

T.C.
KASTAMONU ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİYOMEDİKAL MÜHENDİSLİĞİ ANA BİLİM DALI



DIŞ İSKELET ROBOTLARININ KONTROL MEKANİZMASI
İÇİN BİR TAHMİN ALGORİTMASI

GİZEM ÖREK

YÜKSEK LİSANS TEZİ

DR. ÖĞR ÜYESİ HAYRİYE ALTURAL ÖZKAN

ŞUBAT - 2025

KASTAMONU

TAAHHÜTNAME

Bu tezin tasarımı, hazırlanması, yürütülmesi, arařtırmalarının yapılması ve bulgularının analizlerinde bütün bilgilerin etik davranıř ve akademik kurallar çerçevesinde elde edilerek sunulduđunu; ayrıca tez yazım kurallarına uygun olarak hazırlanan bu çalıřmada bana ait olmayan her türlü ifade ve bilginin kaynađına eksiksiz atıf yapıldıđını, bilimsel etiđe uygun olarak kaynak gösterildiđini bildirir ve taahhüt ederim.

Gizem ÖREK

ÖZET

YÜKSEK LİSANS TEZİ

DIŞ İSKELET ROBOTLARININ KONTROL MEKANİZMASI İÇİN BİR TAHMİN ALGORİTMASI

GİZEM ÖREK

KASTAMONU ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ
BİYOMEDİKAL MÜHENDİSLİĞİ ANA BİLİM DALI
DANIŞMAN:DR. ÖĞR ÜYESİ HAYRİYE ALTURAL ÖZKAN

Bu tez çalışması, rehabilitasyon amaçlı kullanılan dış iskelet robotlarının kontrol mekanizmalarında derin öğrenme modellerinin uygulanabilirliğini değerlendirmek amacıyla gerçekleştirilmiştir. Dış iskelet sistemlerinin, kullanıcının hareketlerini doğru bir şekilde takip edebilmesi için güvenilir referans yörüngelere ihtiyaç duyduğu bilinmektedir. Bu doğrultuda, IMU sensörlerinden elde edilen insan yürüyüş verileri kullanılarak, farklı zaman aralıklarında hareket yörüngelerinin tahmini için Tekrarlayan Sinir Ağları (RNN), Uzun Kısa Süreli Bellek (LSTM) ve Kapılı Tekrarlayan Birim (GRU) modelleri uygulanmıştır. Modelleme sürecinde, ivme ve açısal hız verileri kayan pencere yöntemiyle segmentlere ayrılmış ve farklı giriş (600 ms, 800 ms, 1000 ms) ve çıkış pencere boyutları (100 ms, 200 ms, 300 ms) kullanılarak tüm modeller eğitilmiştir. Her pencere kombinasyonu için ayrı hiperparametre optimizasyonu uygulanarak en iyi model parametreleri belirlenmiştir. Deneysel sonuçlar, RNN modelinin LSTM ve GRU'ya kıyasla daha düşük performans sergilediğini göstermektedir. En iyi performans ise, 600 ms giriş ve 100 ms çıkış penceresiyle eğitilen GRU modeliyle elde edilmiş olup, bu model 0,092 RMSE ve 0,062 MAE değerleri ile en düşük hata oranına ulaşmıştır. Bununla birlikte, GRU ve LSTM modellerinin genellikle benzer hata değerlerine sahip olduğu, ancak çıkış pencere boyutunun artmasıyla LSTM modelinin daha kararlı bir performans sergilediği gözlemlenmiştir. Bu durum, uzun vadeli bağımlılıkların bulunduğu senaryolarda LSTM modelinin daha avantajlı olabileceğini göstermektedir. Öte yandan, hesaplama maliyetleri açısından değerlendirildiğinde, GRU modeli LSTM'ye kıyasla daha az hesaplama gerektiren ve daha hızlı çalışan bir alternatif sunmaktadır.

ANAHTAR KELİMELEER: Dış İskelet, RNN, LSTM, GRU, Tahmin Algoritması

Şubat 2025, 42 Sayfa

ABSTRACT

MSC THESIS

A PREDICTION ALGORITHM FOR THE CONTROL MECHANISM OF EXOSKELETON ROBOTS

GİZEM ÖREK

KASTAMONU UNIVERSITY INSTITUTE OF SCIENCE

DEPARTMENT OF BIOMEDICAL ENGINEERING

SUPERVISOR:ASST. PROF. DR. HAYRIYE ALTURAL ÖZKAN

This thesis was carried out to evaluate the applicability of deep learning models in the control mechanisms of exoskeleton robots used for rehabilitation purposes. It is known that exoskeleton systems need reliable reference trajectories to track the user's movements accurately. Accordingly, Recurrent Neural Networks (RNN), Long Short Term Memory (LSTM), and Gated Recurrent Unit (GRU) models were applied to predict motion trajectories at different time intervals using human gait data obtained from IMU sensors. During the modeling process, the acceleration and angular velocity data were segmented using the sliding window method, and all models were trained using different input (600 ms, 800 ms, 1000 ms) and output window sizes (100 ms, 200 ms, 300 ms). Separate hyperparameter optimization was applied for each window combination to determine the best model parameters. The experimental results show that the RNN model performs poorly compared to LSTM and GRU. The best performance was obtained with the GRU model trained with 600 ms input and 100 ms output window, and this model achieved the lowest error rate with 0.092 RMSE and 0.062 MAE values. However, it is observed that the GRU and LSTM models generally have similar error values, but the LSTM model shows a more stable performance as the output window size increases. This suggests that the LSTM model may be more advantageous in scenarios with long-term dependencies. On the other hand, when evaluated in terms of computational costs, the GRU model offers an alternative that requires less computation and runs faster compared to the LSTM.

