



T.C.
NECMETTİN ERBAKAN
ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



ANORMAL YÜRÜYÜŞ TESPİTİ İÇİN ATALET SENSÖRÜ TABANLI
GIYİLEBİLİR SİSTEM: BİR REHABİLİTASYON DEĞERLENDİRME
YAKLAŞIMI

Yusuf ELAHMED

YÜKSEK LİSANS TEZİ

Bilgisayar Mühendisliği Anabilim Dalı

06-2025
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Yousof ELAHMED tarafından hazırlanan “ANORMAL YÜRÜYÜŞ TESPİTİ İÇİN ATALET SENSÖRÜ TABANLI GİYİLEBİLİR SİSTEM: BİR REHABİLİTASYON DEĞERLENDİRME YAKLAŞIMI” adlı tez çalışması 27/06/2025 tarihinde aşağıdaki jüri tarafından oy birliği ile Necmettin Erbakan Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

Başkan

Unvanı Adı SOYADI

Danışman

Unvanı Adı SOYADI

Üye

Unvanı Adı SOYADI

İmza

Dr. Öğr. Üyesi Alper KILIÇ

Prof. Dr. Mehmet HACİBEYOĞLU

Dr. Öğr. Üyesi Alperen EROĞLU

Fen Bilimleri Enstitüsü Yönetim Kurulu’nun/.../20.. gün ve sayılı kararıyla onaylanmıştır.

Prof. Dr. Havvanur UÇBEYİAY
FBE Müdürü

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

Yusuf ELAHMED

Tarih:

ÖZET

YÜKSEK LİSANS TEZİ

ANORMAL YÜRÜYÜŞ TESPİTİ İÇİN ATALET SENSÖRÜ TABANLI GIYİLEBİLİR SİSTEM: BİR REHABİLİTASYON DEĞERLENDİRME YAKLAŞIMI

Yusuf ELAHMED

Necmettin Erbakan Üniversitesi Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Mehmet HACİBEYOĞLU

2025, 63 sayfa

Jüri

Prof. Dr. Mehmet HACİBEYOĞLU

Dr. Öğr. Üyesi Alper KILIÇ

Dr. Öğr. Üyesi Alperen EROĞLU

Yürüyüş bozuklukları, özellikle protez uzuvların optimal şekilde takılmaması durumunda, asimetrik yürüyüş desenleri ve uzun vadede çeşitli sağlık sorunlarıyla sonuçlanarak bireylerin günlük yaşam aktivitelerini ve rehabilitasyon süreçlerini olumsuz yönde etkileyebilmektedir. Geleneksel yürüyüş analizi yöntemleri büyük ölçüde uzman gözlemlerine dayansa da yapay zekâ ve makine öğrenimi alanındaki ilerlemeler, yürüyüşün otomatik ve nesnel bir biçimde değerlendirilmesine olanak tanıyan yenilikçi çözümler sunmaktadır. Bu çalışmanın temel amacı, alt ekstremitte ampute olanlarda anormal yürüyüş paternlerini tespit etmek ve biyogeribildirim aracılığıyla rehabilitasyon süreçlerini desteklemek amacıyla, atalet sensör tabanlı, yapay zekâ ve makine öğrenimi teknolojilerinden faydalanan bir giyilebilir sistem geliştirmektir. Geliştirilen sistem, dört adet atalet sensöründen oluşmakta olup, toplanan ham veriler; sıfır ortalama ve birim varyansa normalize edilerek, 5 saniyelik sabit uzunluktaki ve 4 saniyelik çakışmalı pencerele bölünmek suretiyle kapsamlı bir ön işleme sürecinden geçirilmiştir. Aykırı değerler, Çeyrekler Arası Aralık yöntemiyle tespit edilerek veri setinden dışlanmıştır. Yürüyüş paternlerinin etiketlenmesinde, yeniden yapılandırma hatalarından faydalanan ve sıralıdan sıralıya çalışan uzun kısa süreli bellek tabanlı bir otokodlayıcı modeli içeren yarı denetimli bir yaklaşım uygulanmıştır. Bunu takiben, kapılı tekrarlayan birim modeli devreye alınmış ve bu model, amputeleri sağlıklı bireylerden ayırt etmede %99'un üzerinde doğruluk sağlamanın yanı sıra, dört sınıflı anomali sınıflandırma görevinde de ortalama %86 doğruluk oranı ile başarılı sonuçlar elde etmiş, uzun kısa süreli bellek ve çift yönlü uzun kısa süreli bellek modellerinin performansını aşmıştır. Bununla birlikte, bu çalışma, ölçeklenebilir yürüyüş değerlendirmeleri için tekrarlayan sinir ağları tabanlı modellerin uygulanabilirliğini ortaya koymakta; giyilebilir sensör teknolojisi, derin öğrenme yöntemleri ve denetimsiz etiketleme yaklaşımlarını bir araya getirmektedir.

Anahtar Kelimeler: Anormal yürüyüş tespiti, giyilebilir sensör, denetimsiz öğrenme

ABSTRACT

MS THESIS

IMU-BASED WEARABLE SYSTEM FOR ABNORMAL GAIT DETECTION: A REHABILITATION ASSESSMENT APPROACH

Yusuf ELAHMED

**THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCE OF
NECMETTİN ERBAKAN UNIVERSITY
THE DEGREE OF MASTER OF SCIENCE
IN COMPUTER ENGINEERING**

Advisor: Prof. Dr. Mehmet HACIBEYOĞLU

2025, 63 Pages

Jury

Prof. Dr. Mehmet HACIBEYOĞLU

Asst. Prof. Alper KILIÇ

Asst. Prof. Alperen EROĞLU

Gait disorders, particularly in cases of improper fitting of prosthetic limbs, can lead to asymmetric gait patterns and long-term various health issues, negatively impacting individuals' daily life activities and rehabilitation processes. Although traditional gait analysis methods largely rely on expert observations, advancements in artificial intelligence and machine learning offer innovative solutions for the automatic and objective evaluation of gait. The primary aim of this study is to develop a wearable system based on an inertial measurement unit that leverages artificial intelligence and machine learning technologies to detect abnormal gait patterns in lower extremity amputees and support rehabilitation processes through biofeedback. The developed system consists of four inertial sensors, and the collected raw data were subjected to a comprehensive preprocessing process, normalized to zero mean and unit variance, and segmented into fixed-length 5-second windows with 4-second overlaps. Outliers were identified and excluded from the dataset using the Interquartile Range method. For the labeling of gait patterns, a semi-supervised approach was applied, incorporating a long short-term memory-based autoencoder model that utilizes reconstruction errors. Subsequently, a gated recurrent unit model was employed, achieving over 99% accuracy in distinguishing amputees from healthy individuals and successfully obtaining an average accuracy rate of 86% in a four-class anomaly classification task, surpassing the performance of long short-term memory and bidirectional long short-term memory models. Furthermore, this study demonstrates the applicability of recurrent neural network-based models for scalable gait assessments, integrating wearable sensor technology, deep learning methods, and unsupervised labeling approaches.

Keywords: Abnormal gait detection, wearable sensor, unsupervised learning

ÖNSÖZ

Bu çalışma süresince akademik gelişimime katkıda bulunan, değerli bilgi ve tecrübeleriyle yol gösteren Prof. Dr. Mehmet HACIBEYOĞLU'na en içten teşekkürlerimi sunarım.

Yousof ELAHMED
KONYA-2025



İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
ÖNSÖZ	vi
İÇİNDEKİLER.....	vii
KISALTMALAR	ix
1. GİRİŞ.....	1
1.1. Çalışmanın Arka Planı ve Yürüyüş Analizi.....	2
1.2. Anormal Yürüyüş Tespiti ve Klinik Önemi	4
1.3. Laboratuvar Tabanlı ve Giyilebilir Yürüyüş Analiz Sistemleri.....	5
1.3.1. Laboratuvar tabanlı sistemler.....	6
1.3.2. Giyilebilir sistemler	6
1.4. Yürüyüş Analizinde Makine Öğrenimi ve Yapay Zekâ	7
2. İLGİLİ ARAŞTIRMALAR	9
2.1. İnsan Yürüyüş Analizi	9
2.2. Protez Geliştirilmesinde Biyogeribildirim Sistemleri.....	11
2.3. Yürüyüş Analizinde Makine Öğrenimi Uygulamaları.....	12
2.4. Atalet Sensörlerin Biyomekaniklerdeki Rolü	15
2.5. Yürüyüş Verileri için Özellik Çıkarma Teknikleri	16
3. KURAMSAL VE KAVRAMSAL ÇERÇEVE.....	18
3.1. Yürüme ve Biyomekanik Temelleri	18
3.1.1. Yürüme döngüsü ve evreleri.....	18
3.1.2. Normal yürümenin biyomekaniği	19
3.1.3. Amputelerde yürüme anormalileri.....	20
3.2. Giyilebilir Sistemler ve Sensör Teknolojisi.....	20
3.2.1. Giyilebilir teknolojilerin gelişimi	20
3.2.2. Atalet sensörü	21
3.3. Yapay Sinir Ağları ve Derin Öğrenme Modelleri	22
3.3.1. Yapay sinir ağlarının temelleri	22
3.3.2. Tekrarlayan sinir ağları	23
3.3.3. LSTM, GRU ve BiLSTM yapılarının karşılaştırılması	25
3.3.4. Derin öğrenme ile sınıflandırma	29
3.3.5. Eğitim, doğrulama ve test kavramlarının rolü	30
4. YÖNTEM VE UYGULAMA SÜRECİ.....	33
4.1. Giyilebilir Cihazın Hazırlanması	33

4.1.1. Donanım bileşenlerinin seçimi	33
4.1.2. Sensörlerin bacaklara yerleştirilmesi	36
4.1.3. Veri iletimi hazırlığı.....	37
4.2. Veri Toplama	37
4.3. Verilerin Ön İşlenmesi.....	40
4.4. LSTM Tabanlı Yeniden Yapılandırma Hatası ile Veri Etiketleme	45
4.5. Denetimsiz Öğrenme ile Çok Sınıflı Etiket Üretimi.....	48
4.6. Yürüyüş Verileri Üzerinde Derin Öğrenme Modelleri ile Yürüyüş Sınıflandırması.....	49
4.7. Anlık Yürüyüş Analizi.....	56
5. TARTIŞMA	58
KAYNAKLAR	60



KISALTMALAR

MÖ: Makine Öğrenmesi

YZ: Yapay Zekâ

RNN: Tekrarlayan Sinir Ağları (Recurrent Neural Network)

LSTM: Uzun Kısa Süreli Bellek (Long Short-Term Memory)

BiLSTM: İki yönlü uzun-kısa süreli bellek (Bidirectional Long Short-Term Memory)

GRU: kapılı tekrarlayan birim (Gated Recurrent Unit)

MSE: Ortalama Kare Hata (Mean Square Error)

RMSE: Kök Ortalama Kare Hata (Root Mean Square Error)

1. GİRİŞ

Yürümek, bireylerin ihtiyaçlarını karşılayan, kişinin çevresiyle etkileşim kurmasını sağlayan ve aynı zamanda toplumdaki bireylerle ilişki kurmanın bir yolu olan en önemli günlük insan aktivitelerinden biridir. Bu nedenle, iki ayaklı hareket insan aktivitelerinin temellerinden biridir ve bu vazgeçilmez aktiviteyi geliştirmek için insan yürüyüşünü tartışmaya, değerlendirmeye ve analiz etmeye yönelik literatürde birçok çalışma yapılmaktadır.

Ancak, günümüzde birçok insan yürüyüş bozukluğundan dolayı günlük işlerini düzgün bir şekilde yapmakta zorlanmaktadır. Ayrıca yanlış yürüyüş insanda başka ağrılara da yol açabilir ve bu bazen yürüme korkusunun nedenlerinden biridir. Yürüyüş bozukluğu; nörolojik hastalıklardan, kas sistemi bozukluklarından, çocukluktan itibaren anormal doğum nedeniyle veya yaşlanmanın bir sonucu olarak yaşlılarda ortaya çıkabilir (Hwang vd., 2024).

Yürüme engelliliği istatistiklerine göre, Amerikan nüfusunun yaklaşık %6,6'sı yürüyüş bozukluğundan mustarıptır (Sie, 2020). Bu çalışmada, bacak uzuvlarından birinin kesilmesinden kaynaklanan diz altı ekstremitte protezlerindeki yürüyüş bozukluğu ele alınmış ve bu rahatsızlığa sahip olan kişilerde yürüyüş bozukluğu incelenmiştir. Amputasyon, bacak uzvunun cerrahi müdahale ile vücuttan kesilmesidir. Kanser, enfeksiyon hastalıkları, savaşlar, yol ve fabrika kazaları, yangınlar ve spor aktivitelerinden kaynaklanan yaralanmalar dahil olmak üzere bir dizi nedenden kaynaklanabilir. Bacak uzvu kesildikten sonra, yaralanan kişiye bir protez takılır. Pasif ve aktif olmak üzere iki tür protez vardır. Pasif protezlerin basitlik, hafiflik ve ekonomik olması gibi avantajları vardır. Öte yandan, aktif protezler eklemlerin doğal hareketini simüle etme yeteneği sağlar, ancak karşılığında pahalı, ağır, karmaşık ve elektriğe ihtiyaç duyarlar, bu da onları herkes için uygun olmayan bir seçenek haline getirir (Asif vd., 2021).

İstatistiklere göre sadece Amerika Birleşik Devletleri'nde her yıl yaklaşık 185,000 yeni alt ekstremitte amputasyonu gerçekleşmekte olup, toplam sayının 2050 yılına kadar 3,6 milyona ulaşması beklenmektedir (Zhang vd., 2019). Bu durum birçok çalışmanın ampute insanlara odaklanmasına yol açmıştır. Aslında protez uzuvlar kişiye uygun değilse sağlık açısından tehdit oluşturmaktadır. Protez uzuv, amputasyon nedeniyle kaybedilen yürüme aktivitesini sağlarken birkaç farklı açıdan da sağlık tehdidi oluşturmaktadır. Kişiye uygun ve eklem hareketlerine uyumlu bir protez uzuva sahip

olmayan kişilerde yürürken denge sağlamakta zorluk yaşanmaktadır. Ayrıca kişinin yürüyüş şekli de yaşla birlikte değiştiğinden, protez uzuv ilk kullanılmaya başlandığında uygun olsa bile belli bir süre sonra uygunsuz hale gelebilmektedir. Protez uzuvlu olan bir kişinin yürüyüşünde tutarlılık veya simetri olmamasının nedeni, her iki bacağındaki kas kütesinin büyüklüklerindeki farklılıktır. Kişi protez bacadan daha çok sağlıklı bacağa güvenirse, yürüyüşte asimetri oluşur ve bu da genel olarak iskeletin ve özellikle omurganın bütünlüğünü etkiler. Protez bacak kullananların yan etkilerini belirlemeyi amaçlayan bir çalışmada, biyomekanik değişiklikler ve kas dengesizliklerinin bel ağrısına neden olduğu bulunmuştur (Sivapuratharasu vd., 2019).

Ampute olan kişilerin sağlık durumlarını, yaşamlarını izlemek ve ayrıca yürüme sorunlarını çözmek için insan yürüyüşü analiz edilmektedir. Yürüyüş analizi, fizyoterapistin biyogeribildirim yoluyla hastayı rehabilite etme sürecine yardım eder ve böylece rehabilitasyon için gereken tedavi seansları azalır. Sonuç olarak, ampute olan kişilerde anormal yürüyüşün nedenlerinin bulunması ve insan yürüyüşünün analiz edilmesi rehabilitasyon eğitiminin etkinliğini arttırmaktadır (Escamilla-Nunez vd., 2020).

1.1. Çalışmanın Arka Planı ve Yürüyüş Analizi

Yapay zekâ (YZ) ve makine öğrenimi (MÖ) teknolojilerinin ortaya çıkışı, birçok alanda hızlı bir büyümeye yol açmış; büyük şirketlerin bu teknolojilere olan ilgisi ve talebinin artmasıyla birlikte, sağlık alanında da hızlı bir gelişme gözlemlenmiştir. MÖ algoritmalarının çeşitliliği, uygulama alanlarının da çeşitlenmesini sağlamıştır. Günümüzde veri bolluğu ve veriye ulaşmanın kolaylaşması, MÖ algoritmalarının verileri en verimli şekilde kullanacak biçimde gelişmesine teşvik etmiştir. Özellikle akıllı mobil cihazlar ve internete bağlanabilen diğer teknolojik araçlar sayesinde veri toplama geçmişe kıyasla oldukça kolay hale gelmiştir. Bu verilerden anlamlı bilgiler elde edebilmek için, verinin arkasındaki yapıyı keşfetmeyi amaçlayan MÖ algoritmaları geliştirilmiştir. Bu algoritmalar, insan öğrenme mekanizmasına benzer bir yaklaşım sergilemekte olup, elde edilen sonuçlara dayanarak kararlar alınmasını mümkün kılmaktadır.

YZ'ye dayalı karar destek sistemleri yaygınlaştıkça, insanlar uzmanlara olduğu kadar makinelere de güvenmeye başlamıştır. Bu durum, sağlıkta YZ uygulamalarının ilgili kritik karar süreçlerinde kullanılmasına yönelik yönlendirmelere neden olmuştur. Günümüzde YZ teknolojileri desteğiyle hastalıkların teşhis edilmesi mümkün hâle gelmiştir. Bu, ya vücuda ait röntgen görüntülerinin analiz edilmesiyle ya da günlük vücut aktivitelerinin izlenmesiyle gerçekleştirilebilmekte ve böylece belirli hastalıkların

oluşumu önceden tahmin edilebilmektedir. Son zamanlarda bu tür uygulamaların, akıllı saatler, tıbbi yüzükler ve benzeri giyilebilir teknolojiler aracılığıyla yaygınlaştığı görülmektedir.

Sağlık hizmetleri, gelişmiş ülkelerde bireylerin hayati aktivitelerini izleyen dijital ikizlere sahip olması sayesinde, teşhis doğruluğunun artırılmasına önemli katkı sağlayan başlıca alanlardan biri hâline gelmiştir (Katsoulakis vd., 2024). YZ'nin, protez cihazlar gibi yapay uzuvlarda uygulanması ise bu cihazların çevresel koşullara uyum sağlamasında büyük bir potansiyel sunmaktadır. Bu çalışmada, alt ekstremitte amputasyonu olan bireyler için YZ destekli giyilebilir bir cihaz geliştirilmiştir. Geliştirilen cihaz, anormal yürüyüşü tespit etmek amacıyla MÖ tekniklerinin yanında atalet sensörlerine dayalı olarak da çalışmaktadır. Oluşturulan MÖ modeli, atalet sensörlerinden elde edilen verileri kullanarak normal ve anormal insan yürüyüşünü ayırt edebilmektedir. Söz konusu sensörler, doğrusal olmayan ve çok boyutlu veri üreterek analizde yüksek hassasiyet sağlamaktadır.

Atalet sensörleri, Parkinson hastalarında yürüyüşün donma gibi motor semptomların algılanmasında hareketlilik destek cihazları içinde önemli bir rol oynamıştır (Sie, 2020). Ayrıca bu sensörler, ampute bireylerde yürüyüş analizine yönelik geliştirilen giyilebilir cihazlarda da etkin bir şekilde kullanılmıştır. Hwang ve arkadaşları (2024), sağlıklı yetişkinler ile nöropati kaynaklı anormal yürüyüşe sahip bireylerin yürüyüş analizini gerçekleştirmek amacıyla, sol ve sağ baldıra yerleştirilen atalet sensörlerinden yararlanmıştır.

Bu çalışmada, MÖ tabanlı anormal yürüyüş sınıflandırması gerçekleştirilmiştir. Yürüyüş analizi veya sınıflandırması alanında daha önce yapılmış birçok çalışma bulunmaktadır. Bu çalışmalar amaçları ve veri toplama yöntemleri açısından çeşitlilik göstermektedir. Bazı çalışmalar kamera tabanlı hareket yakalama sistemlerine, bazıları ayağa yerleştirilen derinlik algılayıcı kameralara, bazıları aletli yürüyüş yollarına ve bazıları ise atalet sensörlerine dayalı giyilebilir cihazlara odaklanmıştır. Atalet sensörlerini diğer yöntemlerden ayıran en önemli özellik, eklem açılarını ölçebilme gibi insan yürüyüş parametrelerini doğrudan ölçebilme yeteneklerine sahip olmaları ve bu işlemler için karmaşık bir özellik seçimi sürecine ihtiyaç duymamalarıdır. Bu yönüyle, özellikle asimetrik yürüyüş analizi için ideal bir çözüm sunarlar. Eklem açılarını ölçmenin yanı sıra, yürüyüş sırasındaki ivmeyi de tespit edebilirler; bu da insan yürüyüşündeki anormalliklerin ve titreşimlerin belirlenmesinde önemli bir avantaj sağlar. Sonuç olarak, YZ algoritmaları ile atalet sensörlerinin sunduğu veriler birleştirilerek, ampute olan

kişilerin yürüyüşlerindeki anormalliklerin tespitine ve rehabilitasyon sürecini hızlandırmaya yönelik biyogeribildirim sağlayan giyilebilir cihazlar geliştirilebilir.

1.2. Anormal Yürüyüş Tespiti ve Klinik Önemi

Anormal yürüyüş tespitinin, hastaların sağlık durumlarına bağlı olarak çeşitli faydaları bulunmaktadır. Uzmanlar genellikle nörolojik, kas-iskelet sistemi veya sistemik bozuklukları tespit edebilmek için bireylerin yürüyüşlerini inceler. Bu tür durumların erken teşhisi, hastalığın ilerlemesini önleyerek tedavi sürecine önemli katkı sağlayabilir. Ampute bireylerde ise anormal yürüyüş tespiti, protezin tasarımının veya hizalamasının yeniden düzenlenmesi açısından kritik bir öneme sahiptir. Ayrıca bu tespit, bireyin proteze alışma sürecinde yanlış yürüyüşten kaçınmasını sağlayarak rehabilitasyon sürecini destekler. Yaşlı bireyler açısından değerlendirildiğinde ise, anormal yürüyüşün erken tespiti düşme riskini azaltmada önemli rol oynar. Günümüzde ise giyilebilir sensörlerin ve MÖ algoritmalarının gelişimi sayesinde, Anlık anormal yürüyüş tespiti mümkün hâle gelmiştir. Bu sistemler, özellikle Parkinson hastalığının günlük takibi ve erken teşhisi gibi klinik uygulamalarda hekimlere önemli ölçüde yardımcı olmaktadır (Balaji vd., 2020).

