLP) gibi yöntemlere kıyasla tatmin edici sonuçlar elde ettiğini göstermektedir. CNN'nin, HAR görevinde başarılı bir şekilde kullanılabildiği ve belirtilen hareketleri yüksek doğrulukla sınıflandırabildiği sonucuna varılmıştır [27].

Fullerton ve ekibinin 2017'deki çalışmasında, günlük aktivitelerin tespiti amacıyla vücuda takılan 9 adet ivmeölçer sensörü kullanıldı. Çalışma, 10 katılımcıdan elde edilen filtrelenmemiş verileri temel aldı. Ortalama ve standart sapma özelliklerini içeren KNN sınıflandırıcısı kullanılarak gerçekleştirilen analizde, %97,6 oranında tanıma doğruluğu elde edildi. Bu sonuçlar, giyilebilir teknolojiler ve ivmeölçer sensörleri gibi unsurların günlük aktivitelerin etkili bir şekilde belirlenmesinde kullanılabilirliğini vurgulamaktadır [28].

Bastas ve ekibinin gerçekleştirdiği çalışmada, 17 transtibial ampute, 16 transfemoral ampute ve 14 sağlıklı gönüllüden oluşan bir katılımcı grubu kullanıldı. Düz zeminde yürüme sırasında, 3 eksenli ivmeölçer ve 3 eksenli jiroskop içeren bir IMU sensörü ile ivme ve açısal hız verileri toplandı. Toplanan veriler, 3 farklı algoritma kullanılarak detaylı bir şekilde analiz edildi. Elde edilen sonuçlar, IMU tabanlı adım sınırlama algoritmalarının daha tutarlı adım sınırlaması sağladığını gösterdi. Bu bulgular, özellikle ampute bireyler ve sağlıklı gönüllüler arasındaki yürüme paternlerini değerlendirmek için kullanılan IMU teknolojisinin etkinliğini vurgulamaktadır [29].

Li ve diğerleri tarafından önerilen çalışmada, yürüme, koşma, merdiven çıkma ve merdiven inme gibi hareket aktivitelerini tespit etmek amacıyla tek bir IMU sensörü kullanılarak üçlü Markov modeline dayalı uyarlanabilir ve çevrimiçi bir algoritma

önerilmektedir. Deneyde, kullanıcının cinsiyeti, boyu ve aktivite hızına bakılmaksızın 10 sağlıklı denek (3 kadın, 7 erkek) yer almıştır. Bu yöntemin IMU sensörleriyle başarılı bir şekilde performans gösterdiği ve önerilen algoritma ile %99,2'ye varan doğruluk oranına ulaştığı açıkça belirtilmiştir. Bu sonuçlar, tek bir IMU sensörünün kullanılmasının ve üçlü Markov modelinin uygulanmasının, çeşitli hareket aktivitelerini başarıyla tanıma konusunda etkili bir yaklaşım olduğunu göstermektedir. Yüksek doğruluk oranları, bu tür algoritmaların giyilebilir teknolojiler ve hareket izleme sistemleri gibi uygulamalarda güvenilir bir şekilde kullanılabileceğini vurgular [30].

Uddin ve Hassan, aktivite tanıma amacıyla vücut sensörlerinden elde edilen verileri kullanarak derin bir Evrişimli Sinir Ağı sunmuşlardır. Bu çalışma, jiroskop, ivmeölçer ve magnetometre gibi çeşitli vücut sensörleri verilerini içermektedir. Veri ön işleme aşamasında, Gauss çekirdek tabanlı Temel Bileşenler Analizi (PCA) ve Z-skor normalizasyonu kullanılmıştır. MHEALTH [31] veri seti üzerinde gerçekleştirilen çalışmada, 10 gönüllünün 12 farklı insan aktivitesi gerçekleştirmesi sonucunda elde edilen sonuçlar değerlendirilmiştir. Tüm deneklerin ortalamasında, önerilen CNN'nin doğruluğu %93.9 olarak kaydedilmiştir. Bu sonuçlar, önerilen CNN modelinin, diğer yöntemlere kıyasla, özellikle Derin İnanç Ağı (DBN) (%90.01) ve Yapay Sinir Ağları (YSA) (%87.99) gibi modellere göre daha yüksek bir başarı oranına sahip olduğunu göstermektedir [32].

Gao ve ekibinin 2020'deki çalışmasında, geometri tabanlı bir hareket modu tanıma sistemi önerilmiştir. Bu sistem, üç sağlıklı katılımcı (3 erkek, 25-30 yaş) ve üç diz altı ampute katılımcı (1 kadın, 2 erkek, 21-42 yaş) üzerinde düz zeminde yürüme, yokuş yukarı yürüme, yokuş aşağı yürüme, merdiven inme ve merdiven çıkma gibi beş farklı hareket modunu tanıma yeteneğini IMU kullanarak test etmiştir. Yapılan deneysel sonuçlar, altı denek ve beş hareket modu için ortalama doğruluk oranının %98,5 olduğunu göstermiştir [33].

Khera ve ekibinin 2020 yılındaki çalışmasında, EMG sinyallerini kullanarak plantarfleksiyon, dorsifleksiyon, inversiyon ve eversiyon gibi ayak hareketlerini sınıflandırdılar. Bu sınıflandırmayı gerçekleştirmek için Destek Vektör Makineleri (SVM), Sinir Ağları ve Lojistik Regresyon gibi algoritmaları kullandılar. Yapılan değerlendirmeler sonucunda, SVM ile maksimum sınıflandırma doğruluğu % 99,6 olarak elde edildiği belirlenmiştir [34].

Krishnaprabha ve ekibi, 30 gönüllüden akıllı telefon kullanarak yürüme, merdiven çıkma, merdiven inme, oturma, ayağa kalkma ve uzanma hareketlerinin ivmeölçer ve jiroskop verilerini toplamıştır. Bu verileri kullanarak, aşırı uyum sorununu azaltmak

amacıyla evrişimli sinir ağlarına dropout tekniğini eklemişlerdir. Dropout tekniği eklenmiş CNN ile eklenmemiş CNN performansları karşılaştırılmıştır. Yapılan karşılaştırmada, Dropout tekniği eklenmiş CNN'nin %96.3 sınıflandırma doğruluğuna ulaştığı ve eklenmemiş CNN'ye göre daha iyi çalıştığı gözlemlenmiştir. Dropout tekniği, ağın aşırı uyumu azaltarak genelleme yeteneğini artırabilir ve böylece modelin daha çeşitli veri setlerinde daha iyi performans göstermesine katkıda bulunabilir [35].

Erdaş ve Güney, insan aktivite tanıma için üç farklı derin öğrenme modeli önermişlerdir: CNN, Evrişimli Uzun Kısa Süreli Bellek (ConvLSTM) ve ConvLSTM tarafından beslenen 3 boyutlu CNN (3D-CNN). Tek ivmeölçer ile oluşturulan veri setinde, CNN, ConvLSTM ve 3D-CNN, sırasıyla %91.77, %92.29 ve %93.69 doğruluk oranlarına ulaşmıştır. Bu sonuçlar, özellikle ConvLSTM ile beslenen 3D-CNN modelinin diğer modellere göre daha yüksek doğruluk sağladığını göstermektedir [36].

Wan ve arkadaşları, insan aktivite tanıma amacıyla akıllı telefon ve atalet sensörlerinden elde edilen veriler üzerinde bir CNN mimarisi önermişlerdir. Uyguladıkları yöntemi, UCI-HAR [37] ve Pamap2 [38] veri setlerine uygulayarak Uzun Kısa Süreli Bellek (LSTM), Çift Yönlü Uzun Kısa Süreli Bellek (BiLSTM), SVM ve Çok Katmanlı Algılayıcı (MLP) gibi çeşitli modellerle karşılaştırmalı bir performans analizi gerçekleştirmişlerdir. Yapılan değerlendirmeler sonucunda, UCI-HAR veri seti için önerilen CNN yöntemi %92.71'lik bir doğruluk oranı ile en yüksek başarıyı elde etmiştir. Bu sonuçlar, akıllı telefon ve atalet sensörleri kullanılarak geliştirilen CNN mimarisinin, insan aktivite tanıma görevlerinde etkili bir şekilde performans sergileyebileceğini göstermekte ve önerilen yöntemin diğer modellere kıyasla üstün bir başarı gösterdiğini ortaya koymaktadır [39].

Mutegeki ve ekibi, insan aktivite tanıma amacıyla bir model önermişlerdir. Bu model, bir girdi katmanı, dört evrişim katmanı, bir LSTM katmanı, bir tam bağlantılı katman ve bir sınıflandırma katmanından oluşan bir CNN-LSTM mimarisine dayanmaktadır. İlk olarak, bu modeli laboratuvarında ayakta durma, oturma ve yürüme hareketlerini içeren üç eksenli ivmeölçer ve jiroskop verilerini kullanarak kendi oluşturdukları iSPL adlı küçük bir veri setine uygulamışlardır. Bu uygulama sonucunda %99.06 doğruluk elde edilmiştir. Daha sonra, aynı modeli yürüme, merdiven çıkma, merdiven inme, oturma, ayağa kalkma ve uzanma hareketlerini içeren 6 farklı insan aktivitesini içeren UCI-HAR açık veri setine uygulamışlardır. Bu veri seti üzerinde elde ettikleri performans sonucu %92.13 doğruluk oranıdır [40].

Huang ve ekibi, insan aktivite tanıma senaryolarında kullanılan CNN tabanlı modellerde kanallar arasında biriken gereksiz bilgilerin azaltılması için daha sık bir CNN modeli önermişlerdir. Bu model, kanallar arası iletişimi sağlamak amacıyla tasarlanmıştır. Araştırmalarını, UCI-HAR, OPPORTUNITY [41], PAMAP2 ve UniMiB SHAR [42] gibi herkese açık veri setlerini kullanarak gerçekleştirmişler ve elde ettikleri sonuçları performans analizi ile değerlendirmişlerdir. UCI-HAR veri seti üzerinde yapılan değerlendirmede, en yüksek doğruluk oranı %96.98 olarak kaydedilmiştir [43].

Challa ve ekibi, giyilebilir sensör verilerinden elde edilen WISDM [44], UCI-HAR ve PAMAP2 veri setleri üzerinde insan tanıma probleminde güçlü bir sınıflandırma modeli tasarlamak amacıyla çalışmışlardır. Bu bağlamda, CNN ve BiLSTM gibi teknikleri birleştiren hibrit bir model geliştirmişler ve bu modeli kullanarak performans analizleri gerçekleştirmişlerdir. Yapılan değerlendirmeler sonucunda, UCI-HAR veri seti üzerinde elde edilen en yüksek doğruluk oranı %96.37 olarak belirlenmiştir [45].

Chaobankoh ve ekibi, 2022 yılında EMG sinyallerini kullanarak dorsifleksiyon, nötral pozisyon ve plantarfleksiyon hareketlerini sınıflandırdı. Bu amaçla, 2 Boyutlu Evrişimli Sinir Ağı (2D-CNN) tercih ettiler. Algoritmanın eğitim aşamasında %99,34 ile yüksek bir başarı elde edilirken, test aşamasında % 71.38 ile ortalama bir başarıya ulaşıldı. Bu sonuçlar, kullanılan 2D-CNN ağına belirli ayak hareketlerini başarılı bir şekilde tanıma yeteneğine işaret etmektedir. Ancak, genelleme kapasitesini değerlendirmek açısından test sonuçları da önem taşımaktadır [46].

Tang ve ekibi, sensör tabanlı aktivite tanıma için Evrişimli Sinir Ağı (CNN) modelini daha güçlendirmek amacıyla yeni bir hiyerarşik bölünmüş evrişim ağı yaklaşımını geliştirmişlerdir. Bu yaklaşımı dört farklı veri setine uygulamışlardır. Elde edilen sonuçlara göre, UCI-HAR veri setinde %97.28, PAMAP2 veri setinde %93.75, WISDM veri setinde %99.02, UniMiB SHAR veri setinde ise %79.02 doğruluk oranları elde edilmiştir [47].

Hysenllari ve ekibi, yürüme, hızlı koşma, bisiklete binme, oturma, ayakta durma ve yatma gibi aktiviteleri tanıyan bir deney yaparak, CNN tabanlı sinir ağı performansının sensör konumuna göre nasıl değiştiğini gözlemlemiştir. Elde edilen sonuçlara göre, CNN'nin sensör ayak bileğinde olduğu zaman doğruluğu %96.57 iken, uyluk bölgesinde olduğu zaman doğruluğu %99.28 olarak belirlenmiştir [48].

Baloch ve ekibinin gerçekleştirdiği çalışmada, insan aktiviteleri sırasında sensörlerden elde edilen PAMAP2 ve RealDisp [49] açık veri setlerine CNN ve CNN-LSTM hibrit modelini uygulayarak %93.78 sınıflandırma doğruluğuna ulaştıkları görülmüştür [50].

Vakacherla ve arkadaşlarının yaptığı çalışmada, 10 denek üzerinde gerçekleştirilen bir insan etkinliği tanıma çalışması bulunmaktadır. Bu çalışmada, deneklerin göğsüne takılan üç eksenli tek bir ivmeölçer kullanılarak ayakta durma, düz zeminde yürüme, yokuşta yürüme, koşma ve çömelme gibi aktiviteler tanınmıştır. Çalışmada, tek boyutlu CNN ve CNN ile LSTM kullanan hibrit bir model olmak üzere iki farklı yöntem denemiştir. Her iki yöntem de çevrimiçi ve gerçek zamanlı olarak değerlendirilmiştir. Gerçek zamanlı değerlendirmelerde sırasıyla %96.6 ve %97.2 doğruluk elde edilmiştir [51].

Vu ve arkadaşları, hareket modu tanıma için dört farklı modeli karşılaştırmışlardır: Rasgele Orman Sınıflandırıcısı (RFC) gibi bir makine öğrenimi modeli ile Tekrarlayan Sinir Ağı (RNN), LSTM ve CNN gibi üç derin öğrenme modeli. Bu modeller, Python dilinde yazılmış ve açık kaynaklı Keras kütüphanelerini temel alan Google Colab ortamında işlenmiştir. Düz zeminde yürüme, ayakta durma, merdiven inme, merdiven çıkma gibi dört farklı yürüyüş modu için 4 sağlıklı katılımcıdan 3 boyutlu ivmeölçer ve jiroskop verileri toplanmıştır. Elde edilen sonuçlara göre, CNN için %99.60, LSTM için %98.68, RFC için %96 ve RNN için %93.65 tanıma doğruluğu elde edilmiştir. Bu sonuçlar, CNN ve LSTM algoritmalarının diğer modellere kıyasla daha iyi bir performans gösterdiğini göstermektedir [52].

1.4. Robot Kontrolü ile İlgili Yapılan Çalışmalar

Başbuğ'un 1995 yılında gerçekleştirdiği doktora tezi çalışmasında, TÜBİTAK MAM Robotik Bölümü'nde tasarlanan ve üretilen 6 serbestlik dereceli MAMROB ER-15 adlı robot üzerinde bulanık adaptif kayan kipli kontrol yöntemleri geliştirilmiş ve robot kontrolü gerçekleştirilmiştir. Yapılan simülasyon çalışmalarında, 3 uzvun yeterli olduğu gözlemlenmiş ve bu nedenle çalışmalar, 3 serbestlik derecesine göre gerçekleştirilmiştir. [53].

Topalbekiroğlu'nun 1996 yılında gerçekleştirdiği tez çalışmasında, 3 serbestlik dereceli bir hidrolik robota ve bir DC servo sistemine adaptif ve öğrenme kontrol yöntemlerini uygulamıştır. Bu çalışma, hidrolik robot ve DC servo sistemini içeren mekatronik sistemlerin kontrolü üzerine odaklanmaktadır. Adaptif kontrol yöntemleri, sistem parametrelerindeki değişikliklere uyum sağlamak ve istenilen performansı elde etmek amacıyla kullanılan bir kontrol yaklaşımıdır. Öğrenme kontrolü ise sistemin çevresindeki koşulları öğrenerek kendini geliştirebilen bir kontrol stratejisidir [54].


Hacıoğlu'nun 2004 yılındaki tez çalışmasında, bir robotun kontrolünü gerçekleştirmek amacıyla farklı kontrol yöntemlerini incelemiş ve uygulamıştır. Bu yöntemler arasında PD kontrol, bulanık kontrol, kayan kipli kontrol ve bulanık mantıklı kayan kipli kontrol çalışmalarını içermektedir. Yapılan bu çalışmalarda, farklı kontrol stratejilerinin robot kontrolündeki performansını değerlendirmiş ve karşılaştırmıştır. Elde edilen sonuçlara göre, Hacıoğlu'nun çalışması bulanık mantıklı kayan kipli kontrol yönteminin en iyi performansı sağladığını göstermiştir. Bu, bulanık mantık ve kayan kipli kontrolün birleştirilmiş hibrit bir kontrol stratejisinin, belirli robotik uygulamalarda daha etkili ve başarılı olabileceğini gösteren bir bulgudur [55].

Klute ve arkadaşları 1998 yılında, pnömatik McKibben aktüatörleri tarafından tahrik edilen aktif bir ayak bileği protezi tasarladılar. Bu çalışma, protezin tasarımı ve pnömatik aktüatörlerin kullanımı ile ilgili bir örnek oluşturarak, aktif protezlerin geliştirilmesine yönelik erken dönemdeki önemli araştırmalardan biridir. Pnömatik aktüatörler, protezin kullanıcıya daha doğal bir yürüyüş deneyimi sağlamak için tasarlanmış ve kullanılmıştır [56].

Versylus ve diğerleri, "Pnömatik Yapay Kas" olarak adlandırılan pnömatik bir protez tasarladılar. Bu protez, yüksek tork üretebilme kapasitesine sahiptir ve kullanıcının gücünü koruyabilmek adına düz yürüme sırasında etkili bir şekilde çalışabilir. İki serbestlik derecesine sahip olan bu diz altı protezi, dorsifleksiyon-plantar fleksiyon ve inversiyon-eversiyon hareketlerini gerçekleştirebilir. Ayrıca, ayak bileğinin yeterli hareket açıklığına sahip olmasını sağlar. Bu tasarım, protezin kullanıcıya doğal ve etkili bir yürüyüş deneyimi sunmak amacıyla yüksek tork üretme yeteneği ve çeşitli hareket serbestlikleri ile öne çıkmaktadır. Bu sayede protez, kullanıcının gücünü etkili bir şekilde destekleyerek düz yürüme sırasında stabilite ve doğruluk sağlar [57].

Pnömatik aktüatörler, genellikle büyük hacimlere ve karmaşık kontrol sistemlerine ihtiyaç duyabilirler. Bu durum, protezin genel boyutunu artırabilir ve bu da hem estetik hem de kullanıcı konforu açısından sorunlar yaratabilir ve bu pnömatik aktüatörlerin kullanımında azalmaya neden olur. Bu sorunların üstesinden gelmek amacıyla, Arizona Eyalet Üniversitesi'nde gerçekleştirilen SPARKy 1 projesi kapsamında, bir ayak protezi tasarlanmıştır. Bu proje, "Seri Elastik Aktüatör" adı verilen bir sistem kullanarak çalışmaktadır. Bu aktüatör, serbestlik derecesine sahip olup güçlü bir fırçasız DC motor ve bilyeli vida içermektedir. Pnömatik aktüatörlerin sunduğu avantajları ve kontrol zorluklarını aşmak için bu tür bir aktüatör kullanımı, daha kompakt bir tasarım ve daha az gürültüyle


birlikte kontrol kolaylığı sağlayabilir. Bu, protezin daha kullanıcı dostu ve etkili bir şekilde kontrol edilebilir hale gelmesini sağlayabilir [58, 59]. SPARKy 3 projesinde, dorsifleksiyon-plantarfleksiyon ve inversiyon-eversiyon hareketlerini gerçekleştirebilecek ikinci bir motor prototipe eklenmiştir. Bu güncelleme, protezin daha geniş bir hareket kabiliyetine sahip olmasını sağlar. Şekil 1'de, SPARKy 1, SPARKy 2 ve SPARKy 3 projelerini gösteren bir görsel bulunmaktadır. Bu projelerin evrimi, protezin tasarımındaki gelişmeleri ve eklenen özellikleri göstermektedir.



Şekil 1. SPARKy projesi. (A) SPARKy projesinin robotik ayak bileği protezinin ilk tasarımı. (B), ağırlık ve boyutun azaltıldığı SPARKy 2 prototipi. (C) iki serbestlik derecesine sahip son prototip SPARKy 3

Herr ve ekibi, ampute bireyin geri kalan kaslarından ölçülen miyoelektrik girdileri kullanarak, Seri Elastik Aktüatöre ek olarak ayak bileğine paralel tek yönlü yay sahip, güçlendirilmiş bir ayak bileği protezi tasarladı. Paralel yay, duruş aşamasında dorsifleksiyon sırasında hem empedansı hem de güç çıkışını düzenleyerek tepe kuvvetini artırır. Bu çalışmada, Şekil 2'de gösterildiği gibi miyoelektrik odaklı bir son durum kontrolörü geliştirilmiştir. Bu kontrolör, amputenin geri kalan kaslarından alınan miyoelektrik sinyalleri kullanılarak protezin durumunu yönetir. Bu yaklaşım, protezin ampute kullanıcının kas


aktivitesine daha iyi uyum sağlamasını sağlayarak doğal ve etkili bir yürüme deneyimi sunmayı hedeflemektedir [60].



Şekil 2. Herr ve ekibinin tasarladığı elektrikli ayak bileği protezinin şeması

Zhu ve ekibi, ayak bileği ve ayak parmağı eklemine kontrol eden iki Seri Elastik Aktüatör içeren ayak bileği eklem protezini tasarladı. Bu protez, açı ve kuvvet sensörleri gibi elemanları içermektedir ve PANTOE 1 olarak adlandırılmaktadır. Sensör sistemi, kullanıcının Şekil 3'te gösterildiği gibi gerçek zamanlı olarak mafsalların konumunu ve momentini takip ederek daha doğal ve istikrarlı bir şekilde hareket etmesini sağlar. Bu sistem, protezin kullanımı sırasında kullanıcının hareketlerini daha etkili bir şekilde algılamak ve bu bilgileri protezin kontrolünde kullanmak amacıyla tasarlanmıştır. [61].

Lawson ve ekibi, merdiven iniş ve çıkışları gibi karmaşık aktiviteleri gerçekleştirebilen bir transfemoral protez tasarımını ele alarak bu protezi kontrol etmek için bir sonlu durum denetleyicisi önerdiler. Bu protez, üzerinde yük sensörleri, açı sensörleri ve atalet ölçüm ünitesi bulunan bir dizi sensör ile donatılmıştır. İki fırçasız DC motor, protezin hareketini sağlar. Sonlu durum denetleyicisi, protezin dengesini korumak, merdiven iniş ve çıkışlarını yönetmek ve kullanıcının çeşitli aktiviteler sırasında güvenli bir şekilde hareket etmesini sağlamak için tasarlanmıştır. Yük sensörleri ve diğer sensörlerden gelen veriler, protezin durumunu gerçek zamanlı olarak izleyip, bu bilgileri kullanarak protezin tepkilerini optimize eder [62].



Şekil 3. PANTOE 1'in CAD modeli

Ficanha ve ekibi, dorsifleksiyon-plantarfleksiyon (DP) (ayak bileğinin yukarı-aşağı hareketi) ve inversiyon-eversiyon (IE) (ayak bileğinin içe-dışa dönme hareketi) hareketlerini gerçekleştirebilen özel bir mekanizma geliştirmişlerdir. Bu mekanizma, insan ayak bileğinin doğal hareketlerini taklit edebilen bir kablo tahrikli sistemdir. Mekanizma, bu hareketleri gerçekleştirmek için iki serbestlik derecesine sahiptir. İki yönde hareket eden DC motorlar, mekanizmanın istenen hareketleri yapmasını sağlar. Ters yönde hareket eden motor dorsifleksiyon-plantarfleksiyon hareketini, aynı yönde hareket eden motor ise inversiyon-eversiyon hareketini gerçekleştirir. Bu tasarımın amacı, kullanıcının doğal ayak bileği hareketini daha gerçekçi bir şekilde taklit etmek ve kullanıcının günlük aktivitelerini daha rahat ve doğal bir şekilde gerçekleştirmesine yardımcı olmaktır [63].

Collins ve Kuo, enerji verimliliğini en üst düzeye çıkarmak amacıyla geliştirdikleri yapay ayakta, topuk vuruşundan sonra enerji depolayan ve duruş aşamasının sonunda bu enerjiyi serbest bırakan mikroişlemci kontrollü bir mekanizma kullanmışlardır. Bu özel mekanizma, doğal yürüyüş sırasında oluşan enerjiyi daha etkili bir şekilde yöneterek kullanıcının metabolik enerji harcamasını minimize etmeyi hedefler. Ayrıca, Collins ve ekibi, ayak bileği eklemi DP ve IE yönlerinde etkinleştiren Bowden kablolarıyla kontrol edilen bir ayak bileği emülatörü de geliştirmişlerdir. Bu emülatör, ayak bileği hareketlerini hassas bir şekilde taklit ederek kullanıcının doğal yürüyüş paternine daha yakın bir deneyim yaşamasını sağlar. Bu tasarım, yapay uzuv teknolojisinin enerji verimliliği ve doğal hareket taklidi konularındaki gelişmelerine örnek teşkil etmektedir [64, 65].


1.5. Ayak Biyomekaniği

Biyomekanik, mekanik bilimini kullanarak insanlar, hayvanlar, bitkiler, mantarlar, hücreler vb. canlıların yapısını, işleyişini ve hareketini inceleyen bilim dalı olarak tanımlanmaktadır [66]. Biyomekanik çalışmalarında kinematik ve dinamik gibi disiplinler önemli bir rol oynamaktadır. İnsanlarda iskelet ve kas sistemlerinin farklı koşulları altında nasıl çalıştığının belirlenebilmesi için biyomekaniğin incelenmesi gerekmektedir.

Çalışma konumuz ayak bileği protez tasarımı olduğu için, insan alt ekstremitesi detaylı bir şekilde incelenmiştir. Alt ekstremitte, üç ana bölgeye ayrılmıştır. İlk bölge, uyluk, kalça eklemi ve diz eklemi arasında bulunan bölgedir. İkinci bölge bacak olarak adlandırılır ve diz eklemi ile ayak bileği eklemi arasında yer alır. Üçüncü ve son bölge ise ayaktır, bu bölge ayak bileğinin altında kalan kısmı kapsar. Alt ekstremitteyi oluşturan kemikler arasında femur, patella, tibia, fibula, tarsal kemikler, metatarsal kemikler ve falanks yer almaktadır, bu kemikler Şekil 4'te gösterilmiştir. Yapay bir ayak bileği eklemi tasarımı, normal yürüyüş sırasında insan ayak bileği kinematikini ve kinetiğini en azından kısmen taklit edecek şekilde gerçekleştirilebilir. Ayak bileği eklemi, gövde ile ayak arasında bir menteşe görevi görür ve tıp literatüründe talocrural, subtalar ve inferior tibiofibular olmak üzere üç eklemi içeren talocrural bölgesi olarak adlandırılır. Ayak bileği eklemi, bacakta tibia ve fibula, ayakta ise talus adlı kemiklerin birbirine bağlanmasıyla oluşur. Ayak bileği ekleminin ürettiği hareketler arasında plantar fleksiyon, dorsifleksiyon, inversiyon ve eversiyon yer almaktadır. Plantar fleksiyon hareketi genellikle gastrocnemius, soleus ve peroneus longus kasları tarafından kontrol edilirken, dorsifleksiyon hareketi tibialis anterior, extensor digitorum longus ve extensor hallucis longus kasları tarafından kontrol edilir. Ayak bileğinin subtalar eklemi, inversiyon ve eversiyon hareketlerine izin verir. Bu bilgiler, yapay bir ayak bileği eklemi tasarımında doğal hareketin taklit edilmesi için rehberlik sağlamaktadır [67,68,69]. Ayak bileği eklemi kaslarının oluşturduğu kuvvetleri doğrudan ölçmek oldukça zor olduğundan, genellikle eklem torklarını tahmin etmek için yaygın bir yöntem, yer reaksiyon kuvvetlerini kaydederek ters dinamikleri uygulamaktır [70].

Tabanın hareket yetenekleri açısından, ayak sagittal düzlemde (ileri-geri yönde) plantarfleksiyon ve dorsifleksiyon, frontal düzlemde (yan yana yönde) inversiyon ve eversiyon, transvers düzlemde (dönme hareketi) ise abduksiyon (ayak parmaklarının dışa doğru hareketi) ve adduksiyon (ayak parmaklarının içe doğru hareketi) hareketlerini gerçekleştirir. Ayak ve ayak bileği, vücudu destekleyen ve hareket ettiren önemli bir yapıdır.

Ayak bileđi, vücut ağırlığını ayađa ileterek bacak ve ayak arasındaki bađlantıyı sađlar. Ayrıca, ayak bileđinin hareket kabiliyeti, dinamik performansın sürdürölmesinden sorumlu olan DP hareketlerini yönetir [71].




Şekil 4. Bacak kemikleri [72]

Femur, insan vücudundaki en uzun ve en güçlü kemik olarak bilinir. Bu kemik, kalçadan dize kadar uzanır ve uyluk kemiđi olarak adlandırılır. Patella ise diz ekleminin ön tarafında yer alan düz, ters çevrilmiş üçgen bir kemiktir. Femur ile eklem yapar ve vücuttaki en geniş sesamoid kemik olarak bilinir. Tibia, bacağın ön ve medial (orta) kısmında bulunan ağırlık taşıyan vücuttaki ikinci en güçlü kemiktir. Tibia genellikle kaval kemiđi olarak adlandırılır. Diđer bir kemik olan fibula, tibianın lateral (yan) tarafında bulunur. Fibula, ince ve uzun bir kemiktir ve baldır kemiđi olarak da bilinir.

1.6. Ayak Anatomisi

Ayak, insan iskeletinin yaklaşık %25'ini oluşturan ve vücut ağırlığını taşıyarak zemine aktaran, yürüyüş sırasında vücudu ön tarafa doğru itmeyi sağlayan karmaşık bir yapıdır. Bu yapı, 26 kemikten oluşan bir anatomiye içerir ve işleyişi oldukça komplekstir. Ayak, yürüme ve koşma sırasında vücut hareketleriyle entegre olduğu için, ayak anatomisinin detaylı bir şekilde incelenmesi ve biyomekaniğinin araştırılması, bu yapının işlevini ve olası bozuklukları anlamak açısından önemlidir [73]. Ayak ve ayak bileği yapısının esnek ve rijit olması, diğer alt ekstremite bölgeleriyle ilişkili hareketleri gerçekleştirebilmek açısından kritiktir. Bu yapılar, özellikle yürüyüş sırasında ayağın hareketinin, alt ekstremite kemiklerinin tüm hareketine eşdeğer olduğu bir denge sağlar [74]. Ayak, Şekil 5'te görüldüğü gibi tarsal kemikler (ossa tarsi), metatarsal kemikler (ossa metatarsi) ve parmak kemikleri (ossa digitorum, phalanges) olmak üzere üç bölüme ayrılır.



Şekil 5. Ayak kemikleri [75]

1.6.1. Ossa Tarsi ve Ossa Metatarsi

Tarsal kemikler, ayak ve ayak bileğinin temel bileşenlerini oluşturan yedi kemikten meydana gelir. Bu kemiklerin yerleşimi şu şekildedir: Talus ile calcaneus kemikleri proksimalde, os cuneiforme mediale, os cuneiforme intermedium, os cuneiforme laterale ve cuboideum ise distalde bulunurlar. Os naviculare kemik ise medialde konumlanır. Talus, ayak bileği ekleminde tibia ve fibula ile birleşirken, calcaneus (topuk kemiği) ile vücut ağırlığını yüklenir. Bu tarsal kemikler, ayak ve ayak bileğinin dayanıklılığını sağlayarak,

çeşitli hareketleri mümkün kılarlar [75, 76]. Calcaneus, tarsal kemikler arasında en geniş olanıdır ve özellikle gastrocnemius (büyük adale) ve soleus (tek kas) kasları için bir kaldıraç kolu görevi görür. Bu kemik, ayağın ekstansiyonu ve fleksiyonu için önemli bir dayanak noktası sağlar. Gastrocnemius ve soleus kasları, Achilles tendonu aracılığıyla calcaneus'a bağlanarak topuk kemiğini hareket ettirir ve ayak bileğinin hareketlerine katkıda bulunur. Metatarsal kemikler ise ayak bileği ile parmak uçları arasındaki bölgeyi oluşturan ön ayak kemikleridir. Bu kemikler, cuneiform kemiklerin ve cuboid kemiğin distal uçlarına bağlanarak ayak parmaklarının tabanını oluştururlar. Metatarsal kemikleri, alt ekstremitedeki birçok kasın giriş ve çıkış noktalarını barındırarak ayakta dengeyi ve hareketi desteklerler. Metatarslar, distal başlarındaki geniş ağırlık taşıma alanları nedeniyle uygun biyomekanik yürüyüş için kritik bir rol oynarlar. Bu yapılar, vücut ağırlığını dengeleyerek ve adımları destekleyerek sağlam ve etkili bir yürüyüşü mümkün kılarlar [77]. Bileği oluşturan kemikler, etrafını saran bağ doku sayesinde bir arada tutunur ve hareketler kas gruplarıyla sağlanır. Her eklem bir çift kas ile bağlantılıdır.


1.7. Yürüyüş Analizi

Bu çalışmanın temel amacı, ayak bileği protezi tasarım sürecinde ilk adım olan insan yürüyüşü ve biyomekaniğini detaylı bir şekilde incelemektir. Bu kapsamda, David A. Winter'ın klinik yürüyüş analizi verileri kullanılarak insan yürüyüşünün kinematik tanımlaması yapılmıştır. Bu tasarım, sağlıklı bir ayak bileği biyomekaniği temsil eden ayak bileği eklem kinematik özelliklerini içermelidir. Özellikle, Dorsifleksiyon-Plantarfleksiyon ve Inversiyon-Eversiyon gibi ayak bileği eklem hareketlerini gerçekleştirebilen protezlerin geliştirilmesi hedeflenmektedir.

Protez ayağın tasarımında ve eyleyici seçiminde en önemli araçlardan biri, insan hareketinin analizi için kullanılan klinik yürüyüş analizi verileridir. Bu veriler, protez ayağın tasarımında kullanıcıya en doğal ve etkili yürüyüş deneyimini sağlamak amacıyla önemli bir rol oynar. Protez ayağın, kullanıcısının ayağını taklit etmesi için gereken hareketleri belirlemede klinik verilerin kullanılması önemlidir. Klinik yürüyüş analizi verileri genellikle mafsal açılarını ölçen hareket yakalama kameraları ve yer tepki kuvvetlerini ölçen kuvvet plakaları gibi teknolojik araçlar kullanılarak elde edilir. Bu veriler, insan anatomik mafsallarının serbestlik derecesi ve hareket aralığı gibi önemli bilgileri sağlar. İskelet gövdenin yer ile temas halinde bulunan tek uzvu olan ayak, bir taraftan protezin ve

kullanıcının ağırlığına, diğer taraftan da zeminden etki eden yer tepki kuvvetlerine maruz kalmaktadır. Bu yüzden ayak kullanıcıya rahatsızlık vermeyecek kadar esnek, üzerine gelen kuvvetleri taşıyabilecek kadar da dayanıklı olmalıdır [78].