KEYWORDS: Exoskeleton, RNN, LSTM, GRU, Prediction

February 2025, 42 Page

TEŞEKKÜR

Tez çalışmam süresince, tez konumun şekillenmesinde ve araştırmamın her aşamasında bana rehberlik eden danışman hocam Dr. Öğr. Üyesi Hayriye ALTURAL ÖZKAN' a teşekkürlerimi sunarım.

Çalışmamın değerlendirilmesinde büyük rol oynayan jüri üyeleri Dr. Öğr. Üyesi Muhammet ÇAKMAK ve Dr. Öğr. Üyesi Selim ÜNAL' a bilimsel katkıları ve değerli görüşleriyle çalışmamı şekillendirmemde bana yardımcı oldukları için teşekkür ederim.

Bu süreçte bana sadece moral desteği sağlamakla kalmayıp, zor zamanlarda motivasyonumu hiç kaybetmememi sağlayan ve çalışmalarına destek veren sevgili eşim Cahit ÖREK'e sonsuz teşekkürlerimi sunarım. Senin yanımda olman, her zorluğu aşmamda en büyük gücüm oldu. Bu çalışmayı senin desteğinle tamamladım ve buna her zaman minnettar kalacağım.

Çok değerli ailem Ali Osman YILMAZ, Demet YILMAZ, Onur YILMAZ ve Yağız Efe YILMAZ'ın bana verdikleri sevgi ve güven bu süreçte güç bulmamı sağladı. Sadece akademik anlamda değil, kişisel olarak da beni sürekli olarak destekleyerek bu zorlu yolu daha kolay hale getirdiğiniz için hepinize teşekkür ediyorum.

Son olarak, manevi desteğini esirgemeyen ve çalışmamın her aşamasında bana fikirlerini sunarak, gözden kaçırdığım noktaları fark etmemi sağlayan sevgili Zuhale Arife KÜÇÜK'e ve çalışmam boyunca emeği bulunan tüm arkadaşlarıma en içten duygularıyla teşekkürlerimi sunarım.

Gizem ÖREK

Kastamonu, 2025

İÇİNDEKİLER

	<u>Sayfa</u>
TEZ ONAYI	ii
TAAHHÜTNAME	iii
ÖZET	iv
ABSTRACT	v
TEŞEKKÜR	vi
İÇİNDEKİLER	vii
ŞEKİLLER DİZİNİ	viii
TABLolar DİZİNİ	ix
SİMGELER VE KISALTMALAR DİZİNİ	x
1. GİRİŞ	1
1.1 Robotik Dış İskeletler	3
1.2 İnsan Hareket Niyeti Tahmini.....	4
1.3 Tahmin Algoritmaları	5
1.3.1 Tekrarlayan Sinir Ağları (RNN).....	6
1.3.2 Uzun Kısa Süreli Bellek (LSTM)	7
1.3.3 Kapılı Tekrarlayan Birim (GRU).....	9
1.4 Veri Ön İşleme Prosesleri	11
1.4.1 Kalman Filtresi	11
1.4.2 Kayan Pencere Yöntemi	13
2. LİTERATÜR TARAMASI	15
3. YÖNTEM	18
3.1 Veri Seti	18
3.2 Ön İşleme	19
3.3 Model Mimarileri.....	21
3.4 Değerlendirme Ölçütleri	24
4. BULGULAR	26
5. TARTIŞMA	34
6. SONUÇ VE ÖNERİLER	36
KAYNAKLAR	37
ÖZGEÇMİŞ	43

ŞEKİLLER DİZİNİ

	<u>Sayfa</u>
Şekil 1.1 Alt ekstremitte dış iskelet robotu genel görünümü	4
Şekil 1.2 Temel bir RNN mimarisi	7
Şekil 1.3 Temel bir LSTM hücresinin mimarisi	8
Şekil 1.4 Temel bir GRU hücresinin mimarisi.....	10
Şekil 1.5 Kayan pencere segmentasyonu gösterimi	14
Şekil 3.1 IMU sensörlerinin yerleşimi	19
Şekil 3.2 Kayan pencere yönteminin gösterimi	20
Şekil 3.3 RNN, LSTM ve GRU modellerinin genel mimarisi	23
Şekil 4.1 Sağ ayak ivmeölçerden alınan referans yörünge sinyalleri.....	26
Şekil 4.2 Sağ ayak jiroskoptan alınan referans yörünge sinyalleri	27
Şekil 4.3 RNN modelinin gerçek ve tahmin edilen değerler ile karşılaştırılması.....	32
Şekil 4.4 LSTM modelinin gerçek ve tahmin edilen değerler ile karşılaştırılması....	32
Şekil 4.5 GRU modelinin gerçek ve tahmin edilen değerler ile karşılaştırılması	33

TABLULAR DİZİNİ

Sayfa

Tablo 2.1 Literatürde yer alan çalışma sonuçlarının özeti	17
Tablo 4.1 Model hiperparametre optimizasyonu	28
Tablo 4.2 Değişen giriş-çıkış pencere boyutları için RNN modelinin performansı ..	29
Tablo 4.3 Değişen giriş-çıkış pencere boyutları için LSTM modelinin performansı	29
Tablo 4.4 Değişen giriş-çıkış pencere boyutları için GRU modelinin performansı ..	30