İnsan yürüyüşünün incelenmesi, başlangıçta görsel gözleme dayanmaktadır. Yürüyüş, birden fazla yürüyüş döngüsünden oluşan döngüsel bir aktivitedir. Bir yürüyüş döngüsü, topuğun yere temas ettiği an olan topuk vuruşu ile başlar ve aynı bacağın bir sonraki topuk vuruşuna kadar devam eder. Bu döngü iki temel aşamadan oluşur: duruş ve salınım. Duruş aşaması, topuk vuruşuyla başlar; vücut ağırlığının ilgili bacağa aktarılması ve ayak parmaklarının yerden ayrılmasına kadar sürer. Ardından başlayan salınım aşaması ise ayak parmaklarının yerden kesilmesiyle başlar ve bacağın ileri doğru hareket ederek yeniden topuk vuruşu yapmasıyla sona erer. Bu aşamalar sırasıyla her iki bacak içinde gerçekleştirilir. Bir yürüyüş döngüsünün yaklaşık %60'ı duruş, %40'ı ise salınım aşamasından oluşur. Bu oranlar, yürüyüşün ritmi ve dengesi açısından kritik öneme sahiptir.

Klinisyen anormal yürüyüşü teşhis etmek için yukarıda belirtilen yürüyüş özelliklerini gözlemler. Çizelge 1.1'de anormal yürüyüşün nedenleri gösterilmektedir.

Çizelge 1.1. Anormal yürüyüşün en önemli nedenleri

Yürüyüş Anormallığı	Neden	Özellikler
Tokat Yürüyüşü	Tibialis anteriorun zayıflığı/felci (ayak düşmesi).	Dorsifleksiyon kontrolünün eksikliği nedeniyle topuk vuruşu sırasında ayak yere çarpar (Whittle, 2014).
Steppage Yürüyüşü	Tam ayak düşmesi (sinir hasarı).	Ayak parmakları yere sürtünür; hasta ayağı kaldırmak için bacağı daha yükseğe kaldırır (Whittle, 2014).
Trendelenburg Yürüyüşü	Kalça abdükörlerinin (gluteus medius/minimus) zayıflığı.	Etkilenmeyen tarafta kalça düşer; gövde denge için etkilenen tarafa kayar (Whittle, 2014).
Hemiplejik Yürüyüş	İnme (tek taraflı felç).	Etkilenen bacak dairesel bir hareketle dışarı doğru sallanır; sert, uzatılmış diz. (Hwang vd., 2024)
Diplejik Yürüyüş	Her iki bacağın felci (örn. omurilik yaralanması).	Makas benzeri bacak hareketi; hasta öne eğilir ve yürümek için kalça kaslarını kullanır (Hwang vd., 2024).
Antaljik Yürüyüş	Alt ekstremitede ağrı (ayak bileği, diz, kalça).	Ağırlık taşımaktan kaçınmak için etkilenen tarafta kısalmış duruş evresi (Hwang vd., 2024).
Ataksik Yürüyüş	Serebellar hasar (örn. alkol zehirlenmesi, nörolojik bozukluklar).	Geniş tabanlı yürüyüş; dengesiz, sallanan hareketler; denge eksikliği (Hwang vd., 2024).
Parkinson Yürüyüşü	Parkinson hastalığı.	Kısa, sürüklenen adımlar; öne eğilen duruş, dönme zorluğu (Raffageau vd., 2019).

Çizelge 1.2’de amputasyondan kaynaklı anormal yürüyüşün çeşitleri gösterilmektedir.

Çizelge 1.2. amputasyondan kaynaklı Anormal yürüyüşün en önemli nedenleri

Yürüyüş Anormallığı	Neden	Özellikler
Diz Altı Amputasyon	Alt bacağın kaybı.	Kullanılan protez bacak; protez tarafta daha kısa duruş evresi, artan enerji harcaması (Schmiegelow vd., 2018).
Diz Üstü Amputasyon	Bütün bacağın kaybı (diz dahil).	Protez bacağı kaldırmak için sirkümdüksiyon veya atlama yürüyüşü; denge için önemli gövde eğilmesi (Schmiegelow vd., 2018).
Kalça Dezartikülasyonu	Kalça eklemi dahil bütün bacağın kaybı.	Şiddetli gövde eğilmesi; abartılı kol sallanması, sınırlı hareket kabiliyeti ve denge (Moura & Garrucho, 2017).
Swing-Through Yürüyüşü	İki taraflı alt ekstremitte amputasyonu (örn. diz üstü çift amputasyon).	Koltuk değneği veya yürüteç kullanır; protezler üzerinde ağırlık taşımadan destekler arasında vücudu öne doğru sallır (Font-Llagunes vd., 2012).

1.3. Laboratuvar Tabanlı ve Giyilebilir Yürüyüş Analiz Sistemleri

İnsan yürüyüş verilerini toplamanın birkaç yolu vardır, bunlardan bazıları laboratuvar tabanlı sistemler ve bazıları ise giyilebilir sistemlerdir. Aşağıda bu iki sistemin özellikleri sırasıyla verilmektedir.

1.3.1. Laboratuvar tabanlı sistemler

Yürüyüş verilerinin toplanmasında kullanılan bazı sistemler, yüksek doğruluk ve kontrol sağlamaları nedeniyle “altın standart” olarak kabul edilmektedir. Bu sistemler, veri toplamada yüksek verimlilik sunar ve genellikle laboratuvar ortamında kullanılır.

- İşaretleyici tabanlı hareket yakalama sistemlerinde, bireyin vücuduna yerleştirilen işaretleyiciler, laboratuvar ortamına yerleştirilen özel kameralar tarafından izlenerek üç boyutlu hareket verileri elde edilir. Bu sistemler oldukça hassas ölçümler sağlayabilir. Örneğin, Vicon kamera sistemi, bu alandaki en yaygın kullanılan sistemlerden biridir (Goldfarb vd., 2021).
- Bir diğer yöntem ise işaretleyici kullanmayan insan poz tahmini sistemleridir. Bu sistemler, tek veya çoklu kamera kullanarak vücut noktalarının konumlarını tahmin eder. Örnek olarak, MediaPipe Pose sistemi, bu amaçla yaygın olarak kullanılmaktadır (Hii vd., 2023).
- Kuvvet plakaları, insan yürüyüş verilerini toplamada kullanılan başka bir önemli sistemdir. Bu plakalar laboratuvar zeminine sabitlenmiştir ve birey, bu plakalar üzerinde yürüdüğünde yere uyguladığı kuvvetler ölçülür. Kuvvet plakaları, özellikle yürüyüş fazlarının tespitinde yüksek doğruluk sağlamalarıyla öne çıkar. Bu tür sistemlere örnek olarak GAITRite platformu verilebilir (Rattanasak et al., 2022).

Laboratuvar tabanlı sistemler hassas kinematik ve kinetik veri toplama için uygun olsa da kullanılması için bazı sınırlamaları vardır:

- Gerekli ekipmanla donatılmış özel bir yere ihtiyaç vardır, gerçek dünya uygulamaları için uygun değildirler.
- Gerekli ekipmanla donatılmış bir laboratuvar inşa etmek yüksek maliyet oluşturur.
- Ekipmanı kurmak ve kullanıma hazır hale getirmek için uzmanlara ve zamana ihtiyaç vardır.
- Veri analizi süreci karmaşıklıklar içerir.

1.3.2. Giyilebilir sistemler

Bu sistemler, esneklik ve taşınabilirlik özellikleriyle öne çıkar. Ölçümlerini gerçekleştirmek için laboratuvara kurulmuş sabit ekipmanlara ihtiyaç duymazlar. Ancak, ayak, baldır, uyluk, gövde, sırt, eller ve baş gibi vücudun belirli bölgelerine yerleştirilen

giyilebilir sensörlerle sınırlıdır. En önemli avantajlarından biri, çeşitli ve gerçek dünya ortamlarında yürüyüş analizine imkân sağlamalarıdır.

Bu sistemlerin en yaygın kullanılan türlerinden biri, ek özellik çıkarma gerektirmeden ivme ve açısal hız verilerinden yürüyüş bilgisi toplayabilen, hafif ve kullanımı kolay atalet sensörleri tabanlı sistemlerdir. Bir diğer önemli sistem ise, ayak ile zemin arasındaki basınç kuvvetlerini ölçmek için kullanılan kuvvet sensörleridir. Kuvvet sensörleri, kuvvet plakalarından farklı olarak, ayakların konumunu ve aralarındaki mesafeyi belirleyemezler. Ayrıca, Elektromiyografi sensörleri, insan kas aktivitesini tespit etmek amacıyla kullanılır; bu sensörler, kasların elektriksel aktivitesinden kaynaklanan sinyalleri kaydeder.

Bu teknolojiler, günlük aktivitelerde hasta rehabilitasyonunun izlenmesinde yaygın olarak kullanılmakta olup, aynı zamanda performans artırma ve yaralanma önleme amacıyla spor biyomekaniğinde de uygulanmaktadır. Giyilebilir sensörler esnek kullanım imkânı sunarken, bazı zorlukları da içermektedir:

- Sensör hizalamasından kaynaklanan nedenlerle, laboratuvar sistemlerine kıyasla daha düşük doğruluk seviyeleri gözlemlenmektedir.
- Elektromiyografi sensörlerinden elde edilen sinyallerin yorumlanabilmesi için gelişmiş algoritmalar gerekmektedir. Atalet sensörleri için ise veri güvenilirliğini artırmak amacıyla tahmin filtreleri ve kalibrasyon protokolleri kullanılmaktadır.

Her iki sensör tipini birleştiren hibrit sistemler üzerine bazı çalışmalar yapılmıştır (Santos vd., 2022). Bu sistemlerin MÖ modelleriyle entegrasyonu, giyilebilir sistemlerin laboratuvar düzeyinde hassasiyete ulaşmasını mümkün kılmıştır.

1.4. Yürüyüş Analizinde Makine Öğrenimi ve Yapay Zekâ

Geleneksel insan yürüyüş analizi, klinisyenin hastayı görsel olarak gözlemlemesine dayanmakta ve klinisyenin deneyimi doğrultusunda hastanın biyomekanik hareketlerindeki anormallikler tespit edilmektedir. Ancak YZ teknolojilerinin gelişmesiyle, hastadan toplanan veriler YZ algoritmaları aracılığıyla analiz edilmekte ve bu sayede klinisyenin karar verme süreci desteklenmektedir. YZ'nin verilerden öğrenme yeteneği, onu diğer geleneksel yöntemlerden ayırmakta ve daha karmaşık, insan benzeri karar mekanizmalarının geliştirilmesine olanak sağlamaktadır. Veri erişiminin yaygınlaşması, bu algoritmaların performansını artırarak sağlık alanında daha etkin kullanılmasını mümkün kılmıştır. Bununla birlikte, YZ insan işlevlerinin

yerini almak yerine, klinisyenlerin elindeki tamamlayıcı bir araç olarak görev yapmaktadır. Bu çalışmada, yürüyüş analizinde manuel veri yorumlama yöntemlerinden, YZ destekli otomatik analiz yöntemlerine geçişin önemi vurgulanmıştır.

MÖ teknikleri yürüyüş analizinde farklı şekillerde kullanılır. En önemli uygulamalar yürüyüşü sınıflandırmak ve eklem hareketlerini tahmin etmektir. Bu modeller normal ve anormal yürüyüşü ayırt edebilir, böylece Parkinson, felç veya amputasyon gibi durumların tanısına yardımcı olur. Parkinson hastaları için düşme riskini önceden tahmin eden sistemler geliştirilmiştir. Rehabilitasyon sürecindeki hastalar ise uzaktan izlenebilir ve biyolojik geri bildirimlerle yürüyüşlerini iyileştirebilirler. Ayrıca, protez kullananlar için adımları fazlara ayırmak gibi uygulamalar da vardır.



2. İLGİLİ ARAŞTIRMALAR

İnsan yürüyüşü analizi alanında literatürde çok sayıda çalışma mevcuttur ve her biri özgün amaçlar doğrultusunda gerçekleştirilmiştir. Bazı araştırmalar, insan adımlarının kinematik verileri ile yürüyüşün çeşitli fazlara ayrılmasını incelerken; diğer çalışmalarda, hastalarda düşme riskini azaltmaya yönelik yürüyüş tahmini üzerinde durulmuştur. Bu çalışmalar, hedefledikleri insan gruplarına göre farklılaşmaktadır. Bazı araştırmalar alt ekstremite amputeleri üzerinde yoğunlaşırken; bazıları nörolojik hastalıklar, özellikle Parkinson hastalığı gibi rahatsızlıkları incelemiştir. Ayrıca, sağlıklı bireylerde aktivite sınıflandırması, birey tanımlama ve spor performansını destekleme gibi amaçlar doğrultusunda yürüyüş analizleri yapılmıştır. Veri toplama yöntemlerinde ise laboratuvar ortamında gerçekleştirilen kontrollü prosedürlerden, serbest ve gerçek dünya koşullarında yapılan ölçümlere kadar geniş bir yelpaze söz konusudur. Veri analizinde ise geleneksel MÖ algoritmaları, derin öğrenme yöntemleri ve diğer analitik yaklaşımlar kullanılmıştır. Bu bölümde, insan yürüyüş analizine yönelik güncel çalışmalara yer verilecektir.

2.1. İnsan Yürüyüş Analizi

Yürüyüş verilerine dayalı insan aktivitesi sınıflandırması alanında Jiang ve Yin (2015), giyilebilir cihazlar kullanarak insan aktivitesinin tanınmasına yönelik doğru ve etkili bir yaklaşım geliştirmeyi amaçlayan bir çalışma sunmuştur. Çalışmada, sağlık hizmetleri bağlamında sensör tabanlı insan aktivitesi tanıma konusu ele alınmış; bu amaçla, vücudun farklı bölgelerine yerleştirilen ivmeölçer ve jiroskoplardan oluşan sensör sistemleri kullanılmıştır. Araştırmanın temel hedefi, aktivite tanıma sürecindeki hesaplama maliyetini azaltmaktır. Bu doğrultuda, araştırmacılar tüm sensörlerden elde edilen zaman serilerini, aktivite görüntüsü olarak adlandırılan yeni bir temsile dönüştüren yenilikçi bir yöntem geliştirmiştir. Bu yöntemde, farklı sensörlerden gelen sinyallerin bir araya getirilerek hizalanması sağlanmış ve ardından ayrık Fourier dönüşümü kullanılarak bu sinyaller tek bir sinyal görüntüsü içerisinde bütünleştirilmiştir. Elde edilen aktivite görüntüleri, daha sonra derin evrişimli sinir ağı ile analiz edilmiştir. Deneysel değerlendirme süreci, üç farklı veri kümesi (UCI, USC ve SHO) üzerinde gerçekleştirilmiş ve yüksek sınıflandırma doğruluğu elde edilmiştir. Elde edilen doğruluk oranları sırasıyla UCI veri seti için %97,59, USC veri seti için %97,83 ve SHO veri seti için %99,93 olarak raporlanmıştır (Jiang & Yin, 2015).

Transfemoral (dizüstü) amputeler üzerine odaklanan çalışmalardan biri olan Ledoux ve arkadaşları (2018), gövdeye monte edilmiş tek bir atalet sensörü kullanılarak yürüyüş aşamalarının tespiti için bir yöntem geliştirmiştir. Çalışma kapsamında, aletli bir koşu bandı üzerinde çeşitli hız ve eğimlerde yürüyen 10 sağlıklı birey ile 5 transfemoral ampute birey üzerinde deneyler gerçekleştirilmiştir. Bu deneylerde, topuk vuruşu ve ayak parmağının yerden kalkışı gibi temel yürüyüş olaylarının tespit edilmesi hedeflenmiştir. Araştırmacılar, ticari protez sistemlerinde yürümenin duruş ve salınım fazlarının tespiti için genellikle yük hücresi ve atalet sensörleri birlikte kullanıldığını belirtmiş; ancak önerilen bu yeni yöntem sayesinde yalnızca tek bir atalet sensörüyle aynı işlevin yerine getirilebileceğini göstermiştir. Böylece, yük sensörlerinin kullanımına gerek kalmadan daha maliyet etkin ve verimli protez sistemlerinin geliştirilmesi mümkün hâle gelmiştir. Çalışmada üç eksen verisi toplamıştır: iki ivmeölçer eksenini ve bir jiroskop eksenini. Yürüyüş yönü sabit tutularak, veriler 500 Hz örnekleme hızında kaydedilmiştir. Deneysel analiz sürecinde üç farklı algoritma uygulanmıştır: eşikleme yöntemi, lineer diskriminant analizi ve ikinci dereceden diskriminant analizi. Veriler filtrelendikten sonra bu üç algoritma kullanılarak analiz edilmiş ve iki temel performans ölçütü değerlendirilmiştir: tespit edilen yürüyüş olaylarının sayısı ve hatalı tespit edilen olayların yüzdesi. Elde edilen sonuçlara göre, her üç algoritma da yaklaşık %92 doğruluk oranı ile yürüyüş olaylarını başarılı şekilde sınıflandırmıştır. Bununla birlikte, genel olarak en yüksek doğruluk oranı eşikleme yöntemi ile elde edilmiştir. Çalışma, özellikle duruş ve salınım yürüyüş fazlarının tek bir atalet sensörü kullanılarak sınıflandırılabilceğini ortaya koyarak, protez tasarımlarında önemli bir potansiyel sunmaktadır(Ledoux, 2018).

Düzensiz yüzeyler nedeniyle ortaya çıkan düşme riskini önlemeye yönelik insan yürüyüş analizini ele alan çalışmalardan biri, Hu ve arkadaşları (2021) tarafından gerçekleştirilmiştir. Çalışmanın amacı, düz olmayan zeminlerin tespiti yoluyla bireylerin potansiyel risk altında olduklarını önceden fark etmelerini sağlamak ve anormal yürüyüş paternleri nedeniyle yaşanabilecek düşmeleri önlemektir. Bu kapsamda, sağlık hizmetlerine yönelik üç farklı derin öğrenme modeli kullanılarak analiz gerçekleştirilmiştir. Veri toplama sürecinde, farklı vücut ağırlıklarına sahip 30 katılımcı, yedi farklı zemin türünde ve her biri yedi tekrar olacak şekilde yaklaşık 15 metre yürümüş; bu süreçte toplamda 6 adet atalet sensörü kullanılmıştır. Her atalet sensörü üç eksenli ivmeölçer, jiroskop ve manyetometre içermektedir. Örnekleme frekansı 100 Hz olarak belirlenmiştir. Bu atalet sensörleri, sol ve sağ uyluklara, sol ve sağ inciklere, sağ bileğe ve belin orta hattına yerleştirilmiştir. Çalışma kapsamında üç farklı model

uygulanmıştır: Evrişimli Sinir Ağı, Uzun Kısa Süreli Bellek (Long Short-Term Memory, LSTM) ağı ve Geliştirilmiş LSTM mimarisi olan Global-LSTM. LSTM modeli için araştırmacılar, veri dizileri arasındaki ardıl bağlantılardan yararlanacak şekilde özgün bir mimari tasarlamıştır. Elde edilen sonuçlara göre, Global-LSTM modeli %92 doğruluk oranı ile diğer iki modelin önüne geçmiştir. Bu çalışma, gerçek dünya koşullarında bireylerin yürüyüş davranışlarını izlemek ve özellikle yaşlı veya nörolojik bozukluklara sahip bireylerde düşme riskini azaltmak amacıyla, giyilebilir sensör teknolojisinin ve derin öğrenme algoritmalarının etkinliğini ortaya koymaktadır (Hu vd., 2021).

2.2. Protez Geliştirilmesinde Biyogeribildirim Sistemleri

Biyogeribildirim, bireylerin sağlık durumlarına dair belirsizlikten kaynaklanan kaygı düzeylerini yönetmelerine olanak tanıırken, aynı zamanda stresli ya da baskı altındaki durumlarda performanslarını iyileştirmelerine de katkı sağlamaktadır. Bu yönüyle biyogeribildirim, fizik tedavi süreçlerinde etkili bir araç olarak değerlendirilmektedir. Biyogeribildirim sistemleri genellikle kalp atım hızı, cilt sıcaklığı, beyin aktivitesi, solunum hızı ve kas gerginliği gibi çeşitli fizyolojik parametreleri ölçmektedir. Elde edilen veriler, bireylere anlık olarak görsel, işitsel ya da dokunsal yollarla iletilmekte ve bireylerin bu verilere dayalı bilinçli kararlar almaları sağlanmaktadır. Böylece, kontrolün doğrudan kullanıcıya aktarılması sağlanmakta ve bireyin öz bakım süreçlerinde aktif rol alması mümkün hâle gelmektedir. Bu alandaki literatür incelendiğinde, biyogeribildirim klinik ve davranışsal uygulamadaki yerini araştıran çok sayıda çalışma bulunmaktadır. Aşağıda, bu kapsamda yapılan bazı önceki çalışmalar özetlenmiştir.