Vücudu anatomik olarak incelediğimizde, Şekil 6'da görüldüğü gibi üç ana düzlem kullanılır. Bu düzlemler vücut hareketlerini ve anatomik ilişkileri daha iyi anlamamıza yardımcı olur.



Şekil 6. Anatomik düzlemler [79]

1. **Sagittal Düzlem:** Bu düzlem, vücudu sağ ve sol olmak üzere iki eşit yarıya böler. Sagittal düzlemde yapılan hareketlere örnek olarak yürüme veya kol ve bacakların yanlara hareketi verilebilir.
2. **Frontal Düzlem (Koronal Düzlem):** Bu düzlem, vücudu ön ve arka olarak iki eşit yarıya böler. Bu düzlemde yapılan hareketlere örnek olarak yana eğilme veya yana kaldırma gibi hareketler verilebilir.

3. Transvers Düzlem (Horizontal Düzlem): Bu düzlem, vücudu alt ve üst olarak iki eşit yarıya böler. Bu düzlemde yapılan hareketlere örnek olarak dönme veya döndürme hareketleri verilebilir.

Bu düzlemler, vücut anatomisi, fizyolojisi ve hareket analizinde kullanılarak, organizmanın yapı ve fonksiyonları hakkında daha ayrıntılı bilgiler sağlar.


Yürüyüş, insanın doğasında yer alan ve genellikle refleks olarak gerçekleşen bir temel aktivitedir. Yürüme sırasında ayağın yerde olduğu süre ve yerden ayrıldığı süre, yürüme döngüsünü oluşturan iki temel fazı temsil eder: basma (duruş) ve salınım fazı. Normal bir yürüyüşte, bu iki faz arasındaki oranlar genellikle belirli bir düzeni takip eder. Yapılan gözlemlere göre, yürüyüşün yaklaşık %60'lık bölümü basma fazında gerçekleşirken, %40'lık bölümü ise salınım fazında geçer. Bu oranlar, yürüme biyomekaniği ve enerji etkinliği açısından önemli bilgiler sağlar. Yürüme döngüsü, vücut ağırlığını etkili bir şekilde taşıyarak ve enerjiyi verimli bir şekilde kullanarak insanların günlük aktivitelerini gerçekleştirmesine olanak tanır [80, 81]. Şekil 7'de yürüyüşün fazları verilmiştir.

1. Basma (Duruş) Fazı: Bu fazda, ayağın yere temas ettiği dönemdir. Yani, bir ayağın yere basarak destek oluşturduğu süreçtir. Bu aşamada bacak ve ayak kasları, vücut ağırlığını taşıyarak dengeyi sağlar. Bu faz beş bölümde incelenir:
 - Topuk Vuruşu ve Topuk Teması: Ayak, yere topuk vuruşuyla temas eder.
 - Ayak Tabanının Yere Teması: Ayağın tabanı, yere tamamen temas eder.
 - Orta Duruş Fazı: Ayak tamamen yerde durur ve vücut ağırlığı eşit olarak dağılır.
 - Topuk Kalkışı: Ayak, topuktan kalkmaya başlar.
 - Ayak Parmaklarının Kalkışı: Ayak parmakları, yere tamamen temas kesilerek kalkar.

Topuk vuruşu ve topuk teması yürüyüş fazının %10'unu teşkil eder. Ayak tabanının yere teması ve orta duruş fazı yürüyüş fazının %30'unu teşkil eder. İtme fazı olan topuk kalkışı ve ayak parmaklarının kalkışı yürüyüş fazının %20'sini teşkil eder.

2. Salınım Fazı: Bu fazda ise ayağın yerden ayrıldığı ve bir sonraki adıma hazırlandığı dönemdir. Kaslar, vücudu ileri itmeye yönelik hareketler yapar ve diğer bacağın adımını atmaya hazır hale gelir.

- Akselerasyon: Ayak parmakları yerden ayrılarak hareketin başlangıcını oluşturur.
- Orta Sallanma: Ayak serbest düşer ve karşı taraf için bir sonraki adımın hazırlığı yapılır.
- Deselerasyon: Ayak parmakları yerle temas ederken hareket yavaşlar ve diğer bacağın hazırlık aşamasına geçilir [82].



Şekil 7. Yürüyüşün fazları [83]

İnsanın hareket etme kabiliyeti, iskelet ve kas sistemlerinin mükemmel bir şekilde birbirleriyle uyumlu çalışmasına bağlıdır. İskelet, vücuttaki tüm kemikleri içerir ve bu kemikler kaslara bağlıdır. Kaslar, kasıldıklarında kemikleri çeker ve bu sayede vücudumuzun hareketini sağlar. Bu koordineli iş birliği, günlük aktivitelerimizi gerçekleştirmemize olanak tanır. Hareket başlatılmak istendiğinde, beyin hemen bir elektrik sinyali gönderir. Bu sinyal, karmaşık bir yolculuğa çıkar. İlk olarak, sinyal omuriliğe ulaşır ve buradan ilgili organa hızlı bir şekilde yönlendirilir. Elektrik akımı, milyonlarca motor biriminden oluşan kasları uyandırır ve sinyali alan lifler anında kasılarak hareketin gerçekleşmesini sağlar. Bu süreç, vücudumuzun istenilen hareketlere hızlı ve hassas bir şekilde yanıt vermesini mümkün kılar.

Yürüyüş, en önemli motor fonksiyonlardan biridir ve bu fonksiyonu gerçekleştiren aktif elemanlardan birinin veya her ikisinin kaybı, bireyin günlük yaşamında önemli

kısıtlamalara neden olabilir. Bu nedenle, alt ekstremitte amputasyonları büyük önem taşır ve bu eksikliklerin en uygun protezlerle doldurulması kritiktir. Yürüyüş analizi, bu süreçte önemli bir rol oynar. Zamansal ve uzaysal kinematik veriler, kişinin yürüme şekli hakkında detaylı bilgiler sağlar. Geçici-mekânsal analiz, yürüme hızı ve ek bileşenler gibi faktörleri belirlemek için kullanılırken, kinematik analiz eklemlerin hareket uzunluğunu ortaya çıkarır. Ayrıca, kinetik analiz, yürüme sırasında etki eden güç ve momentleri inceleyerek biyomekanik açıdan önemli bilgiler sunar [84].

Yürüyüş analizi, yürüme değerlendirmesinin tanımlanması ve yorumlanmasıdır. Bu analizin temel amacı, ortez ve protezlerin etkinliğini araştırmak ve yeni protez tasarımları geliştirmektir. Bu süreç, özellikle amputasyon geçiren bireylerle ilgili olan hastalık grupları için büyük önem taşır. Geçmişte, yürüyüş analizi için doğrudan ölçüm cihazları kullanılmıştır. Örneğin, ayağın zemine temas etme anını belirlemek için kontak anahtarları veya elektro gonyometreler kullanılmıştır [85]. Ayrıca eklem uzuvlarına sarılı potansiyometreler ile eklemlerin bağıl açıları ölçülmüştür [86].

Son zamanlarda klinik yürüyüş analizi için beş temel unsur bulunmaktadır: video kaset incelemesi, genel yürüyüş parametrelerinin ölçümü, kinematik analiz, kinetik ölçüm ve elektromiyografi (EMG). Bu unsurlar, yürüyüş biyomekaniğini anlamak ve değerlendirmek için kapsamlı bir yaklaşım sunar. Kinematik ölçümler, bilgisayara bağlanabilen televizyon kameraları kullanılarak alt ekstremitedeki ana eklemin 3 boyutlu hareketini betimlemektedir. Kinetik ölçümler ise yer reaksiyon kuvvetlerinin ölçümünü içerir ve genellikle kuvvet platformları kullanılarak gerçekleştirilir.

Biyomekanik araştırmaların kökeni, 19. yüzyılın başlarına dayanmaktadır ve bu alandaki ilk resmi çalışmalar, Almanya'da Weber kardeşler tarafından gerçekleştirilmiştir. 1895'te Braune ve Fisher, dijital değişkenleri fotoğraflık görüntülere dönüştürerek yürüyüş analizi yöntemlerinin gelişimine önemli katkılarda bulundular. Hareketin ölçümüne odaklanan kinematik çalışmalar ise 1870'lerde Paris'te Marey ve Kaliforniya'da Muybridge tarafından başlatılmıştır [87]. Yürüme analizine ilişkin ilk yorumlar, Garrison (1929), Bresler ve Frankel (1950) ile Steindler (1953) tarafından yapılmıştır [88-90]. Kinetik ölçümler, Amar tarafından 1920'de ve Elftman tarafından 1938'de kullanılan mekanik tek boyutlu kuvvet platformlarıyla ilk kez ölçülmüştür [91,92]. Yürüyüş sırasında EMG ile kasların elektriksel ölçümleri ise ilk kez 1940'larda ve 1950'lerde Inman ve ekibi tarafından yapılmıştır [93]. 1950'lerde, Verne Inman ve Jacqueline Perry'nin çalışmalarıyla birlikte, bilimsel yürüyüş analizinin klinik kullanımı başlamıştır. Bu dönemde yapılan araştırmalar,

günümüzde hala temel alınan yürüyüş analizi prensiplerini ortaya koymuştur. Günümüzde, yürüyüş analizi sırasında ekstremite hareketi ve yer reaksiyon kuvveti verilerini kullanarak eklem momentleri ve kuvvetlerini hesaplamak için "ters dinamikler" kullanılmaktadır. Bu yaklaşım, yürüyüş sırasında ortaya çıkan biyomekanik değişiklikleri anlamak ve rehabilitasyon süreçlerini geliştirmek için önemlidir. SIAMOC Konsensüs Konferansı'nda bildirildiği üzere, klinik yürüyüş analizi, kuvvet platformları ve optoelektronik sistemlerle gerçekleştirilen çalışmalarla protez alanında karar vermede ve genel rehabilitasyon modellerini tasarlama konusunda etkili bir araç olarak kabul edilmektedir [94].

Ayak bileği hareketini değerlendirmek amacıyla Helen Hayes ayak modeli, literatürde yaygın bir şekilde kullanılan ve ayak bileği kompleksini tek bir katı segment olarak modellenen bir modeldir. Bu model, biyomekanik analizlerde ve yürüme analizlerinde ayak bileği hareketlerini anlamak ve değerlendirmek için bir temel oluşturur [95]. Tek bir segment olarak modellenen ayak modeli ile kuvvet, moment ve güç bilgileri analiz edilebilir; ancak yürüme sırasındaki karmaşık hareketler detaylı bir şekilde gözlemlenemez. Bu sorunu aşmak amacıyla geliştirilen çok segmentli ayak modelleri, ayak bileğinin farklı bölgelerinin hareketlerini inceleyerek ayağın kinematiği hakkında daha detaylı bir anlayış sağlar [96]. Son yıllarda, uzuvdaki her bir işaretçinin hareketini takip eden 3 boyutlu hareket yakalama sistemlerine dayanan çok segmentli ayak modelleri geliştirilmiştir. Antropometri ölçümleri, bu ayak modellerinin geliştirilmesinde önemli bir adımdır ve bu veriler, ortez ve protez tasarımlarında etkili bir rol oynar.

Antropometri, insan bedeninin boyutları, kemik yapısı, yağ oranı gibi fiziksel özelliklerinin yanı sıra farklı noktalara göre atalet momenti ve kütle merkezinin yeri gibi ölçümleri de içeren bir bilim ve araştırma alanıdır. Bu ölçümler, genellikle vücudun çeşitli bölgelerindeki uzunluklar, genişlikler, çevreler, açılar ve diğer boyutlar gibi çeşitli parametreleri içerir. Antropometri, bu ölçümleri sistematik bir şekilde kaydederek, insan vücudunun fiziksel özelliklerini analiz etmek ve çeşitli amaçlar için kullanmak için birçok disiplinin içinde yer alır [97]. Alt ekstremitenin ayak analizinde kullanılacak ayak kütlesi, ayak uzunluğu, ayak kütle merkezinin proksimal ve distal eklem mesafesi gibi antropometrik bilgileri için Dempster tarafından oluşturulan Tablo 1'deki veriler referans alınmıştır [98].

Tablo 1. Ayak için antropometrik veriler

	Uzuv boyu	Uzuv kütlesi	Uzuv kütesinin yerleşimi		ρ: Dönme yarıçapı L: Uzuv boy(ρ/L)		
	xToplam boy	xToplam kütle	Proksimal	Distal	Kütle merkezine göre	Proksimale göre	Distale göre
Ayak	0,152	0,0145	0.5	0,5	0,475	0,69	0,69

f harfiyle gösterilen ayak uzuv kütlesi, (1)'deki gibi kişinin toplam kütesinin yüzdesi olarak yazılabilir, benzer şekilde, ayak uzvunun boyu (2)'deki gibi aynı tablodan yazılabilir.

$$m_f = 0.0145 * m_{top} \quad (1)$$

$$L_f = 0.152 * L_{top} \quad (2)$$

Uzvu kütle merkezinin, uzvu proksimal eklem merkezinden konumu, (3)'teki gibi ifade edilebilir.

$$C_f = 0.5 * L_f \quad (3)$$

Kütle merkezine göre ayak uzvunun eylemsizlik momenti de (4)'teki gibi elde edilir.

$$I_f = m_f * (0.475 * L_f)^2 \quad (4)$$

Winter tarafından gerçekleştirilen bir deneyde, 56,7 kg ağırlığındaki bir gönüllü üzerinde iki boyutlu bir yürüme analizi yapıldı. Gönüllü, bir kuvvet platformunu içeren bir parkurda yürüyerek, her saniyede 70 görüntünün kaydedilmesi sağlandı. Bu görüntüler üzerinde, vücut kütle merkezi, kalça eklemi, diz eklemi, ayak bileği eklemi, 5. metatarsal eklem, başparmak ucu ve topuk koordinatları belirlemek için 7 işaretleyici kullanıldı.


Bu modelde, kuvvet platformları kullanılarak ölçülen yer reaksiyon kuvvet vektörünün etki noktasının konumu, eşitlik (5)'te ifade edilmiştir. Ortak tepki kuvvetlerinin yatay ve düşey bileşenleri, sırasıyla eşitlik (6)'da belirtilmiştir. Eklem momenti, eşitlik (7)'deki formülle hesaplanmaktadır.

Bu modelde, her bir uzvun kütesinin bir nokta-kütle olarak kabul edildiği ve uzvun kütle merkezinin hareket sırasında değişmeden kaldığı, eklemlerin tek merkezli olduğu, her uzvun kütle merkezinin uzva göre konumlanmış olduğu, her uzvun kütle merkezi ile komşu eklem merkezleri arasındaki atalet momentinin hareket sırasında değişmediği ve sabit kaldığı varsayılmaktadır. Bu yaklaşım, her uzva ayrı ayrı odaklanarak bilinmeyen tüm reaksiyon kuvvetlerini ve eklem momentlerini hesaplama olanağı sağlamaktadır.

$$X_p = \frac{M_z + F_x * y_o}{F_y} \quad (5)$$

$$\begin{aligned} R_{xa} &= m_f a_{xf} - R_{xg} \\ R_{ya} &= m_f (a_{yf} + g) - R_{yg} \end{aligned} \quad (6)$$

$$T_a = I_f a_f - R_{xg} \cdot Y_f - R_{yg} (X_p - X_f) + R_{xa} (Y_a - Y_f) + R_{ya} (X_f - X_a) \quad (7)$$



Şekil 8. Diz ve ayak bileği eklem-uzuv modeli

Ayağın yatay eksene göre olan açısı, bacağın dikey eksene göre olan açısı ve ayak bileği eklemine bitişik iki uzuv arasındaki açılar sırasıyla eşitlik (8), (9) ve (10)'da belirtilmiştir. Burada θ_f ayağın yatay eksene göre yaptığı açısı, θ_s bacağın dikey eksene göre yaptığı açısı, A ise ayak bileği eklemine bitişik iki uzuv arasındaki açıyı ifade eder. Ayrıca, θ_a bilek eklemının fleksiyon açılarını temsil eder.

Konum koordinatları ise şu şekildedir: (X_m, Y_m) 5. metatarsal eklemi için konum koordinatlarını, (X_a, Y_a) ayak bileği eklemi için konum koordinatlarını ve (X_k, Y_k) diz eklemi için konum koordinatlarını ifade etmektedir.

$$tg\theta_f = \frac{Y_m - Y_a}{X_m - X_a} \quad (8)$$

$$tg\theta_s = \frac{X_a - X_k}{Y_k - Y_a} \quad (9)$$

$$A = 90 + \theta_s - \theta_f \quad (10)$$

Ortak noktaların lineer hız ve ivme bileşenleri sırasıyla (11), (12), (13) ve (14)'teki gibi hesaplanır.

$$V_{xn} = \frac{X_{n+1} - X_{n-1}}{2t} \quad (11)$$

$$V_{yn} = \frac{Y_{n+1} - Y_{n-1}}{2t} \quad (12)$$

$$a_{xn} = \frac{V_{x(n+1)} - V_{x(n-1)}}{2t} \quad (13)$$

$$a_{yn} = \frac{V_{y(n+1)} - V_{y(n-1)}}{2t} \quad (14)$$

Eklemelerin açısal hız ve ivme bileşenleri sırasıyla (15) ve (16)'da verilmiştir.


$$W_n = \frac{\theta_{n+1} - \theta_{n-1}}{2t} \quad (15)$$

$$a_n = \frac{W_{n+1} - W_{n-1}}{2t} \quad (16)$$


Yürüme mekaniğinin detaylı bir analizi için Winter D.A'nın yürüyüş analizi deneyinden elde edilen veriler kullanılarak MATLAB programı ile çeşitli hesaplamalar yapılmıştır. Bu hesaplamalar sonucunda elde edilen açı, moment, güç ve EMG grafikleri, ayak uzvunun hareketleri hakkında kapsamlı bir bilgi sağlamaktadır.

Şekil 9'da 0,4 saniye anındaki gözlemler, ayağın topuk temasına kadar olan süreçte dorsifleksiyon gerçekleştirdiğini ortaya koymaktadır. Kısa bir plantar fleksiyon döneminden sonra, temas anında oluşan kuvvetlerin etkisiyle tekrar dorsifleksiyon başlamıştır. Bu durum, ayak bileği kinematiği ve temas anındaki biyomekanik değişimleri net bir şekilde göstermektedir. Ayağın yatayda yaptığı açı 95-100 derece aralığında değişirken, Şekil 10'da ayak bileği eklem açısının yaklaşık 30 derece değiştiği gözlemlenmiştir. Bu durum, yürüme sırasında ayak bileğinin yatay düzlemdeki hareketini ve eklem açısındaki değişimleri detaylı bir şekilde ifade etmektedir.


Gastrocnemius ve soleus kasları, ayak bileği eklemine etki eden önemli kas gruplarıdır. Basma fazı sonunda Şekil 11'de gösterilen bu kasların ani kasılması, ayak parmaklarının yere daha güçlü bir şekilde basmasını sağlar. Bu durumda, oluşan moment etkisi ayak bileği ekleminde plantarfleksiyon hareketine neden olur. Aynı zamanda, bu kuvvetin etkisiyle ayağın yere daha hızlı ve güçlü bir şekilde itilmesi sağlanır. Bu an, bir sonraki adımın hazırlanması için kritik bir aşamadır.



Şekil 9. Ayak açısının zamanla değişimi




Şekil 10. Ayak bileği eklem açısının zamanla değişimi




Şekil 11. Gastrocnemius ve Soleus kasları [99]

Sallanma fazında, ayak bileği eklem momenti neredeyse sıfır seviyededir. Ancak duruş fazının sonunda, özellikle gastrocnemius ve soleus kaslarının ani bir şekilde kasılması, Şekil 12'de gösterildiği gibi, oldukça güçlü bir moment etkisine yol açar ve bu etki 90 Nm'ye kadar ulaşabilir.




Şekil 12. Ayak bileği eklem momentinin zamanla değişimi

Şekil 13'te, ayak bileği ekleminin açısal hızının 2,5- (-4,5) rad/s arasında değiştiği gözlemlenmektedir. Birinci döngünün sonunda, ikinci adımın hazırlığı sırasında, her iki kasın etkisiyle birlikte açısal hız artmıştır.




Şekil 13. Ayak bileği ekleminin zamanla açısal hız değişimi

Şekil 14'te gösterildiği gibi, duruş fazının sonunda iki kasın ani kasılmasıyla birlikte ayak bileği ekleminde güçte bir sıçrama meydana gelir ve bu sıçrama 240 W'a kadar ulaşır.




Şekil 14. Ayak bileği eklem gücünün zamana göre değişimi

Şekil 15'teki grafikte, düşey yer reaksiyon kuvvetinin ters 'M' şeklinde değiştiği gözlemlenmektedir. Bu kuvvet, topuk ile temas ettikten sonra vücudu yukarı doğru hızlandırarak, vücut ağırlığının üzerinde bir değere ulaşır.




Şekil 15. Ayak bileği eklemi üzerindeki reaksiyon kuvvetlerinin zamanla değişimi

Yürüyüş analizi, Winter D.A yürüyüş analizi deneyinden elde edilen sayısal veriler kullanılarak MATLAB GUI'de görsel olarak simüle edildi [100]. Bu simülasyonun sonuçları Şekil 16'da sunulmuştur.



Şekil 16. MATLAB GUI yürüyüş analizi simülasyon sonuçları

Şekil 17'deki açısal hızlara bakıldığında, en büyük değişikliğin ayak bileği ekleminde ve beşinci metatarsal ekleminde meydana geldiği gözlemlenmektedir.



Şekil 17. Beş noktanın x eksenine göre hızları
nokta 1: vücut kütle merkezi *nokta 2*: kalça eklemi *nokta 3*:diz eklemi *nokta 4*: ayak bileği eklemi *nokta 5*: 5. metatarsal kemik


Yürüyüş analizi, son yıllarda ayak ve ayak bileği literatüründe hızla gelişen bir alan haline gelmiştir. Bu, özellikle ayak bileği protez tasarımı için önemli bir ön çalışma olarak kabul edilmektedir. Ayrıca, MATLAB GUI üzerinde tüm vücut için yürüme simülasyonu gerçekleştirilmiş ve elde edilen sonuçlar incelenmiştir. Bu sonuçlar, ayak ve ayak bileği eklemi biyomekaniği hakkında çeşitli bilgiler elde etmenin deneysel yöntemlerle mümkün olduğunu göstermektedir.

1.8. Kinematik İnceleme

Bilim ve teknolojinin hızlı ilerleyişi, mekatronik alanında en üst düzey başarının somutlaştığı bir dizi disiplini bir araya getiren robotları ortaya çıkardı. Bu robotlar, makineleri, elektronik sistemleri, bilgisayarları, yapay zekâyı, otomatik kontrolü içeren birçok disiplinin araştırma sonuçlarını birleştirerek muazzam bir başarı elde etmiştir. Gittikçe yaygınlaşan kullanım eğilimi, robotları gereksiz iş yükünden kurtarma amacı taşıyan endüstriyel manipulatörleri içeren, birçok görevi yerine getirebilen ve çok kez programlanabilen sistemler haline getirmiştir. Tipik bir robot, hareketi sağlayan bir kol, el becerisi kazandıran bir bilek ve belirli bir görevi yerine getiren bir uç efektörden oluşmaktadır [101]. Robot çalışmalarında önemli bir aşama, eklemlerin hareketi ve bu hareketlerin robot üzerindeki etkisi arasındaki ilişkiyi belirleyen robot kinematik modelini oluşturmaktır. Yörünge takibini başarıyla gerçekleştirebilmek için, kinematik problemin

etkili bir şekilde çözülmesi büyük bir öneme sahiptir. Kinematik tabanlı kontrol sistemlerini tercih etmemizin bir diğer sebebi, dinamik tabanlı kontrol sistemlerine göre daha basit ve güvenilir çözümler sunmalarıdır [102, 103]. Bir robot manipülatörü, bir dizi bağımsız katı cismin, eklemler aracılığıyla birbirine bağlanarak meydana getirdiği bir zincirden oluşur. Bu zincir, bir ucu sabit bir gövdeye bağlanmışken, diğer ucu serbestçe hareket eden ve robotun belirli bir görevi yerine getirmesini sağlayan bir uç efektöre bağlıdır. Kinematik denklemler, bu zincirin eklemleri ile uç efektör arasındaki matematiksel ilişkiyi ifade eder [104, 105].

Üç boyutlu uzaydaki nesnelerin konumlarına odaklanıyoruz ve bir ayak protezini, adeta bir robot kolunu düşündüğümüzde, bu robot kolunun uç efektörünün hareketini sağlamak için gerekli eklemlerin hareketini hesaplamak önemlidir. Uç efektörün konumu ve yönelimi için ise gerekli eklem açılarını bulmak gereklidir. Bu hesaplamalar, kinematikte ileri kinematik ve ters kinematik olarak iki ana kategoriye ayrılır. Sorunu çözmek için ise genellikle ters kinematik, yani istenilen konum ve yönelime ulaşmak için gerekli eklemlerin açılarını hesaplamak, robotik alanında önemli bir ilkedir [106]. İleri kinematikte, bağlantı uzunlukları ve eklem açıları belirli olduğunda, homojen dönüşüm matrisleri kullanılarak herhangi bir noktanın konumu kolayca hesaplanabilir. Eklemleri bir yapıdaki durumu, eklem uzayında bir durum vektörü olan $\theta(\theta_1, \dots, \theta_n)$ ile temsil edilir. Uç efektörün konumu ve yönelimi ise $X_{UE}(x, y, z, \theta_x, \theta_y, \theta_z)$ şeklinde ifade edilir ve bu, uç efektörün Kartezyen uzayındaki konumunu ve oryantasyonunu belirtir.



Şekil 18. İleri ve ters kinematik şeması [108]


Bu bağlamda, n serbestlik derecesi sayısını temsil eder. Serbestlik derecesi terimi, bir eklemlili yapının karmaşıklığını belirleyen, yapıdaki durumu ifade etmek için kullanılan bağımsız değişken sayısını temsil eder. Durum vektörü θ ve uç efektörün konumu X_{UE} arasındaki ilişki, eşitlik (17) ve (18) ile ifade edilir.

$$X_{UE} = f(\theta) \rightarrow \text{ileri kinematik} \quad (17)$$

$$\theta = f^{-1}(X_{UE}) \rightarrow \text{ters kinematik} \quad (18)$$


1.8.1. İleri Kinematik

Kinematikte kullanılan kontrol teknikleri genellikle eklemlerle birleştirilmiş bağlantılardan oluşan bir iskelet üzerine dayanır. Bu iskelet, mafsallı bir yapıdaki ilk bağlantıdan başlar ve sonunda bir uç efektöre ulaşır. Robot bağlantılarının ve eklemlerinin konumu, hızı ve ivmesi arasındaki ilişkiyi belirlemek, robotun ileri kinematikini sağlar. İleri kinematikte, bir nesnenin üç boyutlu uzaydaki konumunu ve yönelimini tanımlamak için Şekil 19’da görüldüğü gibi manipülatöre ve nesnelere bir koordinat sistemi veya çerçeve eklenir ve bu referans koordinat sistemi üzerinden tanımlanır. Denavit-Hartenberg yöntemi, eklem değişkenlerinin belirlenmesinde en çok tercih edilen yöntemdir. Bu yöntem, 4x4 homojen bir dönüşüm matrisi kullanarak ileri kinematik problemini çözer. Nesnenin koordinat çerçevesini referans koordinat çerçevesine indirgeyerek, nesnenin konumunu etkili bir şekilde hesaplar [107].



Şekil 19. Manipülatöre ve nesnelere eklenen koordinat sistemleri [108]

n eklemlili bir robot manipölatorü olduėunu varsayalım. Bu durumda her eklem iki baėlantıyı birbirine baėladıėı için $n+1$ baėlantı olacaktır. i eklemi, $i-1$ baėlantısını i baėlantısına baėlar. Bu durumda i baėlantısının konumu $i-1$ baėlantısına göre sabitlenir. i eklemi hareket ettiėinde i baėlantısı da hareket edecektir [109].



Şekil 20. D-H deėişkenlerinin belirlenmesi [101]


(19) eşıtlıėindeki q_i , i . eklemin döner mafsali olması durumunda dönme açısı, prizmatik mafsali olması durumunda mafsali yer deėiştirmesi olan eklem deėişkenidir.

$$q_i = \begin{cases} \theta_i & : \text{dönme açısı} \\ d_i & : \text{yer deėiştirme} \end{cases} \quad (19)$$

Koordinat düzlemindeki bir nesnenin yönü, doėrultusu ve boyutlarını deėiştirmeden bir konumdan diėerine belirli bir doėrultu ve yönde yaptığı kayma hareketine öteleme, bu hareketi tanımlayan vektöre de öteleme vektörü denir. Denklem (20)'de verilen ${}^A P$ matrisi uzayda herhangi bir noktayı temsil etsin. Bu noktayı başka bir noktaya taşıdığımızda, yeni nokta denklemdeki eski noktanın ${}^A Q$ öteleme vektörüyle toplanmasından ibarettir. Denklem 21'de P_{yeni} ile gösterilen yeni noktanın eşıtlıėı verilmiştir. Bu eşıtlık, öteleme vektörü kullanılarak bir noktanın konumunu güncelleme matematişel ifadesini saėlar [110]. Şekil 21'de koordinat çerçevesi verilmiştir.

$${}^A P = \begin{bmatrix} {}^A P_x \\ {}^A P_y \\ {}^A P_z \end{bmatrix} \quad (20)$$

$$P_{\text{yeni}} = {}^A P + {}^A Q \quad (21)$$



Şekil 21. Bir manipülatöre bağlı koordinat çerçeveleri

$O_0x_0y_0z_0$, manipülatör tabanına bağlı olarak tutturulmuş sabit çerçevedir. i bağlantısını bağlamak için $O_ix_iy_iz_i$ ekleriz. Denklem (22)'deki q_i 'nin bir fonksiyonu olan A_i 'nin, $O_ix_iy_iz_i$ 'nin $O_{i-1}x_{i-1}y_{i-1}z_{i-1}$ 'e göre, (23)'teki T_j^i 'nin ise $O_jx_jy_jz_j$ 'nin $O_ix_iy_iz_i$ 'ye göre konumunu ve yönelimini ifade eden homojen dönüşüm matrisi olduğunu varsayalım.

$$A_i = A_i(q_i) \quad (22)$$

$$T_j^i = \begin{cases} A_{i+1}A_{i+2}...A_{j-1}A_j & i < j \\ I & i = j \\ (T_j^i)^{-1} & j > i \end{cases} \quad (23)$$

Uç efektörün sabit çerçeveye göre konum ve yönelimini sağlayan homojen dönüm matrisi (24)'teki gibi uç vektör o_n^0 ve dönme matrisi R_n^0 ile belirlenir.

$$H = \begin{bmatrix} R_n^0 & o_n^0 \\ 0 & 1 \end{bmatrix} \quad (24)$$

Uç efektörün sabit çerçevedeki konum ve yönelimi $H = T_n^0 = A_1(q_1)...A_n(q_n)$, homojen dönüşüm A_i ;

$$A_i = \begin{bmatrix} R_i^{i-1} & o_i^{i-1} \\ 0 & 1 \end{bmatrix} \quad (25)$$

Buna göre T_j^i ;

$$T_j^i = A_{i+1}...A_j = \begin{bmatrix} R_j^i & o_j^i \\ 0 & 1 \end{bmatrix} \quad (26)$$

Buradaki $R_j^i = R_{(i+1)}^i...R_j^{(j-1)}$, $o_jx_jy_jz_j$ 'nin $o_ix_iy_iZ_i$ 'ye göre yönelimi, $o_j^i = o_{(j-1)}^i + R_{(j-1)}^i o_j^{(j-1)}$ 'de koordinat vektörleridir. $o' = o'_x x + o'_y y + o'_z z$, bir katı cismin, birim vektörleri x, y, z olan O -xyz ortonormal referans koordinat sistemine göre o' noktasının konumudur. Burada o'_x, o'_y ve o'_z , o' 'nun vektör bileşenleridir. Birim vektörler eşitlik (27)'deki gibi ifade edilir:

$$\begin{aligned}
x' &= x'_x + x'_y + x'_z \\
y' &= y'_x + y'_y + y'_z \\
z' &= z'_x + z'_y + z'_z
\end{aligned} \tag{27}$$


Birim vektörler yönelimi tanımlamak amacıyla rotasyon matrisi olarak adlandırılan 3x3'lük bir ortogonal matrisle (28)'deki gibi birleştirilir.

$$R = \begin{bmatrix} x' & y' & z' \end{bmatrix} = \begin{bmatrix} x'_x & y'_x & z'_x \\ x'_y & y'_y & z'_y \\ x'_z & y'_z & z'_z \end{bmatrix} = \begin{bmatrix} x_x^T & y_x^T & z_x^T \\ x_y^T & y_y^T & z_y^T \\ x_z^T & y_z^T & z_z^T \end{bmatrix} \tag{28}$$

O-xyz referans çerçevesinin z eksenini etrafında α açısı kadar döndürüldüğünü ve döndürülen çerçevenin O-x'y'z' olduğunu varsayalım. Buna göre yeni birim vektörleri (29)'daki gibi tanımlanabilir. Şekil 22'de verilen matematiksel eşitliklerin görselleştirilmiş hali sunulmuştur.

$$x' = \begin{bmatrix} \cos \alpha \\ \sin \alpha \\ 0 \end{bmatrix} \quad y' = \begin{bmatrix} -\sin \alpha \\ \cos \alpha \\ 0 \end{bmatrix} \quad z' = \begin{bmatrix} 0 \\ 0 \\ 1 \end{bmatrix} \tag{29}$$

z eksenini etrafında α açısı, y eksenini etrafında β açısı ve x eksenini etrafında γ açısı kadar döndürüldüğünde elde edilen temel dönme matrisleri sırasıyla (30), (31), (32) eşitliklerinde verilmiştir. Uzayda herhangi bir eksen etrafında dönüşleri tanımlamak için bu matrislerden faydalanabiliriz. x, y ve z eksenlerinde beraber bir dönüş olduğunda bu matrislerin çarpılması gerekir. Buna göre elde edilen matris (33) eşitliğinde verilmiştir [104].