SİMGELER VE KISALTMALAR DİZİNİ

Simgeler

- $^{\circ}$: Derece
 σ : Sigma

Kısaltmalar

- 3B** : Üç Boyutlu
ADAM : Adaptive Moment Estimation (Uyarlanabilir Moment Tahmini)
AI : Artificial Intelligence (Yapay Zekâ)
ANN : Artificial Neural Network (Yapay Sinir Ağı)
CNN : Convolutional Neural Network (Evrişimsel Sinir Ağları)
CoP : Center of Pressure (Basınç Merkezi)
FCN : Fully Convolutional Network (Tam Evrişimli Ağ)
FSR : Force-Sensitive Resistor (Kuvvete Dayanıklı Direnç)
GRFs : Ground Reaction Forces (Yer Reaksiyon Kuvvetleri)
GRU : Gate Recurrent Unit (Kapılı Tekrarlayan Birim)
EEG : Elektroensefalografi
EMG : Elektromiyografi
IMU : Inertial Measurement Unit (Ataletsel Ölçüm Birimi)
LSTM : Long Short-Term Memory (Uzun Kısa Süreli Bellek)
MAE : Mean Absolute Error (Ortalama Mutlak Hata)
MAD : Mean Absolute Deviation (Ortalama Mutlak Sapma)
MIP : Motion Intention Prediction (Hareket Niyeti Tahmin)
MSE : Mean Squared Error (Ortalama Karesel Hata)
NIRS : Near-infrared spectroscopy (Yakın Kızılötesi Spektroskopisi)
NLP : Natural Language Processing (Doğal Dil İşleme)
RF : Random Forest (Rastgele Orman)
RNN : Recurrent Neural Network (Tekrarlayan Sinir Ağları)
ReLU : Rectified Linear Unit (Doğrultulmuş Lineer Birim)
RMSE : Root Mean Squared Error (Kök Ortalama Karesel Hata)
SCI : Spinal Cord Injury (Omirilik Yaralanması)
SP : Serebral Palsi

1. GİRİŞ

Omurilik yaralanması (SCI, Spinal Cord Injury) sonucu meydana gelen hastalıklarda, yaralanmanın tipine ve seviyesine bağlı olarak alt ekstremitelerde, gövdede veya üst ekstremitelerde motor ve/veya duyuşal fonksiyonların ciddi kayıplara yol açabilmektedir (Lajeunesse vd., 2016). İnsan hareketlerinin kısmen veya tamamen kısıtlanması, yalnızca yürüme kabiliyetini değil, aynı zamanda yaşam kalitesini ve günlük hayatta fiziksel yardıma ihtiyaç duymaya neden olan kişisel işleri gerçekleştirme yeteneğini de olumsuz etkilemektedir. Bu tür kayıpların etkilerini hafifletmek ve bireylerin hareket kabiliyetlerini yeniden kazanmalarını sağlamak amacıyla fizik tedavi önemli bir rol oynamaktadır. Fizik tedavi, kas gücünü artırmayı, eklem hareket açıklığını korumayı ve bireylerin günlük yaşam aktivitelerine bağımsız şekilde devam etmelerini desteklemeyi hedefler (Bodur vd., 2024).

Fizik tedavi ve rehabilitasyon alanında kullanılan robotik cihazlar, omurilik yaralanması veya diğer yürüme bozuklukları bulunan hastaların motor becerilerini geliştirmelerine ve rehabilitasyon sürecini hızlandırmalarına önemli ölçüde katkı sağlamaktadır (Gholap vd., 2022). Robotik rehabilitasyon cihazları, özellikle alt ekstremitte rehabilitasyonunda, yürüme süreçlerini desteklemek, hastaların bağımsızlıklarını artırmak ve tedavi etkinliğini artırmak için etkili ve umut vadeden bir yöntem olarak tercih edilmektedir (Bodur vd., 2024; Gholap vd., 2022).

Yürüme problemi olan hastalarda rehabilitasyonun amacı, alt ekstremitte motor fonksiyonlarını yeniden kazanmalarına yardımcı olmaktır. Son yıllarda, yürüme engeli bulunan hastalar için robotik teknolojileri kullanan dış iskeletler (Hasan vd., 2022; Liu vd. 2016; Liu vd., 2022; Moosavian vd., 2021; Shen vd., 2018; Torrealba vd., 2017; Zhang vd., 2018) ve aktif ortezler (Allemand vd., 2009; Daachi vd., 2015; Mahmood vd., 2023) gibi giyilebilir medikal cihazlar geliştirilmiştir. Bahsi geçen robotik dış iskeletler, nörolojik hasarlara bağılı yürüme problemi olan hastaların alt ekstremitte performansını arttırmaya, hareket yardımını sağlamaya ve klinik yürüyüş rehabilitasyonu gerçekleştirmeye yöneliktir.

Yürüme, insanların alt ekstremitelerinin ritmik hareketi sonucu ileri doğru hareket etmelerini sağlayan karmaşık bir süreçtir. Bu süreç, hareket edebilen bir mekanizma olarak insan vücudu için hayati bir işlev taşır. Ancak yürüme, yalnızca bacakların fiziksel hareketleriyle sınırlı değildir; aynı zamanda beyin, sinirler ve kasların sentezlenmiş bir koordinasyonunu içerir (Sethi vd., 2022). Bu koordinasyon, işlevsel bir yürüyüşün temelini oluştururken, işlevsel olmayan yürüyüş, biyomekanik uyumsuzluklar nedeniyle ortaya çıkabilir ve bu durum, erken tanı ve uygun tedavi eksikliği durumunda ciddi sağlık sorunlarına yol açabilir.