Sie ve Hannaford tarafından yürütülen bu çalışma, diz altı ampute bireylerin merdiven inişi sırasında karşılaştıkları hareket kısıtlılıklarını ve geri bildirim eksikliğini ele almayı amaçlamaktadır. Bu doğrultuda, MÖ ve dokunsal geribildirim teknolojilerini kullanan akıllı adım adlı giyilebilir bir cihaz geliştirilmiştir. Cihaz; ayakkabı tabanına yerleştirilen bir kuvvet sensörü ve bir atalet sensöründen oluşan veri toplama birimi ile uyluk veya bileğe takılan dokunsal geri bildirim modülünden meydana gelmektedir. Çift Yönlü Uzun-Kısa Süreli Bellek (Bidirectional Long Short-Term Memory, BiLSTM) ağı kullanılarak sensör verileri analiz edilmiş ve kullanıcının bir sonraki adımını nasıl atması gerektiğine dair ipuçları üretilmiştir. Bu ipuçları adımın uzatılması, kısaltılması veya mevcut pozisyonun korunması yönünde olabilmektedir. Modelin en uygun yapılandırması manuel ızgara arama yöntemiyle belirlenmiş, ancak LSTM algoritmasının

işlem süresinin gerçek zamanlı uygulamalar için yetersiz kalması önemli bir kısıt olarak belirtilmiştir (Sie, 2020).

Nunez ve arkadaşları tarafından gerçekleştirilen sistematik bir incelemede, alt ekstremitte amputasyonu olan bireylerde yürüyüş rehabilitasyonu amacıyla kullanılan biyolojik geribildirim sistemleri değerlendirilmiştir. Toplam 31 tam metin makalenin incelendiği çalışmada, en yaygın kullanılan biyolojik geribildirim türünün görsel geri bildirim olduğu, bunu işitsel ve dokunsal geri bildirim takip ettiği belirtilmiştir. Ancak işitsel ve dokunsal geri bildirim, uygulama açısından daha pratik olabileceği vurgulanmıştır. İnceleme, kullanıcı dostu biyolojik geribildirim sistemlerinin geliştirilmesini önermekte ve erken rehabilitasyonun önemine dikkat çekmektedir. Ayrıca, diz üstü amputelerin diz altı amputelere kıyasla daha belirgin yürüyüş bozuklukları sergilediği bildirilmiştir. Biyolojik geribildirim sistemlerinin geliştirilmesinde iki temel unsura vurgu yapılmıştır: sistemin doğruluğu ve kullanıcıya aşırı bilişsel yük getirmeyecek şekilde sade geri bildirim sunulması. Geri bildirim, kullanıcıyı yönlendiren ama karmaşık olmayan, anlaşılır ve rahatsız etmeyen biçimde sunulması gerektiği ifade edilmiştir. Çalışma ayrıca, biyolojik geribildirim sistemlerinde en sık hedeflenen parametrelerin uzuv yüklemesi, zemin reaksiyon kuvvetleri, simetri oranları, duruş ve adım süresi, kalça ve diz eklem açıları ile gövde salınımı olduğunu, bu parametrelerin öneminin amputasyon seviyesine bağlı olarak değişebileceğini ortaya koymuştur. (Escamilla-Nunez vd., 2020).

2.3. Yürüyüş Analizinde Makine Öğrenimi Uygulamaları

Yapay zekâ (YZ) alanındaki gelişmeler, özellikle tıp olmak üzere hemen hemen her alanda kullanılmaya başlanmıştır. Hastalardan veri toplanmasıyla birlikte YZ, hastalıkların tanınması ve tedavisi gibi görevlerde kullanılabilir. YZ'nin tıp alanında kullanıldığı alanlardan biride, alt ekstremitte amputasyonu olan bireylerin yaşam kalitesini iyileştirmede rehabilitasyon ve yardımcı teknolojiler alanındadır. Uygulamalar, yürüme yüzeylerine uyum sağlayan akıllı protez uzuvlardan, simetriyi, verimliliği ve anormallikleri değerlendirmek için giyilebilir sensörler ve MÖ modelleri kullanan yürüyüş analiz sistemlerine kadar uzanmaktadır. Bu teknolojiyi kullanarak ve giyilebilir teknoloji, anlık veri işleme ve YZ odaklı karar alma ile entegre ederek, rehabilitasyon sürecinde yalnızca tek bir çözümden ibaret olmayan, aynı zamanda akıllı sistemler geliştirilebilir. Bu bölümde, YZ'nin bu alandaki kullanımına odaklanan akademik çalışmalara yer verilmektedir.

Clark'ın "İnsan Destekleyici Biyomekaniği için Tahmini Modelleri Öğrenme" başlıklı çalışmasında, YZ ve MÖ'nün tam işlevli robotik protezlerin geliştirilmesindeki rolü vurgulanmaktadır. Araştırmada, bir sonraki adımı tahmin edebilen ve protez cihazının mekanik hareketlerini kullanıcının doğal hareketleriyle uyumlu hâle getiren bir MÖ modeli geliştirilmiştir. Bu sayede cihazın ergonomisi ve kullanılabilirliği artırılmıştır. Veri toplamak amacıyla, atalet sensörleri ve zemin reaksiyon kuvvetlerini ölçen sensörler kullanılmış; beş katılımcının verileri birleştirilerek tek bir birleşik model oluşturulmuştur. Çalışma, topuk teması ve parmak ucu kalkışı gibi olayların analizde kritik olduğunu ortaya koymuş, adım tahmini için elde edilen modelin Ortalama Mutlak Hata değerinin 1,5 dereceden düşük olduğunu göstererek yüksek doğruluk sağlamıştır. Modeldeki hata kaynaklarının, biyomekanik modellemedeki eksiklikler ve yumuşak dokuların neden olduğu sensör verisi bozulmalarına dayandığı belirtilmiştir. Sistemin sensör düşmesi ve çevresel gürültüye karşı dayanıklı olacak şekilde tasarlanması, modelin güvenilirliğini artırmıştır. Ancak çalışmanın sınırlılıkları arasında, farklı zemin koşulları için verilerin manuel olarak etiketlenme gerekliliği ve gerçek dünya uygulamaları açısından veri toplama sürecinin zahmetli olması yer almaktadır (Clark, 2023).

"İvmelenme zaman serilerine dayalı yaşa bağlı yürüyüş sınıflandırması için derin öğrenme modellerini açıklama" başlıklı çalışmada Zheng ve arkadaşları açıklanabilir yapay zekânın insan yürüyüş analizi üzerindeki uygulanabilirliğini incelemiştir. Bu çalışmanın temel amacı, yetişkinler ile yaşlı yetişkinler arasında yürüyüşe dayalı sınıflandırmayı değerlendirmektir. Araştırmada, yaşlanmanın kas kütlelerinde azalma, kemik yoğunluğunun düşmesi ve yürüyüş paternlerinde değişikliklere yol açtığı belirtilmiş; dolayısıyla yaşa dayalı yürüyüş sınıflandırmasının mümkün olduğu ortaya konulmuştur. Çalışma, sağlık hizmetlerinde otomatik karar verme süreçlerinin açıklanabilirliğini artırmayı hedeflemiştir. MÖ modellerindeki şeffaflık eksikliği, araştırmacıları sağlık uygulamalarında açıklanabilir YZ yöntemlerini kullanmaya yöneltmiştir. Veri toplama sürecinde, 129 yetişkin ve 115 yaşlı yetişkinden, belin L3 segmentine yerleştirilen bir ivmeölçer aracılığıyla veriler elde edilmiştir. Katılımcılardan her biri üç dakikalık yürüme görevini tamamlamıştır. Sensör kurulumunun doğruluğu titizlikle kontrol edilerek verilerin güvenilirliği sağlanmış, ardından gürültü azaltma teknikleri ile ön işleme adımları gerçekleştirilmiştir. Elde edilen veriler eğitim, test ve doğrulama setlerine ayrılmış; ayrıca giriş sinyallerine genlik normalizasyonu uygulanmıştır. Modelleme aşamasında, sınıflandırma için Kapılı Tekrarlayan Birim (Gated Recurrent Unit, GRU) ve evrişimli sinir ağı mimarileri kullanılmış;

hiperparametre optimizasyonu Bayes optimizasyonu yöntemi ile gerçekleştirilmiştir. Modelin açıklanabilirliğini artırmak amacıyla, giriş değişkenlerinin çıktılar üzerindeki etkilerini değerlendirmek için SHAP (SHapley Additive Explanations) yöntemi kullanılmıştır. Elde edilen sonuçlara göre, evrişimli sinir ağı modeli %81,4 doğruluk oranına ulaşırken, GRU modeli %84,5 doğruluk göstermiştir (Zheng vd., 2023).

Alt ekstremitte hareket bozukluğu bulunan bireyleri hedef alan “Sensörlü bir uç kullanarak MÖ tabanlı yürüyüş anomalisi tespiti: bireyselleştirilmiş bir yaklaşım” başlıklı çalışmada, yazar insan yürüyüş performansındaki bozulmayı nörolojik hastalıklar ve yaşlanma süreçleri ile ilişkilendirmiştir. Bu doğrultuda, terapistlerin rehabilitasyon sürecinde karar verme mekanizmalarını destekleyecek teknolojik çözümler önerilmiştir. Araştırma kapsamında, kişisel yardımcı cihazlara veya koltuk değneklerine entegre edilebilecek sensörlü bir uç geliştirilmiş ve bu uç kullanılarak yürüyüş verilerinin toplanması yoluyla anormal yürüyüş desenlerinin tespiti amaçlanmıştır. Geliştirilen sensörlü uç; bir kuvvet sensörü, bir barometre ve bir atalet sensöründen oluşmaktadır. Katılımcılardan düz çizgide yürüme görevleri esnasında veri toplanmıştır. Uygulanan metodoloji üç temel aşamadan oluşmaktadır: özellik oluşturma, özellik çıkarımı ve sınıflandırma. Araştırmacı, bireyselleştirilmiş bir model oluşturmak amacıyla, her bireye özgü veriler kullanarak destek vektör makinesi tabanlı bir anomali tespit modeli geliştirmiştir. Özellik seçimi sürecinde, veri fazlalığını azaltmak ve modelin verimliliğini artırmak amacıyla korelasyon analizi ve rastgele orman yöntemleri kullanılmıştır. Model, ortalama olarak %87,5 doğruluk oranına ulaşmıştır (Otamendi vd., 2023).

Mundt ve arkadaşları tarafından yayımlanan makale, yürüyüş kinematiği ve kinetiğini tahmin etmek için yapay sinir ağı tekniklerinin farklı yaklaşımlarını incelemektedir. German Sport University Cologne tarafından sağlanan veri seti, retro-reflektif işaretleyiciler kullanılarak toplanmıştır; bu işaretleyiciler, 116 katılımcının pelvis, uyluk ve kaval kemiklerine yerleştirilmiştir. Çalışmada, çok katmanlı algılayıcı, LSTM, evrişimsel sinir ağı ve önceden eğitilmiş bir evrişimli sinir ağı modeli kullanılarak transfer öğrenme olmak üzere dört farklı yapay sinir ağı modeli değerlendirilmiştir. Doğrulama yöntemi olarak bir deneyi dışarıda bırak kullanılmış (LOSO, leave-one-subject-out) ve farklı yapay sinir ağlarının modellerinin tahmin performanslarını karşılaştırmak için kök ortalama kare hatası metriği uygulanmıştır. Tüm modeller 40 epoch boyunca eğitilmiş ve sonuçlar, sıfırdan oluşturulan evrişimli sinir ağı modelinin diğer modellere kıyasla en iyi performansı sergilediğini göstermiştir (Mundt vd., 2021).

2.4. Atalet Sensörlerin Biyomekaniklerdeki Rolü

Atalet sensörleri, yalnızca akıllı ve giyilebilir cihazlarda değil, sağlık alanında da önemli bir kullanım alanına sahiptir. Küçük boyutları ve uygun maliyetleri sayesinde yüksek kullanılabilirlik ve güçlü performans sunmaktadır (Hutabarat vd., 2021). Özellikle yürüyüş tespiti çalışmalarında literatürde en yaygın kullanılan sensör türü olup, bu alandaki uygulamaların %67'sinde tek başına, %77'sinde ise diğer sensörlerle birlikte kullanıldığı bildirilmiştir (Prasanth vd., 2021). Aşağıda, atalet sensörlerinin kullanımına ilişkin literatürde yer alan bazı çalışmalara yer verilmektedir.

Hwang ve a tarafından gerçekleştirilen “Eklem Bozukluğunu Göz Önünde Bulundurarak Atalet sensörler ile Makine Öğrenmesi Tabanlı Anormal Yürüyüş Sınıflandırması” başlıklı çalışma, yaşlılar ve alt ekstremitte bozuklukları nedeniyle rehabilitasyon görenlerde yürüyüş sınıflandırmasını incelemiştir. Atalet sensörleri ve yürüyüş yolu sistemleri kullanılarak, diz veya ayak bileği destekleriyle eklem bozuklukları simüle edilen 10 sağlıklı bireyden veri toplanmıştır. Atalet sensörler uyluk ve baldırlara yerleştirilmiş, yürüyüş yolu sistemi ise ayak basıncı ölçülmüştür. Katılımcılar normal, diz destekli ve ayak bileği destekli yürümüş; 50 Hz örnekleme hızıyla, açısal, uzaysal-zamansal ve simetri metrikleri dahil 25 parametre elde edilmiştir. Destek vektör makineleri, rastgele orman ve aşırı gradyan artırma sınıflandırıcıları kullanılarak atalet sensör tabanlı sistem, farklı yürüyüş tiplerini %91'in üzerinde doğrulukla sınıflandırmış fakat yürüyüş yolu sistemi ise eklem bozukluklarını ayırt etmede daha düşük performans göstermiştir (Hwang vd., 2024).

Jacob S. ve arkadaşları tarafından hazırlanan “Spor Hekimliğinde Atalet Sensörleri Tabanlı Giyilebilir Cihazların Faydaları: Anlatsal Bir İnceleme” başlıklı çalışmada, atalet sensörlerinin spor ve tıp alanındaki uygulamaları ele alınmıştır. Son on yılda bu sensörlerin doğruluğu ve teknolojik gelişiminde önemli ilerlemeler kaydedildiği, özellikle zıplama, zemin teması, eklem hareketleri, gövde rotasyonu ve yüzme gibi çeşitli sportif aktivitelerde etkin biçimde kullanıldıkları belirtilmiştir. Sporculardaki hareketlerin değerlendirilmesinde yüksek verimlilik sağladıkları ifade edilmiştir. Bu gelişmeler, sensörlerin akıllı mobil cihazlarla entegrasyonu sayesinde hız kazanmış ve üretici firmaları sensör doğruluğunu artırmaya teşvik etmiştir. (Arlotti vd., 2022).

Miguel ve arkadaşları tarafından gerçekleştirilen çalışmada, yürüyüş döngüsünün topuk vuruşu, düz taban, topuk kaldırma ve salınım aşamalarından oluşan dört aşamasının tespiti incelenmiştir. Nörolojik rahatsızlığı olan bireylere destek olmayı hedefleyen bu çalışma, yalnızca sagittal düzlemde tek bir ataletsel sensörü kullanılarak

gerçekleştirilmiştir. Atalet sensörü ayak tabanına yerleştirilmiş, referans veri toplamak için kuvvete duyarlı dirençler kullanılmıştır. On sekiz katılımcı (9 sağlıklı, 9 hasta) en az 180 saniye koşu bandında yürümüş; sensör örnekleme hızı 100 Hz olmuştur. Veriler ön işlemeye tabi tutulduktan sonra, Eşik Tabanlı ve Gizli Markov Modeli yöntemleriyle sınıflandırma yapılmıştır. Çevrimdışı analiz için MATLAB, gerçek zamanlı işleme için Raspberry Pi 3 Model B kullanılmıştır. Modellerin performansı “zaman farkı” ve “Öklid mesafesi” ile değerlendirilmiş; Gizli markov modeli, eşik tabanlı modele kıyasla anlamlı derecede daha iyi performans göstermiştir (Manchola vd., 2019).

Kılıç tarafından gerçekleştirilen çalışma, insan aktivitesinin tanınması alanına katkı sağlamaktadır. Her ne kadar sağlık odaklı olmasa da, vücuda yerleştirilen atalet sensörlerden elde edilen verilerle kişi tanımlaması yapılmıştır. Çalışmada, UCI veri tabanından alınan ve sekiz kişiye ait ivmeölçer, jiroskop ve manyetometre verilerini içeren veri seti, 19 farklı insan aktivitesini sınıflandırmak amacıyla kullanılmıştır. Bu doğrultuda 1D-LBP ve 1D-FbLBP adlı iki yeni öznelik çıkarım yöntemi önerilmiş, özellikle 1D-FbLBP ile rastgele orman algoritması kullanılarak %91,83 doğruluk elde edilmiştir. Ayrıca, çoklu sensör verilerinin birlikte değerlendirilmesinin, tekil sensör verilerine kıyasla daha yüksek performans sağladığı gözlemlenmiştir. Ek olarak, derin öğrenme yaklaşımlarıyla sensör sinyallerinden görüntüler üretilmiş ve bu görüntüler üzerinden ResNet tabanlı transfer öğrenme yöntemi kullanılarak başarılı kişi tanıma sonuçları elde edilmiştir. Bulgular, transfer öğrenmenin sensör verilerinden anlamlı öznelikler çıkarmada etkili bir yöntem olduğunu göstermektedir. (Kılıç, 2021).

2.5. Yürüyüş Verileri için Özellik Çıkarma Teknikleri

Çoğu durumda, YZ modellerini eğitmek amacıyla toplanan veriler doğrudan modele girdi olarak kullanılmaz; bunun yerine, modelin hedeflenen amaca daha uygun çalışmasını sağlamak için ön işlemden geçirilir. Özellik çıkarma süreci, verilerin daha anlamlı ve verimli hale getirilmesini amaçlayarak filtreleme ve boyut indirgeme gibi teknikleri içerir. Bu işlem yalnızca modelin performansını artırmakla kalmaz, aynı zamanda verilerin yorumlanabilirliğini ve içgörü potansiyelini de güçlendirir. Aşağıda sunulan literatür incelemeleri, bu sürecin YZ uygulamalarındaki önemini ortaya koymaktadır.

Balaji E. ve arkadaşları tarafından gerçekleştirilen çalışma, Parkinson hastalığının evrelerini belirlemeye yönelik bir yaklaşım sunmaktadır. Çalışmada, hastaların yürüyüş verilerini toplamak amacıyla 100 Hz örnekleme hızına sahip, sekiz adet dikey zemin

reaksiyon kuvvet sensörü içeren giyilebilir bir cihaz kullanılmıştır. Açık erişimli 279 yürüyüş kaydından oluşan veri seti analiz edilmiş; ortalama, medyan ve standart sapma gibi istatistiksel ölçümlerle Parkinson hastalarında daha yüksek varyans gözlemlenmiştir. Kinematik analizle adım süresi, duruş süresi, salınım süresi gibi zamansal; adım uzunluğu ve genişliği gibi mekânsal özellikler belirlenmiş ve yürüyüş verimliliğini yansıtan salınım-duruş oranı hesaplanmıştır. Hastalığın evrelendirilmesi için karar ağacı, destek vektör makinesi, topluluk sınıflandırıcı ve bayes sınıflayıcı algoritmaları kullanılmış; modeller doğruluk, duyarlılık, özgüllük, pozitif öngörü değeri ve F-skoru gibi performans metrikleriyle değerlendirilmiştir. En başarılı sonuçlar karar ağacı ve destek vektör makinesi modelleriyle elde edilmiştir. Ancak çalışmanın sınırlılığı, yalnızca motor verilerle sınırlı kalması olup, gelecekte farklı klinik veya bilişsel özelliklerin de eklenmesi gerektiği belirtilmiştir (Balaji vd., 2020).

Timilehin B. ve arkadaşları tarafından yürütülen çalışmada, yürüyüş verileri kullanılarak bireylerin yaşa bağlı yürüyüş kalıplarına göre çocuk, yetişkin ve yaşlı olmak üzere üç gruba ayrılması amaçlanmıştır. Çalışmada, yürüyüş videolarından poz tahmini için AlphaPose yazılımı kullanılmış ve elde edilen eklem koordinatları ile güven puanları derin sinir ağları aracılığıyla analiz edilmiştir. Veriler, Z-puanı normalizasyonu ile gürültü azaltılarak işlenmiş ve yalnızca tek kişinin yer aldığı video segmentleri manuel olarak ayrılmıştır. Toplam 439 bireyin yaş ve cinsiyet etiketli verileri üzerinde, poz tahminiyle elde edilen grafiklerden yürüyüşün uzamsal ve zamansal özellikleri çıkarılmıştır. Yaş tahmininde, kısmen uyarlanabilir kalıntı grafik evrimsel sinir ağı adlı özel bir derin öğrenme modeli kullanılmış ve %99'a varan doğruluk elde edilmiştir. Otomatik öznitelik çıkarımı başarılı sonuçlar verirken, bazı özelliklerin manuel belirlenmesi yöntemin bazı uygulamalarda sınırlılıklarına işaret etmektedir (Aderinola vd., 2024).

3. KURAMSAL VE KAVRAMSAL ÇERÇEVE

3.1. Yürüme ve Biyomekanik Temelleri

Bu bölüm, biyomekanik bir bakış açısıyla yürüyüş analizinin temel prensiplerini ve yürüyüş sağlığına ilişkin temel kavramları açıklayarak insan yürüyüşünün karakteristik özelliklerine dair genel bir çerçeve sunmaktadır. Ayrıca, amputasyon perspektifinden bakıldığında, ampute bireylerin sınıflandırılması, kullanılan protez uzuv türleri ve bu araştırmanın odaklandığı protez sonrası dönemde, yürüyüşte meydana gelen sapmaların tespiti süreci ele alınmaktadır.