Şekil 22. $O-xyz$ referans çerçevesi ve α açısı kadar döndürüldüğünde oluşan yeni $O-x'y'z'$ çerçevesi

$$R_z(\alpha) = \begin{bmatrix} \cos \alpha & -\sin \alpha & 0 \\ \sin \alpha & \cos \alpha & 0 \\ 0 & 0 & 1 \end{bmatrix} \quad (30)$$

$$R_y(\beta) = \begin{bmatrix} \cos \beta & 0 & \sin \beta \\ 0 & 1 & 0 \\ -\sin \beta & 0 & \cos \beta \end{bmatrix} \quad (31)$$

$$R_x(\gamma) = \begin{bmatrix} 1 & 0 & 0 \\ 0 & \cos \gamma & -\sin \gamma \\ 0 & \sin \gamma & \cos \gamma \end{bmatrix} \quad (32)$$

$$R = R_{z,\alpha} R_{y,\beta} R_{x,\gamma} = \begin{bmatrix} \cos \alpha & -\sin \alpha & 0 \\ \sin \alpha & \cos \alpha & 0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} \cos \beta & 0 & \sin \beta \\ 0 & 1 & 0 \\ -\sin \beta & 0 & \cos \beta \end{bmatrix} \begin{bmatrix} 1 & 0 & 0 \\ 0 & \cos \gamma & -\sin \gamma \\ 0 & \sin \gamma & \cos \gamma \end{bmatrix}$$

$$= \begin{bmatrix} \cos \alpha \cos \beta & -\sin \alpha \cos \gamma + \cos \alpha \sin \beta \sin \gamma & \sin \alpha \sin \gamma + \cos \alpha \sin \beta \cos \gamma \\ \sin \alpha \cos \beta & \cos \alpha \cos \gamma + \sin \alpha \sin \beta \sin \gamma & -\cos \alpha \sin \gamma + \sin \alpha \sin \beta \cos \gamma \\ -\sin \beta & \cos \beta \sin \gamma & \cos \beta \cos \gamma \end{bmatrix} \quad (33)$$

Sabit bir noktada dönmeyi ifade eden bu dönme matrislerine öteleme matrislerini de ekleyerek ilerlemeyi inceleyebiliriz. Robotik uygulamalarda, Denavit-Hartenberg gösterimi olarak bilinen homojen dönüşüm matrisi, DH parametresi adı verilen dört temel dönüşüm parametresiyle temsil edilir. Bu parametreler, bir bağlantının bir öncekine göre konumunu ve yönelimini belirtir. Denavit-Hartenberg matrisi, iki koordinat eksenindeki hareket bağlantısını basit matematiksel ifadelerle ifade eder [111-114]. Bir robotun modellenmesi yapılırken önce x, y, z koordinatları belirlenir, ardından a, α , d ve θ değerleri olan DH parametrelerini bulunur ve tablo halinde yazılır. Bu yöntem robotu kinematik olarak modellerken en çok başvurulan yöntemlerden biridir.

$$A = \begin{bmatrix} R & d \\ 0 & 1 \end{bmatrix} \quad (34)$$

$$A_i = Rot_{z,\theta_i} Trans_{z,d_i} Trans_{x,a_i} Rot_{x,\alpha_i} \quad (35)$$

$$= \begin{bmatrix} c\theta_i & -s\theta_i & 0 & 0 \\ s\theta_i & c\theta_i & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & d_i \\ 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} 1 & 0 & 0 & a_i \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & c\alpha_i & -s\alpha_i & 0 \\ 0 & s\alpha_i & c\alpha_i & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}$$

$$= \begin{bmatrix} c\theta_i & -s\theta_i c\alpha_i & s\theta_i s\alpha_i & a_i c\theta_i \\ s\theta_i & c\theta_i c\alpha_i & -c\theta_i s\alpha_i & a_i s\theta_i \\ 0 & s\alpha_i & c\alpha_i & d_i \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (36)$$

Burada;

a, iki eksen arasındaki bağ uzunluğunu (link length),

α , iki eksen arasındaki bağ açısını (link twist),

d, çakışan bağlar arasındaki bağ kaymasını (link offset) ve θ , iki bağ arasındaki eklem açısını (joint angle) vermektedir.

1.8.2. Ters Kinematik

Manipülâtörün uç efektörünün konum ve yönelimi verildiğinde, bu konum ve yönelimi elde etmek için kullanılacak olan tüm olası eklem açılarını hesaplama işlemi oldukça karmaşık bir geometrik problemi olan ters kinematik hesaplamasıdır. Bazı temel ters kinematik çözme yöntemleri Şekil 23'te özetlenmiştir.



Şekil 23. Ters kinematik çözüm yöntemleri

Mekanizmanın geometrisini analiz ederek ve trigonometrik fonksiyonları kullanarak, uç efektör konumu ve öteleme vektörleri üzerinden vektör denklemlerini kullanarak, sistemdeki denklemleri cebirsel olarak çözerek, iteratif yöntemler ve optimizasyon algoritmaları kullanarak eklemlerin açıları elde edilebilmektedir. Makine öğrenmesiyle

eğitilmiş modeller, uç efektör konumu ve giriş açıları üzerinden de eklem açıları tahmin edilebilmektedir.

Her bir çözüm yöntemi, belirli durumlar ve sistem karmaşıklığı için daha uygun olabilir. Genellikle karmaşık robot sistemlerinde sayısal yöntemler daha yaygın olarak kullanılır, ancak basit sistemlerde analitik yöntemler tercih edilebilir. Ayrıca, işlem hızı, doğruluk ve hesaplama maliyeti gibi faktörler de çözüm yöntemi seçiminde etkili olabilir.


1.8.3. Protez Ayağın İleri ve Ters Kinematik Hesaplamaları

1.8.3.1. İleri Kinematik Hesaplamaları

Protez ayak için ileri kinematik analizi gerçekleştirmek amacıyla Denavit-Hartenberg yöntemi kullanılmıştır. İlk olarak, tasarlanan protez ayak, Şekil 24'te gösterilen biçimde, dönme yönleri belirlenerek hareket eksenleri ve koordinat sistemiyle donatılmıştır. Her bir eklem için, Denavit-Hartenberg (D-H) değişkenleri belirlenmiş ve bu bilgiler Tablo 2'de özetlenmiştir. Eşitlik (37) temel alınarak hesaplanan genel dönüşüm matrisi (38), her bir eklem için eklem konumunu belirlemek amacıyla kullanılmıştır. Her bir eklem için, (39), (40), (41) ve (42)'de verilen dönüşüm matrisleri çarpılarak, ileri kinematik bilgisi (43)'teki denklemin içinde yer alan değerler elde edilmiştir. Bu adımlar, her bir eklem için ileri kinematik bilgisini hesaplamak için takip edilen süreci temsil eder. Bu yöntem, tasarlanan protez ayakta meydana gelen hareketleri ve eklem konumlarını belirlemek için matematiksel bir model sağlar. Bu sayede, protez ayak belirlenen kinematik parametreler doğrultusunda istenen hareketleri başarıyla gerçekleştirebilir.

$${}^{i-1}_iT = Rot_{x(\alpha_{i-1})} Trans_{x(a_{i-1})} Rot_{z(\theta_i)} Trans_{z(d_i)} \quad (37)$$

$${}^{i-1}_iT = \begin{bmatrix} \cos \theta_i & -\sin \theta_i & 0 & a_{i-1} \\ \sin \theta_i \cos \alpha_{i-1} & \cos \theta_i \cos \alpha_{i-1} & -\sin \alpha_{i-1} & -\sin \alpha_{i-1} d_i \\ \sin \theta_i \sin \alpha_{i-1} & \cos \theta_i \sin \alpha_{i-1} & \cos \alpha_{i-1} & \cos \alpha_{i-1} d_i \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (38)$$



Şekil 24. Protezin hareket eksenlerinin belirlenmesi

Burada (X_0, Y_0, Z_0) koordinatı referans çerçeve olarak varsayılmıştır. Her bir robot ekleminin konumu bir öncekine göre tanımlanmıştır.

Tablo 2. Protez ayağın D-H değişkenlerinin belirlenmesi

i	α_{i-1}	a_{i-1}	d_i	θ_i
1	0	l_1	0	θ_1
2	90	l_2	0	θ_2
3	-90	l_2	0	0
4	0	l_3	0	θ_3

$${}^0_1T = \begin{bmatrix} \cos \theta_1 & -\sin \theta_1 & 0 & l_1 \\ \sin \theta_1 & \cos \theta_1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (39)$$

$${}^1_2T = \begin{bmatrix} \cos \theta_2 & -\sin \theta_2 & 0 & l_2 \\ 0 & 0 & -1 & 0 \\ \sin \theta_2 & \cos \theta_2 & 0 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (40)$$

$${}^2_3T = \begin{bmatrix} 1 & 0 & 0 & l_2 \\ 0 & 0 & 1 & 0 \\ 0 & -1 & 0 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (41)$$

$${}^3_4T = \begin{bmatrix} \cos \theta_3 & -\sin \theta_3 & 0 & l_3 \\ \sin \theta_3 & \cos \theta_3 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (42)$$

$${}^0_4T = {}^0_1T {}^1_2T {}^2_3T {}^3_4T \quad (43)$$

$$p_x = l_1 + l_2 \cos \theta_1 + l_2 \cos \theta_1 \cos \theta_2 + l_3 \cos \theta_1 \cos \theta_2 \quad (44)$$


$$p_y = l_2 \sin \theta_1 + l_2 \cos \theta_2 \sin \theta_1 + l_3 \cos \theta_2 \sin \theta_1 \quad (45)$$

$$p_z = l_2 \sin \theta_2 + l_3 \sin \theta_2 \quad (46)$$

Tablo 3'te rad cinsinden verilen θ değerlerinde karşılık gelen p_x, p_y, p_z konumları verilmiştir. Elde edilen konumlara göre ayağın durumu Şekil 25'te sırasıyla verilmiştir.

Tablo 3. İleri kinematik sonucunda elde edilen bazı konum noktaları


	p_x	p_y	p_z
$\theta_1 = -1 \quad \theta_2 = 1.2$	37.9320	-17.0256	28.8932
$\theta_1 = -1.2 \quad \theta_2 = 1.2$	34.3316	-18.8580	28.8932
$\theta_1 = -1.5 \quad \theta_2 = 1.2$	28.4312	-20.1824	28.8932
$\theta_1 = -1.5 \quad \theta_2 = 1$	28.8214	-25.6849	26.0856
$\theta_1 = -1.5 \quad \theta_2 = 0.5$	29.5610	-36.1144	14.8622
$\theta_1 = -2 \quad \theta_2 = 0.5$	11.9334	-32.9212	14.8622



Şekil 25. Protez ayağın tablodaki değerlere göre konumu

$\theta_1 = \left[-\frac{\pi}{2}, \frac{\pi}{2}\right]$ ve $\theta_2 = \left[-\frac{\pi}{4}, \frac{\pi}{4}\right]$ 'nin tüm olası kombinasyon değerleri için

p_x, p_y, p_z koordinatlarının grafiği Şekil 26'da çizdirilmiştir.



Şekil 26. Verilen aralıktaki tüm θ_1 ve θ_2 değerleri için p_x, p_y, p_z konumları

1.8.3.2. Ters Kinematik Hesaplamaları

Protez ayağın ters kinematik hesabı için analitik çözüm yöntemi tercih edilmiştir [115].

$\begin{bmatrix} {}^0_1T \end{bmatrix}^{-1} {}^0_4T = {}^1_2T {}^2_3T {}^3_4T$ işlemi bize protez ayağın ters kinematiği sonucu elde edilecek açı değerlerini verecektir. Bunun için aşağıdaki hesaplamalar yapılmıştır.

$$\begin{bmatrix} {}^0_1T \end{bmatrix}^{-1} = \begin{bmatrix} \cos \theta_1 & \sin \theta_1 & 0 & -l_1 \cos \theta_1 \\ -\sin \theta_1 & \cos \theta_1 & 0 & l_1 \sin \theta_1 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (47)$$

$$\begin{bmatrix} {}^0_1T \end{bmatrix}^{-1} {}^0_4T = \begin{bmatrix} \cos \theta_1 & \sin \theta_1 & 0 & -l_1 \cos \theta_1 \\ -\sin \theta_1 & \cos \theta_1 & 0 & l_1 \sin \theta_1 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} r_{11} & r_{12} & r_{13} & p_x \\ r_{21} & r_{22} & r_{23} & p_y \\ r_{31} & r_{32} & r_{33} & p_z \\ 0 & 0 & 0 & 1 \end{bmatrix} = \quad (48)$$

$$\begin{bmatrix} \cos \theta_1 r_{11} + \sin \theta_1 r_{21} & \cos \theta_1 r_{12} + \sin \theta_1 r_{22} & \cos \theta_1 r_{13} + \sin \theta_1 r_{23} & \cos \theta_1 p_x + \sin \theta_1 p_y - l_1 \cos \theta_1 \\ -\sin \theta_1 r_{11} + \cos \theta_1 r_{21} & -\sin \theta_1 r_{12} + \cos \theta_1 r_{22} & -\sin \theta_1 r_{13} + \cos \theta_1 r_{23} & -\sin \theta_1 p_x + \cos \theta_1 p_y + l_1 \sin \theta_1 \\ r_{31} & r_{32} & r_{33} & p_z \\ 0 & 0 & 0 & 1 \end{bmatrix}$$

$${}^1T_3 {}^2T_3 {}^3T_4 = \begin{bmatrix} \cos \theta_2 \cos \theta_3 & -\cos \theta_2 \sin \theta_3 & -\sin \theta_2 & l_2 + l_2 \cos \theta_2 + l_3 \cos \theta_2 \\ \sin \theta_3 & \cos \theta_3 & 0 & 0 \\ \cos \theta_3 \sin \theta_2 & -\sin \theta_2 \sin \theta_3 & \cos \theta_2 & l_2 \sin \theta_2 + l_3 \sin \theta_2 \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (49)$$

İki denklemi birbirine eşitleyerek bağımsız denklemler elde edelim.

$$\begin{bmatrix} \cos \theta_1 r_{11} + \sin \theta_1 r_{21} & \cos \theta_1 r_{12} + \sin \theta_1 r_{22} & \cos \theta_1 r_{13} + \sin \theta_1 r_{23} & \cos \theta_1 p_x + \sin \theta_1 p_y - l_1 \cos \theta_1 \\ -\sin \theta_1 r_{11} + \cos \theta_1 r_{21} & -\sin \theta_1 r_{12} + \cos \theta_1 r_{22} & -\sin \theta_1 r_{13} + \cos \theta_1 r_{23} & -\sin \theta_1 p_x + \cos \theta_1 p_y + l_1 \sin \theta_1 \\ r_{31} & r_{32} & r_{33} & p_z \\ 0 & 0 & 0 & 1 \end{bmatrix} =$$

$$\begin{bmatrix} \cos \theta_2 \cos \theta_3 & -\cos \theta_2 \sin \theta_3 & -\sin \theta_2 & l_2 + l_2 \cos \theta_2 + l_3 \cos \theta_2 \\ \sin \theta_3 & \cos \theta_3 & 0 & 0 \\ \cos \theta_3 \sin \theta_2 & -\sin \theta_2 \sin \theta_3 & \cos \theta_2 & l_2 \sin \theta_2 + l_3 \sin \theta_2 \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (50)$$

Elde edilen bağımsız denklemler aşağıda sıralanmıştır:

- $\cos \theta_1 r_{11} + \sin \theta_1 r_{21} = \cos \theta_2 \cos \theta_3$
- $-\sin \theta_1 r_{11} + \cos \theta_1 r_{21} = \sin \theta_3$
- $r_{31} = \cos \theta_3 \sin \theta_2$
- $\cos \theta_1 r_{12} + \sin \theta_1 r_{22} = -\cos \theta_2 \sin \theta_3$
- $-\sin \theta_1 r_{12} + \cos \theta_1 r_{22} = \cos \theta_3$
- $r_{32} = -\sin \theta_2 \sin \theta_3$

- $\cos \theta_1 r_{13} + \sin \theta_1 r_{23} = -\sin \theta_2$
- $-\sin \theta_1 r_{13} + \cos \theta_1 r_{23} = 0$
- $r_{33} = \cos \theta_2$
- $\cos \theta_1 p_x + \sin \theta_1 p_y - l_1 \cos \theta_1 = l_2 + l_2 \cos \theta_2 + l_3 \cos \theta_2$
- $-\sin \theta_1 p_x + \cos \theta_1 p_y + l_1 \sin \theta_1 = 0$
- $p_z = l_2 \sin \theta_2 + l_3 \sin \theta_2$

Ters kinematik çözümü p_x, p_y, p_z cinsinden elde edelim. Buna göre 12. denklem şu şekilde düzenlenebilir:

$$\sin \theta_2 = \frac{p_z}{l_2 + l_3}$$

$\sin \theta = a \rightarrow \theta = A \tan 2 \left(a, \mp \sqrt{1-a^2} \right)$ eşitliğine benzediği için θ_2 (51)'deki gibi elde edilir.

$$\theta_2 = A \tan 2 \left(\frac{p_z}{l_2 + l_3}, \mp \sqrt{1 - \left(\frac{p_z}{l_2 + l_3} \right)^2} \right) \quad (51)$$

11. denklem şu şekilde düzenlenebilir:

$$(l_1 - p_x) \sin \theta_1 + \cos \theta_1 p_y = 0$$

$a \sin \theta + b \cos \theta = 0 \rightarrow \theta = A \tan 2(-b, a)$ veya $\theta = A \tan 2(b, -a)$ eşitliğine benzediği için θ_1 (52)'deki gibi elde edilir.

$$\theta_1 = A \tan 2(-p_y, (l_1 - p_x)) \text{ veya } \theta_1 = A \tan 2(p_y, (p_x - l_1)) \quad (52)$$

Tablo 4. Ters kinematik sonucunda elde edilen θ_1 ve θ_2 değerleri

	θ_1	θ_2
$p_x = 34.3316$ $p_y = -17.0256$ $p_z = 28.8932$	$-57.3^\circ = -1 \text{ rad}$	$74.3735^\circ = 1.3 \text{ rad}$
$p_x = 34.1316$ $p_y = -18.8580$ $p_z = 28.8932$	$-68.7549^\circ = -1.2 \text{ rad}$	$74.3735^\circ = 1.3 \text{ rad}$
$p_x = 28.4312$ $p_y = -20.1824$ $p_z = 28.8932$	$-85.9438^\circ = -1.5 \text{ rad}$	$74.3735^\circ = 1.3 \text{ rad}$
$p_x = 28.8214$ $p_y = -25.6849$ $p_z = 26.0856$	$-85.9438^\circ = -1.5 \text{ rad}$	$64.6780^\circ = 1.13 \text{ rad}$
$p_x = 29.5610$ $p_y = -36.1144$ $p_z = 14.8622$	$-85.9438^\circ = -1.5 \text{ rad}$	$33.6031^\circ = 0.59 \text{ rad}$
$p_x = 11.9334$ $p_y = -33.9212$ $p_z = 14.8622$	$-114.5915^\circ = -2 \text{ rad}$	$33.6031^\circ = 0.59 \text{ rad}$

Tablo 3 ve Tablo 4'teki sonuçlar irdelendiğinde θ_1 açısında kayma meydana gelmezken θ_2 açısında küçük bir kayma meydana gelmiştir.

Bu aşamada protez ayağın Denavit-Hartenberg model parametreleri belirlenmiş ve bu bilgilere dayalı olarak dönüşüm matrisi oluşturulmuştur. Oluşturulan bu matris, ileri kinematik ve ters kinematik hesaplamalarında kullanılarak uç işlevcinin konumunun kontrol edilmesi hedeflenmiştir. Protez ayağa, ileri kinematik ve ters kinematik değerleri sağlanarak, sistem tasarım parametrelerine bağlı olarak gerçekleştirilmiştir. Bu süreç, protez ayak hareketlerini belirlemek ve uç işlevcinin konumunu kontrol etmek için matematiksel bir temel oluşturur.


1.9. Protez Ayağın Mekanik Tasarımı

Günümüzde, ampute bireyler genellikle düşük maliyetli ve temel fonksiyonlara sahip pasif protezleri veya daha kontrollü ve mikrodeneyleyicili fakat yüksek maliyetli aktif protezleri tercih etmektedirler. Bu çalışmanın odak noktası, diz altı transtibial ampute bireyler için düşük maliyetli, az elemanlı, çok fonksiyonlu bir ayak bileği protezinin tasarımı ve geliştirilmesidir. Ayak bileğini ve ayağını çeşitli nedenlerle kaybetmiş kişiler için, kontrol edilebilir iki serbestlik derecesi olan DP ve IE hareketlerini gerçekleştiren kontrollü bir sistem önerilmektedir. Sistem kontrolünün yapılabilmesi için protezin ana mekanizmasının dinamik bir modeli oluşturulmuştur. Protez çalışmalarının amacı, eksik olan uzvun eksikliğini hissetmeyecek bir cihaz oluşturmaktır. 80'li yıllara kadar, ampute için asimetriye neden olan ve sağlam bacağına göre daha fazla enerji gerektiren yay gibi bileşenler içeren pasif protezler tasarlandı. Pasif protezlerde yaşanan problemler nedeniyle araştırmacılar aktif protez tasarım çalışmalarına ağırlık vermişlerdir [116]. Geliştirilen protez; ticari ayak, aktüatörler, kontrolör, sensörler, bağlantı ve güç ünitesinden oluşur. Protez tasarımında yararlanılan ana kriterler aşağıda sıralanmıştır:

- İnsan anatomisi ile uyumlu olmasının yanı sıra yeterli derecede serbestlik ve hareket açıklığına sahip olmalıdır.
- Hareketlerin istenilen hızda gerçekleşmesi için gerekli kuvvet ve momenti sağlayan aktüatörler mümkün olduğunca küçük ve hafif olmalıdır.
- İvmeölçerler, jiroskop ve magnetometre vb. ölçüm cihazları kontrolör için gerekli giriş sinyallerini sağlar.

Bugün, elektrikli, pnömatik ve hidrolik aktüatörler gibi aktif hareket sağlayan mekanizmalarla, ayrıca yay ve damper gibi pasif etkileri kontrol eden mekanizmalar bulunmaktadır. Güç ünitesi, bu aktif ve pasif aktüatörleri beslemek, çalıştırmak ve diğer elektronik ekipmanları güçlendirmek için kullanılır.

Bu çalışma kapsamında, mekanik tasarım süreci Solidworks yazılımı kullanılarak gerçekleştirilmiştir. Solidworks, mükemmel bir mühendislik tasarım aracı olarak, karmaşık mekanik yapıların üç boyutlu modellemesini sağlayarak tasarım sürecini optimize etmeye yardımcı olur. Protezin ayak olmadan mekanik tasarımı, Solidworks programında Şekil 27'de gösterildiği gibi gerçekleştirilmiş ve iki dereceli hareket serbestliği sağlanmıştır.




Şekil 27. Ayak protezi tahrik mekanizmasının CAD modeli

Tasarlanan mekanizmada kullanılan elemanlar sırasıyla;

1. *Gövde*: Genellikle tasarımın ana çerçevesini oluşturan ve diğer elemanların monte edildiği yapısal bileşen.
2. *Motor Bağlantı Elemanı*: Motorun mekanizma ile bağlantısını sağlayan bir adaptör veya bağlantı elemanı.
3. *L16-P Linear Motor*: Mekanizmanın lineer hareketini sağlamak için kullanılan bir tür lineer motor.
4. *Roadflexion Foot Bağlantı Elemanı*: Ayak bağlantısını sağlayan bir eleman.
5. *Üniversal Mafsal (1/2")*: İki eksen arasında çeşitli açılarda hareket sağlayan, 1/2 inç çapında bir üniversal mafsal.
6. *Üniversal Mafsal (1/4")*: İki eksen arasında çeşitli açılarda hareket sağlayan, 1/4 inç çapında bir üniversal mafsal.

Bu elemanlar, mekanizmanın belirli işlevselliğini ve hareketini sağlamak üzere bir araya getirilmiş temel bileşenlerdir.


Tasarlanan protez ayağın prototipi Şekil 28'de verilmiştir. Tasarımda hafif, düşük maliyetli ve daha az eleman kullanımına özen gösterilmiştir.



Şekil 28. İki serbestlik dereceli protez ayak mekanizmasının prototipi A) yandan görünüm B) önden görünüm

Çalışmamızda protez ayak olarak ticari olarak satılan Roadflexion foot kullanılmıştır. Şekil 29'da gösterilen bu ayak 3 ana parçadan oluşmaktadır. A'da gösterilen Alt kısım 1 Calcaneus ve ön ayağı tanımlar, arka kısım 2 topuğu tanımlar ve bir amortisör görevi görür. Üst kısım 3 ayağın üst kısmını tanımlar ve anterior (ön) tibialis kası olarak işlev görür. Roadflexion foot, serbest bırakılan ve depolanan enerji arasında %60'a varan bir verimliliğe sahiptir. Bu, kullanıcının doğal adımlarını daha etkili bir şekilde atmalarına olanak tanır. Ayrıca, ayak dayanıklı ve sağlam olduğu gibi, elastik yapısı sayesinde dengeyi korumaya yardımcı olur. Bu özellikler, genç kullanıcılar için dinamik bir yapı sunarak, protez ayak seçiminde tercih edilme sebeplerini oluşturur [117].

Motor olarak, aynı yönde hareket ettiklerinde Dorsifleksiyon-Plantarfleksiyon (DP) hareketi ve zıt yönde hareket ettiklerinde İnversiyon-Eversiyon (IE) hareketi yapabilen iki adet lineer motor (L16-100-35-12-P) tercih edilmiştir, bu motorlar Şekil 30'da gösterilmektedir. Kablo kayıpları ve sürtünmelerden kaçınmak amacıyla kablosuz bir mekanizma benimsenmiştir. Hareket açıklığı, kablo sistemi yerine universal mafsallar kullanılarak sağlanmıştır. Bu tercih, sistemde daha düşük enerji kaybı ve daha hassas hareket kontrolü sağlamak amacıyla yapılmıştır.




Şekil 29. Roadflexion foot. A) Protez ayağın iç yapısı B) Protez ayağın ön yan ve arkayandan görünüm

Sürekli gelişen ve değişen dünyamızda teknolojinin ilerlemesiyle birlikte endüstriyel cihazlarda dönme veya doğrusal hareket sağlayan ekipmanlara olan talep, giderek artmaktadır. Doğrusal hareket, yüksek güvenilirlik, yüksek hızda yüksek hassasiyet ve basit elemanlarla iş yapabilme avantajları nedeniyle araştırmacılar arasında tercih edilen bir alan haline gelmiştir. Dönel hareketi üreten elektrik motorlarına dişli, kayış-kasnak sistemi, sonsuz vida gibi yardımcı cihazlar eklenerek veya hidrolik ve pnömatik sistemlerde pompa, filtre, valf, piston gibi elemanlar kullanılarak lineer hareketler elde edilebilir. Ancak, bu yöntemler genellikle bakım gereksinimleri, sürtünme kayıpları, ağırlık ve karmaşıklık gibi zorluklarla karşılaşabilir ve daha fazla hata riskine yol açabilir. Bu nedenle, doğrudan lineer hareket üretebilen, yardımcı elemanlara ihtiyaç duymayan ve daha az enerji kaybına sahip lineer motorlara olan talep artmaktadır. Bu motorlar, gelişmiş performans, düşük bakım ihtiyacı ve enerji tasarrufu gibi avantajlar sunarak endüstriyel uygulamalarda daha etkili ve güvenilir bir çözüm sunmaktadır [118].



Şekil 30. L16-100-35-12-P lineer motor

L16-P olarak adlandırılan lineer motorun hız-kuvvet ve akım-kuvvet eğrileri Şekil 31'de gösterilirken, teknik özellikleri de Tablo 5'te ayrıntılı bir şekilde sıralanmıştır. Bu bilgiler, lineer motorun datasheet'inde yer alan teknik özellikleri temsil etmektedir [119].




Şekil 31. L16-P lineer motor Hız-Kuvvet ve Akım-Kuvvet grafiği

Tablo 5. L16-P teknik özellikleri

Tepe güç noktası	16 mm/s'de 50 N
En yüksek verimlilik noktası	24 mm/s'de 24 N
Maksimum hız (yüksüz)	32 mm/s
Maksimum kuvvet	50 N
Geri tahrik kuvveti	31 N
Strok	100 mm
Kütle	74 g
Giriş gerilimi	12 V
Durma akımı	650 mA
Maksimum statik kuvvet	250 N

Şekil 32'de lineer motorun sürücü devresi olarak kullanılan lineer aktüatör kontrol kartı verilmiştir. Çalışmada kullanılan motorlar aktüatör işlevi gördüğü için lineer aktüatör olarak da adlandırılabilir.

Şekilde çalışmada kullanılan X_1 , X_2 ve X_3 kısımları gösterilmiştir. Burada X_1 ile gösterilen L16-P aktüatör bağlantısıdır. Kabloların renklerine göre hangi bağlantıyı sağladığı aşağıda verilmiştir.



Şekil 32. Lineer aktüatör kontrol kartı

- Sarı: potansiyometre referans negatif
- Siyah: motor (-) terminali
- Kırmızı: motor (+) terminali
- Mor: potansiyometre geribesleme
- Turuncu: potansiyometre geribesleme pozitif

X₂ ile gösterilen radyo kontrol alıcı bağlantısını ifade eder. Buna göre sırasıyla pin numarası ve karşılık gelen fonksiyon aşağıda verilmiştir.

- Ground: siyah
- Güç: kırmızı
- Kontrol: beyaz

X₃ ile gösterilen kontrol arayüzüdür ve pin-fonksiyon eşleşmesi aşağıda verilmiştir.

- Ground
- 6-24 VDC Güç
- RC Servo giriş sinyali
- Akım giriş sinyali (4-20mA)
- Gerilim giriş sinyali (0-3.3V)- 1kHz PWM

Aktüatörün özellikleri Tablo 6'da verilmiştir. Bilgiler kontrol kartı datasheet bilgilerinden alınmıştır [120].

Tablo 6. Lineer aktüatör kontrol kartı teknik özellikleri


Kontrol giriş modları	Dijital: USB, RC Servo, 1kHz PWM
	Analog: 0-3.3V 4-20mA
Denetleyici	10-bit Dual Sample Rate Quasi PD
Uyumlu aktüatörler	PQ12&L12-P Konum geri beslemeli aktüatör 6-12V
	L16, P16 & T16-P Konum geri beslemeli aktüatör 6-12V
	Konum geri beslemeli daha geniş aktüatörler 12V, 24V
Boyut	50mm*50mm
Güç	6-24VDC
Çalışma sıcaklığı	-10°C - 70°C

Solidworkste protez ayak montajı oluşturduktan sonra hareketlerini MATLAB'ta inceleyebilmek ve analiz edebilmek amacıyla Solidworks-MATLAB SimMechanics haberleşmesini gerçekleştirmeliyiz. Bunun için öncelikle MathWorks'ün sitesinden, hangi MATLAB versiyonunu kullanıyorsak ona uygun '*install_addon.m*' ve '*smlink.r20xxx.winxx.zip*' dosyaları indirilir. Bilgisayarın C dizini altında yeni bir klasör oluşturup bu dosyaları doğrudan klasöre kopyalanır. MATLAB'ı yönetici olarak çalıştırıp Command Window'da `cd('C:\Simmechanic')` ve `install_addon('smlink.r20xxx.winxx.zip')` yazıp enter'a bastıktan sonra SolidWorks'e MATLAB eklentisini eklemek için `smlink_linksw` komutu yazılır. SolidWorks'te Simulink aktif edildikten sonra bağlantı tamamlanmış olur. Bu işlemlerden sonra hazırlanan montaj .xml uzantılı olarak kaydedilir. Solidworks'te oluşturulup SimMechanics'e aktarılan montaj Şekil 33'te verilmiştir.

SimMechanics, MathWorks tarafından geliştirilen bir Simulink eklentisidir ve birden fazla katı cismin bir araya gelerek oluşturduğu karmaşık çok bedenli sistemlerin modellenmesi ve simülasyonu için tasarlanmış güçlü bir araçtır. Bu araç, mühendislerin mekanik sistemlerin dinamik davranışlarını anlaması, bu sistemleri modellemesi ve simüle etmesi için kullanılır. SimMechanics, mekanik parçacıklar, mafsallı elemanları, yaylar, sürtünme elemanları ve diğer mekanik bileşenlerin etkileşimlerini modellenmesini kolaylaştırır. Ayrıca, MATLAB ve Simulink ile entegre bir şekilde çalışarak veri akışını yönetir, görselleştirmeyi kolaylaştırır, mühendislerin sistemlerini optimize etmelerini ve gerçek dünya koşullarında test etmelerini sağlar.

1.10. Referans Sinyalin Sınıflandırılması

Bir sistemin giriş sinyalini belirli kategorilere ayırma işlemidir. Bu süreç, genellikle makine öğrenimi ve sinyal işleme teknikleri kullanılarak gerçekleştirilir. Referans sinyalleri, genellikle bir sistemdeki durumu veya bir olayı temsil eder. Sistemin anlık durumunu değerlendirmek ve ona uygun aksiyonlar almak açısından referans sinyalin sınıflandırılması önemlidir. Bu işlem sistemin güvenilirliğini ve performansını artırır. Referans sinyalin sınıflandırılmasıyla ilgili bazı temel adımlar Şekil 34’te verilmiştir.



Şekil 34. Sınıflandırma temel adımları

Sistemi eğitmek için bir dizi referans sinyali toplanmalıdır. Toplanan veriler, gerektiğinde filtrelenmeli, düzenlenmeli veya normalleştirilmelidir. Referans sinyallerinden anlamlı özellikler çıkarılmalıdır. Bu özellikler, sinyalin karakteristiklerini temsil eder ve sınıflandırma için kullanılır. Makine öğrenimi algoritmaları, özellik vektörlerini kullanarak referans sinyallerini belirli kategorilere sınıflandırmak için eğitilir. Bu, öğrenme sürecini içerir, yani algoritma belirli bir görevi öğrenir. Eğitilen model, ayrı bir test veri seti üzerinde değerlendirilmelidir. Bu adım, modelin genelleme yeteneğini kontrol etmek için önemlidir. Eğitilen model, gerçek zamanlı veriler üzerinde kullanılarak referans sinyallerini belirli kategorilere sınıflandırır.

Bu çalışmada protez ayağın daha kullanışlı, etkili, insan vücuduna uygun olmasını sağlamak ve anormal koşullara (değişen hız, yön veya zemin şartları vb.) nasıl adapte olunacağını anlamak amacıyla insan hareketleri toplanılır, öğrenilir, ayak hareketlerinin analizi ve sınıflandırılması gerçekleştirilir.