Biyomedikal mühendisliği alanında yürüyüş analizi, insan hareketini karakterize etmek için önemli bir yöntem olmuştur. Bu analizler, insanların yürüme biçimlerini, hareket desenlerini ve fizyolojik parametrelerini anlamak için kullanılmaktadır (Tao vd., 2012). Bu analizler sonucu elde edilecek olan veriler, özellikle rehabilitasyon amaçlı kullanılan dış iskeletlerin kontrol mimarisinde önemli bir rol oynamaktadır. Dış iskeletler, yürüme analizinin sonuçlarına dayalı olarak geliştirilen teknolojik cihazlar olarak tanımlanmaktadır (Young ve Ferris, 2017). Bundan dolayı yürüme analizlerinin dış iskeletlerde kullanılabilirliği, yürüme sırasında insan vücudu üzerinde oluşan kuvvetleri ve hareketleri anlamak ve bu bilgileri dış iskeletlerin tasarımına entegre etmek anlamına gelir. Yürüyüş analizi sayesinde, bireyin hareket dinamikleri ayrıntılı bir şekilde değerlendirilebilmekte ve bu veriler, dış iskeletin kullanıcının hareketlerine daha hassas ve uyumlu bir şekilde tepki vermesi için kullanılmaktadır. Bu sayede, dış iskeletler kullanıcının doğal yürüyüşüne yakın bir deneyim sunarak rehabilitasyon süreçlerini daha etkili hale getirebilmekte ve hastaların fonksiyonel bağımsızlıklarını artırmaktadır.

Rehabilitasyon amaçlı kullanılan dış iskeletlerin kontrol stratejisindeki temel zorluklardan biri, kullanıcıya uygun bir yürüyüşü modellemek ve tahmin etmektir. Literatürde yer alan geçmiş çalışmalara bakıldığında genellikle önceden tanımlanmış yürüyüş yörüngeleri kullanılmıştır (Veneman vd., 2007; Zoss vd., 2006). Bu sistemlerde, referans yörüngesi olarak sağlıklı bireylerden alınan yürüyüş modellerinin kullanılması, kullanıcının kendi yürüyüş profiline tam olarak uymayan hareketler sergilemesine neden olması olasıdır.

Birçok çalışma, insan yürüyüşünün bir zaman serisi yapısında olduğunu göstermektedir. Bu nedenle bir yürüyüş eyleminin tahmini, esasen bir zaman serisi tahminine veya başka bir deyişle gelecekteki değerlerin geçmiş gözlemlerinden elde edildiği veri yapılarının tahminine dayanmaktadır (Moosavian vd., 2021). İnsan hareketlerinin farklı şekillerde gerçekleştiriliyor olması, hareket niyetini tahmin etmek için geçmiş verilerden öğrenerek gelecekteki olayları veya sonuçları tahmin eden matematiksel veya istatistiksel modellerin kullanımını özellikle uygun hale getirmektedir. Bu bağlamda, vücut sinyallerini analiz etmek ve işlemek için etkili çalışma metodolojileri geliştirmek zorunlu hale gelmiştir (Ragni vd., 2021).

Yapay zekâ (AI, Artificial Intelligence) teknolojisindeki gelişmeler, makine öğrenmesi ve derin öğrenme yöntemlerini hareket yörüngelerinin gelecek tahmini için uygulanabilir bir yaklaşım haline getirmiştir. Makine öğrenimi ve derin öğrenme teknikleri, büyük boyutlu veri setleriyle çalışılması ve kullanılan algoritmaların güçlü öğrenme yeteneği sergilemesi bakımından insan hareketinin gelecek zaman dilimindeki niyetini tahmin etmede etkili bir çözüm sunduğu gözlemlenmiştir. İnsan yürüyüşünün zaman serisi yapısında olduğu göz önünde bulundurulduğunda, bu yöntemler geçmiş gözlemlere dayanarak gelecekteki zaman adımlarını tahmin edebilecektir (Ragni vd., 2021; Zhou vd., 2022).

1.1 Robotik Dış İskeletler

Dış iskeletler, kullanıcının gücünü ve dayanıklılığını artırmak için sensörler, aktüatörler ve kontrolörlerden yapılmış harici yük taşıyan robotik sistemlerdir (Kolaghassi vd., 2022). Robotik, mekanik, biyonik, kontrol teorisi, iletişim teknolojisi ve bilgi işleme teknolojisi ilkelerine dayanan dış iskelet robotları, bireyler tarafından giyilmek üzere tasarlanmaktadır ve kullanıcı kontrollü hareketler yoluyla kullanıcıların belirli görevleri yerine getirmelerine olanak sağlamaktadır (He vd., 2024). Şekil 1.1'de, alt ekstremitelerde dış iskelet robotlarının genel görünümü yer almaktadır. Bu tarz alt ekstremitelerde dış iskelet robotları koşu bantlarına entegre edilebilmekte ve yürüme problemi olan hastaların rehabilitasyon süreçlerinde kullanılmaktadır.