3.1.1. Yürüme döngüsü ve evreleri

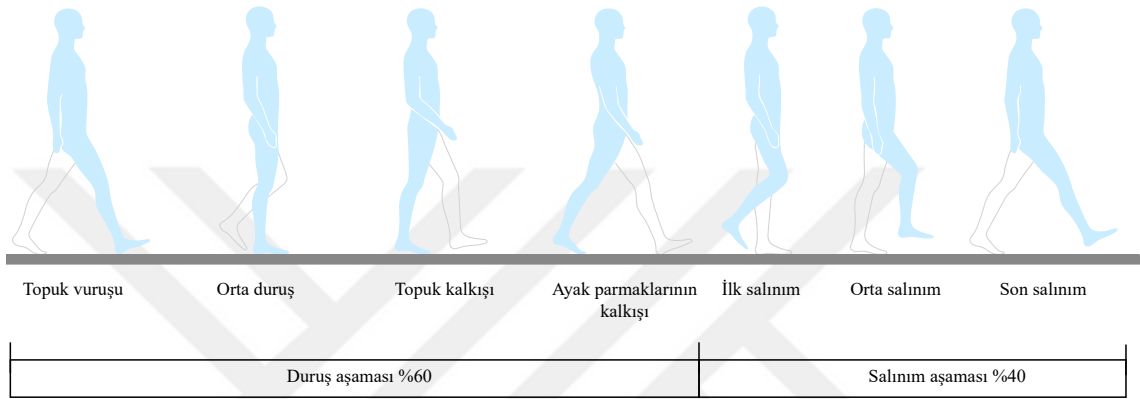
İnsan yürüyüş döngüsü, zamansal ve mekânsal bir karaktere sahip simetrik ve ardışık bir harekettir. Her döngü, her biri birkaç aşamaya sınıflandırılmış iki temel aşamadan oluşur:

1- Duruş aşaması: Bu, ayağın zemine temas ettiği aşamadır. Ayak ile zemin arasında etki eden kuvvetler genellikle kinetik hareket perspektifinden incelenir. Bu aşama, insan yürüyüş döngüsünün yaklaşık %60'ını oluşturur ve aşağıdaki aşamalara ayrılır:

- Topuk vuruşu: Bu, ayağın zemine ilk temasını temsil eder. Bu aşama, duruş aşamasının başlangıcını belirlemede önemli bir aşamadır. Ayakkabının tabanına topukta bir basınç sensörü takılarak veya hareket sensörlerinden alınan kinematik veriler analiz edilerek belirlenir.
- Orta duruş: Bu, bacağın düz olduğu ve yere dik bir çizgi oluşturduğu aşamadır. Bu aşamada, vücudun ağırlığı en yüksek seviyededir.
- Topuk kalkışı: Bu, orta duruş aşamasını takip eden aşamadır ve topuğun yerden kalkmaya başladığı andan itibaren ayağın yalnızca ön ucu yere temas edene kadar devam eder. Bu aşama, vücudun öne doğru hareket etmesini sağlar.
- Ayak parmaklarının kalkışı: Bu, topuk kalkışı aşamasından sonra başlar ve ayak parmaklarının yerden kalkmasıyla sona erer, ardından salınım aşaması gelir.

2- Salınım aşaması: Bu, ayağın salınım pozisyonunda olduğu duruş aşamasını takip eden aşamadır. Bu aşama, insan yürüyüş döngüsünün %40'ını oluşturur ve aşağıdaki aşamalara ayrılır:

- İlk salınım: Bu aşama ayağı yerden tamamen kaldırır, böylece vücudun ağırlığı tamamen diğer ayağa uygulanır.
- Orta salınım: Bu faz salınım fazının orta noktasında gerçekleşir, yani insan yürüyüş döngüsü %80 tamamlanmıştır.
- Son salınım: Bu, insan yürüyüş döngüsünün son aşamasıdır ve ayak parmakları yere değdiğinde sona erer. Bu noktada bir döngü tamamlanır ve yenisi başlar. Şekil 3.1.'de insan yürüyüş döngüsünü zaman içinde göstermektedir.



Şekil 3.1. İnsan yürüyüş fazlarının adım adım temsili.

3.1.2. Normal yürümenin biyomekaniği

Önceki paragrafta belirtilen yürüyüş evreleri belirli bir zamansal ve mekânsal standarda göre ayarlanırsa, yürüyüş normal kabul edilebilir. Yürüyüşün zamansal ve mekânsal özelliklerinde insanlar arasında ufak farklılıklar vardır, bu nedenle bazı çalışmalar her bireyin yürüyüşünü ayrı ayrı incelemeye odaklanmıştır (Otamendi vd., 2023).

Ayak bileği, diz ve kalça eklemlerinin uygun fleksiyonu, sırayla, uygun yürüyüşe yol açar. Duruş evresinde, başlangıçta kalça eklemi vücudun öne doğru hareket etmesini sağlamak için 30 derece fleksiyona gelir ve sonunda itme için 10 derece fleksiyona gelir. Diz eklemi, şoku emmek için Duruş evresinin başında 5-15 derece fleksiyona gelir ve salınım evresinde ayağı yerden kaldırmak için 60 dereceye kadar fleksiyona gelir. Ayak bileği eklemi, Duruş evresinin başında ayağın yerle temasını kontrol eder ve sonunda ileri itme sağlar. Bu çalışmada ayak bileği eklem fleksiyon açısını ölçmek için herhangi bir sensör takılmamıştır, ancak alt bacağın hareketinden dolaylı olarak çıkarım yapılabilmektedir.

3.1.3. Amputelerde yürüme anormalileri

Amputeler, genel biyomekanik sağlıklarını etkileyen çeşitli yürüyüş sapmaları sergiler. Bu yürüyüş sapmaları, protezin amputeye uyacak şekilde ayarlanmasıyla telafi edilir. Ancak, görsel olarak tespit edilemeyen ve klinik rehabilitasyondan sonra bile devam edebilen bazı yürüyüş sapmaları vardır. Bu yürüyüş sapmaları, geç tespit edilirse kaçınılmaz olabilen biyomekanik sağlıkta bozulmaya yol açar. Amputelerde yürüyüş sapmalarına katkıda bulunan çeşitli faktörler bulunmaktadır. Bunlardan bazıları aşağıda sıralanmıştır:

- Asimetri: Bu, sağlıklı uzuv ile protez uzuv arasındaki hareket farklılıklarını ifade eder.
- Değişen Duruş ve Salınım Evreleri: Protez uzuv, vücudun sağlıklı uzuva bağımlılığı nedeniyle daha kısa bir duruş evresine sahiptir.
- Atlama: Bu, protez uzvun salınım evresinde ilerlemesine yardımcı olmak için sağlıklı uzvun aşırı fleksiyonu anlamına gelir.
- Azaltılmış İtme: Bu, plantar fleksör kasların yokluğundan dolayı protez uzvun itme gücünün azalması anlamına gelir.
- Artan Gövde Eğimi veya Yanal Kayma: Bu, vücut dengesini sağlamak için vücudun gövdesinin protez bacağa doğru bükülmesini ifade eder.

3.2. Giyilebilir Sistemler ve Sensör Teknolojisi

3.2.1. Giyilebilir teknolojilerin gelişimi

Son yıllarda, akıllı saatlerden artırılmış gerçeklik cihazlarına kadar uzanan giyilebilir teknoloji alanında önemli gelişmeler yaşanmıştır. Bu cihazlar, kullanıcıyla anlık etkileşim kurarak bilinçli karar alımını destekleyen veriler sunmakta; özellikle sağlık alanında fizyolojik ve biyomekanik izleme imkânı sağlamaktadır. Bu teknolojinin hızlı gelişimi, mikroelektronik, sensör minyatürizasyonu, kablosuz iletişim ve veri işleme algoritmalarındaki ilerlemelere dayanmaktadır. Bununla birlikte, cihaz boyutları, yüksek güç tüketimi ve sınırlı veri analiz yetenekleri gibi bazı teknik zorluklar, yaygınlaşmasını kısıtlamaktadır. Ancak düşük güçlü mikrodenetleyiciler, esnek elektronik sistemler ve mikro-elektro-mekanik sistemler teknolojileri sayesinde, daha hafif ve düşük enerji tüketimli giyilebilir cihazların üretimi mümkün hâle gelmiştir. Bu gelişmeler sonucunda,

söz konusu cihazlar sağlık, spor bilimi, rehabilitasyon ve insan-bilgisayar etkileşimi gibi çeşitli alanlarda yaygın olarak kullanılmaktadır (Ng & Andrysek, 2023).

İnsan yürüyüş analizi bağlamında, giyilebilir cihazlar optik hareket yakalamaya dayanan geleneksel laboratuvar cihazlarının yerini almıştır. Örneğin, atalet sensörü tabanlı giyilebilir sistemler, açısal hız ve doğrusal ve açısal ivme gibi insan hareketine ilişkin sürekli veri sağlama kapasitesine sahiptir ve eklem hareket kalıplarına ilişkin kritik bilgiler sunar.


Donanım ve akıllı yazılımın bu birleşimi, giyilebilir sistemleri pasif veri kaydedicilerden aktif tanı ve geri bildirim araçlarına dönüştürmüştür.

3.2.2. Atalet sensörü

Atalet sensörü, açısal hız ve doğrusal ivme gibi kuvvetlerden bağımsız olarak fiziksel nesnelerin hareketinin geometrik yönlerini ölçebilen bir elektrikli cihazdır. Genellikle bir jiroskop, bir ivmeölçer ve manyometre içerir, ayrıca bazı modellerde yerçekimi sensörü bulunur (Şekil 3.2.).

- İvmeölçer: Bir nesnenin x , y ve z eksenleri boyunca doğrusal ivmesini ölçer.
- Jiroskop: Bir nesnenin x , y ve z eksenleri boyunca açısal hızını ölçer.
- Manyometre: Bir nesnenin Dünya'ya göre yönünü belirleyebilen x , y ve z eksenleri boyunca Dünya'nın manyetik alanını ölçer.

Bu cihaz, bir nesnenin zaman içindeki konumunu ve yönünü ölçmede önemli bir rol oynar. Ayrıca Kalman filtreleme veya Madgwick/Mahony filtreleri gibi sensör birleştirme algoritmalarını uygulayarak sistemin yönünü doğru bir şekilde ölçebilir. Biyomekanik ve giyilebilir yürüyüş analizi bağlamında, ataletsel sensörler taşınabilirlikleri, hafiflikleri, anlık hareket verilerini yakalama yetenekleri ve yüksek zamansal çözünürlükleri nedeniyle değerli, birçok çalışmada kullanılmıştır (Fan vd., 2021; Han vd., 2024; Marcos Mazon vd., 2022). Bu avantajlara rağmen, sensör kaymasına ve çevresel gürültüye karşı hassastırlar.



Şekil 3.2. Atalet sensörü bileşenleri

3.3. Yapay Sinir Ağları ve Derin Öğrenme Modelleri

3.3.1. Yapay sinir ağlarının temelleri

Yapay Sinir Ağları, MÖ'nün bir alt dalı olup, biyolojik nöronların işleyişinden esinlenerek geliştirilen bir hesaplama modelidir. Sınıflandırma, desen tanıma ve regresyon gibi görevleri yerine getirebilen YSA'lar, katmanlar hâlinde düzenlenmiş ve birbirine bağlı yapay nöronlardan oluşur. Geleneksel YZ modellerinden temel farkı, çok sayıda eğitilebilir parametreye (nöronlar arasındaki ağırlıklara) sahip olması sayesinde farklı boyutlardaki verilerle çalışabilmesidir. Düğüm sayısındaki artış, modelin veri içindeki karmaşık desenleri öğrenme yeteneğini artırır. Tipik bir YSA üç temel katmandan oluşur: giriş katmanı, gizli katman ve çıktı katmanı. Giriş katmanı verileri modele hazırlar; gizli katman, öğrenme sürecinde ağırlıkları optimize eder; çıktı katmanı ise modelin nihai tahminlerini sunar. Eğitim süreci, ileri yayılım adı verilen ve her nöronun çıktısını aktivasyon fonksiyonlarıyla hesaplayan aşamadan sonra, ağırlıkların güncellenmesini içeren geriye yayılım ile gerçekleştirilir. Bu süreçte sıkça kullanılan aktivasyon fonksiyonları arasında sigmoid, tanh, ReLU ve softmax yer almaktadır:

- Sigmoid: (0, 1) aralığında çıktı değerleri; ikili sınıflandırma için kullanışlıdır.

$$f(x) = \frac{1}{(1 + e^{-x})} \quad (3.1)$$

- Tanh (Hiperbolik Tanjant): (-1, 1) aralığında çıktı değerleri; sıfır merkezli.

$$f(x) = \frac{(e^x - e^{-x})}{(e^x + e^{-x})} \quad (3.2)$$

- ReLU (Düzeltilmiş Doğrusal Birim): Hesaplama verimliliği ve kaybolan gradyan sorunlarının azaltılması nedeniyle en yaygın kullanılanıdır.

$$f(x) = \max(0, x) \quad (3.3)$$

- Softmax: Logitleri olasılıklara dönüştürmek için çıktı katmanındaki çok sınıflı sınıflandırma problemlerinde kullanılır.

$$f(z_i) = \frac{e^{z_i}}{\sum_{j=1}^n e^{z_j}} \quad (3.4)$$

Modelin öğrenme süreci, geri yayılım adı verilen yinelemeli bir optimizasyon prosedürüne dayalı olarak ağırlıkların güncellenmesini içerir. Bu süreç dört temel aşamadan oluşur: İlk olarak ileri yayılım aşamasında, giriş verileri ağ boyunca ilerletilerek mevcut ağırlıklar kullanılarak çıktı değeri hesaplanır. Ardından, hata hesaplaması yapılır; bu aşamada, tahmin edilen çıktı ile gerçek çıktı arasındaki fark, genellikle ortalama karesel hata veya çapraz entropi kaybı gibi bir kayıp fonksiyonu ile ölçülür. Üçüncü aşamada, geri yayılım yöntemiyle hatalar çıkış katmanından giriş katmanına doğru katman katman dağıtılır; bu süreçte zincir kuralı kullanılarak her parametre için gradyanlar (türevler) hesaplanır. Son olarak, ağırlık güncelleme aşamasında bu gradyanlar kullanılarak her nöronun ağırlıkları ayarlanır (3.5). Hesaplama maliyetini azaltmak ve verimliliği artırmak amacıyla veriler genellikle mini gruplara ayrılır ve ağırlıklar her grup işlendiğinde güncellenir.

$$w_{new} = w_{old} - \eta \times \frac{\partial L}{\partial w} \quad (3.5)$$


Burada η öğrenme oranı ve $\frac{\partial L}{\partial w}$ gradyanı temsil eder.

3.3.2. Tekrarlayan sinir ağları

Tekrarlayan Sinir Ağları (Recurrent Neural Networks, RNN), ardışık veri veya zaman serileri üzerinde çalışabilen derin öğrenme modelleridir. Bu yapılar, her zaman adımında önceki bilgiyi yeniden işleyerek sıralı kalıpları öğrenebilir; böylece zamansal bağımlılıkları yakalayabilirler. Diğer yapay sinir ağlarından farklı olarak, sabit boyutlu giriş-çıkış varsayımına bağlı kalmaksızın değişken uzunlukta veri serilerini işleyebilirler(Wan vd., 2015). Bu özellikleri sayesinde konuşma tanıma, zaman serisi tahmini ve insan hareketi analizi gibi uygulamalarda yaygın olarak kullanılırlar. Örneğin Thu ve arkadaşları yapmış oldukları çalışmada, düz zemin yürüyüşü, ayakta durma,

merdiven çıkma ve inme gibi dört lokomasyon modu başarıyla sınıflandırılmıştır (Vu Thi Thu, 2023; S. Yu vd., 2023).

RNN'lerin en temel yapıtaşı, geçmiş bilgiyi taşıyan ve gelecekteki çıktılara katkı sağlayan gizli durum mekanizmasıdır. Model, girişe ait ağırlık matrisi W_{xh} ile önceki gizli duruma ait ağırlık matrisi W_{hh} kullanarak bu durumu günceller; böylece her bir zaman adımındaki çıktı, hem mevcut girdiye hem de önceki zaman adımındaki bilgiye bağlı olarak üretilir. Şekil 3.3.'de temel bir RNN modelini göstermektedir.



Şekil 3.3. Tekrarlayan sinir ağı (RNN) mimarisi.

Matematiksel olarak, t zamanındaki gizli durum h_t aşağıdaki gibi hesaplanır:

$$h_t = \sigma(W_{hh}h_{t-1} + W_{xh}x_t + b_h) \quad (3.6)$$

y_t Çıktısı aşağıdaki gibi hesaplanır:

$$y_t = \sigma(W_{hy}h_t + b_y) \quad (3.7)$$

Burada:

x_t : t zaman adımındaki girdi

h_{t-1} : Önceki zaman adımından gizli durum

W_{xh}, W_{hh}, W_{hy} : Ağırlık matrisleri

b_h, b_y : Sapma vektörleri

y_t : t zaman adımında çıktı

σ : Aktivasyon fonksiyonu (genellikle tanh, sigmoid veya ReLU kullanılır)


Yukarıdaki denklemler, bir RNN modelinin çıktısını t zamanında hesaplamasının ileri beslemeli sürecini açıklar. Eğitim sürecine zaman içinde geri yayılım denir. Geleneksel sinir ağı eğitiminden daha karmaşıktır çünkü tüm zaman adımları için gradyanları hesaplamayı gerektirir, bu da daha fazla işlem gücü tüketir ve paralel hesaplamada uygulanması zordur. Ancak, zaman içinde geri yayılım çıktındaki hata oranını hesaplamayı ve ardından bunu t_1 'den T 'ye kadar olan zaman adımlarına geri yaymayı içerir. Tekrarlayan ağ her adımda aynı ağırlık matrislerini kullandığından, zaman içinde geri yayılım uzun vadeli bağımlılıkların öğrenilmesini engelleyen kaybolan ve patlayan gradyan sorunlarına karşı hassastır (Y. Yu vd., 2019). Bu sorunu ele almak için LSTM ve GRU gibi daha gelişmiş mimariler geliştirilmiştir (Hewamalage vd., 2021).

3.3.3. LSTM, GRU ve BiLSTM yapılarının karşılaştırılması

Tekrarlayan sinir ağları, zaman adımlarında bir bellek biçimini koruyarak ardışık verileri işlemek üzere tasarlanmıştır. Ancak, geleneksel RNN'ler, uzun vadeli bağımlılıkları öğrenme yeteneklerini engelleyen kaybolan ve patlayan eğimler gibi sorunlardan mustarıdır. Bu sınırlamaları gidermek için, en dikkat çekenleri LSTM, GRU ve BiLSTM olmak üzere birkaç kapılı mimari tanıtılmıştır.

- **Uzun Kısa Süreli Bellek (LSTM):** Hochreiter ve Schmidhuber (1997) tarafından tanıtılan LSTM ağları, standart RNN'lerdeki kaybolan eğim sorununu aşmak için özel olarak tasarlanmıştır. LSTM mimarisi, hücre durumuna giren ve hücreden çıkan bilgi akışını düzenleyen bir bellek hücresi ve üç geçit mekanizması sunar: giriş kapısı, unutma kapısı ve çıkış kapısı.
 - Giriş Kapısı: Yeni girdinin ne kadarının hücreye yazılması gerektiğini belirler.
 - Unutma Kapısı: Önceki hücre durumu bilgilerinin ne ölçüde saklanması veya atılması gerektiğini kontrol eder.
 - Çıktı Kapısı: Hücre durumunun hangi kısmının geçerli zaman adımında çıktı olarak verilmesi gerektiğine karar verir.

Bu kapılar, LSTM'nin uzun menzilli bağımlılıkları sürdürmesini ve zaman adımları boyunca bilgileri seçici olarak hatırlamasını veya unutmasını sağlar ve bu da onu çeşitli dizi öğrenme görevleri için etkili hale getirir. Şekil 3.4. LSTM mimarisini, içsel geçit mekanizmaları ve bellek hücresiyle birlikte şematik olarak tasvir etmektedir.



Şekil 3.4. Uzun Kısa Süreli Bellek (LSTM) hücresi mimarisi.

Burada:

$$\text{Unutma Kapısı: } f_t = \sigma(W_f x_t + R_f h_{t-1} + b_f)$$

$$\text{Giriş Kapısı: } i_t = \sigma(W_i x_t + R_i h_{t-1} + b_i)$$

$$\text{Aday Hücre Durumu: } g_t = \sigma(W_g x_t + R_g h_{t-1} + b_g)$$

$$\text{Çıkış Kapısı: } o_t = \sigma(W_o x_t + R_o h_{t-1} + b_o)$$

$$\text{Hücre Durumu Güncelleme: } c_t = f_t \odot c_{t-1} + i_t \odot g_t$$

$$\text{Gizli Durum: } h_t = o_t \odot \tanh(c_t)$$


$$\text{Çıktı: } y_t = \sigma_y(W_{hy} h_t + b_y)$$

- **Kapılı Tekrarlayan Birim (GRU):** Cho ve diğerleri (2014) tarafından önerilen GRU, hücre durumu ve gizli durumu birleştiren ve unutma ve giriş kapılarını tek bir güncelleme kapısında birleştiren LSTM'nin basitleştirilmiş bir çeşididir. Ayrıca, geçmiş bilgilerin ne kadarının unutulacağını kontrol eden bir sıfırlama kapısı da sunar.
 - Güncelleme Kapısı: Önceki belleğin ne kadarının geleceğe aktarılması gerektiğini belirler.
 - Sıfırlama Kapısı: Yeni durumu hesaplarken önceki durumun ne kadarının unutulacağını kontrol eder.

Basitleştirilmiş mimarisi nedeniyle GRU, birçok görevde karşılaştırılabilir performans elde ederken LSTM'den hesaplama açısından daha verimlidir. Özellikle

hesaplama kaynakları sınırlı olduğunda veya nispeten daha küçük veri kümeleri üzerinde eğitim yapıldığında faydalıdır.

Şekil 3.5. GRU mimarisini, güncelleme ve sıfırlama geçitleri aracılığıyla bilgi akışını düzenleyen yapısıyla birlikte şematik olarak tasvir etmektedir.