Ayak hareketlerini tanıma ve sınıflandırma, kontrol sisteminin etkinliğini değerlendirmek ve sistemin geri bildirim mekanizmalarının nasıl işlediğini anlamak için temel bir adımdır. Kontrol sistemlerinin optimize edilmesi ve iyileştirilmesi için gerekli geri bildirimi sağlar. Sistem üzerinde çalışan verilerin analiz edilmesine ve doğrulanmasına izin verir. Hangi hareketin nasıl tanındığı ve sınıflandırıldığı sistemdeki performansın anlaşılmasına yardımcı olur. Kontrol sistemlerin etkinliği, gerçek zamanlı geri besleme ile ölçülür. Ayrıca bu tanıma ve sınıflandırma gelecekteki hareketleri tahmin etme ve istenmeyen durumları önleme yeteneğini artırır. Örneğin bir kullanıcının düşmek üzere olduğu tahmin edilirse sistem bu durumu algılayarak dengeyi sağlamak için gerekli adımları atabilir. Kullanıcı arayüzü ve etkileşim tasarımında da önemli rol oynar ve kullanıcı deneyimini geliştirebilir. Kullanıcının yürüme hızını, yüzey eğimi gibi çeşitli faktörlere göre otomatik olarak ayarlayabilir veya farklı yürüme stillerine uyum sağlayabilir.

1.10.1. Veri Toplama

Orta Doğu Teknik Üniversitesi Makine Mühendisliği Biyomekanik Laboratuvarı'nda gerçekleştirilen çalışmada, referans sinyal olarak kullanılmak üzere çeşitli veriler elde edilmiştir. Bu veriler, NRF52 tabanlı bir Inemo atalet modülü olan LSM9DS1 kullanılarak toplanmıştır. Atalet modülü, dokuz serbestlik derecesine sahip olup, üç eksenli jiroskop, üç eksenli ivmeölçer ve üç eksenli manyetometre içermektedir.

Çalışmada yer alan 11 sağlıklı denek (8 erkek ve 3 kadın), kuvvet plakası üzerinde kendi hızlarında gerçekleştirdikleri 50 deneme ile Dorsifleksiyon, Plantarfleksiyon, İnversiyon ve Eversiyon hareketlerini tamamlamışlardır. Ayrıca, deneklerin ayak hareketleri dışında laboratuvar boyunca yaptıkları yürüyüş analizi verileri de kaydedilmiştir. Bu denemeler sırasında aynı zamanda yer reaksiyon kuvvetleri de ölçülmüştür. Bu ölçümler Şekil 35'te verilen biyomekanik laboratuvarındaki 0,8 metre genişliğinde, 4,6 metre uzunluğundaki yürüyüş yolu olarak tasarlanan kısımda gerçekleştirilmiştir.

Veriler dört atalet modülü (IMU) aracılığıyla sağ ve sol bacak (alt yan bacak) ile sağ ve sol metatarsallara (ayak) bağlanarak elde edilmiştir. Elde edilen ham veriler National Instruments'ın USB-6212 Çok İşlevli I/O cihazı aracılığıyla PC'ye aktarılmış ve MATLAB kullanılarak çevrimdışı olarak analiz edilmiştir. Örnekleme frekansı 100 Hz olarak belirlenmiştir. Şekil 36'da alt bacak ve ayaktan veri toplamak amacıyla kullanılan 4 IMU modülü ve bu modüllerin bağlandıkları konumlar görülmektedir. Deney öncesinde, eğer aynı

gün içinde ilk kez ölçüm yapılacaksa, IMU'ların senkronize edilmesi gereklidir. Bu senkronizasyon işlemi, IMU'ların benzer veya çok yakın değerlere sahip olmasını gerektirir. Eğer değerler istenen düzeye ulaşmazsa, senkronizasyon işlemi tekrarlanır. IMU'lar birbirine yakın değerlere ulaşıldığında, kayıt işlemine geçilir. Bu süreç, veri toplama işleminin güvenilir ve doğru bir şekilde gerçekleşmesini sağlamak amacıyla uygulanır.

Araştırmanın etik standartlara uygun olarak yürütüldüğünü ve insan haklarına saygı gösterildiğini kanıtlamak amacıyla, çalışma için 24237859-595 numaralı Etik Kurul Onay belgesi, Karadeniz Teknik Üniversitesi Tıp Fakültesi Bilimsel Araştırmalar Etik Kurul Başkanlığı tarafından alınmıştır. Araştırmaya katılan 11 sağlıklı denek, çalışmaya başlamadan önce bilgilendirilmiş onam formunu imzalamıştır. Bu form, deneklere çalışma hakkında detaylı bilgiler verilmesini ve deneklerin gönüllü olarak katılmayı kabul ettiğine dair yazılı bir onay içerir. Bu süreç, katılımcıların araştırmaya katılmadan önce bilgilendirilmiş bir şekilde karar vermelerini sağlar ve insan haklarına saygı gösterir. Tablo 7'de sağlıklı deneklerin yaş, ağırlık ve uzunluk gibi fiziksel özellikleri detaylı olarak sunulmuştur.



Şekil 35. ODTÜ Makine Mühendisliğindeki Biyomekanik Laboratuvarı



Şekil 36. IMU modüllerinin veri toplamak için bağlandıkları konumları


Tablo 7. Gönüllü deneklerin fiziksel özellikleri

Kişi	Uzunluk (m)	Ağırlık (kg)	Yaş (yıl)
1-Erkek	1.78	90	20
2-Erkek	1.81	83	20
3-Erkek	1.80	86	20
4-Erkek	1.75	67	20
5-Kadın	1.72	60	26
6-Erkek	1.90	150	29
7-Kadın	1.64	68	30
8-Erkek	1.80	77	34
9-Erkek	1.80	68	31
10-Erkek	1.62	80	20
11-Kadın	1.65	55	31

1.10.1.1. Ataletsel Ölçüm Birimi

Araştırmacılar, kullanıcıların niyetini ve hareket modunu belirlemek için öncelikle elektromiyografi (EMG) sinyallerini kullanmayı önermişlerdir [121, 122]. Ancak, terleme, sıcaklık değişimleri ve yorgunluk gibi faktörler, kas EMG'sini önemli ölçüde etkileyerek pratik kullanımını kısıtlayabilir. Bu nedenle, son zamanlarda hareket modu tanıma amacıyla non-invaziv bir yöntem olarak aktif elektrotlu kafa derisi elektroensefalografi (EEG) sinyalleri kullanılmıştır [123]. Ancak, EEG sinyallerinin düşük sağlamlığa sahip olması ve yüksek bilgi işleme gereksinimi, bu yöntemin performansını olumsuz etkileyebilir. Bu düşük performans, EEG tabanlı yaklaşımın geniş çapta kullanılmasını sınırlayabilir.

Çalışmada, IMU ölçümlerinin tercih edilme sebepleri arasında taşınabilir ve hafif bir cihaz olması, kullanıcının rahat bir şekilde giyebilmesini sağlaması, vücuttaki hareketleri doğrudan ölçerek mekanik bilgi sağlaması, daha geniş bir hareket aralığına sahip olması ve daha az elektromanyetik girişime maruz kalması bulunmaktadır. Bu özellikler, IMU'ların güvenilir ve tutarlı ölçümler yapabilmesini sağlayarak veri analizi için uygun bir tercih haline getirmiştir. Şekil 37'de görülen LSM9DS1 kartı, bir IMU olarak işlev gören bir sensör modülüdür. Bu modül, içerisinde bulunan jiroskop, ivmeölçer ve magnetometre sensörleri sayesinde cihazın hareketini ve konumunu ölçme yeteneğine sahiptir.



Şekil 37. LSM9DS1 kartı [124]


Jiroskop, açısal hızları derece/saniye cinsinden ölçen bir sensördür. Bu sensör, bir nesnenin bir ekseninde ne kadar hızla döndüğünü ölçer. İvmeölçer ise doğal bir ivme birimi olan ve 9.80665 m/s^2 'ye eşit olan g (yerçekimi) sembolü ile temsil edilen ivmeyi ölçer. Manyetometre, manyetik alanın yoğunluğunu ölçen bir sensördür. Bu sensör, özellikle

dünyamızın manyetik alanını ölçmeye yönelik olarak kullanılır. Manyetik alan genellikle Gauss veya Tesla birimleriyle ölçülür. Bu üç sensörün kombinasyonu, bir IMU oluşturur. Bu tür sensörler genellikle bir araya getirilir ve bir cihazın 3 boyutlu uzayda hareketini ve yönelimini belirlemek için kullanılır. Ancak, bu sensörlerden gelen veriler bazen gürültülü olabilir. Bu nedenle, açıların kaymasını önlemek ve daha doğru ölçümler elde etmek için filtreleme teknikleri kullanılır. Manyetometreden gelen manyetik alan bilgisi, sapma yönelim açısını belirlemede kullanılabilir [125]. Tablo 8’de jiroskop, ivmeölçer ve magnetometre sensörlerinin ölçüm aralıkları verilmiştir [126].


Tablo 8. LSM9DS1’in ölçüm aralığı

Hızlanma	Manyetik Kuvvet	Açısal dönme
$\pm 2/\pm 4/\pm 8/\pm 16$ g	$\pm 4/\pm 8/\pm 12/\pm 16$ gauss	$\pm 245/\pm 500/\pm 2000$ °/s

Denek 1’in dorsifleksiyon, plantar fleksiyon, inversiyon ve eversiyon hareketlerinin analizi ile elde edilen sensör grafiği sırasıyla Şekil 38, 39, 40 ve 41’de verilmiştir.




Şekil 38. Denek 1’in dorsifleksiyon hareketi sonucunda elde edilen sensör ham verileri




Şekil 39. Denek 1'in plantar fleksiyon hareketi sonucunda elde edilen ham sensör verileri

Dorsifleksiyon ve plantar fleksiyon hareket grafiklerine baktığımızda, jiroskop verilerinin x eksenini üzerindeki dönme hareketini ölçtüğünü gözlemliyoruz. Bu dönme hareketi, ayak bileği ekleminin yukarı veya aşağı doğru hareket ettiğini yansıtır. İvmeölçer, eklemin y eksenini boyunca hareketini ölçer ve bu sayede ayak bileğinin yukarı veya aşağı yönlü ivmesini ve konumunu belirler. Dorsifleksiyon sırasında ivmeölçer verilerinde artış gözlenirken, plantar fleksiyon sırasında azalma meydana gelebilir. Magnetometre ise özellikle eklemin y eksenindeki yön değişikliklerini gösterir. Bu, ayak bileği hareketinin yere dik olarak gerçekleştiği dorsifleksiyon ve plantar fleksiyon sırasında önemli bir bilgi sağlar.

İnversiyon ve eversiyon sırasında, jiroskop verileri genellikle y ekseninde zıt yönlü dönme hareketlerini gösterir. Örneğin, ayak içe doğru dönüyorsa y ekseninde negatif bir değer gözlemlenebilir, eversiyon durumunda ise pozitif bir değer görülebilir. İvmeölçer, x eksenini boyunca ayak bileğinin konumunu ve hareketini ölçer. İnversiyon sırasında ivmeölçer verilerinde bir artış gözlenebilirken, eversiyon sırasında bir azalma olabilir. Magnetometre, x eksenini üzerindeki yön değişikliklerini gösterir.



Şekil 40. Denek 1'in inversiyon hareketi sonucunda elde edilen sensör ham verileri



Şekil 41. Denek 1'in eversiyon hareketi sonucunda elde edilen sensör ham verileri


Butterworth düşük geçiren filtre, veri setindeki yüksek frekanstaki gürültüyü azaltmaya yardımcı olan bir filtre türüdür. Bu durumda, f_s (örnekleme frekansı) 100Hz, f_c (kesim frekansı) 5Hz ve n (filtre derecesi) 4 olarak belirlenmiştir. İvme ve jiroskop verileri, bu filtreleme sürecinden geçirilmiş ve ardından hem ileri hem de geri geçişli filtreleme ile faz kaybı minimize edilmeye çalışılmıştır.

Şekil 42 ve Şekil 43'te verilen dorsifleksiyon hareketi ve laboratuvar boyunca 10 tur yürüme hareketi ile ilgili üç boyutlu (3D) konum grafiği, bu filtrelenmiş verilere dayanarak elde edilmiştir. İleri ve geri filtreleme, temizlenmiş verilerin oluşturulmasında rol oynamış ve yüksek frekanstaki gürültünün ortadan kaldırılması, konum tahmininin daha doğru ve istikrarlı olmasına katkı sağlamıştır.


Ayak hareketi ve yürüme hareketi sıklıkla periyodik bir doğaya sahiptir. Periyodiklik, sınıflandırma algoritmalarında kullanışlıdır çünkü bu, belirli bir aktivitenin veya durumun tanımlanabilir ve ayırt edilebilir bir özellik setine sahip olduğunu gösterir. Özellikle, bu tür periyodik hareketlerin zaman serisi verileri, makine öğrenimi veya sınıflandırma modelleriyle analiz edilebilir.

Denek 1'in yürüyüş hareketinden elde edilen ivme verilerini kullanarak hız ve konum hesaplamaları gerçekleştirilmiştir. Bu ivme verileri, düşük geçişli bir filtre uygulanarak daha düzgün hale getirilmiş ve gürültü azaltılmıştır. Filtrelenmiş veriler üzerinde de konum ve hız hesaplamaları yapılarak sonuçlar, hem filtrelenmemiş hem de filtrelenmiş verileri içeren Şekil 44'teki 3D konum/hız grafiği üzerinde görselleştirilmiştir.


Kontrol sistemlerinde konum ve hız verilerinin referans sinyal olarak kullanılması oldukça yaygındır. Bu veriler, sistemdeki hareketleri izlemek, kontrol algoritmalarını uygulamak ve istenen hedeflere ulaşmak için kullanılır. Konum verileri, sistemdeki gerçek konumu temsil eder ve kontrol algoritmaları, bu gerçek konumu referans konumu ile karşılaştırarak hedefe ulaşmak için gerekli düzeltmeleri yapabilir.



Şekil 42. Denek 1'in dorsifleksiyon hareketi sonucu üç boyutlu konumu




Şekil 43. Denek 1'in laboratuvar boyunca yürüme hareketi sonucu üç boyutlu konumu




Şekil 44. Denek 1'in yürüme hareketi sonucu elde edilen filtrelenmiş/filtrelenmemiş ivme verilerinin zamana bağlı hız/konum grafiği


Şekil 45, 46, 47 ve 48, her biri 50 defa tekrarlanan hareketlerin x eksenindeki jiroskop ölçümlerini sunarak, bu hareketlerin belirli periyodik desenler içindeki değişimini gösterir ve bu da sınıflandırma için önemli bilgiler sağlar.




Şekil 45. 6. kişi 50 deneme dorsifleksiyon hareketi Gx verileri



Şekil 46. 6. kişi 50 deneme plantar fleksiyon hareketi Gx verileri



Şekil 47. 6. kişi 50 deneme inversiyon hareketi Gx verileri



Şekil 48. 6. kişi 50 deneme eversiyon hareketi Gx verileri

1.10.2. Öz nitelik Çıkarma

Sensörden alınan verilerin sınıflandırmada kullanılmasının ilk adımı, özellik çıkarma aşamasıdır. Bu aşamada, girdi veri kümesinin boyutu, orijinal verinin önemli bilgilerini içeren daha düşük boyutlu özelliklere indirgenir. Yani, özellik çıkarma işlemi sayesinde, karmaşık veri seti daha anlamlı ve öz bilgilerle temsil edilerek sınıflandırma algoritmasının daha etkili çalışması sağlanır [127].

Ayak ve alt bacak için elde edilen ham sensör verileri, önce toplam, ortalama, standart sapma, çarpıklık, basıklık, kovaryans gibi istatistiksel özellikler çıkarılarak işlendi. Elde edilen bu istatistiksel özellikler daha sonra sınıflandırıcı modellerine eklenmiştir. Veriler, 3 eksenli ivmeölçer, 3 eksenli jiroskop ve 3 eksenli manyetometrelerden oluşan toplamda 9 boyutta işlenmektedir. İlk deneyde, 3790x9 boyutlu özellik matrisindeki her bir özelliğin ortalaması alınarak her bir hareket için 1x9 boyutlu özellik vektörleri elde edilmiştir. Bu vektörler, 11 kişiden alınan 4 farklı hareketten elde edilen özellik vektörleri birleştirilerek 44x9 boyutlu bir özellik matrisi oluşturulmuştur. Eğitim ve test amaçlı olarak, bu özellik matrisi ikiye bölünerek 22x9 boyutlu eğitim ve test matrisleri elde edilmiştir. Çalışmalarda kullanılan istatistiksel özellikler sırasıyla Denklem (53), (54), (55), (56), (57), (58) ve (59)'da ifade edilmiştir.

$$X = \sum_{i=1}^n (x_1 + x_2 + \dots + x_n) \quad (53)$$

X, verilerin toplamını temsil eder; $x_1, x_2, \dots, x_n$ ise örneklerdir ve n, örnek sayısını belirtir.

$$\bar{X} = \frac{X}{n} \quad (54)$$

$\bar{X}$, verilerin toplamının örnek sayısına bölünmesiyle elde edilir.

$$SD = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{X})^2}{n}} \quad (55)$$

Standart sapma (SD), verilerin ortalamadan ne kadar saptığını ifade eder ve bir veri setindeki sayıların dağılımının ölçüsüdür. Çarpıklık (S), veri dağılımının asimetrisini ölçer. Negatif bir çarpıklık sola doğru eğilimi, pozitif bir çarpıklık ise sağa doğru eğilimi ifade eder. Basıklık (k), veri setinin dağılımını Gauss dağılımına göre ölçer. Daha sivri bir dağılım pozitif kurtosis ile ifade edilirken, daha düz bir dağılım negatif kurtosis ile ifade edilir.

$$S = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{X})^3}{\left(\sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{X})^2} \right)^3} \quad (56)$$

$$k = \frac{n \sum_{i=1}^n (x_i - \bar{X})^4}{\left(\sqrt{\sum_{i=1}^n (x_i - \bar{X})^2} \right)^2} \quad (57)$$

$$\text{cov}(x, y) = \frac{\sum_{i=1}^n (x_i - \bar{X})(y_i - \bar{Y})}{n-1} \quad (58)$$

Kovaryans ($\text{cov}(x,y)$), x ve y deęişkenleri arasındaki yönlü ilişkiyi ölçmek için kullanılır. Pozitif bir kovaryans, iki deęişkenin birlikte arttığını gösterirken, negatif bir kovaryans ise biri artarken dięerinin azaldığını ifade eder. Norm, $\|X\|_2$ vektörlerin uzunluęunun veya büyüklüęünün hesaplanmasıdır.

$$\|x\|_2 = \left(\sum_1^n |x_i|^2 \right)^{1/2} = \sqrt{x_1^2 + x_2^2 + \dots + x_n^2} \quad (59)$$

1.10.3. Sınıflandırma

Sınıflandırma işlemi, jiroskop, ivmeölçer ve manyetometre gibi sensörlerden gelen verilerin işlenerek önceden belirlenmiş sınıflara atanması sürecidir. Bu süreçte, önceden etiketlenmiş örnek veri setleri kullanılarak bir model veya algoritma eğitilir. Eğitilen bu model, sensör verilerinden çıkarılan özelliklere dayanarak, yeni ve etiketlenmemiş verilerin hangi sınıfa ait olduğunu tahmin eder. Temelde, modelin öğrenme süreci, etiketlenmiş örnek veri setleri üzerinde gerçekleştirilir ve bu model daha sonra gerçek dünya uygulamalarında belirli sınıflandırma görevlerini başarmak için kullanılır. Çalışmada kullanılan sınıflandırma modelleri sırasıyla açıklanmıştır.

1.10.3.1. Karar Ağaçları

Karar ağacı sınıflandırıcısı, karmaşık karar verme süreçlerini basitleştiren ve çözüm sunan bir denetimli öğrenme yaklaşımdır [128]. Bu algoritma, ağaç benzeri bir yapı oluşturarak kullanıcıya anlaşılabilir ve yorumlanabilir bir çözüm sunar. Ağaç yapıları, görselleştirilebildiği için algoritmanın nasıl kararlar verdiği kolayca anlaşılabilir.

Karar ağacı sınıflandırıcısı, çok sınıflı problemler dâhil olmak üzere çeşitli problemlere uyarlanabilme yeteneği ile öne çıkar. Oluşturulan ağaç, kök düğüm, gizli düğümler ve karar düğümleri olarak adlandırılan terminal düğümlerden oluşur. Bu yapı, karmaşık bir karar sürecini anlamamızı sağlar. Veri setindeki özelliklerin önem düzeyini belirleme özelliği sayesinde, hangi özelliklerin daha etkili olduğunu anlamak mümkündür. Bu, kullanıcıya modelin iç işleyişini daha iyi kavrama fırsatı sağlar. Ancak, karar ağaçları, aşırı öğrenme durumuyla karşılaşabilir. Aşırı öğrenme, modelin eğitim verilerine çok iyi

uyması ancak yeni verilerle başa çıkma yeteneğinin düşük olması durumunu ifade eder. Bu durumu kontrol etmek için modelin karmaşıklığını sınırlamak, veri setini çeşitlendirmek veya ağacın derinliğini belirli bir noktada durdurmak gibi yöntemler kullanılabilir [129,130].

1.10.3.2. Lineer Diskriminant Analizi

Farklı sınıfları kesin bir çizgiyle ayıran, yani farklı sınıflar arasındaki dağılımı maksimuma, sınıf içi dağılımı ise minimuma indirmeye çalışan bu algoritma, Fisher tarafından geliştirilen bir yaklaşımdır [131, 132]. İstatistik, makine öğrenmesi, model tanıma ve yapay öğrenme, veri madenciliği, biyometrik, bilgiye erişim gibi alanlarda sıklıkla kullanılmaktadır. Orijinal veri matrisini daha düşük boyutlu bir matrise dönüştürmeyi amaçlayan LDA, daha çok bir ön işleme olan boyut küçültmede kullanılmasına rağmen bu çalışmada sınıflandırıcı olarak kullanılmıştır [133]. İki sınıflı bir veri setinde, sınıf 1 ve sınıf 2 için olasılıklar sırasıyla p_1 ve p_2 , sınıfların ortalaması ise μ_1 ve μ_2 'dir. Sınıflar içindeki özellik değerlerinin ortalaması μ denklem (60)'daki gibi hesaplanır. Sınıf içi dağılım matrisi S_W ve sınıflar arasındaki dağılım matrisi S_B ortalama değerleri kullanılarak hesaplanır. Daha sonra, amaç, sınıflar arası dağılım matrisini sınıflar içi dağılım matrisine oranlayarak, bu oranın maksimum olduğu ve ayırt edici bir düzlemi temsil eden (63)'teki projeksiyon vektörünü bulmaktır. Bu, sınıfları birbirinden ayıran ve sınıf içindeki dağılımı minimuma indiren bir düzlemi bulmayı amaçlayan güçlü bir sınıflandırma ve özellik çıkarma yöntemidir [134-136].

$$\mu = p_1 \times \mu_1 + p_2 \times \mu_2 \quad (60)$$

$$S_W = \sum_{j=1}^C \sum_{i:c_i=j} (x_i - \mu_j)(x_i - \mu_j)^T \quad (61)$$

$$S_B = \sum_{c=1}^C n_c (\mu_c - \mu)(\mu_c - \mu)^T \quad (62)$$

$$J(w) = \frac{w^T S_B w}{w^T S_W w} \quad (63)$$

x ve W sırasıyla giriş vektörünü ve projeksiyon vektörünü temsil eder. $J(w)$, maksimum sınıf ayrılabilirliğini gösteren ifadedir. μ_c , c sınıfındaki vakaların genel ortalamasını, T eşik değerini temsil eder [137].

1.10.3.3. Naïve Bayes Sınıflandırıcı

Denklem (64)'teki Bayes teoremi temel alan Naïve Bayes sınıflandırıcısı, her bir özelliğin birbirinden bağımsız olduğunu varsayan, dengesiz ve yüksek boyutlu veri setlerinde bile etkili olan basit ama güçlü bir olasılıksal algoritmaya sahiptir. Bu algoritma, her döneme ait parametreleri ayrı ayrı öğrenme yeteneğine sahiptir ve yüksek işlem hızıyla dikkat çeker [138-141].

$$P(A/B) = \frac{P(B/A)P(A)}{P(B)} \quad (64)$$

Burada ifade edilen, $P(A/B)$ ve $P(B/A)$ terimleri, Bayes teoreminin temelini oluşturan olasılıkları ifade eder. Bu teorem, bir olayın diğer olaya göre olasılığını güncellememize yardımcı olan bir matematiksel ilkedir. $P(A/B)$: B olayı gerçekleştiğinde A olayının da gerçekleşme olasılığını ifade eder. $P(B/A)$: A olayı meydana geldiğinde B olayının gerçekleşme olasılığını ifade eder. $P(A)$: A olayının gerçekleşme olasılığını ifade eder. $P(B)$: B olayının gerçekleşme olasılığını ifade eder.

Bu Bayes teoremi, İngiliz matematikçi Thomas Bayes tarafından ortaya atılmış ve verimliliği ile sınıflandırma doğruluğu yüksek olan bir yaklaşım olmuştur. Naïve Bayes sınıflandırıcısı, bir elemanın her bir durumunun olasılığını hesaplayarak en yüksek olasılığa sahip duruma göre sınıflandırma yapar. Bu, özellikle yüksek boyutlu ve dengesiz veri setlerinde etkili bir şekilde kullanılabilen basit ama güçlü bir sınıflandırma algoritmasıdır [142].

1.10.3.4. K- En Yakın Komşu Sınıflandırıcı

K-En Yakın Komşu (KNN) algoritması, yapay zeka ve biyomedikal sinyal analizi gibi alanlarda sıkça kullanılan bir sınıflandırma yöntemidir. Bu algoritma, test verilerini eğitim verileriyle karşılaştırarak sınıflandırma yapar. Temel prensibi, benzer özelliklere sahip olan verilerin birbirine yakın olma eğiliminde olduğunu kullanmaktır. Parametrik olmayan bir yaklaşım olan KNN, basit ve uygulaması kolay bir algoritmadır. Aynı zamanda tahmin gücü yüksektir, hesaplama süresi düşüktür ve çıktının yorumlanması kolaydır. Algoritmanın temel mantığı, bir veri noktasını sınıflandırırken, bu noktanın çevresindeki en yakın k komşuluğu dikkate almaktır. KNN'nin tembel öğrenme kategorisine ait olması, eğitim verileri üzerinde genel bir model oluşturmak yerine, tahmin yapılacak olan veri noktasının komşularını kullanarak lokal bir tahmin yapılmasını sağlar. Bilinmeyen bir veri noktası için KNN, n boyutlu uzayda en yakın k eğitim örneğini belirler. KNN, basit bir yaklaşım olmasına rağmen sağlam bir teorik temele sahiptir [143].

Veri noktaları arasındaki uzaklıkları ölçmek için kullanılan metrikler arasında en yaygın olanı (65)'te verilen Öklid Uzaklığıdır. Ancak, problem bağlamına ve veri setine bağlı olarak diğer metrikleri de tercih etmek mümkündür, örneğin Manhattan (66), Minkowski (67) ve Hamming (68) uzaklıkları gibi [144]. Denklemden x eğitim verisi, y test verisi ve k komşu sayısıdır.

$$\sqrt{\sum_{i=1}^k (x_i - y_i)^2} \quad (65)$$

$$\sqrt{\sum_{i=1}^k |x_i - y_i|} \quad (66)$$

$$\sqrt[q]{\sum_{i=1}^k (|x_i - y_i|)^q} \quad (67)$$

$$D_H = \sum_{i=1}^k |x_i - y_i| \quad (68)$$

K-NN'nin avantajları arasında basitlik, eğitim sürecinin olmaması, çeşitli veri türlerine uyarlanabilme ve sınıflandırma/regresyon problemlerinde iyi performans gösterme potansiyeli bulunmaktadır. Ancak, büyük veri setlerinde ve yüksek boyutlu öznelik uzaylarında hesaplama maliyeti artabilir. Ayrıca, doğru bir K değeri seçimi ve veri setinin uygun ölçeklendirilmesi gibi parametrelerin dikkatlice ayarlanması önemlidir.

1.10.3.5. Destek Vektör Makineleri

Destek Vektör Makineleri (SVM), sınıflandırma ve regresyon problemlerini çözmek için kullanılan bir kontrollü eğitim algoritmasıdır. Son yıllarda özellikle nörogörüntüleme analizi, beyin bozuklukları ve şizofreni ile Alzheimer gibi beyin hastalıklarının tanısında popüler hale gelmiştir [145,146]. SVM'in temel prensibi, veri setindeki sınıflar arasında en geniş ayrımı bulmaktır. Bu geniş ayrım, destek vektör adı verilen belirli veri noktalarının sınırların yakınında bulunmasını sağlar. Bu destek vektörler, sınıflar arasındaki ayrımın belirlenmesinde önemli olan noktalardır. Algoritma, iki sınıf arasında en uzak mesafede bir düzlemle ayıran bir hiperdüzlem oluşturur. Bu hiperdüzlem, sınıfları birbirinden mümkün olduğunca uzakta tutar, böylece sınıflar arasındaki ayrımı maksimize eder. Denklem (69), bu hiperdüzlemleri belirlemek için kullanılan matematiksel ifadeyi temsil eder. SVM, bu denklemleri kullanarak veri noktalarını sınıflandırır ve bu şekilde öğrenir. Bu öğrenme süreci, sınıflar arasındaki ayrımı maksimize etmek için veriler arasında optimal bir hiperdüzlemi bulmayı amaçlar [147]. H_o hiper düzlemi, W ağırlık vektörünü, b sabit sayıyı ve X özellik vektörünü ifade eder. W ve b parametreleri, öğrenme süreci boyunca modelin optimize edilmeye çalışıldığı parametrelerdir.

$$H_o : W^T X + b \quad (69)$$

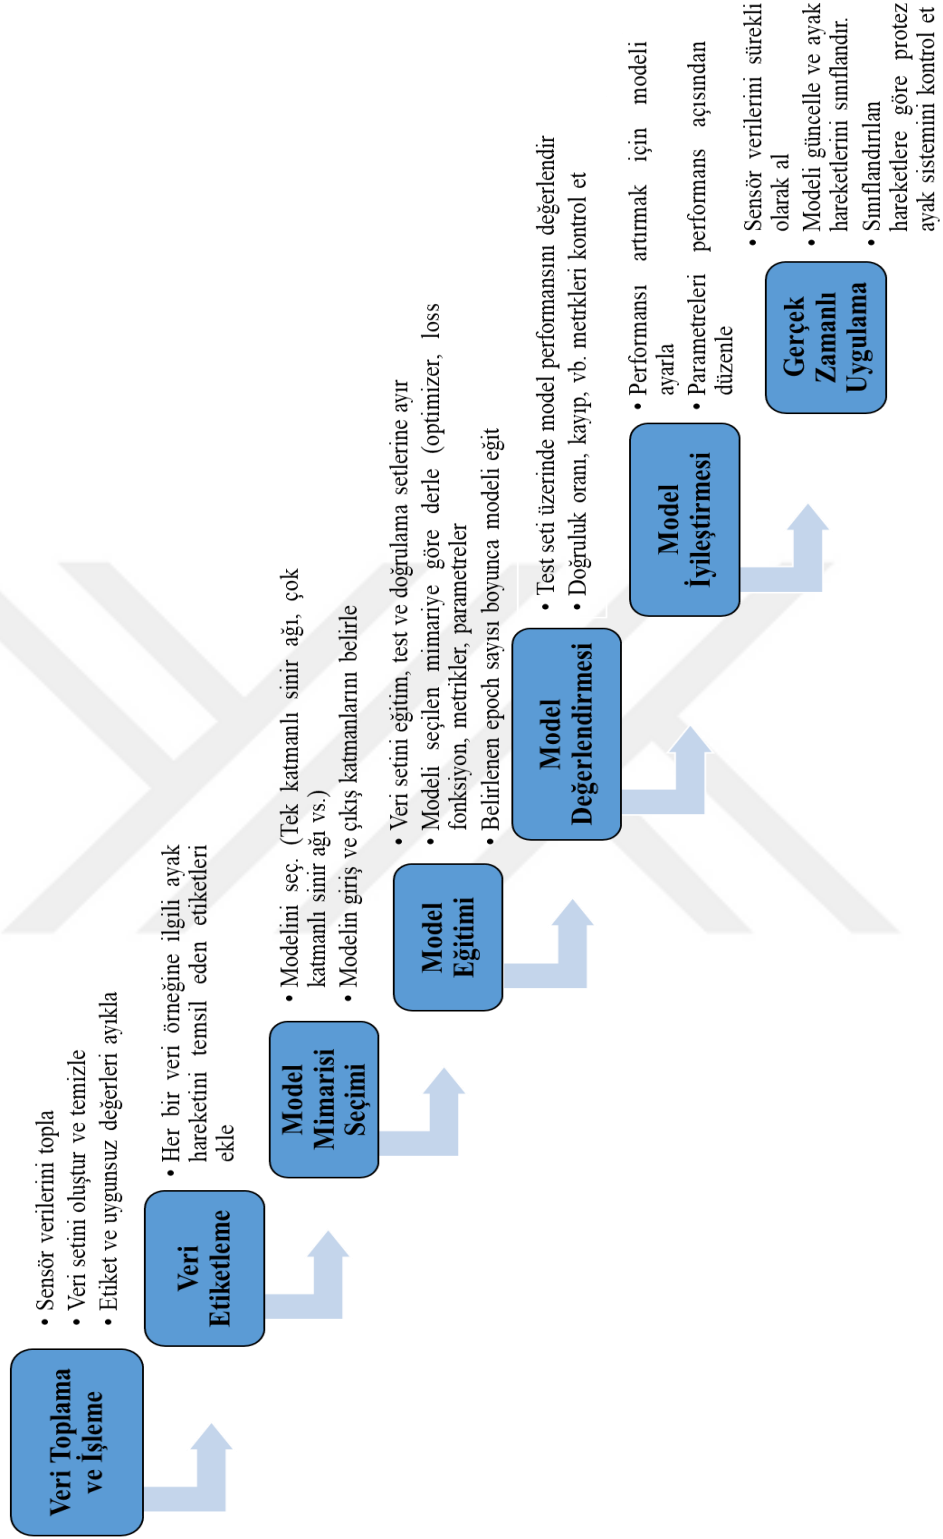
1.10.3.6. Yapay Sinir Ağları

Yapay Sinir Ağları (YSA), beyindeki sinir sisteminden ilham alır ve nöronlar arasında veri iletimini simüle eden bir yapay zekâ modelidir. Giriş katmanı, gizli katman ve çıkış katmanı gibi belirli katmanlardan oluşan basit bir ağda, bu katmanlar arasındaki bağlantılar beyindeki nöronların iletişimini yansıtır. Giriş katmanı, dış dünyadan alınan verilerin yapay sinir ağlarına giriş yaptığı ilk katmandır. Nöronlar, bu giriş katmanından gizli katmana doğru ilerler ve ardından çıkış katmanına yönlendirilir. Çıkış katmanı, gizli katmandan gelen bilgileri işleyerek, giriş verilerine karşılık gelen çıktıları üretir. Bu yapı, bilgi işleme ve öğrenme süreçlerinde giriş verilerini kullanarak çıktıları üretme yeteneği ile beyindeki nöronal iletişimi taklit eder. Yapay Sinir Ağları, geniş bir uygulama yelpazesinde kullanılarak karmaşık problemleri çözmek ve desenleri öğrenmek için başarıyla kullanılmaktadır.