Şekil 1.1 Alt ekstremitte dış iskelet robotu genel görünümü

1.2 İnsan Hareket Niyeti Tahmini

Yürüme eylemi, statik ve dinamik denge korunurken tekrar eden modeller sergileyen döngüsel bir harekettir (Su ve Gutierrez-Farewik, 2020). Hareket niyetinin oluşması sırasında beyin birden fazla fizyolojik aktiviteyi koordine eder ve bunun sonucunda bir elektriksel aktivite sergiler. Bu fizyolojik aktivite merkezi ve çevresel sinir sisteminden, kas aktivitesinden veya basınç kuvvetlerinden çeşitli sensörler aracılığıyla kaydedilebilir. Bu sensörler vasıtasıyla elde edilen veri kümeleri yüksek doğrulukta insan hareket niyeti tahmin (MIP, Motion Intention Prediction) modelleri elde etmek için kullanılabilir (Caldas vd., 2020; Tang vd. 2023).

İnsan hareket niyeti tahmini, sağlık hizmetleri başta olmak üzere rehabilitasyon ve robotik gibi çeşitli alanlarda araştırma aracı haline gelmiştir. Sağlık hizmetlerinde kullanılacak dış iskelet robotlarının kontrol mekanizmalarının oluşturulmasında insan hareket niyetinden elde edilen yürüyüş verileri kullanılmaktadır (Foroutannia vd., 2022; Martinez-Hernandez vd., 2022; Su ve Gutierrez-Farewik, 2020; Wu vd., 2021).

Hareket niyetinin oluşması esnasında beyin tarafından oluşturulan biyoelektrik sinyaller, elektromiyografi (EMG) (Hu vd., 2018; Isezaki vd., 2019; Luo vd., 2024; Xiang vd., 2024), elektroensefalografi (EEG) (Lana vd., 2015; Reynolds vd., 2024; Yen vd., 2023) ve yakın kızılötesi spektroskopisi (NIRS, Near-Infrared Spectroscopy) (Hamid vd., 2022; Khan vd., 2018) gibi ölçüm cihazları tarafından kaydedilerek analiz edilebilmektedir.

Ayrıca, hareket ile ilgili kinematik ve kinetik parametreleri gerçek zamanlı olarak tespit etmek, hareket niyeti tahmini için başka bir yöntemdir. Belirli bir hareket amacı için, hareketi gerçekleştirme yolu nispeten daha iyi bilinmektedir. Ataletsel ölçüm birimleri (IMU, Inertial Measurement Unit) (Foroutannia vd., 2022; Hartog vd., 2021; Kim vd., 2021; Martinez-Hernandez vd., 2022; Shi vd., 2023; Svensson ve Gullberg, 2021), basınç merkezi (CoP, Center of Pressure) (Terrier, 2020; Wang vd., 2020; Yen vd., 2023), kuvvete dayanıklı direnç (FSR, Force-Sensitive Resistor) (Negi vd., 2021; Manna vd., 2023) ve yer reaksiyon kuvvetleri (GRFs, Ground Reaction Forces) (Foroutannia vd.2022; Kim ve Park, 2022; Yen vd., 2023) gibi biyoelektrik temelli olmayan sensörler; kuvvet, ivme ve açısal hız gibi zaman serileri parametrelerini kaydederek tahmin modelleri oluşturmak için özellikler çıkarmaktadır. İnsan vücudunun hareket durumu ve yörüngesi bu sensörler aracılığıyla analiz edebilir ve hareket niyeti tahminlemede hareket amacının oluşturulmasından yürütülmesine kadar olan tüm süreç kapsamlı bir şekilde araştırılabilir (Farina vd., 2014).

1.3 Tahmin Algoritmaları

İnsan vücudunu destekleyici cihazlar fiziksel engelli kişilerin günlük yaşam aktivitelerini daha bağımsız bir şekilde gerçekleştirmelerini sağlar. Bu tür destekleyici cihazlarda, elektronik, robotik ve yazılım gibi çeşitli etkenlere yapay zekânın entegre edilmesi birçok sorunu çözümleyici niteliktedir.

Yapay zekâ, makinelerin çevrelerini anlamalarını, kullanıcı niyetini tanımalarını ve hedeflerine ulaşmak için uygun şekilde hareket etmelerini sağlayan bir algoritma koleksiyonudur. Dış iskelet robotlarının kontrol algoritmasını oluşturmada AI

tekniklerinin kullanılması; yürüme, koşma, merdiven çıkma ve engellerden kaçınma gibi karmaşık aktivitelerin yerine getirilmesini sağlayacaktır (Pancholi vd., 2024).

Tahmin, mevcut ve geçmiş bilgilere dayanarak gelecekteki verileri ileriye dönük analiz etmeyi ifade etmektedir. Tahmin algoritmaları, dış iskelet kontrolünde kullanıcının sonraki hareketini tahmin edebilir ve dış iskeletin eylemlerini önceden ayarlamasına olanak sağlayabilir. Bu, kullanıcı ile dış iskelet arasında daha akıcı ve daha doğal etkileşimlere yol açar. Örneğin, kullanıcının yürüme hızını değiştirme niyetini tahmin etmek, dış iskeletin motor çıktılarına buna göre ayarlamasını sağlayarak daha sezgisel ve duyarlı bir deneyim sunmasını sağlar. Tahmin görevleri, dış iskeletin kullanıcının hareketlerini gerçek zamanlı olarak tahmin etmesini ve yanıtlamasını sağlar (Ren vd., 2022). Belirli kalıpları ya da aktiviteleri tanımlamak veya sınıflandırmak yerine, mevcut giriş verilerine dayanarak kullanıcının amaçladığı hareketleri tahmin etmeye odaklanır. Dış iskelet, yapay zekâ algoritmaları kullanarak giriş verilerini analiz edebilir ve kullanıcının gelecekteki davranışını veya hareketini tahmin edebilir. Bu, dış iskeletin yardımını ve davranışını buna göre ayarlamasını sağlayarak kullanıcıya kesintisiz ve doğal destek sağlar. Tahmin görevleri, kullanıcı ile dış iskelet arasındaki proaktif etkileşimi kolaylaştırarak dış iskelet sisteminin genel performansını, kullanılabilirliğini ve etkinliğini artırabilir.