Şekil 3.5. Gated Recurrent Unit (GRU) hücresi mimarisi.

Burada:

$$\text{Güncelleme Kapısı: } z_t = \sigma(W_z x_t + R_z h_{t-1} + b_z)$$

$$\text{Sıfırlama Kapısı: } r_t = \sigma(W_r x_t + R_r h_{t-1} + b_r)$$

$$\text{Aday Gizli Durum: } g_t = \tanh(W_g x_t + R_g (r_t \odot h_{t-1}) + b_g)$$

$$\text{Gizli Durum Güncelleme: } h_t = (1 - z_t) \odot h_{t-1} + z_t \odot g_t$$

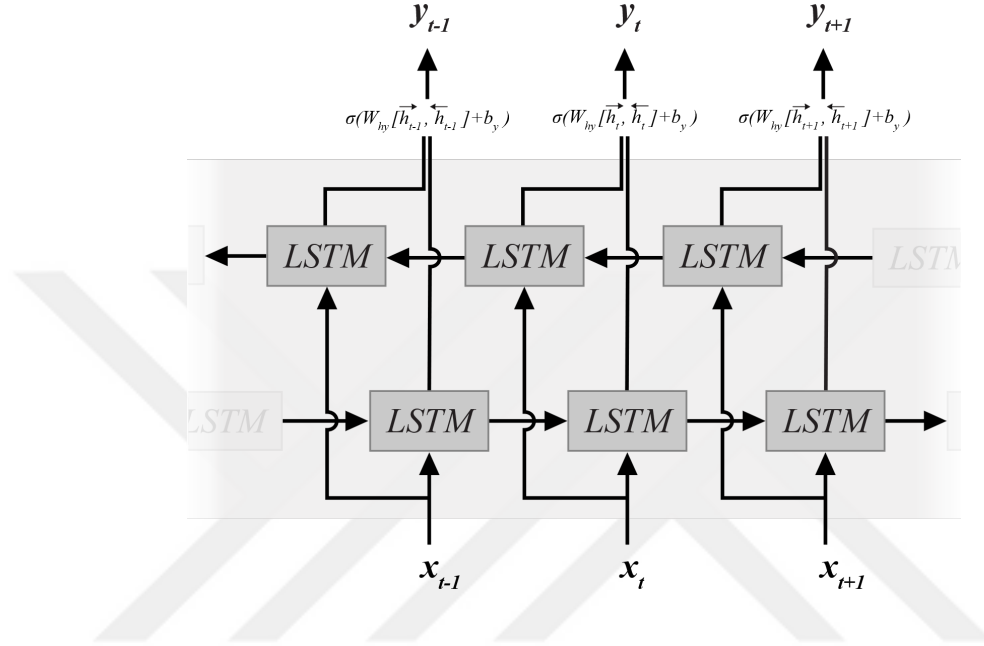
$$\text{Çıktı: } y_t = \sigma_y(W_{h_y} h_t + b_y)$$

- **Çift Yönlü Uzun Kısa Süreli Bellek (BiLSTM):** BiLSTM, iki ayrı LSTM katmanını birleştirerek LSTM'yi genişletir: biri giriş dizisini ileri yönde, diğeri geri yönde işler. Daha sonra her iki yönden gelen çıktılar, genellikle birleştirme yoluyla birleştirilir.

Bu iki yönlü işleme, ağın dizideki her nokta için hem geçmiş (geri) hem de gelecek (ileri) bağlamına erişmesine olanak tanır.

BiLSTM, tüm dizinin mevcut olduğu ve her iki yönden gelen bağlamsal bilgilerin performansı artırdığı görevlerde, örneğin konuşma tanıma, makine çevirisi ve biyomedikal sinyal analizinde özellikle faydalıdır.

Şekil 3.6. girdi dizisini hem ileri hem de geri yönde işleyen iki ayrı LSTM katmanından oluşan BiLSTM mimarisini şematik olarak tasvir etmektedir.



Şekil 3.6. Yığılmış Çift Yönlü Uzun Kısa Süreli Bellek (BiLSTM) mimarisini.

Model, LSTM'deki gibi aynı şekilde hesaplanır, ancak çıktı hesaplaması farklıdır.

Burada:

$$\text{İleri LSTM Gizli Durumu: } \vec{h}_t = LSTM_{\text{İleri}}(x_t, \vec{h}_{t-1})$$

$$\text{Geri LSTM Gizli Durumu: } \vec{h}_t = LSTM_{\text{Geri}}(x_t, \vec{h}_{t+1})$$

$$\text{Birleştirme: } h_t = [\vec{h}_t, \vec{h}_t]$$

$$\text{Çıktı Hesabı: } y_t = \sigma(W_{hy}h_t + b_y)$$

BiLSTM, yalnızca geçmiş değil gelecekteki girdilere de erişebildiği için özellikle doğal dil işleme, zaman serisi ve konuşma tanıma gibi görevlerde daha yüksek başarı sağlar.

Bu modellerin mimari farklılıklarının uygulama performanslarına ve hesaplama gereksinimlerine nasıl yansıdığını daha iyi anlayabilmek için, LSTM, GRU ve BiLSTM yapılarını bazı temel açılardan karşılaştırmak faydalı olacaktır. Çizelge 3.1.'de bu üç

modelin kapı yapıları, bellek kullanımı, hesaplama karmaşıklığı, eğitim süresi ve uygulama uygunluğu gibi çeşitli yönlerden karşılaştırması sunulmuştur.

Çizelge 3.1. LSTM, GRU ve BiLSTM modellerinin temel farklarının karşılaştırması

Özellik	LSTM	GRU	BiLSTM (Çift Yönlü LSTM)
Kapılar	Giriş, Unutma, Çıkış	Güncelleme, Sıfırlama	LSTM ile aynı (iki yönde çalışır)
Bellek Hücresi	Var	Yok	Var (ileri ve geri LSTM içerir)
Karmaşıklık	Yüksek	Daha düşük	LSTM'den daha yüksek (çift yönlü yapıdan ötürü)
Eğitim Süresi	Daha uzun	Daha hızlı	En uzun
Performans	Yüksek	LSTM'ye benzer	Genellikle daha üstün (daha zengin bağlam sağlar)
Uygunluk	Uzun vadeli bağımlılıklar	Verimli sıralı öğrenme	Bağlam farkındalığı gerektiren görevler

3.3.4. Derin öğrenme ile sınıflandırma

MÖ algoritmalarının sağlık alanındaki en kritik kullanım alanlarından biri, teşhisi zor olan hastalıkların tespiti ve tanılanmasıdır (Javaid vd., 2022).

Sınıflandırma görevleri, sinir ağlarının temel görevlerinden biridir. Sinir ağı modeli girdiyi işler ve önceden tanımlanmış sınıflara göre sınıflandırır. Giriş verileri, doğrusal olmayan dönüşümler uygulayan modelin birkaç katmanından geçer. Bu işlem, verilerde hemen belirgin olmayan desenleri algılayarak, yüksek doğrulukla sınıflandırma görevlerini gerçekleştirmesini sağlar. Aşağıdakiler de dahil olmak üzere birkaç sınıflandırıcı mimarisi vardır:

- Tam bağlantılı sinir ağları: Bunlar, önceden çıkarılmış özelliklere sahip yapılandırılmış veriler üzerindeki sınıflandırma görevlerine uygulanır.
- Evrişimli sinir ağları: Bunlar genellikle yerel özellikleri çıkarabilen bir evrişimli filtre uyguladıkları 2B verileri işlemek için kullanılır. Ayrıca, zaman serileri gibi tek boyutlu veriler için de uygulamaları vardır, ancak bu daha az yaygındır.
- Tekrarlayan sinir ağları: Bunlar, zamansal bağımlılıkları modelleyebildikleri için öncelikle sıralı veya zaman serisi veri sınıflandırması için kullanılır. Bu çalışmada, üç çeşit RNN uygulanmıştır.
- Transformatör tabanlı mimariler: Paralelleştirilebilir yapıları ve dikkat mekanizmaları nedeniyle doğal dil işleme ve diğer alanlarda giderek daha fazla kullanılmaktadır.

Sinir ağı modelleri verileri beş aşamada işler. İlk aşama veri hazırlama, veri normalleştirme ve temizleme ile sınıf hazırlamayı içerir. Daha sonra model, atanan göreve uyacak şekilde tasarlanır. Bu, parametre ince ayarı ve çapraz doğrulamayı içeren veriler üzerinde eğitimi içerir. Daha sonra doğrulama gerçekleştirilir ve aşırı öğrenmeyi önlemek için performans ayrı bir doğrulama kümesinde izlenir. Daha sonra, modeli daha önce eğitilmemiş veriler üzerinde test eden değerlendirme ve test başlar. Daha sonra doğruluk, kesinlik, F1-Skoru ve karışıklık matrisi gibi ölçütleri kullanarak genelleme yeteneğini değerlendirir.

3.3.5. Eğitim, doğrulama ve test kavramlarının rolü

Bir sinir ağı modelinin eğitilmesi süreci, öncelikle eğitim, doğrulama ve test veri kümelerinin kullanımını içerir. Bu aşamalar, modelin daha genel ve kapsamlı veri kümelerine genelleştirilebilmesini sağlamak için modeli iyileştirir ve modelin eğitim verilerini ezberlemediğinden emin olur. Bu üç aşama, özellikle sınıflandırma için LSTM ağlarının kullanıldığı sıra modelleme görevlerinde, model geliştirme yaşam döngüsünde önemli bir rol oynar.

- Eğitim Aşaması: Eğitim aşaması, LSTM modelinin, giriş, unutma ve çıkış kapılarıyla ilişkili ağırlıklar dahil olmak üzere, önceden tanımlanmış bir kayıp fonksiyonunu en aza indirmek için iç parametrelerini yinelemeli olarak ayarladığı temel öğrenme aşamasıdır. Optimizasyon, genellikle Adam veya RMSprop gibi gradyan iniş varyantlarını kullanır ve çok sınıflı sınıflandırma durumunda kategorik çapraz entropi kaybını en aza indirmeyi amaçlar. Çıktıdaki hatayı hesaplamak için genellikle Kök Ortalama Kare Hata (Root Mean Square Error, RMSE) (3.8) ve Ortalama Kare Hata (Mean Square Error, MSE) (3.9) kullanılır; bu fonksiyonlar, istenen çıktı ile gerçek çıktı arasındaki farkı ölçen hata metrikleridir.

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3.8)$$

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (3.9)$$

- Doğrulama Aşaması: Doğrulama aşaması, model seçimi ve hiperparametre ayarı için gereklidir. Eğitim sırasında modelin performansını değerlendirmek için ayrı bir alt küme kullanılır ancak gradyan güncellemelerinden hariç tutulur. Bu aşama, her bölümde modelin tarafsız bir değerlendirmesini sağlayarak aşırı uyum veya yetersiz uyum davranışını belirlemeye yardımcı olur.
- Test Aşaması: Test aşaması, modelin genelleme yeteneklerinin tamamen görülmemiş bir veri kümesi üzerinde nihai, nesnel değerlendirmesini sunar. Model ayarını etkileyebilecek doğrulama kümesinin aksine, test kümesi eğitim ve hiperparametre seçimi sırasında dokunulmadan kalır. Bu kümede bildirilen performans ölçümleri, modelin gerçek dünyadaki uygulanabilirliğinin göstergesi olarak kabul edilir. Sınıflandırma bağlamında, yaygın ölçümler şunları içerir:

- Hassasiyet, modelin pozitif olarak tahmin ettiği örneklerden kaçının gerçekten pozitif olduğunu ölçer.

$$Hassasiyet = \frac{TP}{(TP + FN)} \quad (3.10)$$

- Özgüllük, modelin negatif sınıfı doğru bir şekilde tanımlama yeteneğini ölçer.

$$Özgüllük = \frac{TN}{(FP + TN)} \quad (3.11)$$

- Kesinlik, aslında doğru olan pozitif tanımlamaların oranını ölçer.

$$Kesinlik = \frac{TP}{(TP + FP)} \quad (3.12)$$

- F1-Skoru, kesinlik ve hatırlamanın harmonik ortalamasıdır ve bu iki ölçütü dengeler.

$$F1-Skoru = \frac{2(Precision \times Recall)}{(Precision + Recall)} \quad (3.13)$$

- Doğruluk, modelin tüm tahminler genelindeki genel doğruluğunu ölçer.

$$Doğruluk = \frac{(TP + TN)}{(TP + TN + FP + FN)} \quad (3.14)$$

Burada:

- Gerçek Pozitif (TP), anormal veri noktasının anormal olarak doğru şekilde sınıflandırıldığını gösterir.
- Gerçek Negatif (TN), normal veri noktasının normal olarak doğru şekilde sınıflandırıldığını gösterir.

- Yanlış Pozitif (FP), normal veri noktasının anormal olarak yanlış şekilde sınıflandırıldığını gösterir.
- Yanlış Negatif (FN), anormal veri noktasının normal olarak yanlış şekilde sınıflandırıldığını gösterir.



4. YÖNTEM VE UYGULAMA SÜRECİ


Bu bölümde, giyilebilir bir insan yürüyüş analiz sistemi geliştirme sürecine ilişkin metodoloji ayrıntılı olarak açıklanmaktadır. Süreç, atalet sensörler ve mikrodenetleyicinin hazırlanmasıyla başlayıp giyilebilir yapılandırma, anlık veri toplama ve veri iletimi ile sensör kalibrasyon adımlarıyla devam etmektedir. Ardından, elde edilen veriler derin öğrenme modelleriyle analiz edilmek üzere işlenmekte ve LSTM, GRU ve BiLSTM modelleriyle eğitilmek üzere doğrulama ve test kümelerine ayrılmaktadır. Tüm bu adımların temel amacı, insan yürüyüş anomalilerini doğru ve sağlam bir şekilde tespit ederek dört ayrı sınıfa ayırmaktır.

4.1. Giyilebilir Cihazın Hazırlanması

İnsan yürüyüşünü analiz etmeye yönelik geliştirilen giyilebilir sistemin donanım seçimi, fiziksel yerleşimi ve kablosuz veri iletimi süreçleri bu bölümde detaylandırılmıştır.

4.1.1. Donanım bileşenlerinin seçimi

- **Atalet Sensörü:** BN0055, üç eksenli 14 bit ivmeölçer, ± 2000 derece/saniye aralığında üç eksenli 16 bit jiroskop, üç eksenli jeomanyetik sensör ve Bosch Sensortec'in sensör füzyon yazılımını çalıştıran 32 bitlik Cortex M0+ mikrodenetleyiciyi tek bir pakette birleştiren bütünleşmiş bir sistemdir. Sensörlerin ve sensör füzyonunun tek bir cihazda birleşmesi, özellikle giyilebilir donanım gibi uygulamalarda entegrasyonu kolaylaştırarak geliştirme süresini ve karmaşıklığını azaltır. Şekil 4.1.A cihazın fiziksel boyutlarını, Şekil 4.1.B ise mikrodenetleyicilerle bağlantıyı sağlayan elektronik bileşenleri içeren GY-BNO055 breakout kartını göstermektedir.



Şekil 4.1. BNO055 atalet sensörü (A) fiziksel boyutları ve eksen yönelimi, (B) bir baskılı devre kartı (PCB) üzerindeki görünümü.

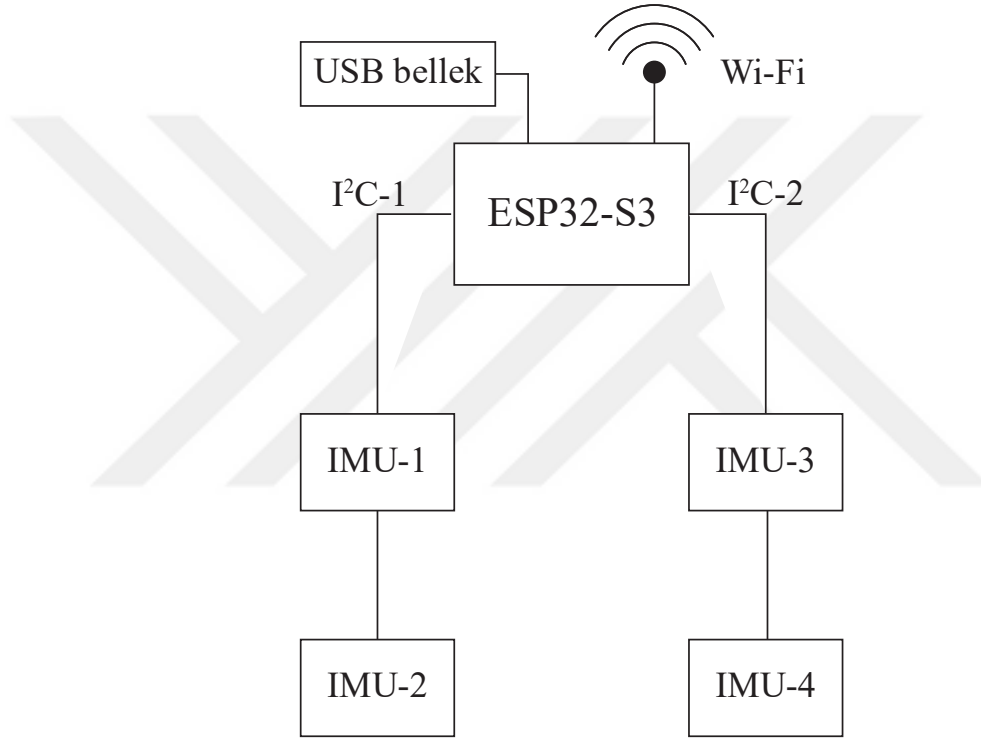
Çizelge 4.1, bu çalışmada kullanılan BNO055 sensörüne ait teknik özellikleri özetlemektedir.

Çizelge 4.1. BNO055 sensörünün teknik özellikleri

Özellik	Açıklama / Değer
Sensör Tipi	9 eksenli mutlak yönelim sensörü (İvmeölçer + Jiroskop + Manyetometre)
Sensör Füzyonu	Dahili 32-bit Cortex M0+ MCU ile Bosch Sensortec füzyon algoritması
İvmeölçer Ölçüm Aralığı	$\pm 2g / \pm 4g / \pm 8g / \pm 16g$
Jiroskop Ölçüm Aralığı	$\pm 125 / \pm 250 / \pm 500 / \pm 1000 / \pm 2000$ derece/saniye (dps)
Manyetometre Ölçüm Aralığı	$\pm 1300 \mu T$ (X, Y eksenini), $\pm 2500 \mu T$ (Z eksenini)
Arayüz	I ² C ve UART (yapılandırılabilir)
Çalışma Modları	Config, AccOnly, MagOnly, GyroOnly, AMG, IMU, Compass, M4G, NDOF, NDOF_FMC_OFF
Güncelleme Hızı	Moda bağlı olarak 100 Hz'e kadar
Kalibrasyon	Otomatik ve manuel kalibrasyon desteklenmektedir


- **Mikrodenetleyici:** ESP32-S3, Espressif Systems tarafından geliştirilen güçlü ve çok yönlü bir mikrodenetleyicidir. Modern gömülü sistemlerin taleplerini karşılamak üzere tasarlanmıştır. YZ hızlandırılmalı çift çekirdekli Xtensa® 32-bit LX7 işlemciye sahiptir. ESP32-S3'ün temel avantajlarından biri, iki sensörün tek bir porta bağlanmasına izin veren ve her sensör arasındaki iletişim için adres değiştirme yükünü azaltan iki I²C portu da dahil olmak üzere zengin bütünleşmiş çevre birimleri setidir. Ek olarak, mikrodenetleyici yerel USB OTG (On-The-Go) işlevselliğini

destekler, yüksek hızlı veri aktarımını etkinleştirir, bu da onu yürüyüş verilerini depolamak için harici bir USB belleği bağlamak için uygun bir seçenek haline getirir. Dahili Wi-Fi (802.11 b/g/n) desteği, ESP32-S3'ün kablosuz bağlantı yeteneklerini geliştirerek, Anlık sistemlerde güvenilir ve hızlı veri iletimi için uygun bir platform sunmaktadır. Bu özelliği sayesinde, bu çalışmada önerilen sistemin gerçekleştirilmesinde ESP32-S3 mikrodenetleyicisi uygun bir tercih olarak öne çıkmaktadır. Şekil 4.2, mikrodenetleyicinin diğer sistem bileşenleriyle olan bağlantı yapısını şematik olarak göstermektedir.



Şekil 4.2. Yürüyüş verisi toplamak için tasarlanmış giyilebilir cihazın mimarisi.

Dört atalet sensörü, I²C protokolü üzerinden kablolu mikrodenetleyiciye bağlanmıştır. Veriler, TCP protokolü üzerinden kablosuz ağ aracılığıyla bilgisayara gönderilmiştir. Şekil 4.3, ortada mikrodenetleyici ve dört sensör bulunan giyilebilir sistemi göstermektedir.

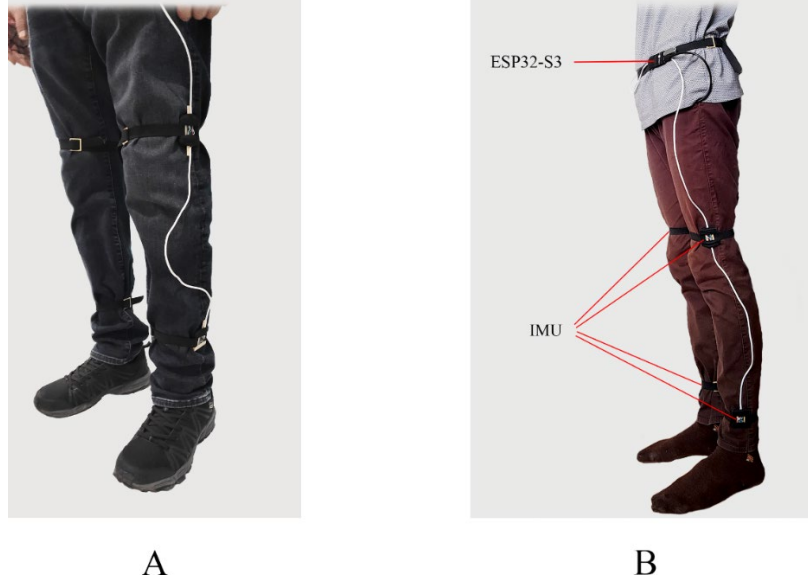


Şekil 4.3. Yürüyüş verisi toplamak için geliştirilen giyilebilir cihazın prototipi.