Algılayıcı (Perceptron), giriş değerleri, ağırlıklar, ağırlıklı toplam ve aktivasyon fonksiyonu bileşenlerinden oluşan eğitilebilir bir yapay sinir hücresidir ve tek katmanlı yapay sinir ağlarının temel birimidir [149]. Bu yapay nöron, 1928-1971 yılları arasında yaşamış olan psikolog Frank Rosenblatt tarafından 1958’de ortaya atılmıştır [150]. Her bir giriş özelliği, ilgili ağırlık ile çarpılır, bu çarpımlar toplanır ve ardından bir aktivasyon fonksiyonundan geçirilir. Bu işlem, ağın çıkışını üretir. Matematiksel olarak (70)’teki gibi ifade edildiğinde, y tek katmanlı perceptronun çıkışı, ω_i i. girişin ağırlığı, x_i i. giriş ve b bias terimini ifade eder. Ancak, tek katmanlı perceptron sadece doğrusal ayrılabilir problemleri çözebilir. Daha karmaşık problemleri çözmek için çok katmanlı perceptronlar gibi daha gelişmiş yapay sinir ağı modellerine ihtiyaç duyulur.

$$y = f \sum_{i=1}^n (\omega_i x_i + b) \quad (70)$$

Sınıflandırma modelinin oluşturulması ve değerlendirilmesi için takip edilen temel aşamalar Şekil 49’da verilmiştir.




Şekil 49. Ayak hareketleri sınıflandırma modeli süreci

1.10.3.7. Derin Sinir Ağları

Günümüzde teknolojinin hızlı gelişimi, büyük miktardaki verilerin işlenmesi ve anlamlı çıktılarının elde edilmesi için derin öğrenme kullanımını zorunlu hale getirmiştir. Derin öğrenme, yapay zekâ alanında bir alt dal olan ve özellikle büyük veri setlerinde karmaşık desenleri tespit etmek için tasarlanmış bir makine öğrenimi tekniğidir. Derin öğrenme, büyük veri setlerini hızlı bir şekilde işleyebilme avantajına sahiptir. Derin sinir ağları, milyonlarca veya milyarlarca veri noktasını aynı anda değerlendirip öğrenebilir, bu da geleneksel yöntemlere kıyasla daha hızlı ve etkili bir çözüm sunar [151].

Derin öğrenme, makine öğrenimi alanındaki gelişmiş bir versiyon olup, yapay zekâ dünyasında akıllı sistemlerin en son aşamasını temsil eder. Popülerliği sürekli artarak, derin öğrenme teknolojisi yavaş yavaş insan yaşamının çeşitli yönlerini otomatik hale getiren ve farklı alanlarda yaygın olarak uygulanan bir inovasyon haline gelmiştir [152].

Yapay zekâ alanında iki ayrı yöntemi temsil eden makine öğrenimi ve derin öğrenme arasındaki önemli bir fark, özellik çıkarma ve sınıflandırmanın nasıl işlendiğidir. Şekil 50'de belirtilen temel ayrım, özellik çıkarma ve sınıflandırmanın her iki yöntemde de nasıl gerçekleştirildiğini göstermektedir.



Şekil 50. Derin öğrenme ve makine öğrenmesi arasındaki özellik çıkarma ve sınıflandırma işleyiş karşılaştırması [153]

1.10.3.8. Konvolüsyonel Sinir Ağları

Sensörler aracılığıyla insan faaliyeti tanıma konusunda, geleneksel makine öğrenimi yöntemleri olan k-NN ve SVM gibi yaklaşımlar gerçek zamanlı tahminler elde etmede kullanılabilir. Ancak, bu yöntemlerle elde edilen manuel özelliklere güvenmek, performans açısından idealin altında sonuçlara yol açabilir. Bu zorluk, araştırmacıları daha karmaşık ve özgün özellikleri otomatik olarak öğrenebilen Konvolüsyonel (Evrişimli) Sinir Ağları'nı (CNN) benimsemeye yönlendirmiştir [154].

CNN'lerin ilham kaynağı, David Hubel ve Torsten Wiesel'in 1959'da hayvan görsel korteksindeki hücrelerin küçük bir alıcı alan içinde ışığı algılayabildiğini keşfetmelerine dayanmaktadır. Bu gözlemler, bilgisayarlı görü ve sinir ağlarının gelişiminde temel bir rol oynamıştır. Daha sonra, Kunihiro Fukushima 1980 yılında, Hubel ve Wiesel'in çalışmalarından esinlenerek, ilk teorik CNN modelini önerdi. Bu model, özellikle görsel tanıma görevleri için tasarlanmış ve gelişmiş özellik çıkarma yetenekleri sunan katmanlar içermiştir. Fukushima'nın önerdiği bu model, CNN'lerin temelini oluşturmuş ve günümüzde birçok yapay zekâ uygulamasında yaygın olarak kullanılmaktadır [155]. CNN'lerin tarihindeki önemli bir döneme işaret eden ilk büyük başarı, LeCun ve ekibi tarafından 1998 yılında tanıtılan 7 katmanlı LeNet5 algoritmasıyla gerçekleşti. Bu çığır açan adım, özellikle küçük bir veri seti üzerinde (10 sınıflı) gerçekleştirilen çalışmalara dayanmış olmasına rağmen, CNN'lerin karmaşık özellikleri etkili bir şekilde çıkarabilme ve tanıma yeteneklerini gösterdiği bir dönemi temsil eder [156].

CNN'ler, protez ayaklar için ayak hareketlerini sınıflandırmada kullanıldığında, bir dizi avantaj sunar. Bu avantajlar arasında uzaysal hiyerarşileri öğrenme, ilgili özellikleri otomatik olarak çıkarma, zaman serisi verilerini etkili bir şekilde işleme, aktarım öğreniminden yararlanma, çeşitli giriş sensörlerine uyum sağlama ve gerçek zamanlı çıkarımı destekleme yetenekleri bulunur. Ayak hareketlerini sınıflandırmak karmaşık bir görevdir çünkü farklı hareketler, girdi verilerinde çeşitli mekansal desenleri içerebilir. Özellikle, CNN'lerin mekansal ilişkileri anlamak ve ince değişiklikleri ayırt etmek konusundaki yetenekleri, ayak hareketlerini daha kesin ve doğru bir şekilde sınıflandırmalarını sağlar. CNN'ler genellikle evrişim katmanları, pooling katmanları ve tam bağlantılı katmanlar gibi bileşenleri içerir. Bu yapı, CNN'lerin karmaşık desenleri öğrenme yeteneğini temsil eder.


1.11. Sistemin Kontrolü

Bir sistemde, sinyallerin anlık olarak alınması, hızlı bir şekilde işlenmesi ve aktüatörlere iletilmesi önemlidir, ancak bu süreç kullanıcıyı rahatsız etmemelidir. Bu nedenle, sistem, istenen performansı elde etmek ve kullanıcı deneyimini optimize etmek için kontrol edilmelidir. Kontrol, bir sistemin belirli bir amaç doğrultusunda yönetilmesi ve düzenlenmesi sürecini ifade eder. Bu kontrol süreci, birbirine bağlı bileşenlerden oluşan sistemin performansını değerlendirmeyi ve çeşitli test yöntemleriyle denemeyi mümkün kılar.

Bir kontrol sistemi, dış dünyadan gelen bilgileri içeren giriş bölümü, sistemin performansını gösteren çıkış bölümü ve kontrol eyleminin gerçekleştiği denetleyici kısım olmak üzere üç temel öğeden oluşur. Kontrol sistemlerini sınıflandırmak için kullanılan iki temel yaklaşım ise açık çevrim kontrol ve kapalı çevrim kontroldür. Açık çevrim kontrolde, kontrol eylemi giriş sinyaline bağlı olarak gerçekleşir ve sistem güncellenmeden kontrol sağlanır. Kapalı çevrim kontrol sistemlerinde ise sistemin sürekli olarak güncellenmesi geri besleme mekanizmasıyla sağlanır. Bu sistemde kontrol eylemi hem giriş sinyaline hem de çıkış yanıtına bağlı olarak gerçekleştirilir. Kapalı çevrim kontrol sistemlerinde, bir ölçü aleti aracılığıyla geri besleme sağlanır. Bu sistemde giriş ve çıkış sürekli olarak karşılaştırılır ve olası hataların sıfırlanması için düzeltici eylemler gerçekleştirilir [157]. Tez kapsamında kapalı çevrim kontrol sistemlerine odaklanılmıştır.


Kontrol sisteminin girişine bağlı olarak çıkışının zaman içinde nasıl değiştiğini gösteren zaman yanıtı, geçici ve kararlı hal tepkilerinden oluşur. Geçici yanıt, bir sistemin girişindeki anlık bir değişiklik veya bozulma sonrasında ortaya çıkan davranışı ifade eder. Bu, bir sistemin yeni kararlı durumuna ne kadar hızlı ulaştığını veya bir durumdan diğerine geçiş sırasında nasıl davrandığını yansıtır. Geçici yanıt, bir sistemin dinamik davranışını ve kararlılığını anlamak açısından oldukça önemlidir. Sistemin yeni bir kararlı duruma ulaşması için geçen süre ve bu geçiş sırasında oluşabilecek salınımlar veya aşmalarla karakterizedir.

Kararlı durum tepkisi ise, bir sistemin uzun bir süre geçtikten sonra kararlı bir duruma ulaştıktan sonraki davranışını temsil eder. Diğer bir deyişle, tüm geçici etkiler ortadan kalktığında ve sistem sabit veya periyodik bir duruma ulaştığında sistemin verdiği tepkiyi ifade eder. Mühendisler, kontrol sistemlerini analiz etmek ve tasarlamak için belirli performans kriterlerini karşılamak amacıyla bu kavramları kullanır. Kontrol sistem tasarımının temel aşamaları Şekil 51’de verilmiştir.



Şekil 51. Kontrol sistem tasarım temel aşamaları


Kontrol sistemlerinin tasarım ve analizi süreçlerinde, fiziksel sistemlerin karmaşıklığını anlamak ve etkili bir kontrol stratejisi geliştirmek için sistemin matematiksel modeline ihtiyaç duyulur. Genellikle, sistemin dinamik davranışını tanımlayan diferansiyel denklemlerle ifade edilen bu matematiksel model, kontrol mühendislerine başlangıç noktası sağlar. Bu, sistemin içsel ilişkilerini, değişkenlerini ve tepkilerini anlamak için bir çerçeve oluşturur, bu da optimize edilmiş bir kontrol stratejisi tasarlamak için temel bir adımdır [158]. Protez ayağı hareket ettirecek olan lineer motorların Şekil 52’de verilen eşdeğer devresi üzerinde çalışmak, kontrol sistem tasarımında kritik bir aşamadır. Bu aşama, protez ayağın istenen hareketleri gerçekleştirebilmesi için gerekli olan kontrol stratejisinin geliştirilmesine odaklanır.




Şekil 52. DC lineer motorun eşdeğer devresi

Kontrol edilecek sistemin davranışı, ilk olarak dinamik bir model üzerinden ayrıntılı bir analizle incelenir. Oluşturulan matematiksel model, fiziksel ölçümlerle test edilir ve geçerliliği doğrulanır. Sonrasında, elde edilen model temelinde bir denetleyici tasarlanır ve bu tasarım gerçek sistemde uygulanır. Motorun fiziksel davranışını anlamak için matematiksel modelinden faydalanılır; matematiksel modeli oluşturmak için ise fizik yasalarından yararlanılır.

Süperpozisyon yöntemi kullanılarak gerçekleştirilen çözümle birlikte, motorun parametrelerini içeren blok diyagramı Şekil 53'te sunulmuştur. Ayrıca, sistemin kapalı çevrim transfer fonksiyonundan türetilen işaret akış diyagramı Şekil 54'te gösterilmiştir. Denklemler Ek-1 kısmında ayrıntılı olarak verilmiştir.




Şekil 53. DC lineer motorun parametreleri yerleştirilmiş blok diyagramı



Şekil 54. Kapalı çevrim DC lineer motor sisteminin işaret akış diyagramı

Lineer motorların aynı yönde döndüğü bir kontrol sistemi modellemek istediğimizde, her iki motorun hız sinyallerini toplamamız gerekmektedir. Şekil 55'te, bunu Simulink ortamında ifade eden bir blok diyagramı görülmektedir. Her iki motorun konum sinyallerini toplayarak bir kontrol sistemi modellemek, genellikle iki motorun pozisyonlarını birleştirerek bir bütün olarak yönetmeyi amaçlar. Bu yaklaşım, iki motorun belirli bir konumda senkronize bir şekilde çalışmasını sağlamak, birbirlerine göre pozisyonlarını dengelemek veya belirli bir hedef konuma ulaşmalarını sağlamak için kullanılabilir. Denetleyici tasarımlarında, motorların eş zamanlı bir şekilde belirli bir hedef konuma ulaşmaları amacıyla konum sinyallerine dayalı bir modelleme yapılmıştır.




Şekil 55. Lineer motorlar aynı yönde döndüğünde elde edilen blok diyagramı

1.11.1. Oransal-İntegral-Türevsel Denetleyici ile Kontrol

PID denetleyici, oransal (P), integral (I) ve türevsel (D) terimlerinin baş harflerinden türetilmiş bir kontrol yöntemidir ve endüstride yaygın olarak kullanılmaktadır. Bu yöntem, basit ve anlaşılır bir yapısıyla öne çıkar; orantılı, integral ve türevsel terimleri kullanarak sistem stabilitesini ve performansını artırma yeteneğine sahiptir.

Oransal terim, mevcut hatanın büyüklüğüne bağlı olarak kontrol sinyalini üretir. Eğer sistem çıkışı hedef değerin altındaysa, oransal terim çıkışı hedefe doğru artırmaya çalışır. İntegral terim, sistem sürekli bir hataya sahipse, zamanla bu hatayı düzelterek sistemin stabil hale gelmesini sağlar. Türevsel terim, hatanın hızını değerlendirir ve bu hızı azaltarak sistem üzerindeki aşırı tepkilere engel olur.

PID kontrol sisteminin blok diyagramı, Şekil 56'da gösterilmiştir. Bu diyagramda, girdi olarak hedef konum $r(t)$ ve ölçülen konum $y(t)$ kullanılır. PID kontrol algoritması, bu iki sinyali karşılaştırarak hata sinyalini $e(t)$ oluşturur ve oransal (K_p), integral (K_i) ve türevsel (K_d) kazançları kullanarak kontrol sinyalini $u(t)$ üretir. Bu kontrol sinyali, sistemin istenen performansı göstermesini sağlamak amacıyla kullanılır.



Şekil 56. PID kontrol blok diyagramı

$$u(t) = K_p e(t) + K_i \int_0^t e(\tau) d\tau + K_d \frac{de(t)}{dt} \quad (71)$$

PID denetleyici için K_p , K_i ve K_D parametrelerinin seçilmesinde amaç, sistemin en az hata, en az aşım ve en hızlı cevabı verecek şekilde ayarlanmalarını sağlamaktır.

1.11.2. Bulanık Mantık Denetleyici ile Kontrol

Günlük hayatta sıkça kullandığımız pek çok kelimenin anlamı ve düşünce süreçleri genellikle belirsiz ve bulanık olabilir. İşte bu belirsizlik ve bulanıklıkla başa çıkmak amacıyla 1965 yılında California Üniversitesi'nde öğretim üyesi olan Lotfi A. Zadeh tarafından geliştirilen bir teori bulanık mantık teorisidir [159].

Boolean mantık teorisinde bir eleman ya bir kümenin üyesidir ya da değildir; ancak bulanık mantık teorisinde üyelik derecesi kavramı bulunur ve bir elemanın her iki kümeyle de ilişkisi, üyelik derecesine bağlı olarak belirlenir. Bu, elemanın bir kümeye tam olarak ait olmaması durumunu da içerir. Üyelik fonksiyonu, bir elemanın bir kümeye ait olma derecesini 0 ile 1 arasında bir değerle ifade eder. Bulanık mantık, deterministik ve stokastik matematiğin anormal ve düzensiz problemleri çözmekte yetersiz kaldığı durumlar için geliştirilmiştir. Bu teori, bulanık matematik kullanarak sistemlerin matematiksel modellerini karmaşık işlemlere ihtiyaç duymadan yönetebilir. Geleneksel kontrol sistemlerinden farklı olarak, belirsiz ve kesin olmayan bilgiler içeren sistemlerle başa çıkabilir.


Bulanık kontrol teknolojisi, insan düşünce ve dilsel kontrol yeteneğini taklit edebilir. Bu, dilsel değişkenler ve bulanık kümeler kullanarak kesin olmayan bilgileri temsil etmek için bir araç sağlar. Bu özellik, gerçek dünyada sıkça karşılaşılan belirsizliklerle başa çıkabilen ve esneklik sağlayan bir kontrol yaklaşımı sunar [160].

Günümüzde, kontrol sistemlerinde bulanık mantık uygulamaları önemli bir yer edinmiştir. Bulanık mantık kontrolü, temelde üç ana bileşen içerir: bulanıklaştırma birimi, kural tabanı birimi ve durulaştırma birimi. Bulanıklaştırma ünitesi, girişteki değişken değerlerini ölçer, bunları derecelendirir ve bu bilgiyi dilsel değişkenlere dönüştürerek bulanıklaştırma fonksiyonunu oluşturur. Bu aşama, belirli durumları veya değerleri ifade eden bulanık kümelerin oluşturulmasını içerir. Bir Bulanık Mantık Denetleyicisi (BMD) içinde, bulanık bir sistemin dinamik davranışı, uzman bilgisine dayalı bir dizi dilsel tanımlama kuralı ile tanımlanır. BMD'nin bilgi tabanı, veri tabanı ve bulanık kontrol kural tabanı olmak üzere iki ana bileşenden oluşur. Bulanık mantık denetleyicileri, sistemin belirli koşullarda nasıl tepki vermesi gerektiğini belirleyen, kontrol amacını gerçekleştirmek için tasarlanmış bir dizi kural üzerinde çalışır. Bu kurallar, genellikle uzman politikasını karakterize eden dilsel değişkenler ve bulanık kümelerle "eğer-o halde" biçiminde ifade edilir [161, 162]. Kurallar durulaştırma ünitesinde kesin bir değere dönüştürülerek gerçek

bir sisteme uygulanması sağlanır. Böylece durulaştırma aşamasında sistemi kontrol etmek için bulanık çıktıyı net çıktıya dönüştürme işlemi gerçekleştirilmiş olur. BMD'nin genel yapısı Şekil 57'de verilmiştir. Şekilde G_1 , G_2 ve G_3 kazançları; sistemin belirli özelliklerini kontrol etmek ve ayarlamak için kullanılır, $e(k)$ hata sinyali; mevcut örnekleme anındaki referans ve çıkış arasındaki farkı hata sinyalini, $e(k-1)$ bir önceki örnekleme anındaki hata değişimini ifade etmektedir. Sistemin girişine $D(k)$ verilir. Referans giriş $r(k)$ hedef değeri temsil ederken $y(k)$ sistemin çıkışını ifade eder.

$$e(k) = r(k) - y(k) \quad (72)$$

$$de(k) = e(k) - e(k-1) \quad (73)$$




Şekil 57. Bulanık mantık denetleyici genel yapısı

Bulanıklaştırma ve durulaştırma aşamalarında kullanılan üyelik fonksiyonları, bulanık mantık sistemlerinde giriş ve çıkış değişkenlerinin belirsizlik derecelerini belirtmektedir. Bu fonksiyonlar, giriş ve çıkış uzayları için belirli alt kümeleri oluşturarak, sistemdeki belirsizlikle başa çıkarlar. Üçgen, Gauss, yamuk, Cauchy, sigmoid, sinusoid gibi çeşitli üyelik fonksiyonları mevcuttur. Bu çalışmada, üçgen üyelik fonksiyonu tercih edilmiştir.

Üçgen üyelik fonksiyonu genellikle belirli bir tepe değerine ve belirli bir genişliğe sahip üçgen bir profili ifade eder. Matlab/Simulink ortamında oluşturulan üçgen bulanık üyelik fonksiyonu modeli Şekil 58’de gösterilmiştir.

Şekilde x_1 , x_2 ve x_3 üçgenin yerini ve şeklini belirleyen parametrelerdir. Giriş x kesin değişkendir ve çıkış $\mu(x)$ üçgenin bulanık alt kümesindeki bir üyelik değeridir. Üçgen üyelik fonksiyonunun matematiksel ifadesi (74)'te verilmiştir.

$$A_{\Delta} = \max \left(\min \left(\frac{x - x_1}{x_2 - x_1}, \frac{x_3 - x}{x_3 - x_2} \right), 0 \right) \quad (74)$$




Şekil 58. Üçgen üyelik fonksiyonunun Simulink modeli

Bulanıklaştırma aşamasında, kesin değerler belirli bir üyelik fonksiyonu aracılığıyla bulanık üyelik değerlerine dönüştürülür. Bu dönüşüm, genellikle sistemin belirli bir durumunu temsil etmek için kullanılan alt kümelerle ilişkilidir. Bu durumda, hata ve hatanın değişimi, yedi farklı alt kümeye bölünmüştür: negatif büyük (NB), negatif orta (NM), negatif küçük (NS), sıfır (ZZ), pozitif büyük (PB), pozitif orta (PM) ve pozitif küçük (PS). Kesin değerler, bu üyelik fonksiyonlarının üçgensel bulanık alt kümelerinin tepe konumlarını temsil eder. Yani, belirli bir değer bu üçgensel üyelik fonksiyonlarına uygulandığında, her bir alt kümenin üyelik derecesi belirlenir ve bulanık bir ifade elde edilir. Seçilen kural tablosu Tablo 9’da ve kuralların modeli Şekil 59’da verilmiştir [163,164].

Tablo 9. Bulanık mantık denetleyicinin 49 kurallı kural tablosu

du		e						
		NB	NM	NS	ZZ	PS	PM	PB
de	NB	NB	NB	NM	NM	NS	NS	ZZ
	NM	NB	NM	NM	NS	NS	ZZ	PS
	NS	NM	NM	NS	NS	ZZ	PS	PS
	ZZ	NM	NS	NS	ZZ	PS	PS	PM
	PS	NS	NS	ZZ	PS	PS	PM	PM
	PM	NS	ZZ	PS	PS	PM	PM	PB
	PB	ZZ	PS	PS	PM	PM	PB	PB



Şekil 59. Bulanık kuralların Simulink modeli


Bu sürecin üçüncü adımında, BMD, merkezi alanları elde etmek için durulaştırma birimi değerlerini kesin bir yöntemle hesaplar. Durulaştırma işlemi, aynı zamanda alan merkezi yöntemi olarak bilinir ve kontrol sinyalinde gerekli değişiklikleri üretir. Belirlenen parametrelerin ardından, bu parametreler bir araya getirilerek alt sistem oluşturulur. Son aşamada ise oluşturulan bloklar birbirine bağlanır. Girişler (e ve Δe) ile çıkış (Δu) arasındaki süreçler düzenlenir. Bu aşamada kullanıcı, üyelik fonksiyonlarının parametrelerini düzenleme ve değiştirme imkanına sahiptir.

1.11.3. Kayan Kipli Denetleyici ile Kontrol

Fiziksel bir sistem genellikle, bilinen mevcut bilgilerle sınırlı kalarak, çözüm kolaylığı açısından diğer özellikleri ihmal ederek ve baskın özelliklere odaklanarak modellenir. Ancak, bu tür basitleştirmeler gerçek sistemleri tam olarak yansıtmaz ve genellikle eksik veya yetersiz kalır. Bilgi eksikliği nedeniyle modelde belirsizlikler ortaya çıkar [165]. Sistemin çevresi ile etkileşim sonucu ortaya çıkan harici bozucular da bilinmeyen unsurlardır ve modelde dikkate alınmalıdır. Bu bilinmeyenler, sistem üzerinde olumsuz etkiler yaratabilir. Tüm bu uyumsuzluklara rağmen, gerekli performans kriterini sağlamak için bir kontrol metodolojisi geliştirilmesi önemlidir. Bu zorlukları aşmak için geliştirilen kayan kipli kontrol yöntemi, özellikle belirsizliklere, harici bozuculara ve değişken çalışma koşullarına karşı direnç gösterme yeteneği ile bilinir. Temel prensibi, bir kayma yüzeyi oluşturarak sistem değişkenlerini bu yüzey üzerinde kontrol etmeye dayanır.

Kayan Kipli Denetleyici (KKD), temelde Lyapunov kararlılık koşullarına dayanır ve bu sayede sistem belirsizliklerine, parametre değişimlerine ve çevresel bozucu etkilere karşı duyarsız ve dayanıklı bir kontrol sağlar. KKK'de amaç, sistemi belirli bir durum uzayına yönlendirmek ve bu bölgede tutmaktır. Bu duruma ulaşıldığında, kayma hareketi bu bölgede kalmaya zorlanır ve sistem, denge noktasında kaymaya devam eder. Sistem, dengeye ulaştığında, kayma rejimine geçer ve bu aşamada olumsuzluklardan etkilenmez hale gelir.


Bu kontrol stratejisinin çalışma prensibi, sistemin dinamik davranışının gerekli performansı sağlayan anahtarlama yüzeyine ulaşmasını (erişme evresi) ve istenen referans değerine oturana kadar bu yüzeyde kaymasına (kayma evresi) dayanır. Bu evreleri gerçekleştirmek için iki farklı kontrol kuralı kullanılır: geri besleme kuralı ve anahtarlama kuralı. Kontrol işareti, idealde sonsuz frekansa sahip bir anahtarlama sinyali şeklinde oluşur. Bu özellik, KKD'nin yüksek performanslı ve dayanıklı bir kontrol sağlama yeteneğine önemli katkıda bulunur [166, 167]. KKD'de, sistemin durum değişkenleri belirli bir uzay koordinat sistemi üzerinde temsil edilir. Bu yaklaşım, faz düzlemi yaklaşımı olarak bilinir ve sistemin kararlılığını ve davranışını analiz etmek için etkili bir araç olarak kabul edilir. Şekil 60'ta hata ve hatanın türevi arasındaki ilişkiyi görselleştiren faz düzlemi verilmektedir.



Şekil 60. Kayan kipli denetleyici faz düzlemi [168]


1.11.4. Uyarlanabilir Denetleyici ile Kontrol

Uyarlanabilir (Adaptif) kontrol, kontrol edilen bir sistemin dinamik özelliklerindeki değişimlere ve belirsizliklere uyum sağlamak amacıyla tasarlanmış bir kontrol stratejisidir. Bu strateji, sistemin çevresel koşullarındaki değişikliklere, parametre dalgalanmalarına veya belirsizliklere hızlı ve etkili bir şekilde yanıt vererek, sistemin performansını optimize etmeyi amaçlar. Temel olarak, uyarlanabilir kontrol sürekli olarak sistemdeki belirsizlikleri ve değişen koşulları izler ve değerlendirir. Ardından, elde edilen bu bilgiler kullanılarak kontrol parametreleri veya stratejileri dinamik olarak güncellenir, böylece sistem çevresindeki değişen koşullara uyum sağlanır. Bu yaklaşım, sistemdeki belirsizliklerin etkisini en aza indirerek istenen performansın sağlanmasına olanak tanır. KKD ve adaptif denetleyici birbirine çok benzer gibi görünse de amaçları ve çalışma prensipleri birbirinden farklıdır. KKD, belirli bir bölgede sistem çıkışını sabit tutmayı amaçlarken, uyarlanabilir denetleyici sistemdeki belirsizliklere veya değişen koşullara yanıt vererek performansı optimize etmeyi hedefler. Uyarlanabilir kontrol yapısı Şekil 61’de gösterilmiştir.



Şekil 61. Uyarlanabilir (Adaptif) denetleyici kontrol yapısı [169]

Uyarlama mekanizması yalnızca "iyi" kontrol parametrelerini aramakla kalmaz, aynı zamanda bu parametreleri sürekli olarak optimize etmek için bir mekanizma sağlar. Çalışmamızda Model Referanslı Adaptif Kontrol (MRAC) kullanılmıştır. MRAC, bir referans modeli kullanarak kontrolör parametrelerini adaptif olarak güncelleyen bir denetleyici türüdür. MRAC sistemlerinde uyum yasası adaptif kontrol altındaki sistemin tepkisinin, bir referans modelin tepkisi ile mümkün olduğunca uyumlu olmasını sağlamak için parametreleri arar. Bu uyum, izleme hatasını minimize etmeyi amaçlar. İzleme hatası, gerçek çıkış ve referans model çıkışı arasındaki farkı temsil eder. MRAC, bu izleme hatasını minimize etmek için denetleyici parametrelerini sürekli olarak günceller. Şekil 62’de MRAC sisteminin şeması verilmiştir.



Şekil 62. Model referanslı adaptif kontrol genel şeması [170]

2. YAPILAN ÇALIŞMALAR, BULGULAR VE İRDELEME


2.1. Sınıflandırma Çalışmaları

2.1.1. Makine Öğrenmesi Algoritmalarıyla Ayak Hareketlerinin Her Kişi için Ayı Ayrı Sınıflandırılması


20-34 yaşları arasındaki on bir gönüllüden ayağın metatarsalına bağlı IMU sensöründen alınan hareket verileriyle dokuz parametre ölçülmüştür. Bu parametrelerden toplam, ortalama, standart sapma, kovaryans, çarpıklık ve basıklık gibi istatistiksel öznitelikler çıkarılarak boyut küçültülür. Ardından, sınıflandırma işlemi için Karar Ağacı, LDA, Naïve Bayes, KNN ve SVM gibi sınıflandırıcılar kullanılarak her bir kişi için ayrı ayrı gerçekleştirilir. Elde edilen sınıflandırma doğrulukları, 11 gönüllü için ortalaması alınarak değerlendirilir ve en yüksek doğruluk oranı %97,2 ile KNN için elde edilmiştir.

Sınıflandırma doğrulukları, tüm çalışmalarda 5-kat çapraz doğrulama yöntemiyle hesaplanmıştır. Bu yöntem, veri setini beş eşit parçaya böler ve her bir parçayı sırayla test ve eğitim için kullanarak doğruluk değerlerinin ortalamasını alır. İlk aşamada, tüm parametreler için öznitelik olarak toplam kullanılmış ve 5 denemenin sonuçları kaydedilmiştir. Daha sonra, ikinci aşamada ortalama özniteliği, üçüncü aşamada, ortalama, standart sapma, çarpıklık ve basıklık gibi belirli öznitelikler, dördüncü aşamada ise standart sapma, çarpıklık ve kovaryans gibi farklı öznitelikler kullanılarak aynı işlem gerçekleştirilmiştir. Daha sonra, bu dört sonucun ortalaması alınarak tablodaki değerler elde edilmiştir. Bu adımlar, tüm sınıflandırıcılar için tekrarlanmıştır. Linear SVM ve Quadratic SVM için ayrı sonuçlar elde edildikten sonra, SVM için ortalamaları alınarak tek bir tablo oluşturulmuştur. Ayak için ham test verilerinin sınıflandırma doğrulukları sırasıyla Şekil 63, 64, 65, 66 ve 67’de verilmiştir. Bu şekiller, her bir adımda kullanılan özniteliklerin ve sınıflandırıcıların performansını gösterir. TP = Gerçek Pozitif, TN = Gerçek Negatif, FP = Yanlış Pozitif ve FN = Yanlış Negatif olmak üzere sınıflandırma doğruluğu (SD) eşitlik (75)’teki gibi hesaplanmaktadır.


$$SD = \frac{TP + TN}{TP + TN + FP + FN} \quad (75)$$




Şekil 63. Ayak için ham test verilerinin Karar Ağacı sınıflandırma doğruluğu
SD: Sınıflandırma Doğruluğu G: Gönüllü




Şekil 64. Ayak için ham test verilerinin LDA sınıflandırma doğruluğu
SD: Sınıflandırma Doğruluğu G: Gönüllü



Şekil 65. Ayak için ham test verilerinin Naïve Bayes sınıflandırma doğruluğu
SD: Sınıflandırma Doğruluğu G: Gönüllü



Şekil 66. Ayak için ham test verilerinin KNN sınıflandırma doğruluğu
SD: Sınıflandırma Doğruluğu G: Gönüllü



Şekil 67. Ayak için ham test verilerinin SVM sınıflandırma doğruluğu
SD: Sınıflandırma Doğruluğu G: Gönüllü

Tablolardaki gönüllü sonuçlarının ortalamalarına göre, KNN %97,2 ile en yüksek doğruluğa sahipken, Karar Ağaçları %63,75 ile en düşük doğruluğu göstermektedir. LDA, Naïve Bayes ve SVM gibi diğer yöntemler ise %95'in üzerinde doğruluk elde etmektedir. Bu sonuçlar, Karar Ağaçlarının insan hareketi sınıflandırması için uygun olmadığını, diğer sınıflandırıcıların ise başarılı performans gösterdiğini ve bu amaç için kullanılabileceğini göstermektedir.

2.1.2. Ayak Hareketi Sınıflandırmasında Yapay Sinir Ağlarının Diğer Makine Öğrenmesi Algoritmalarıyla Karşılaştırılması

Bu çalışmada, 11 gönüllünün ayak ve alt bacaklarından alınan IMU verileri kullanılarak LDA, Naïve Bayes, Doğrusal-SVM (L-SVM), Karesel-SVM (Q-SVM), İnce-KNN (F-KNN), Ağırlıklı-KNN (W-KNN) ve Yapay Sinir Ağları (YSA) gibi yöntemlerle sınıflandırma yapılmıştır. İlk çalışmada her bir kişinin sınıflandırması ayrı ayrı yapılmışken, bu çalışmada tüm kişilerin verileri birleştirilerek tek bir veri seti oluşturulmuş ve sonuçlar bu birleştirilmiş veri setine göre değerlendirilmiştir. Tablo 10 farklı KNN

sınıflandırıcılarının, Tablo 11 ise çalışmada kullanılan farklı sinir ağı sınıflandırıcılarının özelliklerini vermektedir.