1.3.1 Tekrarlayan Sinir Ağları (RNN)

Tekrarlayan Sinir Ağları (RNN, Recurrent Neural Network) mimarisi, özellikle sıralı ve zaman bağlı verilerin işlenmesi için tasarlanan ileri beslemeli yapay sinir ağı türüdür. RNN'ler, girdiler arasındaki bağımlılıkları öğrenmek için geri besleme (recurrent) döngülerine sahiptir, bu da önceki zaman adımlarındaki bilgilerin daha sonraki adımlara aktarılmasına yarar. Bu özellik, RNN'leri özellikle metin, konuşma, zaman serisi ve hareket verileri gibi ardışık verilerde etkili kılar (Zhou vd., 2020).

RNN'ler, önceki girdiler hakkında bilgi yakalayan gizli bir durumu koruyarak ardışık verileri işlemek üzere tasarlanmıştır. Temel mimari, bir giriş katmanı, bir gizli katman ve bir çıkış katmanından oluşur. RNN'ler, Şekil 1.2'de gösterildiği gibi, tekrarlayan bağlantılara sahiptir ve bu da bilgilerin ağlar içinde döngüye girmesine olanak tanır.

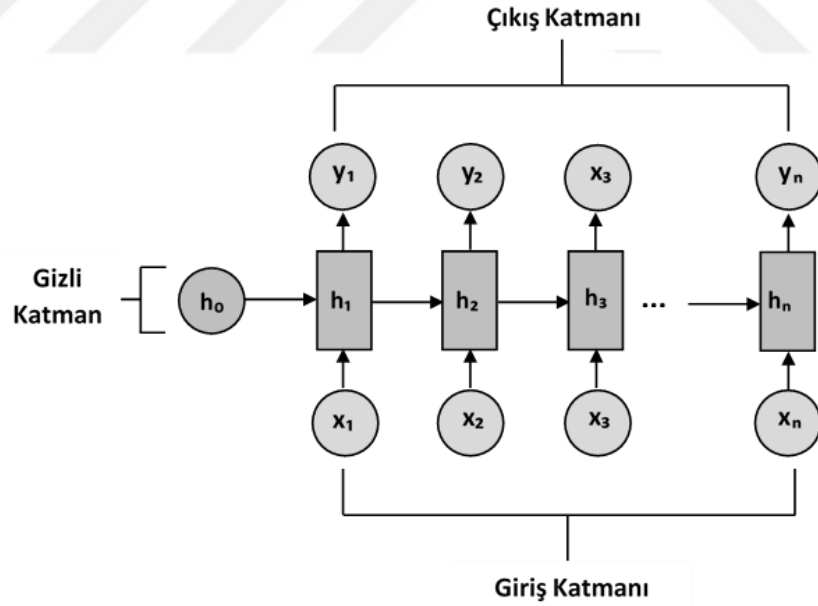
Her bir t zaman adımında RNN'nin, bir giriş vektörü (h_t) hesaplanır. Bu durum, hem mevcut giriş (x_t) hem de bir önceki zaman adımının gizli katman (h_{t-1}) kullanılarak güncellenir (Mienye vd., 2024). Bu süreç matematiksel olarak şu şekilde ifade edilir:

$$h_t = \sigma_y(w^{x,h}x_t + w^{h,h}h_{t-1} + b_h) \quad (1.1)$$

Burada σ_y aktivasyon fonksiyonu olarak yaygın şekilde kullanılan hiperbolik tanjant fonksiyonudur. b_h gizli katmanın bias (önyargı) terimi, $w^{x,h}$ giriş ile gizli katman arasındaki ağırlık matrisi, $w^{h,h}$ gizli katmanlar arasındaki ağırlık matrisidir. Her t zaman adımındaki çıkış (y_t) ise genellikle şu şekilde hesaplanır:

$$y_t = \sigma_y(w_{hy}h_t + b_y) \quad (1.2)$$

Burada w_{hy} gizli ve çıkış katmanları arasındaki ağırlık matrisidir, b_y çıkış katmanının önyargı terimi ve σ_y çıkış katmanının aktivasyon fonksiyonudur.