4.1.2. Sensörlerin bacaklara yerleştirilmesi

Sensörler, alt ekstremite segmentlerinin hareketini doğru şekilde izlemek amacıyla uyluk ve baldır bölgelerine stratejik olarak yerleştirilmiştir. Bu yerleşim, yürüyüşün duruş ve salınım evrelerinde segmental ivme ve açısal hız ölçümünü mümkün kılar. Sensörlerin doğru hizalanması ve güvenli bir şekilde sabitlenmesi, hareket kaynaklı hataları azaltarak verilerin uzuv hareketini doğru yansıtmasını sağlar. Seçilen konumlar, yürüyüş dinamiklerini analiz etmek, anormallikleri tespit etmek ve MÖ ile sınıflandırma yapmak için gerekli kinematik verileri sağlamaktadır.

Şekil 4.4, sensörlerin nasıl yerleştirildiğini göstermekte olup, A kısmında ampute bireylerin, B kısmında ise sağlıklı bireylerin uzuvlarına uygulanan sensör yerleşim yöntemleri sunulmaktadır.



Şekil 4.4. Geliştirilen giyilebilir cihazın (A) Ampute birey ve (B) Sağlıklı birey üzerindeki konumu.

4.1.3. Veri iletimi hazırlığı

Kullanılan sensörler hem otomatik hem de manuel kalibrasyon yeteneklerine sahiptir. Ancak, mevcut çalışmada manuel kalibrasyon uygulaması mümkün olmadığından, sensörler otomatik kalibrasyon modunda çalıştırılmıştır. Her sensör, üç eksenle jiroskop ve üç eksenle doğrusal ivme verisi olmak üzere altı veri üretmektedir. Dört sensörün eş zamanlı kullanımı sonucunda, toplamda 24 özellik içeren ve zaman damgasıyla desteklenen bir veri seti elde edilmektedir. Ölçülen veriler ya USB bellek üzerine kaydedilmekte ya da anlık analiz amacıyla doğrudan bir bilgisayara aktarılmaktadır. Veri iletiminin doğruluğunu ve sürekliliğini göstermek amacıyla her çalışma modunda bir LED göstergesi kullanılmaktadır.


4.2. Veri Toplama

Bu çalışmada, katılımcılar kontrollü yürüme koşulları altında karakteristik yürüyüş modellerini temsil edecek şekilde seçilmiştir. Deneylere toplam on kişi katılmış ve iki gruptan oluşmaktadır: beş sağlıklı kişi ve beş tek taraflı transtibial (diz altı) amputasyonu olan kişi.

Her katılımcı, standart yüzey koşulları altında, özellikle eğim veya basamak olmayan düz zeminde, yaklaşık 300 metre uzunluğunda belirlenmiş bir yolda yürümüşlerdir. Her yürüyüş seansı katılımcı başına yaklaşık beş dakika sürmüştür. Toplamda, sağlıklı bireylerden yaklaşık 25 dakikalık yürüyüş verisi toplanmış ve alt ekstremité amputasyonu olan bireylerden eşdeğer bir süre kaydedilmiştir. Bu dengeli veri

toplama işlemi sağlıklı ve ampute sınıf arasında güvenilir karşılaştırmalı analiz yapılmasını kolaylaştırmıştır.

Kapsamlı bir insan yürüyüş kalıpları yelpazesini yakalamak için iki ayrı yürüyüş protokolü kullanılmıştır. İlk protokol, kısa ve düz bir yol boyunca gidip gelme şeklinde yürümeyi içeren bir protokoldür (Şekil 4.5.A). Bu yöntem, tipik iç mekân yürüyüş koşullarını simüle ederek, sık sık başlama-durma geçişleriyle doğrusal hareket sırasında yürüyüş verilerinin toplanmasını sağlamıştır. İkinci protokol, katılımcıların dönüşleri de içeren daha doğal yürüme desenlerini elde edebilmek amacıyla oval biçimli bir yolda sürekli olarak yürümeleridir (Şekil 4.5.B). Bu yaklaşım, gerçek dünya ortamlarında denge ve koordinasyonu değerlendirmek için kritik olan dönüş ve kavisli yürüyüş gibi yön değişiklikleri sırasında yürüyüş dinamiklerini yakalamak için tasarlanmıştır (Ur Rehman vd., 2019). Bu iki yöntemi birleştirerek, çalışma hem doğrusal hem de doğrusal olmayan yürüyüş yörüngelerini kapsamayı ve böylece yakalanan yürüyüş verilerinin sağlamlığını ve geliştirilebilirliğini artırmayı amaçlamıştır.



Şekil 4.5. Yürüyüş protokolleri: (A) Düz çizgide yürüme ve (B) Oval yürüme.

- **Ham Verileri Kaydetme:** Yürüyüş ölçümlerinin bütünlüğünü, erişilebilirliğini ve kronolojik sırasını sağlamak için, tüm ham sensör verileri doğrudan yapılandırılmış bir dosya biçiminde flaş belleğe kaydedilmiştir. Depolama sistemi, minimum gecikme ve güvenilir zaman damgasıyla anlık veri kaydını desteklemek üzere tasarlanmış ve bu sayede son işlem sırasında yürüyüş dizilerinin hassas zamansal analizi sağlanmıştır.
- **Flaş Bellek ve Dosya Yapısı:** Her atalet sensörü tarafından toplanan, üç eksen boyunca doğrusal ivme ve açısal hız dahil ham veriler, flaş belleğe sırayla yazılmıştır. Veri kaydı protokolü, hızlı yazma işlemlerini ve bellek alanının verimli kullanımını sağlayan kompakt ve tutarlı bir CSV biçimini izlemiştir. Her veri kaydı, otomatik olarak eklenen bir zaman damgasıyla birlikte tüm aktif kanallardan gelen sensör okumalarını içermektedir. Veriler, zamana bağlı olarak sıralanmış bir zaman serisi yapısında organize edilmiştir; bu yapı, yürüyüş sekanslarının analitik olarak doğrusal ve tutarlı bir biçimde yeniden oluşturulmasını mümkün kılmıştır.
- **Otomatik Zaman Damgası Ekleme:** Her bir veri girişine, sistemin gerçek zamanlı saati temel alınarak, veri yakalama anında otomatik olarak bir zaman damgası atanmıştır. Bu uygulama, sensör verilerinin yüksek doğrulukla senkronize edilmesini sağlamış ve birden fazla atalet sensöründen elde edilen verilerin zaman açısından hizalanmış biçimde analiz edilmesini mümkün kılmıştır. Zaman damgalama mekanizması, veri toplama sürecinde gecikmeleri en aza indirmek amacıyla örnekleme iş parçacığından bağımsız şekilde çalışacak biçimde yapılandırılmıştır. Tüm zaman damgaları, oturum başlangıcına göre milisaniye cinsinden kaydedilmiş olup, yürüyüş döngülerinin zamansal dinamiklerinin ayrıntılı biçimde incelenebilmesi için yeterli zaman çözünürlüğü sunmuştur.

Çizelge 4.2., flaş belleğe kaydedilen bir atalet sensörüne ait altı veri girişinin yapısını göstermektedir. CSV dosya, tüm sensörlerdeki kayıtlı özelliklerin tam setini içeren ve her zaman damgası için 24 ayrı veri girişinden oluşmaktadır. Ancak, burada yalnızca yedi temsilî alan örnek olarak sunulmuştur.

Çizelge 4.2. Ham sensör verilerine ait alanlar ve örnek değerler

Alan No.	Alan Adı	Veri Tipi	Açıklama	Örnek Değer
1	Zaman Damgası (ms)	uint32	Oturum başlangıcından itibaren geçen süre (milisaniye)	15320
2	İvme_X (m/s ²)	float	X eksenini doğrultusunda doğrusal ivme	0,18
3	İvme_Y (m/s ²)	float	Y eksenini doğrultusunda doğrusal ivme	-9,62
4	İvme_Z (m/s ²)	float	Z eksenini doğrultusunda doğrusal ivme	0,91
5	Jiroskop_X (°/s)	float	X eksenini doğrultusunda açısal hız	2,34
6	Jiroskop_Y (°/s)	float	Y eksenini doğrultusunda açısal hız	-1,17
7	Jiroskop_Z (°/s)	float	Z eksenini doğrultusunda açısal hız	0,09

Bu yapı, her bir veri girişinin sonraki segmentasyon, senkronizasyon ve MÖ süreçleri için gerekli tüm bilgileri eksiksiz biçimde içermesini sağlamaktadır.

4.3. Verilerin Ön İşlenmesi

Ön işleme, giyilebilir sensörlerden elde edilen ham eylemsizlik verilerinin temiz, anlamlı ve sonraki MÖ görevleri için uygun olmasını sağladığı için yürüyüş analizinde kritik bir adımdır. Bu bölüm, gürültüyü azaltmak, sensör verilerini normalleştirmek ve zaman serisi kayıtlarını anlamlı dizilere bölmek için kullanılan çeşitli teknikleri ayrıntılı olarak açıklamaktadır.

- **Sensör Düzeltme ve Eksen Hizalaması:** BNO055 sensörlerinden elde edilen veriler, sol ve sağ uyluk ve baldırdan gelen 3 eksenli jiroskop ve ivmeölçer sinyallerini içerir. Ön işleme sırasında, sol uyluk ve baldırdan gelen X eksenini verileri, tüm uzuvlar boyunca hareket yönünde tutarlılığı sağlamak için ters çevrilmiştir. Bu eksen düzeltme işlemi, özellikle sağlıklı ve ampute bireylerin yürüme desenlerinin karşılaştırmalı analizinde, veri temsili açısından simetrisinin korunmasını sağlamak adına kritik bir öneme sahiptir (Çizelge 4.3.).

Çizelge 4.3. Sol bacak sensörlerinden elde edilen verilerde uygulanan simetri düzeltmeleri

Sensör Konumu	Sinyal Adı	Uygulanan İşlem
Sol Uyluk	Açısal Hız - X Eksen (rps)	İşaret Tersleme ($\times -1$)
Sol Uyluk	Doğrusal İvme - X Eksen (m/s ²)	İşaret Tersleme ($\times -1$)
Sol Baldır	Açısal Hız - X Eksen (rps)	İşaret Tersleme ($\times -1$)
Sol Baldır	Doğrusal İvme - X Eksen (m/s ²)	İşaret Tersleme ($\times -1$)

- **Bant Geçiren Filtreleme:** Yüksek frekanslı gürültüleri ve düşük frekanslı kaymaları ortadan kaldırmak amacıyla, kesim frekansları 0,5–10 Hz. arasında olan ikinci dereceden Butterworth bant geçiren bir filtre uygulanmıştır. Bu frekans bandı, yürüme dinamiklerini etkili bir şekilde yakalarken, alakasız hareket kaynaklı bozulmaları ve temel sapmaları bastırmada oldukça etkilidir (Tiwari & Joshi, 2020).

Filtreleme işlemi aşağıdaki şekilde tanımlanır:

$$[b, a] = \text{butter}(2, [f_{low}, f_{high}]/(f_s/2), \text{bandpass}) \quad (4.1)$$

Parametreler:

$f_{low} = 0,5$ (Alt kesim frekansı)

$f_{high} = 10$ (Üst kesim frekansı)

$f_s = 50$ (Örnekleme frekansdır)

Çok değişkenli zaman serisi sinyallerine bu filtreyi uygulamak için MATLAB'da `idfilt()` fonksiyonu kullanılmıştır.

- **Normalizasyon:** Tüm özelliklerin öğrenme sürecine eşit şekilde katkıda bulunmasını sağlamak için, filtrelenmiş sinyaller z-puanı normalizasyonu kullanılarak normalize edilmiştir:

$$X_{\text{norm}} = \frac{X - \mu}{\sigma} \quad (4.2)$$

Burada:

X : sinyalin ham değeri

σ : Verinin ortalaması

μ : Verinin standart sapması

Bu ölçekleme yaklaşımı, her sensör kanalını sıfır ortalama ve birim varyansa standartlaştırır.

- **Segmentasyon ve Zaman Serisi Dönüşümü:** Veriler gürültüden arındırılıp normalize edildikten sonra, sürekli akışı öğrenilebilir dizilere dönüştürmek için sabit uzunlukta pencereleme bölünmüştür. Her bir zaman serisi kaydı, her biri $5 \times f_s$ örnekleme adımı içeren sabit uzunlukta, 5 saniyelik segmentlere ayrılmıştır. Bu pencereleme süresi, yürüyüş döngülerinin zamansal olarak yeterli düzeyde temsil edilmesini sağlarken, analiz için gerekli olan çözünürlükle de dengeli bir yapı sunmaktadır (Hu vd., 2021). Pencere uzunluğu, literatürde önerilen aralıklar dikkate

alınarak ve deneysel gözlemler temel alınarak belirlenmiştir. Bu yaklaşım hem sağlıklı hem de ampute bireylerin yürüyüş karakteristiklerinin anlamlı şekilde karşılaştırılabilmesi için uygun bir zaman ölçeği sunar.

- **Örtüşmeli Pencereleler:** Veri çeşitliliğini artırmak ve eğitim verisinin boyutunu genişletmek amacıyla, her biri 4 saniyelik örtüşmeye sahip pencereleler oluşturulmuştur. Bu kayan pencere yaklaşımı, segment sınırlarında bilgi kaybını önleyerek modelin genelleme kabiliyetini artırmaktadır. Örtüşmeli pencereleme işlemi, MATLAB ortamında `buffer()` fonksiyonu kullanılarak gerçekleştirilmiştir. Bu işlemde kullanılan parametreleler aşağıdaki gibidir:

Pencere Boyutu: 5 saniye (250 örnek)

Örtüşme Süresi: 4 saniye (200 örnek)


Adım Boyutu: 1 saniye (50 örnek)

Bu yöntem, derin öğrenme modelleri özellikle RNN için uygun, yeterli bir veri temsili elde edilmesini sağlar. Her bir segment, modelin beklediği giriş formatıyla uyumlu hale gelmesi için transpoze edilerek hücre dizileri içinde depolanmaktadır. Bu yapı, zaman serisi verilerinin ardışık yapısını korurken modelin öğrenme kapasitesini maksimize etmeyi hedefler.

Sinyalin her iki ucundan 15 saniyelik bölüm, sensör yerleştirme, deneğin hazırlanması gibi analizle ilgisi olmayan hareketleri ortadan kaldırmak amacıyla kesilmiştir.

Bu bölümde sunulan ön işleme aşamaları, giyilebilir atalet sensörlerinden elde edilen yürüyüş verilerinin tutarlı, gürültüsüz ve model eğitimi için uygun formatta olmasını sağlamaktadır. Uygulanan bant geçiren filtreleme, normalizasyon ve örtüşmeli pencereleme gibi teknikler, yürüyüşe özgü kritik hareket dinamiklerinin korunmasına olanak tanırken, sağlam öznitelik çıkarımı için gerekli yapıyı da oluşturmaktadır. Bu şekilde hazırlanan veri kümesi, yürüyüş sınıflandırması ve anomali tespiti gibi sonraki analiz adımları için güçlü bir temel oluşturmaktadır.

Şekil 4.6. ve Şekil 4.7., ham sinyallerin örnek temsillerini göstermektedir.



Şekil 4.6. Bir sağlıklı bireyden elde edilen sol uyluk jiroskop x-ekseni verisinin 5 saniyelik bölümü.

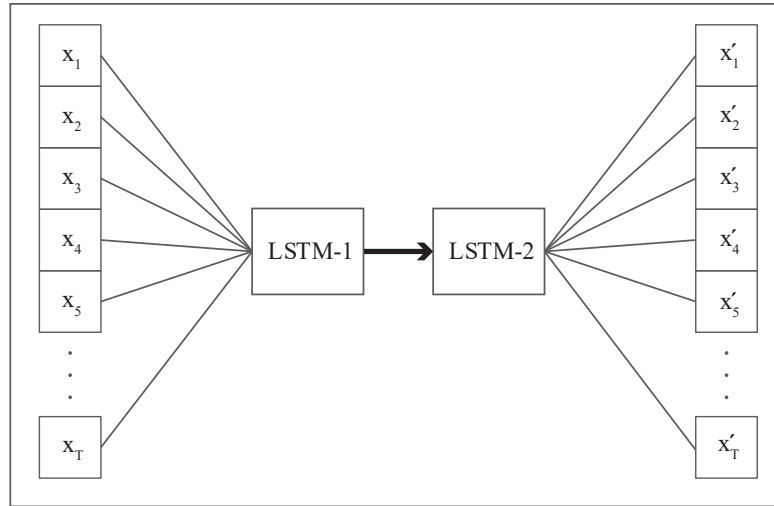


Şekil 4.7. Bir sağlıklı bireyden elde edilen jiroskop ve ivmeölçer verilerinin 5 saniyelik örnekleri: (A) Sol uyluk jiroskop, (B) Sol uyluk ivmeölçer, (C) Sol baldır jiroskop ve (D) Sol baldır ivmeölçer.

4.4. LSTM Tabanlı Yeniden Yapılandırma Hatası ile Veri Etiketleme

MÖ tabanlı yürüyüş analizinde, özellikle ampute olan kişiler ve sağlıklı bireyler gibi heterojen deneklerden elde edilen biyomedikal sinyallerle çalışırken, yüksek kaliteli etiketli veri elde etmek, en zorlu görevlerden biri olmaya devam etmektedir. Manuel etiketleme zaman alıcı olmakla kalmayıp, farklı değerlendiriciler arasında tutarsızlıklara yol açabilmektedir. Geleneksel eşik tabanlı yöntemler ise ardışık hareket verilerindeki zamansal bağımlılıkları yakalamakta yetersiz kalabilmektedir. Bu zorlukları aşmak amacıyla, LSTM katmanları kullanarak, bir otomatik kodlayıcı yapısını taklit eden derin öğrenme tabanlı yarı denetimli bir etiketleme yaklaşımı benimsenmiştir. Bu yöntem, yeniden yapılandırma hatasından yararlanarak, veri odaklı ve denetimsiz biçimde sağlıklı ve anormal yürüyüş kalıplarını etkili şekilde ayırt etmeyi mümkün kılmaktadır.

- **Modele Genel Bakış:** Genellikle otomatik kodlayıcı olarak adlandırılrsa da uygulamamız klasik otomatik kodlayıcı mimarilerinden farklıdır. Darboğaz temsili kullanan ayrı bir kodlayıcı-kod çözücü eşleştirmesi yerine, modelimiz, çıkış modu dizi olarak yapılandırılmış iki yığılmış LSTM katmanından oluşmaktadır (Şekil 4.8.). Model, her zaman adımında giriş dizisini yeniden yapılandıracak şekilde eğitilmekte ve böylece zamansal kısıtlamalar altında girdiyle kendi arasındaki dönüşümü öğrenmektedir. Son katman, girdi ile aynı sayıda özellik çıkışı veren tam bağlantılı bir katmandır ve sinir ağı, MSE fonksiyonu kullanılarak eğitilmektedir. Bu tasarımın temel mantığı, modelin yalnızca sağlıklı yürüyüş dizileri üzerinde eğitildiğinde, bu kalıplara iyi genelleme yapabilmesi; ancak anormal dizileri doğru şekilde yeniden yapılandıramaması ve dolayısıyla daha yüksek yeniden yapılandırma hataları üretmesidir.



Şekil 4.8. Yeniden yapılandırma hatasını elde etmek için kullanılan dizi-dizi (sequence-to-sequence) mimarisi.

- **Veri Hazırlığı ve Çapraz Doğrulama Stratejisi:** Modelin sağlamlığı ve genellenebilirliği sağlamak amacıyla, sağlıklı bireylerin veri seti K katlı çapraz doğrulama yöntemiyle 5 alt kümeye bölünmüştür. Her katmanda, bir alt küme doğrulama için ayrılırken kalan K-1 alt küme eğitim için kullanılmıştır. Bu yöntem, aşırı öğrenmenin önlenmesine yardımcı olmuş ve model performansının farklı örneklerde daha güvenilir şekilde değerlendirilmesini sağlamıştır.
- **Yeniden Yapılandırma Hatasının Hesaplanması:** Her katmanda model eğitildikten sonra hem sağlıklı doğrulama seti hem de ampute veri seti için tahminler yapılmıştır. Her dizi için yeniden yapılandırma hatası, gerçek ve tahmin edilen diziler arasındaki RMSE olarak hesaplanmış ve tüm zaman adımları ile özellikler üzerinden ortalanmıştır. Bu da sonraki sınıflandırma işlemleri için temel teşkil etmiştir.

Anomali tespiti için karar eşiği belirlemek amacıyla, sağlıklı doğrulama setinden elde edilen yeniden yapılandırma hatalarının ortalama ve standart sapması hesaplanmıştır. Eşik değeri şu şekilde tanımlanmıştır (Moore vd., 2009):

$$Eşik = \mu_{sağlıklı} + 2\sigma_{sağlıklı} \quad (4.3)$$

Bu istatistiksel olarak belirlenmiş eşik, sağlıklı örneklerin büyük çoğunluğunun altında kalmasını sağlarken, ampute bireyler gibi dinamikleri belirgin şekilde farklı olan örneklerin anormal olarak işaretlenmesine imkân tanımaktadır.