Tablo 10. F-KNN ve W-KNN özellikleri

Model Türü	F-KNN	W- KNN
komşuluk sayısı (K)	1	10
mesafe ölçüleri	Euclidean	Euclidean
mesafe ağırlığı	equal	squared inverse

Tablo 11. Çalışmada kullanılan sinir ağlarının özellikleri

	Dar Sinir Ağı	Orta Sinir Ağı	Geniş Sinir Ağı	Çift Katmanlı Sinir Ağı	Üç Katmanlı Sinir Ağı
Tam Bağlantılı Katman Sayısı	1	1	1	2	3
İlk katman boyutu	10	25	50, 100	10	10
İkinci katman boyutu	-	-	-	10	10
Üçüncü katman boyutu	-	-	-	-	10
Aktivasyon	ReLU	ReLU	ReLU	ReLU	ReLU
İterasyon sayısı	1000	1000	1000	1000	1000

İlk olarak, eğitim ve test verilerinin ortalama özniteliği seçilerek ortalaması alındı. Daha sonra, bu veriler beş kat çapraz doğrulama yöntemiyle sınıflandırıcılara verildi. Beş deneme sonucunun ortalaması alınarak dört farklı ayak hareketinin sınıflandırma doğrulukları elde edildi. Bu doğruluk değerleri, Tablo 12 ve Tablo 13'te Sınıflandırma Doğruluğu 1 (SD-1) olarak sunuldu. İkinci olarak, toplam öznitelik seçilerek sınıflandırma doğrulukları Sınıflandırma Doğruluğu 2 (SD-2) olarak verildi. Özellik olarak ortalama, standart sapma, çarpıklık ve basıklık seçildiğinde elde edilen sonuçlar Sınıflandırma Doğruluğu 3 (SD-3) olarak sunuldu. Son olarak, öznitelikler standart sapma, çarpıklık ve kovaryans seçilerek elde edilen sonuçlar aynı tabloda Sınıflandırma Doğruluğu 4 (SD-4) olarak gösterildi. Bu şekilde, farklı özniteliklerin ve sınıflandırıcıların sınıflandırma performansı detaylı bir şekilde incelendi.

Tablodaki değerler, çeşitli makine öğrenimi modellerinin farklı görevler veya veri kümeleri üzerinde elde ettiği doğruluk yüzdeliklerini göstermektedir. Doğruluk, bir sınıflandırma modelinin gerçek etiketleri ne kadar doğru tahmin ettiğini belirten önemli bir ölçüttür.

Tablo 12. Ayak için ham eğitim verilerinin sınıflandırma doğruluğu (%)

Sınıflandırıcı	Sınıflandırma Doğruluğu				
	SD-1	SD-2	SD-3	SD-4	Ortalama
LDA	67.26	68.18	85.48	81.82	75.69
Naïve Bayes	76.38	77.30	97.30	77.26	82.06
L-SVM	88.18	89.10	91.82	81.82	87.73
Q-SVM	86.36	87.28	90	89.08	88.18
F-KNN	80	86.38	89.10	80.92	84.1
W-KNN	82.76	86.40	80.92	80.02	82.53
Dar Sinir Ağı	87.38	86.38	88.20	84.54	86.63
Çift Katmanlı Sinir Ağı	80.94	86.38	86.36	77.28	82.74

Tablo 13. Ayak için ham test verilerinin sınıflandırma doğruluğu (%)

Sınıflandırıcı	Sınıflandırma Doğruluğu				
	SD-1	SD-2	SD-3	SD-4	Ortalama
LDA	64.54	66.34	80.90	80.92	73.18
Naïve Bayes	60	63.62	84.58	77.28	71.37
L-SVM	66.34	69.98	90	80.90	76.80
Q-SVM	66.36	69.98	86.36	87.26	77.49
F-KNN	67.24	70.90	82.74	74.54	73.86
W-KNN	70	70	90.90	72.72	75.91
Dar Sinir Ağı (DSA)	68.2	69.10	84.58	72.70	73.65
Çift Katmanlı Sinir Ağı	72.72	69.08	85.46	75.46	75.68

Tabloları incelediğimizde, tek bir özellik seçildiğinde eğitim verileri için L-SVM'nin %89,10'lık ortalama doğrulukla en yüksek sınıflandırma başarısına ulaştığını, test verileri

için ise en yüksek doğruluk oranının %72,72 ile Çift Katmanlı Sinir Ağı (B-YSA) tarafından sağlandığını görmekteyiz. Birden fazla özelliğin kullanılması durumunda ise eğitim verileri için %97,3 ile Naive Bayes, test verileri için ise %90,9 doğrulukla W-KNN'nin en yüksek doğruluğu gösterdiğini görüyoruz. Tüm özelliklerin ortalamasına bakıldığında ise, hem eğitim hem de test verileri için en yüksek performansın SVM ile elde edildiği dikkat çekmektedir.

Ayrıca, alt yan bacak için IMU sensöründen alınan ham veriler, özellik çıkarma işleminden sonra ayak için kullanılan sınıflandırıcılarla aynı sırayla sınıflandırılır. Alt bacak için elde edilen doğruluklar Tablo 14'te sunulmuştur. Tabloya göre LDA, eğitim verilerinin sınıflandırılmasında SD-1 sonuçlarında ortalama %90,94, ortalama sonuçlarda ise % 67,50 ile en yüksek doğruluğu sağlamaktadır.


Tablo 14. Alt bacak için ham eğitim verilerinin sınıflandırma doğruluğu (%)

Sınıflandırıcı	Sınıflandırma Doğruluğu				
	SD-1	SD-2	SD-3	SD-4	Ortalama
LDA	90.94	65.44	56.36	57.26	67.50
Naïve Bayes	50.90	62.72	60.02	59.10	58.19
L-SVM	67.26	59.08	59.08	68.16	63.40
Q-SVM	58.16	49.10	59.08	69.10	58.86
F-KNN	50	47.30	39.10	60	49.10
W-KNN	52.72	49.10	35.46	51.80	47.27
Dar Sinir Ağı (DSA)	59.96	59.08	46.38	62.72	57.04
Çift Katmanlı Sinir Ağı	53.62	51.82	51.82	52.72	52.50

Ayak hareketlerinin sınıflandırılmasında ayağa ve alt bacağa bağlanan sensörlerden gelen veriler incelenmiştir. Ayağın hareket aralığı daha fazla olduğundan sınıflandırma doğruluğu alt bacağa göre daha yüksektir. Bu da beklenen durumdur.

Ayak ham verilerinin sınıflandırılmasına ilişkin tüm sonuçlar, Şekil 68'de görsel olarak sunulmuştur. Bu verilere göre, en yüksek doğruluk oranları %97,3 ile SD-3 özniteliklerinde elde edilmiştir. Bu özniteliklere dayanarak farklı yapay sinir ağlarının (DSA, OSA, GSA, B-YSA, T-YSA) sonuçları elde edilmiş ve bu sonuçlar Tablo 15'te derlenmiştir. İlginç bir şekilde, tek katmanlı sinir ağlarının sınıflandırma doğruluğunun, iki ve üç katmanlı sinir

ağlarından daha yüksek olduğu görülmüştür. Ayrıca, ilk katmanın boyutunun artmasıyla birlikte, sonuçların doğruluğunun da arttığı gözlemlenmiştir.



Şekil 68. Ayak için ham verilerin sınıflandırma doğruluğu (%) 1-ortalama; 2- toplam; 3- ortalama, standart sapma, çarpıklık, basıklık; 4-standart sapma, çarpıklık, kovaryans; 5- özellik sonuçlarının ortalaması

Tablo 15. Farklı sinir ağlarının karşılaştırma sonuçları (%)

	Ortalama
Dar sinir ağı (DSA)	88.18
Orta sinir ağı (OSA)	90.02
Geniş sinir ağı (GSA)	90.92
Çift katmanlı sinir ağı (B-YSA)	86.38
Üç katmanlı sinir ağı (T-YSA)	79.10

Bir sonraki adımda Naïve Bayes, SVM, KNN ve YSA karşılaştırılması için bu öznitelikler kullanılarak sonuçlar tekrar elde edilmiş ve Tablo 16'ya kaydedilmiştir.

Tablo 16. Naïve Bayes, SVM, KNN ve YSA karşılaştırma sonuçları (%)

	Ortalama
Naïve Bayes	92.74
L-SVM	90
KNN	90.92
YSA	93.66

Tüm çalışmalar incelendiğinde YSA algoritmasının ayak hareketlerinin sınıflandırılmasında daha iyi çalıştığı görülmüştür. Bu çalışma aynı zamanda insan hareketlerinin sınıflandırma yoluyla belirlenebileceğini de göstermiştir.

Tablo 17'de literatürdeki EMG ve IMU verileriyle yapılan çalışmaların karşılaştırma sonuçları verilmiştir.

Tablo 17. Ayak hareketleri sınıflandırmasında EMG ve IMU verilerinin karşılaştırılması

	Bu çalışma	Maragliulo[171]	Khera[172]	Hooda[173]
Sensör	IMU(4)	sEMG(2)	sEMG(2)	sEMG (6)
Hareket türü	4 hareket	5 hareket	4 hareket	4 hareket
	sagittal	sagittal	sagittal	sagittal
	frontal		frontal	frontal
Sınıflandırıcı	YSA	SVM	SVM	SVM
Doğruluk (%)	93.66	90.04	93.23	91.85
Gönüllü sayısı	11 sağlıklı	3 sağlıklı	10 sağlıklı	20 sağlıklı 5 hasta

Literatürdeki çoğu çalışma, hareket tanıma için EMG sinyallerini kullanmaktadır. EMG verilerinin analizinin karmaşıklığı nedeniyle, bu çalışma alt ekstremite hareket tanıma için yalnızca IMU verilerini kullanmayı önermektedir. Önerilen yöntemle elde edilen sonuçlar, sadece IMU verilerini kullanarak yüksek sınıflandırma doğruluğunu


göstermektedir. Maragliulo ve arkadaşlarının yaptığı çalışmada SVM algoritması ile aynı düzlemde 5 hareketi incelemiş ancak tek düzlemde olmasına rağmen daha düşük sınıflandırma doğruluğu elde edilmiştir. Khera ve arkadaşları, daha az katılımcıya sahiptir, SVM algoritması ve EMG sinyallerini kullanmıştır, bu da daha düşük doğrulukla sonuçlanmıştır. Hooda ve arkadaşları gönüllü sayısını artırmış ancak daha düşük doğruluk elde etmiştir, bu da IMU'nun EMG'ye kıyasla daha güvenilir olduğu fikrini desteklemektedir.

2.1.3. Evrişimli Sinir Ağı ile Ayak Hareketlerinin Sınıflandırılması

Bu çalışmada, bir temel Evrişimli Sinir Ağı (CNN) modeli oluşturulmuş ve eğitilmiştir. İkinci çalışmada hazırlanan veri seti kullanılmıştır. Veri seti yüklendikten sonra, her veri örneği için uygun etiketler oluşturulmuş ve veri seti %80 eğitim ve %20 test olarak ikiye ayrılmıştır. Daha sonra, CNN modelini oluşturmak için uygun katmanlar ve seçenekler belirlenmiş ve bu model eğitim verisi üzerinde eğitilmiştir. Eğitim sürecindeki hata ve doğruluk değerleri görselleştirilerek modelin performansı takip edilmiştir. Ayrıca, validasyon seti üzerindeki doğruluk değerleri de görselleştirilerek modelin eğitim sırasında ne kadar iyi genelleştiği ve overfitting (aşırı uydurma) olup olmadığını kontrol etmek amaçlanmıştır. Oluşturulan model Şekil 69'da verilmiştir.

Giriş verisi, her biri 3790 zaman adımı ve 9 özelliğe sahip olan $[3790 \times 9 \times 1]$ boyutunda bir tensördür. Bu veri üzerinde 3×3 boyutunda 32 filtre kullanılarak evrişim işlemi uygulanır. 'Same padding' seçeneğiyle boyut korunur. Ardından Batch Normalization (toplu normalleştirme) kullanılarak ağı eğitimi süreci hızlandırılır. Bu normalleştirme işlemi, her evrişim katmanından sonra uygulanır. ReLU aktivasyon fonksiyonu, negatif girişleri sıfıra ayarlayarak doğrusal olmayan bir işlem uygular. Max Pooling katmanı, özellik haritasının boyutunu yarıya düşürmek için kullanılan bir havuzlama katmanıdır. 2×2 boyutunda bir pencere kullanılarak en büyük değer seçilir. İkinci bir evrişim katmanı uygulanır. Bu katmanda, 3×3 boyutunda 64 filtre kullanılır ve 'same padding' seçeneğiyle boyut korunur. İkinci bir normalleştirme katmanı, ikinci evrişim katmanından sonra uygulanır. İkinci ReLU aktivasyon fonksiyonu, ikinci evrişim katmanından sonra uygulanır. Özellik haritasının boyutunu yarıya düşürmek için bir kez havuzlama katmanı kullanılır. Ardından, 128 nöron içeren bir Fully-Connected katmanı (tam bağlantılı katman) uygulanır. Bu katman, özellik haritasındaki tüm özellikleri düzleştirir. %50 oranında Dropout uygulanarak aşırı uyumu

önlemeye çalışılır. Sınıflandırma için bir tam bağlantılı katman daha eklenir. Bu katman 4 nörona sahiptir çünkü sınıf sayısı 4'tür. Sınıflandırma sonuçlarını olasılık dağılımına dönüştürmek için Softmax fonksiyonu kullanılır. Bu, her sınıfın olasılığını belirtir. Son olarak, sınıflandırma yapmak için kullanılan bir katman daha eklenir. Softmax aktivasyon fonksiyonuyla belirlenen olasılıklara dayanarak sınıf tahminleri yapılır.




Şekil 69. CNN modeli katmanları

MATLAB editöründe hazırlanan kodda eğitim sırasında kullanılan optimizasyon algoritması 'Adam' olarak belirlenmiştir. Adam, öğrenme hızını adaptif moment tahminleri

kullanarak ayarlar. Maksimum eğitim dönemi sayısı, 'MaxEpoch' parametresiyle 1000 olarak belirlenmiştir. Bir epoch, tüm eğitim verisinin model üzerinden bir kez geçirilmesini ifade eder. Mini-batch eğitimi, her iterasyonda birçok örneği içeren küçük veri yığınlarını kullanarak ağı eğitmeyi sağlar. 'MiniBatchSize' parametresi 50 olarak ayarlanmıştır.

Doğrulama işlemi, 'ValidationFrequency' parametresiyle her 10 epoch'ta bir gerçekleştirilir. Bu, modelin eğitim sırasında düzenli aralıklarla doğrulama verisi üzerinde değerlendirilmesini sağlar. Eğitim sürecinde doğruluk ve hatanın epoch boyunca değişimi Şekil 70'te gösterilmiştir.



Şekil 70. CNN modeli eğitim sonuçları

Eğitim sırasında her bir epoch sonunda, modelin eğitim verisi üzerindeki tahminlerinin gerçek etiketlerle karşılaştırılmasıyla eğitim doğruluğu hesaplanır. Bu nedenle eğitim doğruluğu, modelin eğitim verisine ne kadar iyi uyarlandığını gösterir. Validasyon doğruluğu, modelin daha önce görmediği test verisi üzerindeki performansını ölçer. Bu nedenle, validasyon doğruluğu, modelin genelleme yeteneğini ve gerçek dünya performansını yansıtır. Çalışmada 10 eğitim sonucunda ortalama eğitim doğruluğu %96,57 ortalama %85,56 validasyon doğruluğu olarak hesaplanmıştır. Bu çalışma denetleyicileri derin öğrenmeyle birleştirmek için yapılan bir ön çalışma olmuştur.

2.1.4. 1D-ResCNN Modeli ile Ayak Hareketlerinin Sınıflandırılması

Gönüllü kişilerden toplanan veriler Spider editöründe Phyton programlama dili kullanılarak önerilen derin öğrenme algoritmasında kullanılmak üzere hazırlanmıştır. Hazırlanan veri seti ile performans analiz çalışmaları Spider, Jupiter editörleri ve Google Colab üzerinden yürütülmüştür. Çalışmalarda Keras, TensorFlow, PyTorch kütüphaneleri tercih edilmiştir. TensorFlow, açık kaynaklı bir çerçeve olup Phyton, C, Java gibi programlama dillerini desteklemektedir. Çoklu GPU desteği sayesinde yüksek performanslı sayısal hesaplamalara olanak tanır. PyTorch, basit bir arayüz sağlayan açık kaynaklı bir çerçevedir. Güçlü GPU desteğiyle TensorFlow'un en güçlü rakibidir. Keras, çoklu GPU desteğiyle TensorFlow'a, hızlı kurulum için basit arayüzüyle PyTorch'a benzeyen açık kaynaklı bir çerçevedir. TensorFlow iş akışına kolayca entegre edilebilmektedir [174].


Çalışmamızda PyTorch için 2200, 9, 100 olarak sırasıyla örnek sayısı, kanal sayısı ve uzunluk belirlenmiştir. 4 hareket için 4 sınıf belirlenmiştir. Eğitimde de testte de eşit sayıda veri olması için dengeli bir şekilde dağıtılmıştır. Verilerin %80'i eğitim için %20'si test için kullanılmıştır. Eğitim verilerinin de %20'si validasyon için kullanılmıştır. Veriler PyTorch'un anlayacağı dile çevrilmiştir. Eğitim, test ve validasyon verileri torch verilerine çevrilerek PyTorch'un anlayacağı tensörler haline getirilmiştir. Derin öğrenme modeli oluştururken öncelikle özellik matrisinin boyutları ve etiket vektörünün boyutları verilerek modelin giriş ve çıkış boyutları belirlenir. *Features* dizisinin şekli, özellik matrisinin boyutlarını, *labels* dizisinin şekli ise etiket vektörünün boyutlarını gösterir. Tablo 18'de evrişimli sinir ağı modelinin parametre değerleri verilmektedir.

Tablo 18. Derin öğrenme modeli eğitim parametreleri

eğitim verisi	validasyon verisi	test verisi	batch size	epoch
(1408,9,100)	(352,9,100)	(440,9,100)	100	50

'batch size' bir seferde işlenecek örnek sayısını, toplu boyutu ifade eder. Büyük bir veri kümesini daha küçük toplu boyutlarına bölerek eğitim sürecini hızlandırılabilir. 'epoch' eğitim sayısını verir. Eğitim süresince kaç kez tüm eğitim veri setinin model tarafından geçirileceğini belirtir. Modelin daha fazla öğrenme yapmasını sağlar.


Şekil 71’de önerilen 1D-ResCNN modelinin mimarisi verilmektedir. Birinci aşamada öznitelikleri elde etmek için giriş zaman verilerini filtre matrisi ile çarparak evrişim işlemlerini gerçekleştirir. Batch size 100 olan 100 tane 9 kanallı 100 uzunluklu veri konvolüsyona tabi tutulur. İkinci aşamada verinin fazla büyümesini engellemek amacıyla Batch Normalization işlemi yapılır. Üçüncü aşamada ReLU aktivasyon fonksiyonuna tabi tutulur. Dördüncü aşamada ResBlock’a sokulur. Burada verinin değerli kısımları çıkarılır. Beşinci aşamadan sonra yapılan işlemler tekrarlanır. Dokuzuncu aşama olan sınıflandırma aşamasına kadar olan kısımda öznitelik çıkarma işlemleri gerçekleştirilir. Bu sekiz katmanda ham veri alınır, öznitelik çıkarılır ve bu öznitelikleri sınıflandırılır. Sınıflandırma aşamasında sırasıyla lineer katman, ReLU aktivasyon fonksiyonu, lineer katman, ReLU aktivasyon fonksiyonu ve son olarak tekrar lineer katman aşamalarından geçirilir.



Şekil 71. Önerilen 1D-ResCNN modelinin mimarisi

Azaltılmış özelliklerle ilgili zorlukları azaltmak ve CNN'lerin eğitimini kolaylaştırmak için Res-Block yapısı kullanıldı. Önerilen Res-Block mimarisi, Şekil 72'de görsel olarak gösterilmektedir. Bu Res-Block yapısı, iki toplu normalleştirme katmanı ve ReLU aktivasyon fonksiyonu ile tamamlanan 3x3 filtreli iki evrişimli katman içerir. Optimizasyon amacıyla, modelde seçilen yöntem olarak ADAM optimizieri kullanılmıştır. Bu optimize edici, eğitim süreci sırasında sinir ağının yakınsama hızını ve genel performansını arttırmada çok önemli bir rol oynar.

Giriş verisi, ilk konvolüsyon katmanından geçirilir ve ardından toplu normalleştirme ve ReLU aktivasyon fonksiyonu uygulanır. Daha sonra, ikinci konvolüsyon katmanından geçirilen çıkışa tekrar toplu normalleştirme ve ReLU aktivasyon fonksiyonu uygulanır. Bu noktada, kısayol (shortcut) bağlantısı ile birleştirilen çıkış, son bir ReLU aktivasyon fonksiyonundan geçirilerek döndürülür. Bu blok, geleneksel bir evrişimli sinir ağı bloğundan farklı olarak, giriş verilerini bir "shortcut" bağlantısı ile ekleyerek ağıın öğrenme kapasitesini artırmak ve eğitimini kolaylaştırmak için tasarlanmıştır. Bu tür bloklar, modelin daha derin ve daha etkili öğrenmesine yardımcı olabilir. Ayrıca, gradyan kaybını azaltarak eğitimi stabilize edebilirler. Bu yapı, bilgiyi daha akıcı bir şekilde akış halinde tutar ve ağıın daha kısa sürede ve daha etkin bir şekilde öğrenmesini sağlar.



Şekil 72. Res-Block katmanları [175]

Önerilen modelin tüm aşamalarının Python çıktısı Şekil 73'te verilmiştir.

Katman Türü	Giriş Boyutu	Çıkış Boyutu	Parametre
CNN model	[100, 9, 100]	[100, 4]	–
Conv1d	[100, 9, 100]	[100, 16, 100]	448
BatchNorm1d	[100, 16, 100]	[100, 16, 100]	32
ReLU	[100, 16, 100]	[100, 16, 100]	–
Res-Block	[100, 16, 100]	[100, 16, 100]	–
Sequential	[100, 16, 100]	[100, 16, 100]	–
Conv1d	[100, 16, 100]	[100, 16, 100]	784
BatchNorm1d	[100, 16, 100]	[100, 16, 100]	32
Conv1d	[100, 16, 100]	[100, 16, 100]	784
BatchNorm1d	[100, 16, 100]	[100, 16, 100]	32
Conv1d	[100, 16, 100]	[100, 32, 100]	1,568
BatchNorm1d	[100, 32, 100]	[100, 32, 100]	64
ReLU	[100,32,100]	[100, 32, 100]	–
Res-Block	[100, 32, 100]	[100, 32, 100]	–
Sequential	[100, 32, 100]	[100, 32, 100]	–
Conv1d	[100, 32, 100]	[100, 32, 100]	3,104
BatchNorm1d	[100, 32, 100]	[100, 32, 100]	64
Conv1d	[100, 32, 100]	[100, 32, 100]	3,104
BatchNorm1d	[100, 32, 100]	[100, 32, 100]	64
Linear	[100, 3200]	[100, 2048]	6,555,648
ReLU	[100, 2048]	[100, 2048]	–
Linear	[100, 2048]	[100, 1024]	2,098,176
ReLU	[100, 1024]	[100, 1024]	–
Linear	[100, 1024]	[100, 4]	4,100


Şekil 73. Ayrıntılı 1D-ResCNN mimarisi

Tablo 19’da epoch değeriindeki değişimin sonuçlara etkisi incelenmiştir.

Tablo 19. Epoch değerlerinin sonuçlar üzerindeki etkisi

	Eğitim hatası	Eğitim doğruluğu	Validasyon hatası	Validasyon doğruluğu
epoch=10	0.00232	1	0.0141	0.998
epoch=50	4.1e-5	1	0.0108	0.998
epoch=100	3.52e-6	1	0.0111	0.998
epoch=500	1.74e-8	1	0.0131	0.998
epoch=1000	8.74e-9	1	0.0361	0.995

Tabloda, en yüksek doğruluğa ulaşmak için yapılan analizlerin sonuçları sunulmuştur. Bu analizler, epoch değerinin hem hata oranını en aza indirmeye hem de yanıt süresini optimize etme açısından incelenmiştir. Sonuçlar, epoch değeri üzerinde yapılan deneyler sonucunda belirlenen optimum değer olan 50'ye göre elde edilmiştir. Şekil 74'te önerilen modelin epoch değerine göre doğruluk ve hata sonuçları grafiksel olarak gösterilmiştir.




Şekil 74. Önerilen modelin doğruluk ve hata sonuçları


Önerilen modelin performansını değerlendirmek amacıyla, tek katmanlı sinir ağı (SLP), iki gizli katman ve bir çıkış katmanını içeren çok katmanlı sinir ağı (MLP) ve bir yapay

sinir ağı modeli (YSA) ile karşılaştırmalı bir analiz yapılmıştır. Bu karşılaştırma, eğitim doğruluğu, validasyon doğruluğu ve validasyon hatası olmak üzere üç farklı metrik üzerinden gerçekleştirilmiştir. Elde edilen grafikler, her bir modelin performansını zamanla nasıl değiştirdiğini görsel olarak göstermektedir. Bu şekilde, hangi modelin en iyi performansı sağladığına dair kapsamlı bir değerlendirme yapılmıştır.


Çalışmada kullanılan YSA modelinde, giriş katmanındaki nöron sayısı, sensör parametre sayısı (9) ile zaman serisinin uzunluğunun (100) çarpımına eşittir; yani toplamda 900 nöron bulunmaktadır. İlk tam bağlı katmanın çıkış nöron sayısı 256'dır ve ikinci tam bağlı katmanın çıkış nöron sayısı ise 128'dir. Bu durum, ilk katmandan gelen 256 çıkışın ikinci katmanda 128 nörona indirgendiği anlamına gelir. Çıkış katmanındaki nöron sayısı, modelin genel çıkış boyutunu belirler. Bu modelde, çıkış boyutu 4 olduğu için çıkış nöron sayısı da 4'tür. Eğitim hatası, eğitim doğruluğu, validasyon hatası ve validasyon doğruluğu grafikleri sırasıyla Şekil 75, 76, 77 ve 78'de verilmiştir.




Şekil 75. Önerilen modelin eğitim hatasının diğer modellerle karşılaştırılması



Şekil 76. Önerilen modelin eğitim doğruluğunun diğer modellerle karşılaştırılması



Şekil 77. Önerilen modelin validasyon hatasının diğer modellerle karşılaştırılması



Şekil 78. Önerilen modelin validasyon doğruluğunun diğer modellerle karşılaştırılması

Grafikleri incelediğimizde, dört farklı modelin eğitim sürecindeki performansı hakkında çeşitli gözlemler yapabiliriz:

SLP modeli, başlangıçta düşük bir doğrulukla başlar, ancak eğitim süreci ilerledikçe doğrulukta belirgin bir artış gösterir. Bu durum, modelin eğitim verisindeki desenleri daha iyi anlamaya başladığını gösterebilir. YSA modeli, orta düzeyde bir doğrulukla başlar ve eğitim süreci boyunca doğrulukta artış gösterir. 50 epoch sonunda mükemmel bir doğruluk elde eder. Bu, modelin veri setindeki karmaşıklıkları başarılı bir şekilde öğrendiğini gösterebilir. MLP modeli, YSA modeline göre daha yüksek bir başlangıç doğruluğuna sahiptir ve eğitim süreci boyunca doğrulukta belirgin bir artış gösterir. Bu durum, modelin veri setindeki karmaşıklıkları iyi bir şekilde öğrenme yeteneğini yansıtabilir. CNN modeli, yüksek bir başlangıç doğruluğuyla başlar ve eğitim süreci boyunca çok hızlı bir şekilde mükemmel bir doğruluk elde eder. CNN'ler genellikle yapısal verilerle iyi çalışır ve zaman serisi gibi verilerde özellikleri daha etkili bir şekilde öğrenebilir.

Tablo 20, literatürde çeşitli hareket tanıma sistemlerinde kullanılan sensör türleri, katılımcı sayısı, kullanılan yöntem ve bildirilen doğruluk oranlarını sunmaktadır. Bu tabloya göre, IMU sensörleri ve CNN tabanlı yöntemlerin sıkça beraber kullanıldığı gözlemlenmektedir. Önerilen yöntem %99,8 gibi son derece yüksek bir doğruluk elde etmiştir, bu da oldukça yüksek bir başarı oranıdır. Diğer çalışmalarda en yüksek başarı oranları %99,6 ile CNN ve %98,68 ile LSTM ile elde edilmiştir. Bizim çalışmamızla karşılaştırıldığında, onların yaklaşımının sadece sagittal düzlemdeki ayak hareketlerini tanımaya ve daha az katılımcıyla deneyler yapmaya odaklandığı için daha düşük sağlamlık sergilediği görülmüştür. Ek-2'de çalışmalarda kullanılan hareket çeşitleri ayrıntılı olarak verilmiştir. Tablo 21, önerilen algoritmanın literatürde sıkça kullanılan diğer derin öğrenme modelleriyle elde edilen sonuçlarını karşılaştırmaktadır.

1D-ResCNN modeli, protez ayaklardan gelen hareket verilerini ustaca işleyip sınıflandırır. 'Res' (artık) bloklarının mimariye entegrasyonu, derin ağların eğitimine yardımcı olurken üstün performans sağlar. Res-Block'ların ve toplu normalleştirme katmanlarının evrimsel sinir ağına dahil edilmesi, önerilen modelin hız, sağlamlık ve doğruluk açısından literatürdeki diğer yöntemlere göre üstün performans sergilemesini sağlar. Bu çalışmanın benzersizliği, yeni bir veri setinin kullanılması, yeni bir modelleme yaklaşımının getirilmesi ve bu modelin literatürdeki diğer yöntemlere göre kanıtlanmış üstün performansından kaynaklanmaktadır.


Tablo 20. Önerilen modelin literatürdeki diğer çalışmalarla karşılaştırılması

Referans	Sensör	Gönüllü Sayısı	Yöntem	Hareket	Doğruluk(%)
Wang 2018 [176]	Açı sensörü	1	LSTM	Wang ^(a)	98.3
Feng 2019 [177]	Strain gauge Açı sensörü	3	CNN	Feng ^(b)	93.1
Su 2019 [178]	IMU	11	CNN	Su ^(c)	94.15
Lu 2020 [179]	IMU	10	CNN	Lu ^(d)	98.06
Bijalwan 2021 [180]	IMU	30	CNN-LSTM	Bijalwan ^(e)	90
Narayan 2021 [181]	IMU	8	CNN	Narayan ^(f)	94.34
Vu 2022 [52]	IMU	4	CNN	Vu ^(g)	99.6
Vakacherla 2023 [51]	İvmeölçer	10	CNN	Vakacherla ^(h)	98.1
Önerilen model	IMU	11	1D-ResCNN	Aydın Fandaklı ⁽ⁱ⁾	99.8


RNN, LSTM ve GRU algoritmaları, sıralı verilerin işlenmesinde yaygın olarak kullanılan algoritmalar arasındadır. Ancak, RNN'nin uzun süreli bağımlılıkları iyi işleyememe sorunu vardır. Bu sorunu çözmek için LSTM geliştirilmiştir. LSTM, uzun vadeli bağımlılıkları daha etkili bir şekilde yönetmek için tasarlanmıştır. GRU ise, LSTM'ye benzer bir RNN türüdür ancak karmaşık yapıları daha basit bir şekilde temsil eder. Bu basitleştirme, eğitim sürecini hızlandırır ve hesaplama maliyetini azaltır. Bu nedenle, GRU genellikle LSTM'nin alternatifi olarak kullanılır. Tabloda, bu algoritmaların çalışılan epoch değerleri için eğitim sırasında beklenen performansı sağlayamadığı ve istenilen sonuçlara ulaşamadığı gözlemlenmiştir. Özellikle LSTM'nin düşük performansı, ResCNNLSTM modelinin başarısını olumsuz yönde etkilemiş ve ResCNN modelinin doğruluğunu azaltmıştır. CNN modeli, ResCNN algoritmasına kıyasla daha derin evrişim katmanlarına sahiptir. Bu durum hem performansın yavaş olmasına hem de düşük doğruluk elde edilmesine neden olmuştur. Şekil 79, 80, 81 ve 82'de Tablo 21'de verilen literatürdeki diğer modelin önerilen modelle karşılaştırılması sonucu elde edilen eğitim doğruluğu, validasyon doğruluğu, eğitim hatası ve validasyon sonuçları verilmiştir.

Tablo 21. Önerilen modelin literatürdeki diğer derin öğrenme modelleriyle karşılaştırılması


		epoch=10	epoch=50	epoch=100	epoch=500
CNN	Accuracy	94.55	99.55	98.86	98.86
	Precision	94.90	99.55	98.87	98.87
	Recall	94.55	99.55	98.86	98.86
	F1 score	94.55	99.54	98.87	98.86
LSTM	Accuracy	28.86	53.41	93.64	98.41
	Precision	15.59	54.40	94.07	98.42
	Recall	28.86	53.41	93.64	98.41
	F1 score	19.35	51.05	93.65	98.41
RNN	Accuracy	28.64	65.91	68.64	96.82
	Precision	14.70	63.12	67.26	96.85
	Recall	28.64	65.91	68.64	96.82
	F1 score	19.33	60.72	64.31	96.80
GRU	Accuracy	32.50	57.73	74.32	93.41
	Precision	25.03	44.67	75.11	93.41
	Recall	32.50	57.73	74.32	93.41
	F1 score	27.29	50.19	69.68	93.38
ResCNN	Accuracy	99.32	100	100	99.32
	Precision	99.32	100	100	99.34
	Recall	99.32	100	100	99.32
	F1 score	99.32	100	100	99.32
ResCNNLSTM	Accuracy	92.27	95.68	95.45	97.05
	Precision	92.45	95.83	95.51	97.06
	Recall	92.27	95.68	95.45	97.05
	F1 score	92.32	92.32	95.47	97.04




Şekil 79. Önerilen modelin eğitim doğruluğunun diğer derin öğrenme modelleriyle karşılaştırılması



Şekil 80. Önerilen modelin validasyon doğruluğunun diğer derin öğrenme modelleriyle karşılaştırılması



Şekil 81. Önerilen modelin eğitim hatasının diğer derin öğrenme modelleriyle karşılaştırılması




Şekil 82. Önerilen modelin validasyon hatasının diğer derin öğrenme modelleriyle karşılaştırılması


2.2. Kontrol Çalışmaları

2.2.1. PID Denetleyici Simulasyon Sonuçları

PID denetleyicili sistemin girişine birim basamak tepkesi uyguladığımızda sistem çıkışında aşmanın olduğu ve $35.05 \mu s$ 'de 0.98 'e karşılık gelen referansı yakaladığını görülmektedir. Sisteme endüvi endüktansı $L_b = 0.036H$ dahil edilerek ve $K_p = 4000$, $K_i = 1$ ve $K_D = 0.01$ alınarak elde edilen grafik Şekil 83'te, Tablo 22'ye göre elde edilen karşılaştırma sonuçları Şekil 84'te verilmiştir.