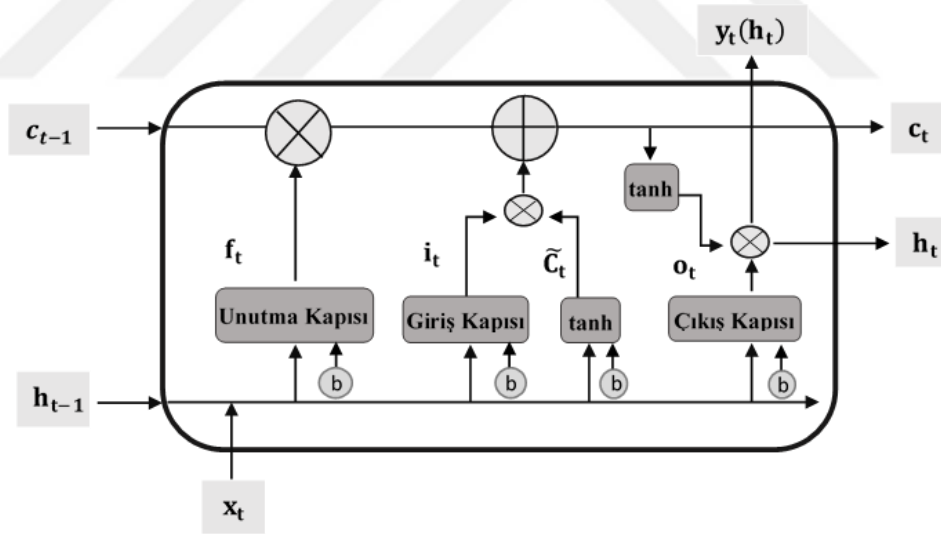
Şekil 1.2 Temel bir RNN mimarisi

1.3.2 Uzun Kısa Süreli Bellek (LSTM)

Uzun Kısa Süreli Bellek (LSTM, Long Short-Term Memory), Tekrarlayan Sinir Ağlarının (RNN) bir türüdür ve özellikle sıralı verilerdeki (zaman serisi, metin, vb.)

uzun vadeli bağılıkları öğrenme yeteneğine sahiptir. LSTM'ler, uzun vadeli bağımlılıkları öğrenme konusunda standart RNN'lerden daha etkilidir çünkü bilgiyi daha uzun süre koruyabilme yeteneğine sahiptir (Kolaghassi vd., 2023; Ren vd., 2022). Bu yetenek, LSTM hücrelerinin içinde yer alan hafıza hücreleri (memory cells) ve bunların kontrol edilmesini sağlayan özel kapı mekanizmaları (giriş (input), unutma (forget) ve çıkış (output) kapıları) sayesinde mümkün olur. Bu kapılar, önemli bilgilerin uzun süre boyunca saklanmasına ve gereksiz bilgilerin unutulmasına olanak tanır. Bu durum onları zaman serisi modelleme ve tahmini gibi görevler için oldukça uygun hale getirir (Zhu vd., 2021).

LSTM mimarisi, dört sinir ağı ve hücre adı verilen farklı bellek bloklarını içeren bir zincir yapısına sahiptir. LSTM ünitesinde giriş kapısı, unutma kapısı ve çıkış kapısı olmak üzere üç doğrusal olmayan kapı bulunur. Bu üç kapı, bilgi iletimini ve nihai sonuç hesaplamasını kontrol etmek için tasarlanmıştır (Jia vd., 2021). Bir LSTM mimarisinin temel yapısı Şekil 1.3'te gösterilmektedir.



Şekil 1.3 Temel bir LSTM hücresinin mimarisi

LSTM'deki ilk adım, hücre durumundan hangi bilginin atanılacağına karar vermektir. Bu karar, unutma kapısı olarak isimlendirilen bir sigmoid (σ) katman aracılığıyla, önceki andan gelen çıkış bilgisi h_{t-1} ve mevcut andaki giriş bilgisi x_t okunarak verilir. Hücre durumundaki her sayıya 0 ile 1 arasında bir f_t değeri çıktısı verir (Jia vd., 2021; Ren vd., 2021). İfade Eşitlik 3'te yer alan denkleme göre formülize

edilmektedir. Burada w_f ağırlık matrisini ve b_f ise önyargı vektörünü temsil etmektedir.

$$f_t = \sigma(w_f[h_{t-1}, x_t] + b_f) \quad (1.3)$$

Daha sonraki adımda, hücre durumunda hangi yeni bilginin depolanacağı belirlenir. Öncelikle, giriş kapısı adı verilen bir sigmoid katman, güncellenecek $i_{(t)}$ değerlerini belirler. İkinci olarak, bir vektör \tilde{c}_t aday hücre durumunu oluşturulmak için bir tanh katmanı kullanılarak gerçekleştirilir (Ren vd., 2021).

$$i_t = \sigma(w_f * [h_{t-1}, x_t] + b_i) \quad (1.4)$$

$$\tilde{c}_t = \tanh(w_c * [h_{t-1}, x_t] + b_c) \quad (1.5)$$

Eski hücre durumu c_{t-1} daha sonra unutma kapısından elde edilen f_t ile çarpılır ve giriş kapısından elde edilen güncellenmiş değer i_t daha sonra yeni hücre aday vektörü \tilde{c}_t 'nin çarpımına eklenir. Böylece en son hücre durumunu c_t elde edilir:

$$c_t = f_t * c_{t-1} + i_t * \tilde{c}_t \quad (1.6)$$

Sonuç olarak, çıkış veya tahmin edilen sonuç belirlenmelidir. Sonuç, hücre c_t 'nin mevcut durumuna dayanacaktır. Mevcut andaki giriş bilgisi x_t , bekleyen çıktı o_t 'nin sonucunu belirlemek için bir sigmoid katmandan geçirilir. Belirsiz üretim o_t , hücre durumu c_t ile çarpılır ve mevcut anda belirlenen h_t sonucunu elde etmek için katman tarafından işlenir (Ren vd., 2021).