Eşiğe dayalı olarak, her diziye ikili bir etiket atanmıştır:

- Sağlıklı (Etiket = 0): Yeniden yapılandırma hatası < eşik
- Anormal (Etiket = 1): Yeniden yapılandırma hatası \geq eşik


Çizelge 4.4. dizi-dizi model ile yeniden yapılandırma hatasına dayalı sınıflandırma doğrulukları

Veri Kümesi	Toplam Örnek Sayısı	Doğru Sınıflandırılan	Doğruluk (%)
Sağlıklı	1575	1540	%97,70
Ampute	1600	1525	%95,30

Çapraz doğrulama işlemi tamamlandıktan sonra, öğrenme kapasitesini maksimize etmek amacıyla model tüm sağlıklı diziler üzerinde yeniden eğitilmiştir. Bu nihai model, tüm veri setinde değerlendirilmiş ve yeniden yapılandırma hataları hesaplanarak daha önce belirlenen eşikle karşılaştırılmıştır (Şekil 4.9.). Etiketleme performansı doğrulama aşamasıyla tutarlı kalmış ve modelin denetimsiz anomali algılayıcı olarak etkinliğini bir kez daha doğrulamıştır.

Çizelge 4.5. RMSE tabanlı anomali tespiti için eşik değeri ve grup istatistikleri

Metrik	Sağlıklı Ortalama	Ampute Ortalama	Std Sapma (Sağlıklı)	Eşik Değeri
Yeniden Yapılandırma Hatası	0,3	0,45	0,04	0,38



Şekil 4.9. Sağlıklı bireyler ve ampute bireyler için yeniden yapılandırma hatası dağılımının karşılaştırması.

Yeniden yapılandırma hataları hesaplanıp ikili etiketler atandıktan sonra, bu etiketler ve hata vektörleri, anomali dizileri daha ayrıntılı sınıflandırmak için bir kümeleme modeline beslenmiştir. Böylece, normal yürüyüşten düşük, orta ve yüksek

sapma gibi daha ince sınıflandırmalar yapılmış ve sonraki aşamalarda denetimli modeller için temel veri sağlanmıştır.

4.5. Denetimsiz Öğrenme ile Çok Sınıflı Etiket Üretimi

- **Aykırı Değerlerin İnterkuartil Aralık Yöntemi ile Elenmesi:** Denetimsiz kümeleme işleminden önce, ampute bireylerin yeniden yapılandırma hatalarındaki istatistiksel aykırı değerler filtrelenmiştir. Bu amaçla, interkuartil aralık (Interquartile Range) yöntemi kullanılmıştır. Yeniden yapılandırma hatası dağılımının 25. (Q1) ve 75. (Q3) yüzdilik değerleri hesaplanarak, interkuartil aralık değeri şu şekilde tanımlanmıştır (Moore vd., 2009):

$$IQR = Q3 - Q1 \quad (4.4)$$

Veri noktalarının, $[Q1 - 1,5 \times IQR, Q3 + 1,5 \times IQR]$ aralığının dışında kalması durumunda, söz konusu örnekler aykırı değer olarak sınıflandırılmış ve analiz dışı bırakılmıştır. Bu ön işleme adımı, sensör kaynaklı anomaliler veya aşırı sapma gösteren yürüyüş örneklerinin, izleyen kümeleme sürecini istatistiksel olarak bozmamasını sağlamıştır.

- **Ampute Yeniden Yapılandırma Hatalarının K-Ortalamlar (K-Means) ile Kümelenmesi:** Aykırı değerlerden arındırılmış ampute yeniden yapılandırma hataları, yürüyüş sapmalarındaki doğal gruplamaları ortaya çıkarmak amacıyla K-Ortalamlar algoritması ile kümelenmiştir. K-ortalamlar, sağlık alanındaki birçok çalışmada kullanılmaktadır (Eckhardt vd., 2023). Klinik değerlendirmelere ve ampute yürüyüşündeki çeşitliliğe dayanarak küme sayısı $k = 3$ olarak belirlenmiştir. Yerel minimumlara takılmayı önlemek ve yakınsamanın kalitesini artırmak için algoritma 10 tekrar ile çalıştırılmış ve maksimum iterasyon sayısı 500 olarak sınırlandırılmıştır. Benzerlik ölçütü olarak, zamansal ve biyomekanik verilere duyarlı olduğu gösterilmiş olan Manhattan uzaklık metriği tercih edilmiştir.

Küme merkezleri, ortalama yeniden yapılandırma hatalarına göre artan sırada sıralanmış ve her kümeye klinik anlam taşıyan şu etiketler atanmıştır: ‘Sağlıklı Benzeri’, ‘Hafif Sapmış’, ‘Sapmış’.

Bu işlem, yalnızca yeniden yapılandırma hatalarına dayanarak, ampute bireylerin yürüyüş örneklerinin klinik olarak anlamlı şekilde kategorize edilmesini mümkün kılmıştır.

- **Etiket Atama ve Sınıflandırma için Veri Hazırlığı:** Kümeleme işleminin ardından, her bir ampute örneğe, ait olduğu küme doğrultusunda bir sınıf etiketi atanmıştır. Bu etiketler, tamamı ‘Sağlıklı’ olarak etiketlenmiş kontrol grubundaki örneklerle birleştirilmiştir. Verilerin dengeli ve rastgele şekilde dağılması için tüm örnekler karıştırılmış ve %80 eğitim – %20 test oranında ayrılmıştır. Etiketler, denetimli sınıflandırma algoritmalarında kullanılmak üzere kategorik değişken biçiminde kodlanmıştır.

Bu işlem sonucunda, yeniden yapılandırma hatasına dayalı anomali tespiti problemi, çok sınıflı bir sınıflandırma problemine dönüştürülmüştür. Çizelge 4.6., sınıf bazında eğitim ve test veri kümesi dağılımını sunmaktadır.

Çizelge 4.6. Sınıf bazında eğitim-test veri kümesi dağılımı

Sınıf Etiketi	Toplam Örnek Sayısı	Eğitim Kümesi (%80)	Test Kümesi (%20)
Sağlıklı	500	400	100
Sağlıklı Benzeri	558	457	101
Hafif Sapmış	569	447	122
Sapmış	412	327	85
Toplam	2039	1631	408

4.6. Yürüyüş Verileri Üzerinde Derin Öğrenme Modelleri ile Yürüyüş Sınıflandırması

Önceden etiketlenmiş zaman serisi verilerine dayalı insan yürüyüşünün sınıflandırılması, amputasyon gibi yürüyüş bozukluklarının olduğu klinik senaryolarda bireylerin işlevsel durumuna dair kritik bilgiler sağlar. Bu bölümde, daha önceki kümeleme adımından elde edilen önceden etiketlenmiş yürüyüş desenlerini sınıflandırmak için derin öğrenme modelleri LSTM, GRU ve BiLSTM kullanılmıştır. Her model eğitilip değerlendirildikten sonra, en iyi performansı gösteren mimari üzerinde 5 katlı çapraz doğrulama uygulanarak sağlam genelleştirme performansı sağlanmıştır.

Bir önceki bölümde belirtildiği üzere, yürüyüş veri seti, ilgili özelliklerin çıkarılması için önceden işlenmiş ve yeniden yapılandırma kaybına dayalı denetimsiz bir kümeleme yaklaşımıyla etiketlenmiş zaman serisi verilerinden oluşmaktadır. Veri seti, 3175 örnek (250 zaman adımı ve 24 özellik) içermektedir. Kümelemeden türetilen etiketler, dört sınıfa ayrılmış farklı yürüyüş desenlerini temsil eder: Sağlıklı, Sağlıklı Benzeri, Hafif Sapmış ve Sapmış.

- **Model Mimarileri:** Her model, MATLAB'ın Derin Öğrenme Araç Kutusu kullanılarak uygulanmış olup, adil karşılaştırmalar için tutarlı giriş özellikleri ve hiperparametreler kullanılmıştır. Mimariler, yalnızca tekrarlayan katmanda (LSTM, GRU veya BiLSTM) farklılık gösteren ortak bir yapıya sahiptir. Genel mimari aşağıdaki gibidir:

1. Dizi Giriş Katmanı: [24, 250] boyutunda giriş dizilerini kabul eder; burada 24 özellik sayısı, 250 ise dizi uzunluğudur.
2. Tekrarlayan Katman: 128 gizli birim içeren LstmLayer, GruLayer veya BilstmLayer.
3. Dropout Katmanı: Aşırı öğrenmeyi önlemek için $p = 0,3$ olasılıkla dropout uygular.
4. Tam Bağlantılı Katman: Tekrarlayan katmanın çıktısını 4 sınıf puanına eşler.
5. Softmax Katmanı: Puanları sınıf olasılıklarına dönüştürür.
6. Sınıflandırma Katmanı: Çok sınıflı sınıflandırma için çapraz entropi kaybını hesaplar.

Verilen bir $x = [x_1, x_2, \dots, x_T]$ dizisi için matematiksel çıktı formülasyonu şu şekildedir:

$$h_T = f_{\text{recurrent}}(x; \theta_{\text{recurrent}}) \quad (4.5)$$

$$z = W_{fc}h_T + b_{fc} \quad (4.6)$$

$$p = \text{softmax}(z) = \frac{\exp(z)}{\sum_{j=1}^c \exp(z_j)} \quad (4.7)$$

$$\hat{y} = \arg \max_i p_i \quad (4.8)$$

Burada ($f_{\text{recurrent}}$) tekrarlayan katman fonksiyonu (LSTM, GRU veya BiLSTM), ($\theta_{\text{recurrent}}$) parametreleri, (W_{fc}) ve (b_{fc}) ise tam bağlantılı katmanın ağırlıkları ve sapmalarıdır; (\hat{y}) ise tahmin edilen sınıftır.

- **LSTM Tabanlı Yürüyüş Sınıflandırıcısı:** LSTM modeli, bellek hücreleri ve kapılar (unutma, giriş ve çıkış kapıları) kullanarak yürüyüş dizilerindeki uzun vadeli bağımlılıkları yakalamak için tasarlanmıştır. LSTM katmanı, giriş dizisini tek yönlü olarak işler ve son zaman adımında gizli bir durum (h_t) üretir (Çıkış Modu = 'son'). LSTM'nin denklemleri şöyledir:

$$f_t = \sigma(W_f[x_t, h_{t-1}] + b_f) \quad (4.9)$$

$$i_t = \sigma(W_i[x_t, h_{t-1}] + b_i) \quad (4.10)$$

$$o_t = \sigma(W_o[x_t, h_{t-1}] + b_o) \quad (4.11)$$

$$c_t = f_t \odot c_{t-1} + i_t \odot \tanh(W_c[x_t, h_{t-1}] + b_c) \quad (4.12)$$

$$h_t = o_t \odot \tanh(c_t) \quad (4.13)$$

Burada f_t , i_t , ve o_t sırasıyla unutma, giriş ve çıkış kapılarıdır; c_t , hücre durumudur ve σ , sigmoid fonksiyonudur.

- **GRU Tabanlı Yürüyüş Sınıflandırıcısı:** GRU modeli, bilgi akışını kontrol etmek için güncelleme ve sıfırlama kapılarını kullanan, LSTM'ye göre hesaplama açısından daha verimli bir alternatiftir. Daha az parametreye sahip olması, orta düzey karmaşıklıkta veri setleri için uygun olmasını sağlar. GRU denklemleri şöyledir:

$$r_t = \sigma(W_r[x_t, h_{t-1}] + b_r) \quad (4.14)$$

$$z_t = \sigma(W_z[x_t, h_{t-1}] + b_z) \quad (4.15)$$

$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tanh(W_h[x_t, r_t \odot h_{t-1}] + b_h) \quad (4.16)$$

Burada (r_t), sıfırlama kapısı, (z_t), güncelleme kapısıdır.

- **BiLSTM Tabanlı Yürüyüş Sınıflandırıcısı:** BiLSTM modeli, dizileri hem ileri hem de geri yönde işleyerek çift yönlü zamansal bağımlılıkları yakalar. Bu, geçmiş ve gelecek bağlamının sınıflandırma doğruluğunu artırabileceği yürüyüş analizi için özellikle önemlidir. BiLSTM, ileri ve geri gizli durumları birleştirir:

$$h_T^{forward} = f_{LSTM}^{forward}(x; \theta_{forward}) \quad (4.17)$$

$$h_T^{backward} = f_{LSTM}^{backward}(x; \theta_{backward}) \quad (4.18)$$

$$h_T = [h_T^{forward}, h_T^{backward}] \quad (4.19)$$

Birleştirilmiş gizli durum (h_T), tam bağlantılı katmana geçirilir ve çıktı boyutu $2H$ olarak iki katına çıkar.

- **Eğitim Yapılandırması:** Tüm modeller, uyarlanabilir öğrenme oranı nedeniyle derin öğrenme görevlerinde etkili olan Adam optimize edici kullanılarak eğitilmiştir. Modeller arasında tutarlı olan eğitim hiperparametreleri Çizelge 4.7.'de özetlenmiştir:

Çizelge 4.7. RNN modellerinin eğitimi için kullanılan hiperparametreler


Parametre	Değer
Optimize Edici	Adam
Maksimum Epok	50
Mini Grup Boyutu	32
Öğrenme Oranı	0,002
Gradyan Kırpma Eşiği	1
Veri Karıştırma	Her epokta
Dropout Olasılığı	0,3

Kayıp fonksiyonu, çapraz entropi kaybı olarak tanımlanmıştır:


$$L = - \sum_{i=1}^N \sum_{c=1}^C y_{i,c} \log(p_{i,c}) \quad (4.20)$$

Burada ($y_{i,c}$), i örneği için doğru sınıf c ise 1, değilse 0 olan gerçek etikettir ve ($p_{i,c}$), tahmin edilen olasılıktır.

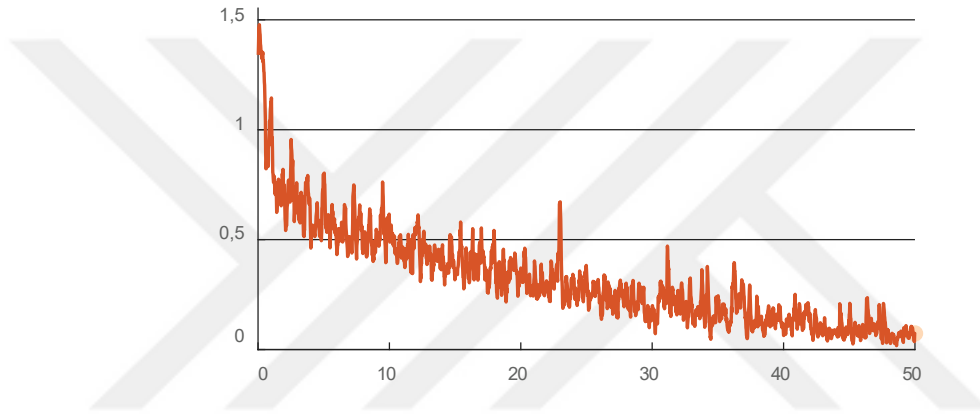
Aşırı öğrenmeyi azaltmak için veriler her epokta karıştırılmıştır. Dropout katmanı, eğitim sırasında tekrarlayan katman çıktılarının %30'unu rastgele devre dışı bırakarak aşırı öğrenmeyi azaltır. Şekil 4.10., Şekil 4.11. ve Şekil 4.12. sırasıyla LSTM, GRU ve BiLSTM modellerine ait kayıp fonksiyonu eğrilerini göstermektedir.



Şekil 4.10. LSTM modelinin eğitim sırasındaki kayıp eğrisi.



Şekil 4.11. GRU modelinin eğitim sırasındaki kayıp eğrisi.



Şekil 4.12. BiLSTM modelinin eğitim sırasındaki kayıp (loss) eğrisi.

- **Model Değerlendirme ve Seçimi:** Her model, veri setinin %20'sini oluşturan ayrılmış bir test seti üzerinde başlangıçta değerlendirilmiştir. Performans metrikleri arasında doğruluk, hassasiyet, geri çağırma ve F1-skoru, özgüllük yer almıştır (Çizelge 4.8.).

Çizelge 4.8. Farklı RNN modellerinin sınıflandırma metrikleri

Model	Doğruluk (%)	Makro Hassasiyet	Makro Geri Çağırma	Makro F1-Skoru
LSTM	81,62	0,81	0,82	0,81
GRU	86,03	0,86	0,85	0,86
BiLSTM	78,19	0,78	0,78	0,78

Sırasıyla LSTM, GRU ve Çift Yönlü LSTM (BiLSTM) modellerinin sınıflandırma performansına ilişkin karışıklık matrisleri Şekil 4.13., Şekil 4.14. ve Şekil 4.15.'te detaylarıyla birlikte sunulmuştur.

	Sağlıklı	Sağlıklı Benzeri	Hafif Sapmış	Sapmış	Doğruluk	
Sağlıklı	100				%100,0	
Sağlıklı Benzeri		91	10		%90,1	%9,9
Hafif Sapmış		21	81	20	%66,4	%33,6
Sapmış			24	61	%71,8	%28,2
	%100,0	%81,2	%70,4	%75,3		
		%18,8	%29,6	%24,7		

Şekil 4.13. LSTM modeli performansının karışıklık matrisi.

	Sağlıklı	Sağlıklı Benzeri	Hafif Sapmış	Sapmış	Doğruluk	
Sağlıklı	100				%100,0	
Sağlıklı Benzeri		90	11		%89,1	%10,9
Hafif Sapmış		13	97	12	%79,5	%20,5
Sapmış			21	64	%75,3	%24,7
	%100,0	%87,4	%75,2	%84,2		
		%12,6	%24,8	%15,8		

Şekil 4.14. GRU modeli performansının karışıklık matrisi.

	Sağlıklı	Sağlıklı Benzeri	Hafif Sapmış	Sapmış	Doğruluk	
Sağlıklı	100				%100,0	
Sağlıklı Benzeri		91	10		%90,1	%9,9
Hafif Sapmış		26	79	17	%64,8	%35,2
Sapmış			36	49	%57,6	%42,4
	%100,0	%77,8	%63,2	%74,2		
		%22,2	%36,8	%25,8		

Şekil 4.15. BiLSTM modeli performansının karışıklık matrisi.

Model performanslarının değerlendirilmesinde kullanılan metrikler olan Hassasiyet, Geri Çağırma, F1-Skoru ve Özgüllük değerleri, Çizelge 4.9., Çizelge 4.10. ve Çizelge 4.11.'de ayrıntılı olarak sunulmuştur.

Çizelge 4.9. LSTM modelinin sınıflandırma performans metrikleri

Sınıf	Hassasiyet	Geri Çağırma	F1-Skoru	Özgüllük
Sağlıklı	1	1	1	1
Sağlıklı Benzeri	0,8125	0,901	0,8545	0,9316
Hafif Sapmış	0,7044	0,6639	0,6835	0,8811
Sapmış	0,7531	0,7177	0,7349	0,9381

Çizelge 4.10. GRU modelinin sınıflandırma performans metrikleri

Sınıf	Hassasiyet	Geri Çağırma	F1-Skoru	Özgüllük
Sağlıklı	1	1	1	1
Sağlıklı Benzeri	0,8738	0,8911	0,8824	0,9577
Hafif Sapmış	0,7519	0,7951	0,7729	0,8881
Sapmış	0,8421	0,7529	0,795	0,9629

Çizelge 4.11. BiLSTM modelinin sınıflandırma performans metrikleri

Sınıf	Hassasiyet	Geri Çağırma	F1-Skoru	Özgüllük
Sağlıklı	1	1	1	1
Sağlıklı Benzeri	0,7778	0,901	0,8349	0,9153
Hafif Sapmış	0,632	0,6475	0,6397	0,8392
Sapmış	0,7424	0,5765	0,649	0,9474

En yüksek doğruluk ve dengeli metrikler temelinde, GRU modeli 5 katlı çapraz doğrulama ile daha fazla doğrulama için seçilmiştir.

- **K-Katlı Çapraz Doğrulama:** Sağlam genelleştirme sağlamak için GRU modeli üzerinde 5 katlı çapraz doğrulama gerçekleştirilmiştir. Veri seti beş eşit kata bölünmüş, her kat için %80 eğitim ve %20 test için kullanılmıştır. Çapraz doğrulama süreci şu şekilde tanımlanmıştır:

$$\text{Veri Seti} = \{(x_i, y_i)\}_{i=1}^N, \quad \text{Bölmeler} = \{D_1, D_2, \dots, D_5\} \quad (4.21)$$

$$\text{Eğitim Seti}_k = \bigcup_{j \neq k} D_j, \quad \text{Test Seti}_k = D_k \quad (4.22)$$

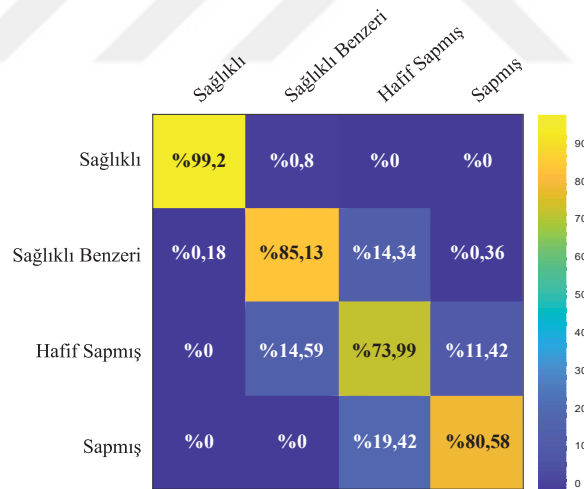
GRU modeli, her katın eğitim setinde bağımsız olarak eğitilmiş ve ilgili test setinde değerlendirilmiştir. Katlar arası ortalama karışıklık matrisi Şekil 4.16.'da gösterilmiştir.

Çapraz doğrulama sonuçları Çizelge 4.12.'de özetlenmiş olup, katlar arası ortalama doğruluk ve makro ortalama metrikler sunulmuştur.