Şekil 83. PID denetleyicili sistemin birim basamak tepkesi




Şekil 84. K_p , K_i ve K_d parametrelerine göre PID denetleyici karşılaştırması

Tablo 22. Farklı PID parametrelerine göre geçici tepke parametrelerinin karşılaştırılması


		Geçici tepke parametreleri
PID1	$K_p = 1$	oturma süresi: 261.2 s
	$K_i = 0.1$	%100'den fazla aşma var
	$K_d = 0.1$	sürekli durum hatası yok
PID2	$K_p = 1$	oturma süresi: 123.5 s
	$K_i = 1$	%100'den fazla aşma var
	$K_d = 1$	sürekli durum hatası yok
PID3	$K_p = 10$	oturma süresi: 25.55 s
	$K_i = 1$	aşma yok
	$K_d = 0.1$	sürekli durum hatası yok
PID4	$K_p = 100$	oturma süresi: 30 ms
	$K_i = 1$	aşma var
	$K_d = 0.1$	% 2'lik sürekli durum hatası var
PID5	$K_p = 1000$	oturma süresi: 410 μ s
	$K_i = 1$	aşma yok
	$K_d = 0.1$	sürekli durum hatası yok
PID6	$K_p = 1000$	oturma süresi: 31.85 μ s
	$K_i = 1$	%2'den az aşma var
	$K_d = 0.01$	sürekli durum hatası yok
PID7	$K_p = 2000$	oturma süresi: 34.36 μ s
	$K_i = 1$	%12 aşma var
	$K_d = 0.01$	sürekli durum hatası yok
PID8	$K_p = 4000$	oturma süresi: 35.05 μ s
	$K_i = 1$	%26 aşma var
	$K_d = 0.01$	sürekli durum hatası yok
PID9	$K_p = 4000$	oturma süresi: 105 μ s
	$K_i = 1$	aşma yok
	$K_d = 0.1$	sürekli durum hatası yok

Grafik ve tablodaki sonuçlara göre, PID6'nın diğerlerine göre daha iyi çalıştığı görülmektedir. PID7 ve PID8'in tepe süreleri daha kısa olmasına rağmen oturma sürelerinin daha uzun olduğu ve yüksek oranda aşmaya neden olduğu görülmektedir. PID9'da aşma olmamasına rağmen PID6'ya göre oturma süresi daha uzun sürmüştür. Bu sonuçlara göre PID6 ve PID9 arasında tekrar karşılaştırma yapmak amacıyla belirli bir aralık içerisinde eşit olasılıklı rastgele değerler üreten bir giriş verildiğinde sisteme olan etkileri incelenmiştir ve Şekil 85'te sunulmuştur.




Şekil 85. PID6 ve PID9'un rastgele giriş tepkisinin karşılaştırılması

Başlangıçta PID9'un aşma yaptığı, PID6'nın aşma yapmadığı ancak zamanla PID9'un sisteme daha iyi uyum sağladığı ve PID6'nın aşma yapmaya eğilimli olduğu görülmektedir. Bu durumda PID9'un farklı durumlara daha iyi uyum sağladığını söyleyebiliriz. Şekil 86'da bir sonraki çalışma için seçilen PID denetleyici blok diyagramı gösterilmiştir.



Şekil 86. PID9'un Simulink blok diyagramı


2.1.3 bölümünde gerçekleştirilen çalışmanın bir parçası olarak, test verisi üzerinde eğitilmiş bir model kullanılarak tahminler yapılmıştır. Bu tahminler, bir PID denetleyicisinin hedeflerini belirlemek için kullanılmıştır. Ardından, her tahmin için bir PID denetleyici uygulanmıştır. Bu PID denetleyici, tahmin edilen etiketlerin her biri için bir hedef durum belirler ve bu hedefe ulaşmak için PID algoritmasını kullanarak bir kontrol sinyali üretir. Son olarak, bu kontrol sinyalleri, mevcut durumu güncellemek için kullanılmıştır. Her adımda, hedef durum ve mevcut durum arasındaki farkı hesaplamak için bir PID kontrol döngüsü çalıştırılmıştır. CNN eğitime entegre edilen PID, tahminlerden elde edilen verileri işlemek için kullanılan bir kontrol mekanizması olarak düşünülmelidir. Hedef takibi için derin öğrenme ile elde edilen sonuçları değerlendirmek üzere Simulink'te PID9 denetleyicisi kullanılmıştır. Şekil 87'de derin öğrenme tabanlı PID denetleyicisinin sonuçları verilmiştir.



Şekil 87. CNN ile eğitilmiş bir modelin çıkışının PID denetleyici takibi


2.2.2. Bulanık Mantık Denetleyici Simulasyon Sonuçları

Bulanık mantık denetleyicili bir sistemin girişine birim basamak tepkisi uyguladığımızda sistem çıkışında aşmanın olmadığı ve yerleşme süresini %2 toleranslı olarak kabul ettiğimizde, 6,0213 ms'de 0.98'e karşılık gelen referansı yakaladığı Şekil 88'de görülmektedir.



Şekil 88. Bulanık mantık denetleyicili sistemin birim basamak tepkisi


Şekil 89'da görüldüğü gibi PID'ye uyguladığımız rastgele girişi BMD'ye uyguladığımızda girişi aşmasız bir şekilde takip ediyor; ancak programın koşma süresi çok uzuyor. Bu da protez ayak kontrolü açısından istenmeyen bir durum.




Şekil 89. Bulanık mantık denetleyicili sistemin rastgele giriş tepkisi

2.2.3. Yapay Sinir Ağları Simulasyon Sonuçları

Simulinkte oluşturduğum sinir ağı modelinde aktivasyon fonksiyonunu değiştirerek Şekil 90'da görüldüğü gibi sisteme etkisi incelenmiştir.




(a)



(b)

Şekil 90. Sinir ağında farklı aktivasyon fonksiyonlarının karşılaştırılması a) 1.08-1.18 ms aralığı b) 5.79-5.86 aralığı büyütülmüş hali


Şekiller incelendiğinde ‘elliot’ aktivasyon fonksiyonunun daha iyi performans gösterdiği görülmektedir. Şekil 91’de bu aktivasyon fonksiyonunu kullanarak yapılan çalışmada girişi 1.05 ms’de yakaladığı, ancak çok fazla gürültülü çıkış verdiği görülmektedir. Protez uygulamamızda tercih edilmeyen bir denetleyici olmuştur.



Şekil 91. Sinir ağıyla denetlenen sistemin birim basamak tepkesi

2.2.4. Kayan Kipli Denetleyici Simulasyon Sonuçları

Kayan kipli denetleyicili sistemin girişine birim basamak tepkesi uyguladığımızda sistem çıkışında aşmanın olmadığı ve yerleşme süresini %2 toleranslı olarak kabul ettiğimizde, çatırtıyı azaltmada signum fonksiyonu kullanıldığında 0,422 milisaniyede, tanh fonksiyonu kullanıldığında 0,435 ms’de ve yumuşak bir doyum fonksiyonu kullanıldığında 0,9609 ms’de 0.98’e karşılık gelen referansı yakaladığı görülmektedir. Signum fonksiyonu kısa sürede referansı yakalamasına rağmen toplam cevap verme süresi çok uzun olduğundan tercih edilmemiştir. Şekil 92’de görüldüğü gibi BMD’ye göre daha hızlı tepki verir; ancak çok gürültülü bir çıkış elde edilmektedir.



Şekil 92. Kayan kipli denetleyicili sistemin birim basamak tepkisi

2.2.4.1. Sistem Tabanlı Kayan Kipli Denetleyici Tasarımı

Sistemi (76) eşitliğindeki gibi varsayalım:

$$M_t \ddot{\theta}(t) = u(t) + d(t) \quad (76)$$

Bu eşitlikte, M_t lineer motor kütlesi, $\ddot{\theta}(t)$ açış sinyali, $u(t)$ kontrol girişi ve $d(t)$ bozucu giriş, $|d(t)| \leq \beta$ ve β anahtarlama kazancıdır. Kararlı bir dinamik sistem için faz uzayında $s=0$ denklemi kayma yüzeyini tanımlar. Buna göre kayma mod fonksiyonu (77) eşitliğindeki gibi seçilmelidir.

$$s(t) = \lambda e(t) + \dot{e}(t) \quad (77)$$

$\theta(t)$ gerçek konum ve $\theta_d(t)$ istenen konum olmak üzere izleme hatası $e(t)$ ve onun türevi $\dot{e}(t)$ eşitlik (78) ve (79)'da verilmiştir.

$$e(t) = \theta(t) - \theta_d(t) \quad (78)$$

$$\dot{e}(t) = \dot{\theta}(t) - \dot{\theta}_d(t) \quad (79)$$

Hurwitz koşulu $\lambda > 0$ 'ı sağlamalıdır. $s(t) = 0$ durumunda yüzey birinci dereceden doğrusal zamanla değişmeyen sistem $\dot{e} = -\lambda e$ 'ye karşılık gelir. Bant genişliği olarak adlandırılan λ , denetleyici ve sistemin performansını ilgilendiren pozitif bir sabittir. Zamanla konum ve hız izleme hatası λ değeriyle birlikte üstel olarak sifıra yönelecektir:

$$e(t) = e(0)e^{-\lambda t} \quad t \rightarrow \infty$$

Buna göre, $\dot{s}(t) = \lambda \dot{e}(t) + \ddot{e}(t) = \lambda \dot{e}(t) + \ddot{\theta}(t) - \ddot{\theta}_d(t)$ eşitliği yazılabilir. Buradan,

$$\dot{s}(t) = \lambda \dot{e}(t) + \frac{1}{M_t}(u + d(t)) - \ddot{\theta}_d(t) \quad (80)$$

$$s\dot{s} = s(\lambda \dot{e} + \frac{1}{M_t}(u + d(t)) - \ddot{\theta}_d(t)) \quad (81)$$

$\beta > 0$ ve $k > 0$ için $\dot{s} = -\beta \operatorname{sgn} s - ks$ üstel erişim kanunu olmak üzere, $s\dot{s} < 0$ koşulunu sağlayan kayan kipli denetleyici aşağıdaki gibi tasarlanır:

$$u(t) = M_t(-\lambda \dot{e} + \ddot{\theta}_d - \frac{1}{M_t}(ks + \beta \operatorname{sgn} s)) \quad (82)$$


Lyapunov fonksiyonu $V = \frac{1}{2}s^2$ için;

$$\dot{V} = s\dot{s} = s(-ks - \frac{1}{M_t}\beta \operatorname{sgn} s + \frac{1}{M_t}d(t)) = \frac{1}{M_t}(-ks - \beta|s| + sd(t)) \leq -\frac{1}{M_t}ks^2 \quad (83)$$

$$\dot{V} = -\frac{2}{M_t}kV \quad (84)$$


$$V(t) \leq e^{-\frac{2}{M_t}(t-t_0)} V(t_0) \quad (85)$$

$k > 0$ için $V(t)$, k değeriyle üstel olarak sıfıra yönelecektir [182]. Şekil 93'te tasarlanan kayan kipli denetleyici kullanılarak elde edilen sonuçlar gösterilmiştir.




Şekil 93. $\lambda = 1200$, $\beta = 100$ ve $k = 40$ ve $d(t) = \sin t$ değerleri için kayan kipli denetleyici konum takibi

Denetleyicinin ne kadar iyi çalıştığını gösterebilmek amacıyla 50 saniyelik hareketin 5 saniyelik kısmının takibi Şekil 94'te gösterilmiştir.




(a)



(b)

Şekil 94. Kayan kipli denetleyicinin Denek 1'in dorsifleksiyon hareketi y eksen konumunu takibi a) 5sn'lik hareket b) 0.5 s'lik kısmın büyütülmüş halı




Şekil 95. Denek 1'in dorsifleksiyon hareketi için kontrol işareti


Kayma yüzeyinden çıkılması durumunda, hızlı ve sürekli yön değiştiren bir kontrol işareti üretilir. Bu hızlı ve kesintisiz yön değişimleri, sistemdeki geri beslemeyi sağlamak ve istenmeyen durumu düzeltmek için kullanılır. Ancak, bu sürekli ve sık yön değişimleri, bir "çatırtı" efekti yaratabilir. Çatırtı, kontrol sinyalinin ani ve keskin değişimleriyle karakterize edilen bir durumdur. 2. tasarımda çatırtıyı azaltmak amacıyla anahtarlama fonksiyonu $\beta \tan\left(\frac{s}{\varepsilon}\right)$ kullanılır ve kontrol işareti eşitlikteki gibi elde edilir.

$$u(t) = M_t(-\lambda \dot{e} + \ddot{\theta}_d - ks) - \beta \tan\left(\frac{s}{\varepsilon}\right) \quad (86)$$


Anahtarlama fonksiyonu olarak $\beta \tan\left(\frac{s}{\varepsilon}\right)$ ve referans olarak sinüs fonksiyonu verildiğinde Şekil 96'daki sonuçlar elde edilmiştir.



Şekil 96. $\lambda = 1200$, $\beta = 100$, $k = 200$, $d(t) = \sin t$, $\varepsilon = 0.01$ için sinüs takibi



(a)




(b)

Şekil 97. Farklı erişim yasalarına göre KKD'nin verdiği tepki a) 50s'lik sinüs takibi b) büyütülmüş hali

Yapılan tasarıma göre signum fonksiyonlu eksponansiyel erişim kanununa göre tasarladığımız KKD tanh fonksiyonuna dayalı KKD'ye göre daha iyi performans gösterdi. İdealde tanh fonksiyonu çatırtıyı azaltmak için kullanılsa da simülasyonda farklı bir sonuç elde edilmiştir.

2.2.5. Uyarlanabilir (Adaptif) Denetleyici Simulasyon Sonuçları

Burada hem denetleyici hem referans model hem de uyarlama mekanizması tasarımı yapılmıştır. Denetleyici olarak PID, BMD ve YSA modelleri eklenmiş ve hibrit modeller için sonuçlar elde edilmiştir. Ancak, adaptif BMD modeli tepki verme konusunda oldukça yavaş kalmaktadır. Adaptif YSA modeli başlangıçta iyi çalışsa da, yapılan çalışmada 30 saniye sonra takibi bırakıp kötü bir sonuç verdiği gözlemlenmiştir. Adaptif PID'nin sonuçları Şekil 98'de sunulmuştur. Sonraki aşamada sistem tabanlı adaptif kayan kipli denetleyici tasarlanmıştır.



Şekil 98. Adaptif PID konum takibi

2.2.5.1. Sistem Tabanlı Adaptif Kayan Kipli Denetleyici Tasarımı

x_1 ve x_2 konum ve hız, M_t motor kütlesi ve pozitif bir sabit, $|d(t)| \leq D$ ile sınırlı belirsiz bir bozucu giriş olmak üzere;

$$\frac{dx_1}{dt} = x_2 \quad (87)$$

$$M_t \frac{dx_2}{dt} = u(t) + d(t) \quad (88)$$

şeklinde tanımlanan bilinmeyen bir sistemin kayma değişkeni ve konum izleme hatası eşitlikte verilmiştir.

$$s = \dot{e} + \lambda e = x_2 - q \quad (89)$$

$$q = \dot{x}_d - \lambda e \quad (90)$$

$$e = x_1 - x_d \quad (91)$$

$$s = \dot{x}_2 - q \quad (92)$$


Adaptif kayan kipli denetleyicinin kontrol işareti, adaptif kompanzasyon bileşeni u_a , geri besleme bileşeni u_{s1} ve sağlamlık bileşeni u_{s2} 'nin toplamıdır. $k_s > 0$, $\beta > 0$ ve $\varepsilon > 0$ olmak üzere;

$$u = u_a + u_{s1} + u_{s2} \quad (93)$$


$$u_a = \hat{\theta} \dot{q}, \quad u_{s1} = -k_s s, \quad u_{s2} = -\beta \tanh\left(\frac{s}{\varepsilon}\right) \quad (94)$$

$$u = \hat{\theta} \dot{q} - k_s s - \beta \tanh\left(\frac{s}{\varepsilon}\right) \quad (95)$$

Burada adaptif yasa $\gamma > 0$ olmak üzere $\dot{\hat{\theta}} = -\gamma \dot{q} s$ ile ifade edilir.



(a)



(b)

Şekil 99. Adaptif KKD konum takibi a) 1s'lik sinüs dalgası takibi b) büyütülmüş hali

Tasarlanan Adaptif KKD modelinin konum takibi performansının diğer denetleyicilere göre daha iyi olduğu, referansı anında takip ettiği ve kayan kipli denetleyicide yaşanan çatırtı sorununun ortadan kalktığı görülmektedir.

3. SONUÇLAR

Bu çalışma, protez ayak tasarımı ve kontrolü alanında çeşitli tekniklerin uygulanmasıyla ilgili kapsamlı bir araştırmayı kapsamaktadır. Ayağın biyomekanik analizi, yürüyüş analizi ve kinematik analiz gibi ön çalışmalar yapılarak, doğal ve etkili bir yürüyüş hareketinin gerçekleştirilmesi için gerekli parametreler belirlenmiştir. Ayrıca, ileri kinematik ve ters kinematik hesaplamaları yapılarak, protez ayak hareketlerinin daha doğru bir şekilde modellenebilmesi için gerekli adımlar atılmıştır.

Mekanik tasarım aşamasında, protez ayak için sağlam, hafif ve esnek bir yapı oluşturmak için çeşitli malzemeler ve tasarım teknikleri üzerinde durulmuştur. Kinematik analiz sonuçları, mekanik tasarımın optimize edilmesine yardımcı olmuş ve daha doğal bir hareket sağlamak için tasarım parametrelerinin belirlenmesine katkı sağlamıştır. Özellikle, protez ayak hareketlerini gerçekleştirebilen ve sağlıklı bir ayak bileği biyomekaniği temsil eden ayak bileği eklem kinematik özelliklerini içeren bir tasarım hedeflenmiştir.

Ayak hareketlerinin sınıflandırılması için hem makine öğrenme teknikleri hem de derin öğrenme yöntemleri kullanılmıştır. Geliştirilen derin öğrenme yaklaşımının, hareketlerin daha doğru ve etkili bir şekilde sınıflandırılmasına yardımcı olduğu gözlemlenmiştir. Ayak hareketlerinin sınıflandırılması amacıyla toplanan veriler, kişisel protez ayak tasarımının oluşturulmasına olanak sağlamaktadır. Bu yaklaşım, her bireyin hareket desenlerini ve ihtiyaçlarını dikkate alarak özelleştirilmiş bir protez ayak geliştirmeyi amaçlamaktadır. Veri seti, farklı bireylerin gerçek zamanlı olarak kaydedilmiş ayak hareketlerini içermektedir. Her bir bireyin özgün hareket desenlerini ve tercihlerini yansıtmak üzere genişletilmiş ve çeşitlendirilmiştir. Sonuç olarak, bu veri tabanlı yaklaşım, her bireyin ihtiyaçlarına uygun olarak özelleştirilmiş protez ayak tasarımlarının oluşturulmasını sağlar. Her bireyin benzersiz hareket desenleri ve tercihleri dikkate alınarak, protez ayaklar daha uyumlu ve işlevsel hale getirilir. Bu da kullanıcıların daha rahat ve etkin bir şekilde hareket etmelerine olanak tanırken, yaşam kalitelerini artırır.

Kontrol stratejileri olarak, PID, bulanık mantık, yapay sinir ağları, kayan kipli denetleyici, uyarlanabilir (adaptif) denetleyici gibi çeşitli yöntemler denenmiştir. Sistem tabanlı KKD ve sistem tabanlı adaptif KKD tasarımları geliştirilmiştir. Yapılan simülasyonlar sonucunda, en iyi sonuçların adaptif kayan kipli denetleyicinin kullanımıyla elde edildiği görülmüştür. Adaptif kayan kipli denetleyici, protez ayak hareketlerini daha

hassas bir şekilde kontrol edebilirken, kullanıcının dinamik ihtiyaçlarına da uyum sağlayabilme özelliğiyle dikkat çekmektedir. Bu çalışma, protez ayak teknolojisinin gelişimi için önemli bir katkı sağlamıştır. Gelecekte, daha fazla deneysel çalışma ve kullanıcı geri bildirimleriyle, adaptif kayan kipli denetleyicinin protez ayak kullanıcılarının yaşam kalitesini artırmada nasıl daha etkili bir şekilde kullanılabileceği daha da araştırılmalıdır.



4. ÖNERİLER

Bu tez kapsamında, protez ayak teknolojisinin geliştirilmesi için çeşitli öneriler öne çıkmaktadır. İlk olarak, geliştirilen protez ayakların klinik denemelerle test edilmesi ve kullanıcı geri bildirimlerinin alınması, tasarımın iyileştirilmesi ve optimize edilmesi açısından önemlidir. Ayrıca, protez ayak tasarımının fonksiyonel çeşitliliğinin artırılması, farklı aktiviteler için optimize edilmesi ve kullanıcıların spor yapma, koşma, tırmanma gibi farklı hareketlilik ihtiyaçlarını karşılamak için araştırılmalıdır.

Malzeme ve üretim teknolojilerinin geliştirilmesi de önemlidir; daha hafif, dayanıklı ve maliyet etkin malzemelerin kullanılması, 3D baskı gibi yenilikçi üretim teknolojilerinin değerlendirilmesi önerilmektedir.

Ayrıca, protez ayaklardaki enerji tüketimi ve batarya ömrünün artırılması için yeni teknolojilerin incelenmesi gerekmektedir. Kullanıcı arayüzleri ve kontrol sistemlerinin geliştirilmesi, protez ayakları daha kolay ve doğal bir şekilde kontrol etmeyi sağlayacak teknolojilerin araştırılmasını teşvik etmek önemlidir. Veri analizi ve yapay zeka tekniklerinin kullanılmasıyla daha akıllı ve kişiselleştirilmiş protez ayakların tasarlanması hedeflenmektedir.

Sürdürülebilirlik ve geri dönüşüm konularında da çalışmalar yapılmalı, protez ayakların üretiminde ve kullanımında sürdürülebilir malzemelerin tercih edilmesi ve geri dönüşümün teşvik edilmesi önemlidir. Son olarak, endüstriyel partnerlerle iş birliklerinin güçlendirilmesi ve akademik kurumlarla ortak araştırma projelerinin yürütülmesi, protez ayak teknolojisinin hızla ilerlemesini sağlayabilir.

Ayrıca, EMG (Elektromiyografi) ve EEG (Elektroensefalografi) gibi yöntemlerle protez ayakların kontrol edilmesi de araştırılabilir ve bu yöntemlerin entegrasyonu ile kullanıcıların daha doğal ve etkin bir şekilde protez ayaklarını kullanmaları sağlanabilir. Bu öneriler, protez ayak teknolojisinin geliştirilmesi ve ampute bireylerin yaşam kalitesinin artırılması için önemli fırsatlar sunmaktadır.

5. KAYNAKLAR

1. Ajibade, A., Akinniyi, O.T. & Okoye, C.S. (2013). Indications and Complications of Major Limb Amputations in Kano, Nigeria. *Ghana Medical Journal*; 47(4), 185-188.
2. Batzianoulis, I., Krausz, N. E., Simon, A. M., Hargrove, L., & Billard, A. (2018). Decoding the grasping intention from electromyography during reaching motions, *Journal of Neuro- Engineering and Rehabilitation*, 15(1), 57.
3. Ziegler-Graham, K., MacKenzie, E. J., Ephraim, P. L., Travison, T. G., & Brookmeyer, R. (2008). Estimating the prevalence of limb loss in the United States: 2005 to 2050, *Archives Physical Medicine and Rehabilitation*, 89(3), 422-429.
4. Owings, M.F., & Kozak, L.J. (1998). Ambulatory and inpatient procedures in the United States, 1996. *Vital Health and Statistics* 13. (139):1-119.
5. Hyattsville, Md. (1998). *National Center for Health Statistics*, U.S. Dept. of Health and Human Services, Centers for Disease Control and Prevention.
6. Spoden, M., Nimptsch, U., & Mansky, T. (2019). Amputation rates of the lower limb by amputation level - observational study using German national hospital discharge data from 2005-2015. *BMC Health Services Research*, 19(8), 1-9.
7. Eilenberg, M., Hartmut, G., & Hugh, H. (2010). Control of a powered anklefoot prosthesis based on a neuromuscular model, *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 18, 164–173.
8. McDermott, M. M., Greenland, P., & Liu, K. (2001). Leg symptoms in peripheral arterial disease: associated clinical characteristics and functional impairment. *JAMA*, 286(13), 1599-1606.
9. Akdoğan E., & Demir H. (2012). *Rehabilitation Technologies : Biomechatronics Point of View*. A Roadmap of Biomedical Engineers and Milestones, Intech.
10. Yang, D., Yang, W., Huang, Q., & Liu, H. (2017). Classification of multiple finger motions during dynamic upper limb movements. *IEEE Journal of Biomedical and Health Informatics*, 21(1): 134–141.
11. Alderson, S. W. (1954). *The electric arm*. Human Limbs and Their Substitutes, McGraw-Hill, New York.

12. Ng, S.K., & Chizeck, H.J. (1997). Fuzzy model identification for classification of gait events in paraplegics. *IEEE Transactions on Fuzzy Systems*, 5, 536-544.
13. Pappas, I. P., Popovic, M. R., Keller, T., Dietz, V., & Morari, M. A. (2001) reliable gait phase detection system. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 9(2), 113-125.
14. Palmer, M.L. (2002). Sagittal plane characterization of normal human ankle function across a range of walking gait speeds, Massachusetts Institute of Technology, Doctoral dissertation, Cambridge, MA, USA.
15. Schache, A.G., Blanch, P.D., Dorn, T.W., Brown, N.A., Rosemond, D., & Pandy, M.G. (2011). Effect of running speed on lower limb joint kinetics. *Medicine & Science in Sports & Exercise*, Jul;43(7):1260-1271.
16. Luo, G., & Stefanyshyn, D. (2012). Limb force and non-sagittal plane joint moments during maximum-effort curve sprint running in humans. *Journal of Experimental Biology*, 215(24), 4314-4321.
17. Mantyjarvi, J., Lindholm, M., Vildjiounaite, E., Makela, S.M., & Ailisto, H.A. (2005). Identifying users of portable devices from gait pattern with accelerometers. *IEEE International Conference on Acoustics, Speech, and Signal Processing*, 2, 973–976, Philadelphia.
18. Rong, L., Zhiguo, D., Jianzhong, Z. & Ming, L. (2007). Identification of Individual Walking Patterns Using Gait Acceleration. *1st International Conference on Bioinformatics and Biomedical Engineering*, 543-546, Wuhan.
19. Rong, L., Jianzhong, Z., Ming, L., & Xiangfeng, H. (2007). A Wearable Acceleration Sensor System for Gait Recognition. *2nd IEEE Conference on Industrial Electronics and Applications*, 2654-2659, Harbin.
20. Trung, N.T., Makihara, Y., Nagahara, H., Mukaigawa, Y., & Yagi, Y. (2012). Performance evaluation of gait recognition using the largest inertial sensor-based gait database. *5th IAPR International Conference on Biometrics (ICB)*. 360–366, New Delhi.
21. Ngo, T.T., Makihara, Y., Nagahara, H. Mukaigawa, Y., & Yagi, Y. (2014). The largest inertial sensor-based gait database and performance evaluation of gait-based personal authentication. *Pattern Recognition*, 47(1), 228–237.
22. Seel, T., Raisch, J., & Schauer, T. (2014). IMU-based Joint Angle Measurement for Gait Analysis. *Sensors*, 14(4), 6891-6909.
23. San-Segundo, R., Montero, J. M., Barra-Chicote, R., Fernández, F., & Pardo, J. M. (2016). Feature extraction from smartphones inertial signals for human activity segmentation, *Signal Processing*, 120, 359-372.

24. Pärkkä, J., Ermes, M., Korpipää, P., Mäntylä, J., Peltola, J., & Korhonen I. (2006). Activity classification using realistic data from wearable sensors. *IEEE Transactions on Information Technology in Biomedicine*, 10(1), 119-128.
25. Wu, D., Wang, Z.L., Chen, Y., & Zhao, H.Y. (2016). Mixed kernel based weighted extreme learning machine for inertial sensor based human activity recognition with imbalanced dataset. *Neurocomputing*, 190, 35-49.
26. Quraishi, M. A., Ishak, A. J., Ahmad, S., Hassan, M. K., Qurishi, M. A., Ghapanchizadeh, H., & Alamri, A. (2016). Classification of ankle joint movements based on surface electromyography signals for rehabilitatin robot applications. *Medical and Biological Engineering & Computing*, 55(5), 747-758.
27. Zebin, T., Scully, P.J., & Ozanyan, K.B. (2016). Human activity recognition with inertial sensors using deep learning approach. *IEEE SENSORS*, 1-3, Orlando.
28. Fullerton, E., Heller, B., & Munoz-Organero, M. (2017). Recognizing human activity in free-living using multiple body-worn accelerometers, *IEEE Sensors Journal*, 17(16), 5290-5297.
29. Bastas, G., Fleck, J.J., Peters, R.A., & Zelik, K.E. (2018). IMU-based gait analysis in lower limb prosthesis users: Comparison of step demarcation algorithms. *Gait & Posture*, 64, 30-37.
30. Li, H., Derrode, S., & Pieczynski, W. (2019). An adaptive and on-line IMU-based locomotion activity classification method using a triplet Markov model. *Neurocomputing*, 362, 94-105.
31. Banos, O., Garcia, R., Holgado-Terriza, J. A., Damas, M., Pomares, H., Rojas, I., Saez, A., & Villalonga, C. (2014). mHealthDroid: A novel framework for agile development of mobile health applications. *International Workshop on Ambient Assisted Living and Daily Activities*, 91-98, Belfast.
32. Uddin, M.Z., & Hassan, M. M. (2019). Activity recognition for cognitive assistance using body sensors data and deep convolutional neural network. *IEEE Sensors Journal*, 19, 8413-8419.
33. Gao, F., Liu, G., Liang, F., & Liao, W-H. (2020). IMU-based locomotion mode identification for transtibial prostheses, orthoses, and exoskeletons. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 28(6), 1334-1343.
34. Khera, P., Kumar, N., & Ahuja, P. (2020). Machine Learning based Electromyography Signal Classification Feature Selection for Foot Movements. *Journal of Scientific& Industrial Research*, 79(11), 1011-1016.

35. Krishnaprabha, K.K., & Raju, C.K. (2020). Predicting human activity from mobile sensor data using CNN architecture. *2020 Advanced Computing and Communication Technologies for High Performance Applications (ACCTHPA)*, 206-210, Cochin.
36. Erdas, Ç.B., & Güney, S. (2021). Human activity recognition by using different deep learning approaches for wearable sensors. *Neural Processing Letters*, 53, 1795–1809.
37. Anguita, D., Ghio, A., Oneto, L., Parra, X., & Reyes-Ortiz, J.L. (2013). A Public Domain Dataset for Human Activity Recognition using Smartphones. *The European Symposium on Artificial Neural Networks*, 437-442.
38. Reiss, A., & Stricker, D. (2012). Introducing a new benchmarked dataset for activity monitoring. *16th International Symposium on Wearable Computers*, 108–109.
39. Wan, S., Qi, L., Xu, X., Tong, C., & Gu, Z. (2020). Deep Learning Models for Real-Time Human Activity Recognition With Smartphones. *Mobile Networks Applications*, 25(2), 743–755.
40. Mutegeki, R., & Han, D.S. (2020). A CNN-LSTM approach to human activity recognition. *2020 International Conference on Artificial Intelligence in Information and Communication*, 362-366, Fukuoka.
41. Roggen, D., Calatroni, A., Rossi, M., Holleczeck, T., Förster, K., Tröster, G., Lukowicz, P., Bannach, D., Pirkel, G., Ferscha, A., Doppler, J., Holzmann, C., Kurz, M., Holl, G., Chavarriaga, R., Sagha, H., Bayati, H., Creatura, M., & Millan, J. D. R. (2010). Collecting complex activity datasets in highly rich networked sensor environments. *Seventh International Conference on Networked Sensing Systems (INSS)*, 233-240, Kassel.
42. Micucci, D., Mobilio, M., & Napoletano, P. (2017). *i Applied Sciences*, 7(10), 1101.
43. Huang, W., Zhang, L., Gao, W., Min, F., & He, J. (2021). Shallow Convolutional Neural Networks for Human Activity Recognition Using Wearable Sensors. *IEEE Transactions on Instrumentation and Measurement*, 70, 1–11.
44. Weiss, G. (2019). WISDM Smartphone and Smartwatch Activity and Biometrics Dataset . UCI Machine Learning Repository.
45. Challa, S. K., Kumar, A., & Semwal, V. B. (2022). A Multibranch CNN-BiLSTM Model for Human Activity Recognition Using Wearable Sensor Data. *International Journal of Computer Graphics*, 38(2), 4095–4109.

46. Chaobankoh, N., Jumphoo, T., Uthansakul, M. Phapatanaburi, K., Sindhupakorn, B., Rooppakhun, S., & Uthansakul, P. (2022). Lower Limb Motion Based Ankle Foot Movement Classification Using 2D-CNN. *Computers, Materials & Continua*, 73(1), 1269-1282.
47. Tang, Y., Zhang, L., Min, F., & He, J. (2023). Multiscale Deep Feature Learning for Human Activity Recognition Using Wearable Sensors. *IEEE Transactions on Industrial Electronics*, 70(2), 2106–2116.
48. Hysenllari, E., Ottenbacher, J., and McLennan, D. (2022). Validation of Human Activity Recognition Using Aconvolutional Neural Network on Accelerometer and Gyroscope Data. *German Journal Exercise and Sport Research*, 52(2), 248–252.
49. Banos, O., Toth, M., & Amft O. (2014). REALDISP Activity Recognition Dataset. UCI Machine Learning Repository.
50. Baloch, Z., Shaikh, F. K., & Unar. (2022). CNN-LSTM-Based Late Sensor Fusion for Human Activity Recognition in Big Data Networks, *Wireless Communications and Mobile Computing*, 55, 1-16.
51. Vakacherla, S.S., Kantharaju, P., Mevada, M., & Kim, M. (2023). Single Accelerometer to Recognize Human Activities Using Neural Networks, *Journal of Biomechanical Engineering*, 145(6), 1-11.
52. Vu, H.T.T., Cao, H-L., Dong, D., Verstraten, T., Greerrooms, J., & Vanderborght, B. (2022). Comparison of machine learning and deep learning-based methods for locomotion mode recognition using a single inertial measurement unit. *Frontier in Neurorobotics*, 16, 1-15.
53. Başbuğ, R. M. (1995). *Bulanık Adaptif Kayan Kipli Robot Kontrolü*, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, İstanbul.
54. M. Topalbekiroğlu, M. (1996). *Control of Robotic Systems by Using Adaptive Control and Learning Methods*. Gaziantep Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Gaziantep.
55. Hacıoğlu, Y. (2004). *Bir Robotun Bulanık Mantıklı Kayan Kipli Kontrolü*, İstanbul Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul.
56. Klute, G.K., Czerniecki, J., & Hannaford, B. (1998). Development of Powered Prosthetic Lower Limb. *Proceedings of the First National Meeting*, Veterans Affairs Rehabilitation Research and Development Service, Washington.
57. Versluys, R., Beyl, P., Van Damme, M., Desomer, A., Van Ham, R., & Lefeber, D. (2009). Prosthetic feet: State-of-the-art review and the importance of mimicking human ankle–foot biomechanics. *Disability and Rehabilitation: Assistive Technology*, 4(2), 65-75.

58. Bellman, R. D., Holgate, M. A., & Sugar, T. G. (2008). SPARKy 3: Design of an active robotic ankle prosthesis with two actuated degrees of freedom using regenerative kinetics. *2nd IEEE RAS & EMBS International Conference on Biomedical Robotics and Biomechatronics*, 511-516, Scottsdale.
59. Hitt, J. K., Sugar, T. G., Holgate, M., & Bellman, R. (2010). An active foot ankle prosthesis with biomechanical energy regeneration. *ASME Journal of Medical Devices*, 4(1), 011003.
60. Au, S. K., Weber, J. & Herr, H. (2009). Powered Ankle-Foot Prosthesis Improves Walking Metabolic Economy. *IEEE Transactions on Robotics*, 25(1), 51-66.
61. Zhu, J., Wang, Q., & Wang, L. (2010). PANTOE 1: Biomechanical design of powered ankle-foot prosthesis with compliant joints and segmented foot. *IEEE/ASME International Conference on Advanced Intelligent Mechatronics*, 31-36, Montreal.
62. Lawson, B.E., Varol, H.A., Huff, A., Erdemir, E., & Goldfarb, M. (2013). Control of stair ascent and descent with a powered transfemoral prosthesis. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 21(3), 466-473.
63. Ficanha, E.M., Rastgaar, M. & Kaufman, K.R. (2014). A two-axis cable-driven ankle-foot mechanism. *Robotics and Biomimetics*, 1, 1-13.
64. Collins, S.H., & Kuo, A.D. (2010). Recycling Energy to Restore Impaired Ankle Function during Human Walking. *PLOS ONE*, 5(2), 1-6.
65. Collins, S.H., Kim, M., Chen, T., & Chen, T. (2015). An ankle-foot prosthesis emulator with control of plantarflexion and inversion-eversion torque. *IEEE International Conference on Robotics and Automation (ICRA)*, 1210–1216, Seattle.
66. Hatze H. (1974). Letter: The meaning of the term "biomechanics". *Journal of Biomechanics*, 7(2), 189-190.
67. Moore, K. L., Dalley, A. F. & Agur, A. M. (2013). *Clinically Oriented Anatomy*. Lippincott Williams & Wilkins.
68. Cronin, N. J., Avela, J., Finni, T., & Peltonen, J. (2013). Differences in contractile behaviour between the soleus and medial gastrocnemius muscles during human walking. *The Journal of Experimental Biology*, 216(5), 909–914.
69. Lundberg, A., Svensson, O.K., Németh, G., Selvik, G. (1989). The axis of rotation of the ankle joint. *Journal of Bone & Joint Surgery*, 71(1), 94-99.

70. Robertson, G., Caldwell, G., Hamill, J., Kamen, G. & Whittlesey, S. (2013). *Research Methods in Biomechanics*, Human Kinetics Publishers.
71. Valmassy, R. L. (1996). *Clinical Biomechanics of the Lower Extremities*, Mosby, St. Louis.
72. URL-1. (2022, Ekim 10).
Bacak Kemikleri: <https://theskeletalsystem.org/tr/bacak-kemikleri.html>
adresinden alınmıştır.
73. Chan, C.W., & Rudins, A. (1994). Foot biomechanics during walking and running. *Mayo Clinic Proceedings*, 69(5), 448-461.
74. Aksu, A. (2022). *Ayak Kor Egzersizlerinin Adölesan Voleybol Oyuncularında Ayak Biyomekaniği, Denge ve Sportif Performans İle Yaralanma İnsidansı Üzerine Olan Etkinliğinin Araştırılması*, Yıldırım Beyazıt Üniversitesi, Sağlık Bilimleri Enstitüsü, Doktora Tezi, Ankara.
75. Yalçınsoy, E. (2010). *Beden Eğitimi ve Spor Yüksekokulu Öğrencilerinde Ayak Biyomekaniği ve Egzersizin Ayak Biyomekaniği Üzerine Etkisi*, Celal Bayar Üniversitesi, Tıp Fakültesi, Uzmanlık Tezi, Manisa.
76. Manganaro, D., Dollinger, B., Nezwak, T.A., & Sadiq, N.M. (2023). *Anatomy, Bony Pelvis and Lower Limb, Foot Joints*. StatPearls [Internet]. Treasure Island (FL), StatPearls Publishing.
77. Chan, C.W., & Rudins, A. (1994). Foot biomechanics during walking and running. *Mayo Clinic Proceedings*, 69(5), 448-461.
78. Önen, Ü. (2011). *İnsan Yürüyüşü Destekleyici Dış İskelet Tasarımı ve Kontrolü*, Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, Konya.
79. URL-2. (2023, Aralık 5).
Anatomik Düzlemler: <https://www.anatomi.gen.tr/anatomi-eksenler-ve-duzlemler.html>
adresinden alınmıştır.
80. Perry, J., & Burnfield, J.M. (1992). Gait Analysis: Normal and Pathological Function. *JAMA*, 268(22), 3257-3258.
81. Stauffer, R. N., Chao, E. Y., & Brewster, R. C. (1977). Force and motion analysis of the normal, diseased, and prosthetic ankle joint. *Clinical Orthopaedics and Related Research*, 127, 189-196.
82. Radcliffe, O.W., & Foort, J. (1961). *The patellar Tendon-Bearing Below Knee Prosthesis*, Dept. of Engineering, University of California, Berkeley.
83. URL-3. (2023, Ekim 15).
Yürüyüşün Fazları: <https://www.fizyoplatform.com/konu-yurume-mekanizmasi-fazlari-ve-asamaları-patolojik-yuruyusler.html>
adresinden alınmıştır.

84. Pfister, A., West, A. M., Bronner, S. & Noah J.A. (2014). Comparative abilities of Microsoft Kinect and Vicon 3D motion capture for gait analysis. *Journal of Medical Engineering and Technology*, 38(5), 274-280.
85. Blanc, Y., & Vadi, P. (1981). An inexpensive but durable foot-switch for telemetered locomotion studies. *Biotelemetry and Patient Monitoring*, 8(4), 240-245.
86. Chao, E.Y. (1980). Justification of triaxial goniometer for the measurement of joint rotation. *Journal of Biomechanics*, 13(12):989-1006.
87. Whittle, M. W. (1996). Clinical gait analysis: A review, *Human Movements Science*, 15(3), 369-387.
88. Garrison. F.H. (1929). *An introduction to the History of Medicine*. Philadelphia and London, W.B. Saunders Co.
89. Bresler, B. & Frankel, J.P. (1950). The Forces and Moments in the Leg During Level Walking. *Journal of Fluids Engineering*, 72(1), 27-36.
90. Steindler, A. (1953). A historical review of the studies and investigations made in relation to human gait. *Journal of Bone and Joint Surgery* 35-A(3), 540-542.
91. Amar, J. (1920). *The Human Motor*. New York, E.P. Dutton & Co..
92. Elftman, H. (1938). The measurement of the external force in walking. *Science*, 88(2276), 152-153.
93. Inman, V.T., Ralston, H.J., & Todd, F. (1981). *Human walking*. Baltimore, MD: Williams and Wilkins.
94. Benedetti, M.G., Beghi, E., De Tanti, A., Cappozzo, A., Basaglia, N., Cutti, A.G., Cereatti, A., Stagni, R., Verdini, F., Manca, M., Fantozzi, S., Mazzà, C., Camomilla, V., Campanini, I., Castagna, A., Cavazzuti, L., Del Maestro, M., Croce, U.D., Gasperi, M., Leo, T., Marchi, P., Petrarca, M., Piccinini, L., Rabuffetti, M., Ravaschio, A., Sawacha, Z., Spolaor, F., Tesio, L., Vannozzi, G., Visintin, I., & Ferrarin M. (2017). SIAMOC position paper on gait analysis in clinical practice: General requirements, methods and appropriateness. Results of an Italian Consensus Conference. *Gait Posture*, 58, 252-260.
95. Brodsky, J.W., Polo, F.E., Coleman, S.C., & Bruck, N. (2011). Changes in gait following the Scandinavian Total Ankle Replacement. *Journal of Bone and Joint Surgery*, 93(20), 1890-1896.
96. Novak, A.C., Mayich, J., Perry, S.D., Daniels, T.R., & Broadsky, J.W. (2014). Gait Analysis for Foot and Ankle Surgeons— Topical Review, Part 2: Approaches to Multisegment Modeling of the Foot. *Foot and Ankle International*, 35(2), 178-191.

97. Kaptı, A. O. (2001). *İnsan Alt Ekstremitelerinin İncelenmesi ve Aktif Dizüstü Protezi Tasarımı*, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, İstanbul.
98. Dempster, W. T., Gabel, W. C., & Felts, W. J. L. (1959). The Anthropometry of Manual Work Space for the Seated Subjects. *American Journal of Physical Antropology*, 17(4), 289–317.
99. URL-4. (2023, Ekim 17) Gastrocnemius ve Soleus kasları: <https://www.foot-pain-explored.com/gastrocnemius.html> adresinden alınmıştır.
100. Winter, D. A. (2009). *Biomechanics and Motor Control of Human Movement*. University of Waterloo, Waterloo, Ontario, Canada, John Wiley & Sons, Inc.
101. Bingül, Z., & Küçük, S. (2005). *Robot Tekniği-I*, Birsen Yayınevi.
102. Dokuzlu, S. (2015). 4 Serbestlik Dereceli Robot Kolu Kinematik Denklemlerinin Destek Vektör Makinası ile Çözümü. İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul.
103. Murray, R. M., Li, Z., & Sastry, S.S. (1994). *A Mathematical Introduction to Robotic Manipulation (1st ed.)*. CRC Press.
104. Siciliano, B., Sciavicco, L., Villani, L., & Oriolo, G. (2010). *Robotics Modelling, Planning and Control*. Springer Science & Business Media.
105. Küçük, S., Bingül, Z. (2004). *Robot Sistemlerinde Kinematik Yöntemlerin Karşılaştırılması*, Politeknik Dergisi, 7(2), 107-117.
106. Drexler, D. A. (2014). New Methods for Solving the Inverse Kinematics Problem of Serial Robot Manipulators. Budapest University of Technology and Economics Department of Control Engineering and Information Technology, In Partial Fulfillment of the Requirements for the Doctor of Philosophy, Budapest.
107. Fu, K.S., Gonzalez, R.C., & Lee, C.S.G. (1987). *Robotics: Control, Sensing, Vision and Intelligence*. McGraw-Hill Book Company.
108. Craig, J.J. (2004). *Introduction to Robotics: Mechanics and Control (3rd ed.)* Pearson Prentice Hall.
109. Spong, M.W., Hutchinson, S., & Vidyasagar, M. (2020). *Robot Modeling and Control 2nd Edition*, Wiley.
110. Zafer Bingül, Serdar Küçük, Robot Kinematiği, 2017, Umuttepe Yayınları.
111. Köker, R., Çakar, T. & Sari, Y. (2014). A Neural-Network Committee Machine Approach to the Inverse Kinematics Problem Solution of Robotic Manipulators. *Engineering with Computers*, 30, 641–649.

112. Güven, K. (2017). *İnsansı Robot Kontrolü için Operatör Hareketleri Algılama Sistemi*. Başkent Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Ankara.
113. Denavit, J., & Hartenberg, R. (1955). A Kinematic Notation for Lower Pair Mechanisms Based on Matrices. *ASME Journal of Applied Mechanics*, 77, 215-221.
114. Öztürk, M. (2014). Antropomorfik Robotların Dinamiği ve Adaptif Kontrol Uygulamaları: Matlab/Simulink Modelleme. İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul.
115. Uzuner, S., Akkuş, N., & Toz, M. (2020). 5-DOF serial robot manipulator design, application and inverse kinematic solution through analytical method and simple search technique. *Pamukkale University Journal of Engineering Sciences*, 26(2), 392-401.
116. Colborne, G.R., Naumann, S., Longmuir, P.E., & Berbrayer D. (1992). Analysis of mechanical and metabolic factors in the gait of congenital below knee amputees: A comparison of the SACH and Seattle feet. *American Journal of Physical Medicine&Rehabilitation*, 71(5), 272-278.
117. URL-5. (2023, Ekim 17) Roadflexion foot ve özellikleri: <https://www.roadrunnerfoot.com/product/roadflexionhp/> adresinden alınmıştır.
118. Green, C.W. & Paul, R.J.A. (1969). Application of DC linear machines as short-stroke and static actuators. *Proceedings of the Institution of Electrical Engineers*, 116(4), 597-604.
119. URL-6. (2023, Ekim 21) L16-P lineer motor Hız-Kuvvet ve Akım-Kuvvet grafiği: <https://www.actuonix.com/assets/images/datasheets/ActuonixL16Data sheet.pdf> adresinden alınmıştır.
120. URL-7. (2023, Ekim 21). Lineer Aktüatör Kontrol Kartı teknik özellikleri: <https://www.actuonix.com/assets/images/datasheets/ActuonixLACDatasheet.pdf> adresinden alınmıştır.
121. Peeraer, L., Aeyels, B., & Van der Perre, G. (1990). Development of EMG-based mode and intent recognition algorithms for a computer-controlled above-knee prosthesis. *Journal of Biomedical Engineering*, 12(3), 178-182.
122. Chen, B., Wang, Q., & Wang, L. (2015). Adaptive slope walking with a robotic transtibial prosthesis based on volitional EMG control. *IEEE/ASME Transactions on Mechatronics*, 20(5), 2146-2157.
123. Luu, T.P., Brantley, J.A., Nakagome, S., Zhu, F., & Contreras-Vidal, J.L.(2017). Electro cortical correlates of human level-ground, slope, and stair walking. *PLoS ONE*, 12(11), 1-15.

124. URL-8. (2024, Ocak 4). LSM9DS1: <https://www.sparkfun.com/products/retired/13284> adresinden alınmıştır.
125. Oz, M.N., Budak, S., Kurnaz, E., Durdu, A. (2022). Orientation Determination in IMU Sensor with Complementary Filter. *Turkish Journal of Forecasting*, 6(1), 34-39.
126. URL- 9. (2024, Ocak 4). LSM9DS1 datasheet: <https://www.st.com/en/mems-and-sensors/lsm9ds1.html> adresinden alınmıştır.
127. Aydin Fandakli, S., & Aydemir, O. (2017). A fast and highly accurate EMG signal classification approach for multifunctional prosthetic fingers control. *40th International Conference on Telecommunications and Signal Processing (TSP)*, 395-398.
128. Safavian, S. R., & Landgrebe, D.A. (1991). A survey of decision tree classifier methodology. *IEEE Transactions on Systems, Man and Cybernetics*, 21(3), 660-674.
129. Dev, V.A., Eden, M.R. (2019). Gradient Boosted Decision Trees for Lithology Classification. *Computer Aided Chemical Engineering*, 47, 113-118.
130. MTech, S. M., Rajput, D. S. (2019). Nonlinear Decision Tree Regression. *Deep Learning and Parallel Computing Environment for Bioengineering Systems*, 153-164.
131. Li, C. (2014). *Fisher Linear Discriminant Analysis*.
132. Tharwat, A., Gaber, T., Ibrahim, A., & Hassanien, A.E. (2017). Linear discriminant analysis: A detailed tutorial. *AI Communications*; 30(2), 169-190.
133. McLachlan, G., (2004). *Discriminant analysis and statistical pattern recognition*. New York, John Wiley & Sons.
134. Stanimirova, I., Daszyowski, M., Walczak B. (2013). Chapter 8-Robust methods in analysis of multivariate food chemistry data. *Data Handling in Science and Technology*, 28, 315-340.
135. Vaibhaw, J.S., & Pattnaik, P.K. (2020). Chapter 2- Brain- computer interfaces and their applications. *An Industrial IoT Approach for Pharmaceutical Industry Growth*, 31-54.
136. Witten, I. H., Frank, E., Hall, M. A., & Pal, C. J. (2017). *Data Mining Practical Machine Learning Tools and Techniques 4th Edition*, Elsevier.
137. Fisher, R.A. (1936) The Use of Multiple Measurements in Taxonomic Problems. *Annals of Eugenics*, 7, 179-188.

138. Misra, S., & Li, H. (2020). Chapter 9- Noninvasive fracture characterization based on the classification on sonic wave travel times. *Machine Learning for Subsurface Characterization*, 243-287.
139. Mushtaq, M. S., & Mellouk, A. (2017). 2-Methodologies for Subjective Video Streaming QoE Assessment. *Quality of Experience Paradigm in Multimedia Services*, 27-57.
140. Han, J., Kamber, M., & Pei, J. (2011). *Data Mining Concept and Techniques*. 3rd Edition, Morgan Kaufmann Publishers.
141. Friedman, N., Geiger, D. & Goldszmidt, M. (1997). Bayesian Network Classifiers. *Machine Learning*, 29, 131–163.
142. Bhargavi, P., & Jyothi, S. (2009). Applying Naive Bayes Data Mining Technique for Classification of Agricultural Land Soil. *International Journal of Computer Science and Network Security*, 9(8), 117-122.
143. Subasi, A. (2020). Chapter 3-Machine learning techniques. *Practical Machine Learning for Data Analysis Using Python*, 91-202.
144. Gohari, M., & Eydi, A.M. (2020). Modelling of shaft unbalance: Modelling and multi discs rotors using K-Nearest Neighbor and Decision Tree Algorithms. *Measurement*, 151, 107253.
145. Pisner, D.A., Schnyer, D.M. (2020). Chapter 6- Support vector machine. *Machine Learning*, 101-121.
146. Malek, S., Hui, C., Aziida, N., Cheen, S., Toh, S., & Milow, P. (2019). Ecosystem monitoring through predictive modeling. *Encyclopedia of Bioinformatics and Computational Biology*, 3, 1-8.
147. Theodoridis, S., & Koutroumbas S. (2006). *Pattern Recognition*. 3rd Edition, Elsevier, USA.
148. Kahraman, B. (2022). Modeling of Artificial Neural Networks and Image Processing Algorithms for Bread Wheat Quality Classification, Gaziantep University, The Graduate School of Engineering and Science, Master of Science, Gaziantep.
149. Eren, B. (2022). Deep Learning Based Channel Equalization for MIMO ISI Channels. Bilkent University, The Graduate School of Engineering and Science, Master of Science, Ankara.
150. Rosenblatt, F. (1962). *Principles of Neurodynamics: Perceptrons and the Theory of Brain Mechanisms*, Spartan Books, University of Michigan.

151. Arora, V., Yin-Kwee Ng, E., & Singh, A. (2022). Chapter 1- Machine learning and its applications. *Smart Electrical and Mechanical Systems*, Academic Press, 1-37.
152. Lakshmi, J.V.N. (2022). Deep learning on medical image analysis on COVID-19 x-ray dataset using an X-Net architecture. *Deep Learning for Medical Applications with Unique Data*, Academic Press, 71-106.
153. Krishnan, S. (2021). *Biomedical Signal Analysis for Connected Healthcare*, London, Academic Press.
154. Simonyan, K., & Zisserman, A. (2015). Very Deep Convolutional Networks for Large-Scale Image Recognition, *arXiv*, 1409.1556.
155. Ghosh, A., Sufian, A., Sultana, F., Chakrabarti, A., & De, D. (2019). Fundamental Concepts of Convolutional Neural Network.
156. LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324.
157. Dorf, R.C., & Bishop, R. H. (1998). *Modern Control Systems 8th Edition*, Addison Wesley.
158. Tuncay, M.T. (2016). Sabit Mıknatıslı DC Lineer Motor Tasarımı ve Denetimi, Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, Ankara.
159. Zadeh, L.A. (1965). Fuzzy Sets. *Information and Control*, 8, 338-353.
160. Ardam, H. (2002). Bulanık Mantık Denetimli Bir AC/AC Konvertör, Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, Ankara.
161. Altas, I. H., & Sharaf, A.M. (2007). A generalized Direct Approach for Designing Fuzzy Logic Controllers in Matlab/Simulink Gui Environment. *International Journal of Information Technology and Intelligent Computing*, 4(1).
162. Lee, C.C. (1990). Fuzzy Logic in Control Systems: Fuzzy Logic Controller-Part I. *IEEE Transactions on Systems, Man and Cybernetics*, 20, 404-418.
163. Altas, İ.H. (2007). Bulanık Mantık Denetleyici: Matlab/Simulink Ortamı için Bir Modelleme, *Otomasyon Dergisi*, Bileşim Yayınları, 58-62.
164. Altaş, İ. H. (2017). *Fuzzy Logic Control in Energy Systems with Design Applications in MATLAB/Simulink*. The Institution of Engineering and Technology (The IET) Books, London.

165. Bayındır, M.İ. (2003). Ayrık Zaman Kayma Kipli Kontrol Yönteminin Servo Sistemlere Uygulanması, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi.
166. Aydın Fandaklı, S. (2014). Anten konum kontrolünde kayan kipli kontrol yönteminin PID ve bulanık mantık kontrol yöntemiyle karşılaştırılması, Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi.
167. Akpolat, Z.H. (1999). Application of Fuzzy-Sliding Mode Control and Electronic Load Emulation to the Robust Control of Motor Drives, University of Nottingham, PhD Thesis.
168. Khandani, F., Soleymani, S., & Mozafari, B. (2011). Optimal allocation of SVC to enhance Total Transfer Capability using Hybrid Genetics Algorithm and Sequential Quadratic Programming. *The 8th Electrical Engineering/ Electronics, Computer, Telecommunications and Information Technology (ECTI) Association of Thailand - Conference 2011*, Khon Kaen, Thailand, 861-864.
169. Landau, I.D., Lozano, R., M'Saad, M., & Karimi, A. (2011). *Adaptive Control Algorithms, Analysis and Applications 2nd Edition*, Springer Science & Business Media.
170. Slotine, J-J.E., & Li, W. (1991). *Applied Nonlinear Control*, Prentice Hall, New Jersey.
171. Maragliulo, S., Lopes, P.A., Osório L.B., de Almeida A.T., & Tavakoli, M. (2019). Foot Gesture Recognition Through Dual Channel Wearable EMG System. *IEEE Sensors Journal*, 19, 10187–10197.
172. Khera, P., Kumar, N., & Ahuja, P. (2020). Machine Learning based Electromyography Signal Classification with Optimized Feature Selection for Foot Movements. *Journal of Scientific & Industrial Research*, 79(11), 1011-1016.
173. Hooda, N., & Kumar, N. (2021). Optimal Channel-set and Feature-set Assessment for Foot Movement Based EMG Pattern Recognition. *Applied Artificial Intelligence*; 35(1), 1685-1707.
174. Mayerich, D., Sun, R., & Guo. J. (2022). Chapter Fifteen – Deep Learning, *Microscope Image Processing (Second Edition)*, Academic Press, 431-456.
175. URL-10.(2023,Mart6)Res-NetBlokYapısı:
https://d2l.ai/chapter_convolutional-modern/resnet.html adresinden alınmıştır.
176. Wang, C., Wu, X., Ma, Y., Wu, G., & Luo, Y. (2018). A flexible lower extremity exoskeleton robot with deep locomotion mode identification. *Complexity*, 1-9.

177. Feng, Y., Chen, W., & Wang, Q. (2019). A strain gauge based locomotion mode recognition method using convolutional neural network. *Advanced Robotics*, 33(5), 254–263.
178. Su, B.Y., Wang, J., Liu, S.Q., Sheng, M., Jiang, J., & Xiang, K. (2019). A CNN-Based Method for Intent Recognition Using Inertial Measurement Units and Intelligent Lower Limb Prosthesis. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 27(5), 1032–1042.
179. Lu, Z., Narayan, A., & Yu, H. (2020). A Deep Learning Based End-to-End Locomotion Mode Detection Method for Lower Limb Wearable Robot Control. *2020 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)* 4091–4097, Las Vegas.
180. Bijalwan, V., Senwal, V. B., & Gupta, V. (2022). Wearable-Sensor based Pattern Mining for Human Activity Recognition: Deep Learning Approach, *Industrial Robot*, 49(1), 21-33.
181. Narayan, A., Reyes, F.A., Ren, M., & Haoyong, Y. (2022). Real-Time Hierarchical Classification of Time Series Data for Locomotion Mode Detection. *IEEE Journal of Biomedical and Health Informatics*, 26(4), 1749–1760.
182. Liu, J. (2017). *Sliding Mode Control Using MATLAB*, Academic Press.

6. EKLER

Ek 1. DC Lineer Motorun Dinamik Denklemleri

DC lineer motorun eşdeğer devresindeki toplam sürtünme kuvveti F_d (E.1) eşitliğinde verilmiştir.

$$F_d = \alpha v(t) + F_c + F_s \quad (\text{E.1})$$

Hareketli ünite, Newton'un hareket yasalarına göre hareket etmektedir ve bu davranış, (E.2) ve (E.3) eşitliğinde açıklanmıştır. Hareketli ünitenin dinamik denklemi, (E.4)'te olduğu gibi ifade edilir. Elektriksel olarak üretilen kuvvet, (E.5)'te belirtilmiştir.

$$M_t \frac{dv(t)}{dt} = \sum F_t \quad (\text{E.2})$$

$$M_t \frac{dv(t)}{dt} = F_e(t) - \alpha v(t) - F_c - F_s \quad (\text{E.3})$$

$$M_t \frac{dv(t)}{dt} = F_e(t) - F_d - F_l \quad (\text{E.4})$$

$$F_e(t) = K i_a(t) \quad (\text{E.5})$$

Newton ve Kirchhoff yasaları kullanılarak lineer motorun hareketli parçasının diferansiyel denklemleri sırasıyla (E.6) ve (E-7)'de ifade edilmiştir.

$$\frac{dv(t)}{dt} = \frac{K i_a(t)}{M_t} - \frac{\alpha v(t)}{M_t} - \frac{F_l}{M_t} \quad (\text{E.6})$$

$$e(t) = R_a i_a(t) + L_b \frac{di_a(t)}{dt} + e_b(t) \quad (\text{E.7})$$

Eşitlik (E-8)'de ifade edilen DC lineer motorun durum denklemi ve (E-9)'da verilen çıkış denkleminde motor hızı $v(t)$ ve endüvi akımı $i_a(t)$ olmak üzere iki durum değişkeni bulunmaktadır. Motorun durum-uzay denklemi, (E-10)'da, çıkış denklemi (E-11)'de verilmiştir.

$$\begin{bmatrix} \frac{dv(t)}{dt} \\ \frac{di_a(t)}{dt} \end{bmatrix} = \begin{bmatrix} -\frac{\alpha}{M_t} & \frac{K}{M_t} \\ -\frac{K}{L_b} & \frac{R_a}{L_b} \end{bmatrix} \begin{bmatrix} v(t) \\ i_a(t) \end{bmatrix} + \begin{bmatrix} 0 \\ \frac{1}{L_b} \end{bmatrix} e(t) + \begin{bmatrix} -\frac{1}{M_t} \\ 0 \end{bmatrix} F_l \quad (\text{E-8})$$

$$v(t) = \begin{bmatrix} 1 & 0 \end{bmatrix} \begin{bmatrix} v(t) \\ i_a(t) \end{bmatrix} \quad (\text{E-9})$$

$$\frac{dX_s}{dt} = AX_s(t) + Be(t) \quad (\text{E-10})$$

$$v(t) = CX_s(t) \quad (\text{E-11})$$

Burada $X_s(t)$ durum vektörü (E-12), A durum geçiş matrisi (E-13), B giriş matrisi (E-14) ve C çıkış matrisini (E-15) ifade eder. Bu denklemler durum uzayı temsili olan bir lineer zamanla değişen (LTI) sistem için temel denklemlerdir. Durum-uzay denkleminin Laplace dönüşümü (E-16) ve (E-17)'de verilmiştir.

$$X_s(t) = \begin{bmatrix} v(t) \\ i_a(t) \end{bmatrix} \quad (\text{E-12})$$

$$A = \begin{bmatrix} -\frac{\alpha}{M_t} & \frac{K}{M_t} \\ -\frac{K}{L_b} & \frac{R_a}{L_b} \end{bmatrix} \quad (\text{E-13})$$

$$B = \begin{bmatrix} 0 \\ \frac{1}{L_b} \end{bmatrix} \quad (\text{E-14})$$

$$C = [1 \ 0] \quad (\text{E-15})$$

$$sX_s(s) = AX_s(s) + BE(s) \quad (\text{E-16})$$

$$V(s) = CX_s(s) \quad (\text{E-17})$$

Sistemin iki girişi bulunmaktadır: endüvi gerilimi $e(t)$ ve yük kuvveti F_l . Bu sistemin tek bir çıkışı ise hareketli ünitenin hızı $v(t)$ 'dir. Yük kuvveti F_l ihmal edildiğinde, endüvi gerilimi ile hız arasındaki transfer fonksiyonu şu şekilde elde edilir:

$$V(s) = C[sI - A]^{-1}B \quad (\text{E-18})$$

$$T(s) = \frac{V(s)}{E(s)} = \frac{1}{\det(sI - A)} [1 \ 0] \begin{bmatrix} s + \frac{R_a}{L_b} & \frac{K}{M_t} \\ -\frac{K}{L_b} & \frac{\alpha}{M_t} \end{bmatrix} \begin{bmatrix} 0 \\ \frac{1}{L_b} \end{bmatrix} \quad (\text{E-19})$$

Sistemin durum uzay modeline geçiş yapmak için, öncelikle integratör çıkışları durum değişkenleri olarak tanımlanır. Bu durum değişkenleri (E-20), durum denklemleri (E-21), (E-22), (E-23) ve çıkış denklemi (E-24) ile sunulur. Durum denklemleri genellikle vektör-matris formunda düzenlenir ve bu şekilde (E-25)'teki eşitlik elde edilir.

$$x = \begin{bmatrix} x_1 \\ x_2 \\ I_a \end{bmatrix} \quad (\text{E-20})$$

$$\dot{x}_1 = x_2 \quad (\text{E-21})$$

$$\dot{x}_2 = -\frac{\alpha}{M_t} x_2 + KM_t I_a \quad (\text{E-22})$$

$$\dot{I}_a = -KL_a x_2 - \frac{R_a}{L_b} I_a + L_b e_a \quad (\text{E-23})$$

$$y = \theta = x_1 \quad (\text{E-24})$$

$$\begin{bmatrix} \dot{x}_1 \\ \dot{x}_2 \\ \dot{I}_a \end{bmatrix} = \begin{bmatrix} 0 & 1 & 0 \\ 0 & -\frac{\alpha}{M_t} & KM_t \\ 0 & -KL_b & -\frac{R_a}{L_b} \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ I_a \end{bmatrix} + \begin{bmatrix} 0 \\ 0 \\ L_b \end{bmatrix} e_a \quad (\text{E-25})$$

$$G(s) = \frac{K}{s^2 L_b M_t + s(\alpha L_b + R_a M_t) + \alpha R_a + K^2} \quad (\text{E-26})$$

L_b, R_a, K, α, M_t parametrelerini belirleyerek blok diyagramına yerleştirmemiz gerekmektedir. L_b değerini denetleyici tasarımını basitleştirmek amacıyla ihmal etme yöntemine başvururuz. Tablo 5'te verilen lineer motorun parametreleri kullanılarak diğer değerler aşağıdaki gibi elde edilmiştir:

$$R_a = 12 / 0,65 = 18,46 \Omega \quad (\text{E-27})$$

$$F_c = m_2 * g = 0,24 * 9,81 = 2,3544 \text{ N} \quad (\text{E-28})$$

$$\alpha = \frac{F_{yük} - F_c}{v_{yük}} = \frac{50 - 2,3544}{16 * 10^{-3}} = 2977,85 \quad (\text{E-29})$$

$$K = Kuvvet / Akım = 50 / 0,4 = 125 \quad (\text{E-30})$$

Ek 2. Tablo 20'deki Çalışmalarda Kullanılan Hareket Çeşitleri

Wang ^(a)	oturma, ayakta durma, düz zeminde yürüme, merdiven çıkma, merdiven inme
Feng ^(b) , Su ^(c) , Lu ^(d)	merdiven çıkma, merdiven inme, düz zeminde yürüme, rampa çıkma, rampa inme
Bijalwan ^(e)	jogging, normal yürüme, parmak ucu yürüme, topuk yürüme, merdiven çıkma, merdiven inme, mekik çekme
Narayan ^(f)	16 hareket modu: oturma, ayakta durma, merdiven çıkma, merdiven inme, düz zeminde yürüme, sağa kavisli yürüme, sola kavisli yürüme, sağa dönme, sola dönme vb.
Vu ^(g)	merdiven çıkma, merdiven inme, düz zeminde yürüme, ayakta durma
Vakacherla ^(h)	ayakta durma, düz zeminde yürüme, yokuşta yürüme, koşu, squat
Aydin Fandakli ⁽ⁱ⁾	dorsifleksiyon, plantarfleksiyon, inversiyon, eversiyon

ÖZGEÇMİŞ

Üniversite eğitimine 2006 yılında Karadeniz Teknik Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü'nde başlamıştır. 2011 yılında Elektrik-Elektronik Mühendisliği bölümünden birincilikle mezun olmuştur. Aynı yıl Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği Ana Bilim Dalı'nda yüksek lisans öğrenimine başladı. 24.08.2011 tarihinde Öğretim Üyesi Yetiştirme Programı kapsamında Erzurum Teknik Üniversitesi Kontrol ve Kumanda Sistemleri Anabilim Dalına araştırma görevlisi olarak atanmıştır. 25.05.2012 tarihinde kadrosu Karadeniz Teknik Üniversitesi Elektrik-Elektronik Mühendisliği Bölümüne aktarılmıştır. 2014 yılında yüksek lisansını tamamlamıştır ve aynı yıl doktora eğitimine başlamıştır. Araştırma görevlisi olarak çalışmaya devam etmektedir. İyi derecede İngilizce, orta derecede Almanca bilmektedir.

Burslar

- TÜBİTAK BİDEB 2228-B Yüksek Lisans Öğrencileri için Doktora Bursu, 2015-2019.
- TÜBİTAK BİDEB 2224-B Yurt İçi Bilimsel Etkinliklere Katılım Desteği Programı, 2014.

SCI/SCI-E indekslerine giren dergilerde yayınlanan makaleler

Aydın Fandaklı, S., & Okumus, H.I. (2024). Deep learning based ankle-foot movement classification for prosthetic foot. *Neural Computing and Applications*, <https://doi.org/10.1007/s00521-024-09780-1>

Diğer dergilerde yayınlanan makaleler

Aydın Fandaklı, S., & Okumuş, H. İ., (2023). Comparison of Artificial Neural Networks with other Machine Learning Methods in Foot Movement Classification. *Karadeniz Fen Bilimleri Dergisi*, 13(1), 153-171.

Aydın Fandaklı, S., & Okumuş, H. İ., (2021). Classification of the Foot Movements with Inertial Measurement Sensor for Ankle-Foot Prosthesis. *Karadeniz Fen Bilimleri Dergisi*, 11(2), 463-475.