Çizelge 4.12. GRU modelinin K-kat çapraz doğrulama performans sonuçları

Kat	Doğruluk (%)	Makro Hassasiyet	Makro Geri Çağırma	Makro F1-Skoru
1	86,73	0,885	0,862	0,87
2	85,05	0,875	0,858	0,856
3	86,03	0,86	0,867	0,861
4	79,41	0,797	0,798	0,793
5	85,54	0,864	0,85	0,855
Ortalama	84,55	0,856	0,847	0,847
Standart Sapma	2,94	0,035	0,028	0,031

Şekil 4.16., 5 katlı çapraz doğrulama sonucunda elde edilen ortalama karışıklık matrisini göstermektedir.



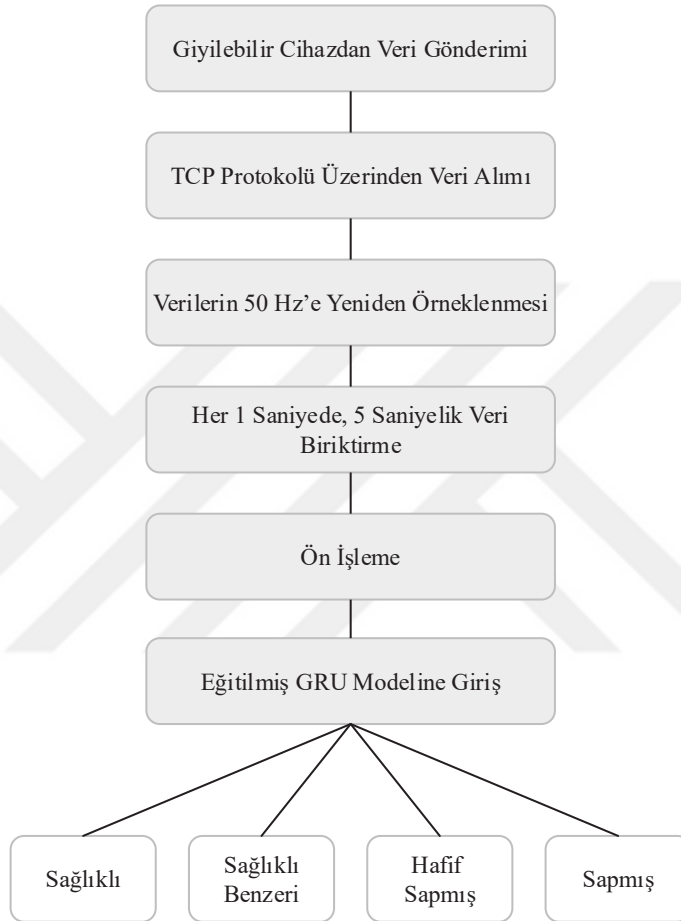
Şekil 4.16. 5 katlı çapraz doğrulama ile elde edilen GRU modeli performansının ortalama karışıklık matrisi.

4.7. Anlık Yürüyüş Analizi

Bu bölümde, sistemin anlık yürüyüş analizine olanak tanıyan uygulama yapısı sunulmaktadır. Daha önceki bölümlerde detaylandırılan donanım ve yazılım bileşenleri ile oluşturulan sistem, sensör verilerinin anlık olarak toplanmasını, işlenmesini ve kullanıcıya görsel olarak sunulmasını sağlamaktadır.

Anlık analiz, verilerin bekletilmeden işlenmesi ve kayıpsız şekilde iletilmesi ile mümkün kılınmıştır. Bu yapı, klinik ortamlarda ya da saha testlerinde protez kullanıcılarının yürüyüş paternlerinin anında izlenmesini mümkün hale getirmektedir.

Şekil 4.17.'de anlık veri toplama ve analiz sürecini gösteren sistem diyagramı yer almaktadır:



Şekil 4.17. Anlık yürüyüş analizi sistem akış şeması.

5. TARTIŞMA

GRU modeli, doğruluk açısından LSTM ve BiLSTM modellerini geride bırakarak %86,03 doğruluk oranı elde etmiştir. Bu üstünlük, GRU'nun etkili kapı mekanizmasına bağlanabilir; bu mekanizma, hesaplama basitliğini korurken yürüyüş dizilerindeki zamansal bağımlılıkları yakalamada başarılıdır. Özellikle klinik ortamlarda, protez yürüyüşteki telafi edici hareketler gibi karmaşık dinamikler sıkça görülür. GRU'nun güncelleme ve sıfırlama kapıları içeren sadeleştirilmiş mimarisi, bu desenleri BiLSTM'den daha az hesaplama kaynağı kullanarak etkili bir şekilde modellemektedir.

LSTM modeli, uzun vadeli bağımlılıkları yakalama yeteneğine rağmen, daha yüksek parametre karmaşıklığı nedeniyle bu veri setinde aşırı öğrenmeye yatkın olabilir ve daha düşük performans göstermiştir. BiLSTM modeli, çift yönlü işlem kapasitesine sahip olmasına rağmen, GRU tarafından geride bırakılmıştır; bu, tek yönlü işlem ve etkili kapı mekanizmasının bu yürüyüş sınıflandırma görevi için yeterli olduğunu göstermektedir.

GRU için 5 katlı çapraz doğrulama sonuçları, %84,55 ortalama doğruluk ve %2,94 standart sapma ile orta düzeyde bir stabilite göstermektedir. BiLSTM'ye kıyasla nispeten yüksek varyans, veri bölümlerine duyarlılığı yansıtabilir ve bu, hastalardaki yürüyüş desenlerindeki çeşitliliğe işaret edebilir. Şekil 4.16.'de verilen ortalama karışıklık matrisi, yanlış sınıflandırmaların ağırlıklı olarak komşu sınıflar arasında meydana geldiğini göstermektedir. Özellikle, "Sağlıklı Benzeri" ile "Hafif Sapmış" ve "Hafif Sapmış" ile "Sapmış" sınıfları arasında sınırlı düzeyde örtüşmeler gözlemlenmiştir. Bu durum, yürüyüş desenlerinin sınır durumlarında benzerlik göstermesinden kaynaklanabilir. Bu gözlem, denetimsiz kümeleme sonucu elde edilen etiketlerin doğasıyla da örtüşmektedir. Etiketler otomatik olarak oluşturulduğu için, sınıflar arasında ince farklar tam olarak ayırt edilememiş olabilir. Bununla birlikte, uzak sınıflar arasında (örneğin "Sağlıklı" ile "Sapmış" arasında) herhangi bir yanlış sınıflandırma tespit edilmemiştir. Bu da modelin genel eğiliminin tutarlı olduğunu ve ciddi bozuklukları sağlıklı yürüyüşlerle karıştırmadığını göstermektedir.

Denetimsiz kümeleme kullanılarak etiketlerin oluşturulması, bir anomali tespit problemini denetimli bir sınıflandırma görevine dönüştürmüş ve GRU gibi güçlü RNN modellerinin uygulanmasını mümkün kılmıştır. GRU'nun verimli mimarisi, yürüyüş döngülerindeki (örneğin, duruş ve salınım fazları) temel zamansal bağımlılıkları

BiLSTM'den daha düşük hesaplama karmaşıklığı ile yakalamada özellikle etkili olmuştur.

Önceki yürüyüş sınıflandırma çalışmalarına kıyasla, GRU modelimiz, denetimsiz etiketleme yaklaşımı sayesinde pahalı manuel etiketleme ihtiyacını azaltırken rekabetçi doğruluk sunmaktadır. Örneğin, (Hwang vd., 2024), atalet sensörü tabanlı bir sistemle RF kullanarak üç sınıflı sınıflandırmada %91, iki sınıflı (normal-anormal) ayırma ise %99 doğruluk rapor etmiştir. (Otamendi vd., 2023) ise sensörlü baston ucu verileriyle OC-Destek Vektör Makineleri kullanarak multipl skleroz hastalarında %82,5, sağlıklı bireylerde %87,5 doğruluk elde etmiştir. Her iki çalışma ya sağlıklı bireylerde simüle bozukluklara ya da multipl skleroz hastalarına odaklanırken, bu çalışma gerçek ampute bireylerden veri toplayarak klinik geçerliliği yüksek bir yaklaşım sunmaktadır. Hwang daha az özellik (6–18) ve geleneksel MÖ yöntemleri, Otamendi ise bastondan türetilmiş 90 özellik ile tek sınıflı destek vektör makinesi kullanırken, GRU modelimiz, denetimsiz kümeleme ile belirlenen dört sınıf için %86 ortalama, sağlıklı vs. ampute ayırma için ise %99'un üzerinde doğruluk sağlamaktadır.

Zamansal modelleme yeteneği sayesinde, RNN tabanlı yaklaşımımız hem ölçeklenebilir hem de karmaşık yürüyüş dinamiklerini yakalama açısından üstündür. Özellikle BiLSTM, Hwang'ın düşük doğruluklu destek vektör makineleri ve Otamendi'nin statik özelliklere dayalı tek sınıflı destek vektör makinesine kıyasla zamansal bağlamı daha etkili modellemektedir. Öte yandan, bu çalışmaların kinematik özelliklere (ör. diz veya baston açısı) odaklanması, bizim açısız parametrelerin önemine dair bulgularımızla örtüşmektedir.

Bu çalışmada elde edilen sonuçlar umut verici olsa da bazı önemli sınırlamalar mevcuttur. İlk olarak, kullanılan veri kümesi sınırlı bir çeşitliliğe sahiptir. Veriler yalnızca beş amputeye ait olup, tamamı erkek katılımcılardan toplanmıştır. Bu durum, modelin genellenebilirliğini sınırlandırmakta ve farklı demografik gruplardaki (örneğin kadın, yaşlı bireyler) yürüyüş paternlerini temsil etme kapasitesini azaltmaktadır.

Bu sınırlamalar göz önüne alındığında, gelecekteki çalışmaların daha çeşitli veri kümeleri, uzman etiketleme süreçleri ve açıklanabilir yapay zekâ tekniklerini içermesi önerilmektedir. Ayrıca, sensörlerin konum bilgisine göre normalize edilmesi durumunda daha hassas ve başarılı bir sınıflandırma performansı elde edilebilir. Bunun yanı sıra, konum bilgisinin 25. parametre olarak bir özellik şeklinde kullanılması da modelin etkinliğini artırabilir.

KAYNAKLAR

- Aderinola, T. B., Connie, T., Ong, T. S., Teoh, A. B. J., & Goh, M. K. O. (2024). Gait-based age group classification with adaptive graph neural network. *Engineering Applications of Artificial Intelligence*, 137, 109081.
- Arlotti, J. S., Carroll, W. O., Affifi, Y., Talegaonkar, P., Albuquerque, L., Burch, R. F. V., Ball, J. E., Chander, H., & Petway, A. (2022). Benefits of IMU-based Wearables in Sports Medicine: Narrative Review. İçinde *International Journal of Kinesiology and Sports Science* (C. 10, Sayı 1). <https://doi.org/10.7575/aiac.ijkss.v.10n.1p.36>
- Asif, M., Tiwana, M. I., Khan, U. S., Qureshi, W. S., Iqbal, J., Rashid, N., & Naseer, N. (2021). Advancements, Trends and Future Prospects of Lower Limb Prosthesis. *IEEE Access*, 9. <https://doi.org/10.1109/ACCESS.2021.3086807>
- Balaji, Brindha, & Balakrishnan. (2020). Supervised machine learning based gait classification system for early detection and stage classification of Parkinson's disease. *Applied Soft Computing Journal*, 94. <https://doi.org/10.1016/j.asoc.2020.106494>
- Clark, G. (2023). *Learning Predictive Models for Assisted Human Biomechanics*. Arizona State University.
- Eckhardt, C. M., Madjarova, S. J., Williams, R. J., Ollivier, M., Karlsson, J., Pareek, A., & Nwachukwu, B. U. (2023). Unsupervised machine learning methods and emerging applications in healthcare. İçinde *Knee Surgery, Sports Traumatology, Arthroscopy* (C. 31, Sayı 2). <https://doi.org/10.1007/s00167-022-07233-7>
- Escamilla-Nunez, R., Michelini, A., & Andrysek, J. (2020). Biofeedback systems for gait rehabilitation of individuals with lower-limb amputation: A systematic review. İçinde *Sensors (Switzerland)* (C. 20, Sayı 6). <https://doi.org/10.3390/s20061628>
- Fan, B., Xia, H., Xu, J., Li, Q., & Shull, P. B. (2021). IMU-based knee flexion, abduction and internal rotation estimation during drop landing and cutting tasks. *Journal of Biomechanics*, 124. <https://doi.org/10.1016/j.jbiomech.2021.110549>
- Font-Llagunes, J. M., Barjau, A., Pàmies-Vilà, R., & Kövecses, J. (2012). Dynamic analysis of impact in swing-through crutch gait using impulsive and continuous contact models. *Multibody System Dynamics*, 28(3). <https://doi.org/10.1007/s11044-011-9300-9>
- Goldfarb, N., Lewis, A., Tacescu, A., & Fischer, G. S. (2021). Open source Vicon Toolkit for motion capture and Gait Analysis. *Computer Methods and Programs in Biomedicine*, 212. <https://doi.org/10.1016/j.cmpb.2021.106414>
- Han, S. L., Cai, M. L., & Pan, M. C. (2024). Inertial Measuring System to Evaluate Gait Parameters and Dynamic Alignments for Lower-Limb Amputation Subjects. *Sensors*, 24(5). <https://doi.org/10.3390/s24051519>

- Hewamalage, H., Bergmeir, C., & Bandara, K. (2021). Recurrent Neural Networks for Time Series Forecasting: Current status and future directions. *International Journal of Forecasting*, 37(1). <https://doi.org/10.1016/j.ijforecast.2020.06.008>
- Hii, C. S. T., Gan, K. B., Zainal, N., Mohamed Ibrahim, N., Azmin, S., Mat Desa, S. H., van de Warrenburg, B., & You, H. W. (2023). Automated Gait Analysis Based on a Marker-Free Pose Estimation Model. *Sensors*, 23(14). <https://doi.org/10.3390/s23146489>
- Hu, B., Li, S., Chen, Y., Kavi, R., & Coppola, S. (2021). Applying deep neural networks and inertial measurement unit in recognizing irregular walking differences in the real world. *Applied Ergonomics*, 96. <https://doi.org/10.1016/j.apergo.2021.103414>
- Hutabarat, Y., Owaki, D., & Hayashibe, M. (2021). Recent Advances in Quantitative Gait Analysis Using Wearable Sensors: A Review. *IEEE Sensors Journal*, 21(23). <https://doi.org/10.1109/JSEN.2021.3119658>
- Hwang, S., Kim, J., Yang, S., Moon, H.-J., Cho, K.-H., Youn, I., Sung, J.-K., & Han, S. (2024). Machine learning based abnormal gait classification with IMU considering joint impairment. *Sensors*, 24(17), 5571.
- Javaid, M., Haleem, A., Pratap Singh, R., Suman, R., & Rab, S. (2022). Significance of machine learning in healthcare: Features, pillars and applications. *International Journal of Intelligent Networks*, 3. <https://doi.org/10.1016/j.ijin.2022.05.002>
- Jiang, W., & Yin, Z. (2015). Human activity recognition using wearable sensors by deep convolutional neural networks. *MM 2015 - Proceedings of the 2015 ACM Multimedia Conference*. <https://doi.org/10.1145/2733373.2806333>
- Katsoulakis, E., Wang, Q., Wu, H., Shahriyari, L., Fletcher, R., Liu, J., Achenie, L., Liu, H., Jackson, P., Xiao, Y., Syeda-Mahmood, T., Tuli, R., & Deng, J. (2024). Digital twins for health: a scoping review. İçinde *npj Digital Medicine* (C. 7, Sayı 1). <https://doi.org/10.1038/s41746-024-01073-0>
- Kılıç, Ş. (2021). *Derin öğrenme yöntemleri kullanılarak giyilebilir sensörlerden kişi tanıma*.
- Ledoux, E. D. (2018). Inertial Sensing for Gait Event Detection and Transfemoral Prosthesis Control Strategy. *IEEE Transactions on Biomedical Engineering*, 65(12). <https://doi.org/10.1109/TBME.2018.2813999>
- Manchola, M. D. S., Bernal, M. J. P., Munera, M., & Cifuentes, C. A. (2019). Gait phase detection for lower-limb exoskeletons using foot motion data from a single inertial measurement unit in hemiparetic individuals. *Sensors (Switzerland)*, 19(13). <https://doi.org/10.3390/s19132988>
- Marcos Mazon, D., Groefsema, M., Schomaker, L. R. B., & Carloni, R. (2022). IMU-Based Classification of Locomotion Modes, Transitions, and Gait Phases with Convolutional Recurrent Neural Networks. *Sensors*, 22(22). <https://doi.org/10.3390/s22228871>

- Moore, D. S., McCabe, G. P., & Craig, B. A. (2009). *Introduction to the Practice of Statistics* (C. 4). WH Freeman New York.
- Moura, D. L., & Garruço, A. (2017). Hip disarticulation – case series analysis and literature review. *Revista Brasileira de Ortopedia (English Edition)*, 52(2). <https://doi.org/10.1016/j.rboe.2016.09.008>
- Mundt, M., Johnson, W. R., Potthast, W., Markert, B., Mian, A., & Alderson, J. (2021). A comparison of three neural network approaches for estimating joint angles and moments from inertial measurement units. *Sensors*, 21(13). <https://doi.org/10.3390/s21134535>
- Ng, G., & Andrysek, J. (2023). Classifying Changes in Amputee Gait following Physiotherapy Using Machine Learning and Continuous Inertial Sensor Signals. *Sensors*, 23(3). <https://doi.org/10.3390/s23031412>
- Otamendi, J., Zubizarreta, A., & Portillo, E. (2023). Machine learning-based gait anomaly detection using a sensorized tip: an individualized approach. *Neural Computing and Applications*, 35(24). <https://doi.org/10.1007/s00521-023-08601-1>
- Prasanth, H., Caban, M., Keller, U., Courtine, G., Ijspeert, A., Vallery, H., & Von Zitzewitz, J. (2021). Wearable sensor-based real-time gait detection: A systematic review. *Sensors*, 21(8), 2727.
- Raffegeau, T. E., Krehbiel, L. M., Kang, N., Thijs, F. J., Altmann, L. J. P., Cauraugh, J. H., & Hass, C. J. (2019). A meta-analysis: Parkinson's disease and dual-task walking. *Çinde Parkinsonism and Related Disorders* (C. 62). <https://doi.org/10.1016/j.parkreldis.2018.12.012>
- Santos, G., Wanderley, M., Tavares, T., & Rocha, A. (2022). A multi-sensor human gait dataset captured through an optical system and inertial measurement units. *Scientific Data*, 9(1). <https://doi.org/10.1038/s41597-022-01638-2>
- Schmiegelow, M. T., Sode, N., Riis, T., Lauritzen, J. B., Duus, B. R., & Lindberg-Larsen, M. (2018). Re-amputations and mortality after below-knee, through-knee and above-knee amputations. *Danish Medical Journal*, 65(12).
- Sie, A. (2020). *Smart Step: Wearable Mobility Assistance using Machine Learning and Haptic Feedback*. University of Washington.
- Sivapuratharasu, B., Bull, A. M. J., & McGregor, A. H. (2019). Understanding Low Back Pain in Traumatic Lower Limb Amputees: A Systematic Review. *Çinde Archives of Rehabilitation Research and Clinical Translation* (C. 1, Sayı 1-2). <https://doi.org/10.1016/j.arrct.2019.100007>
- Tiwari, A., & Joshi, D. (2020). An Infrared Sensor-Based Instrumented Shoe for Gait Events Detection on Different Terrains and Transitions. *IEEE Sensors Journal*, 20(18). <https://doi.org/10.1109/JSEN.2020.2994956>
- Ur Rehman, R. Z., Del Din, S., Shi, J. Q., Galna, B., Lord, S., Yarnall, A. J., Guan, Y., & Rochester, L. (2019). Comparison of walking protocols and gait assessment systems

- for machine learning-based classification of parkinson's disease. *Sensors (Switzerland)*, 19(24). <https://doi.org/10.3390/s19245363>
- Vu Thi Thu, H. (2023). *Gait detection algorithm applying for transtibial prosthesis*. Vrije Universiteit Brussel.
- Wan, J., Wang, D., Hoi, S. C. H., Wu, P., van Merriënboer, B., Bahdanau, D., Dumoulin, V., Serdyuk, D., Warde-farley, D., Chorowski, J., Bengio, Y., Szegedy, C., Reed, S., Sermanet, P., Vanhoucke, V., Rabinovich, A., Pan, J., Ng, C. J., Teoh, A. J., ... Daniel Povey, X. Z. & S. K. (2015). A Critical Review of Recurrent Neural Networks for Sequence Learning arXiv : 1506 . 00019v2 [cs . LG] 29 Jun 2015. *International Journal of Computer Vision*, 106(March 2013).
- Whittle, M. W. (2014). *Gait analysis: an introduction*. Butterworth-Heinemann.
- Yu, S., Yang, J., Huang, T. H., Zhu, J., Visco, C. J., Hameed, F., Stein, J., Zhou, X., & Su, H. (2023). Artificial Neural Network-Based Activities Classification, Gait Phase Estimation, and Prediction. *Annals of Biomedical Engineering*, 51(7). <https://doi.org/10.1007/s10439-023-03151-y>
- Yu, Y., Si, X., Hu, C., & Zhang, J. (2019). A review of recurrent neural networks: Lstm cells and network architectures. İçinde *Neural Computation* (C. 31, Sayı 7). https://doi.org/10.1162/neco_a_01199
- Zhang, K., Xiong, C., Zhang, W., Liu, H., Lai, D., Rong, Y., & Fu, C. (2019). Environmental Features Recognition for Lower Limb Prostheses Toward Predictive Walking. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 27(3). <https://doi.org/10.1109/TNSRE.2019.2895221>
- Zheng, X., Otten, B., Reneman, M. F., & Lamoth, C. J. C. (2023). Explaining deep learning models for age-related gait classification based on time series acceleration. *arXiv preprint arXiv:2311.12089*.