$$o_t = \sigma(W_o * [h_{t-1}, x_t] + b_o) \quad (1.7)$$

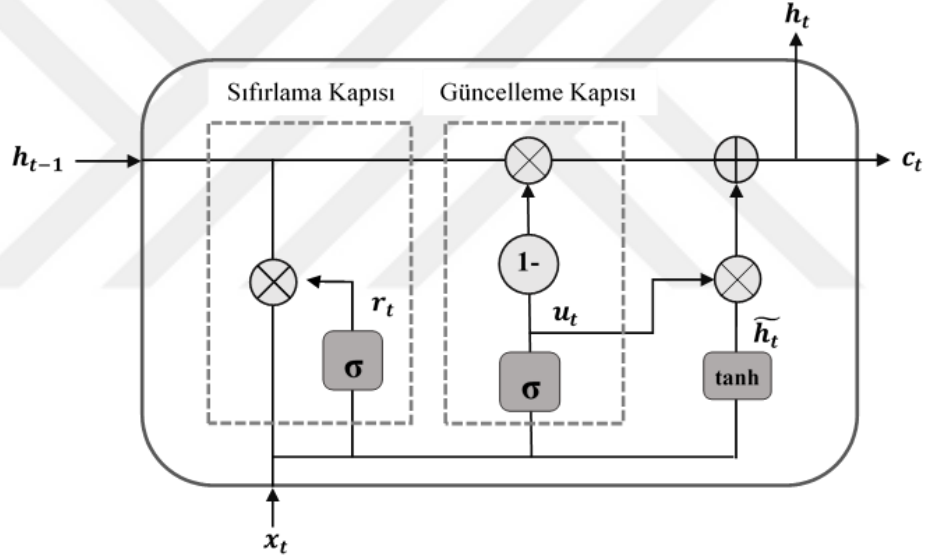
$$h_t = o_t * \tanh(c_t) \quad (1.8)$$

1.3.3 Kapılı Tekrarlayan Birim (GRU)

Cho vd. (2014) tarafından geliştirilen Kapılı Tekrarlayan Birim (GRU, Gated Recurrent Units), Tekrarlayan Sinir Ağları (RNN) içinde LSTM ağlarına bir alternatif

olarak önerilmiştir. (Cho vd., 2014). GRU'lar, LSTM modellerine kıyasla daha basit bir mimariye sahip olup, daha az parametre kullanmaktadır. Bu özellik, modelin eğitiminin daha kolay gerçekleştirilmesine olanak tanırken, hesaplama maliyetini de daha verimli bir düzeye getirmektedir (Wu vd., 2023).

GRU, zaman serisi verilerindeki zamansal bağımlılıkları yakalamada etkili bir yöntemdir. GRU, gradyan kaybolması ve uzun süreli bellek yetersizliği gibi problemlere çözüm sunabilmektedir (Lin vd., 2024). LSTM hücresinin giriş, unutma ve çıkış kapılarından oluşan yapısının aksine, GRU hücresi, Şekil 1.5'te görüldüğü üzere temel olarak sıfırlama kapısı (r_t) ve güncelleme kapısından (u_t) oluşmaktadır (Wu vd., 2023).



Şekil 1.4 Temel bir GRU hücresinin mimarisini

Güncelleme kapısı, önceki gizli durumun ne kadarının yeni gizli duruma aktarılacağını belirler. Sıfırlama kapısı ise önceki gizli durumun hangi kısmının unutulacağını belirler (Wu vd., 2023).

$$r_t = \sigma(w_r x_t + u_r h_{t-1} + b_r) \quad (1.9)$$

$$u_t = \sigma(w_u x_t + u_u h_{t-1} + b_u) \quad (1.10)$$

Burada σ sigmoid aktivasyon fonksiyonunu ifade etmektedir. b_r ve b_u eğitim sırasında öğrenilecek önyargı (bias) vektörleridir; w_r ve w_u eğitim sırasında öğrenilecek ağırlık matrislerini ifade etmektedir. Sıfırlama kapısı fonksiyonundan elde edilen özelliklere dayanarak, aday gizli durum \tilde{h}_t önceki gizli durumun güncellenmiş bir versiyonunu oluşturur (Wu vd., 2023).

$$\tilde{h}_t = \tanh (w_h x_t + u_h [x_t * h_{t-1}] + b_h) \quad (1.11)$$

Güncelleme kapısının etkisiyle önceki gizli durum ile aday gizli durum birleştirilerek yeni gizli durum h_t elde edilir.

$$h_t = u_t * h_{t-1} + (1 - u_t) * \tilde{h}_t \quad (1.12)$$

Burada, u_t 'den gelen değerler 1'e yakın olduğunda daha önceki geçici bağımlılık özelliği bilgisi hatırlanmakta; u_t 'den gelen değerler 0'a yakın olduğunda ise ilişkisiz önceki zamansal özellik bilgisinin kaybolmaktadır (Wu vd., 2023).

1.4 Veri Ön İşleme Prosesleri

1.4.1 Kalman Filtresi

Kalman filtresi, bir sistemin mevcut durumunu tahmin etmek ve sensör ölçümlerindeki hataları düzeltmek amacıyla iki temel aşamada çalışır: tahmin ve güncelleme. İlk olarak, tahmin aşamasında, sistemin bir sonraki durumu, önceki duruma ve sistem dinamiklerine dayanarak hesaplanır. Bu adımda, gelecekteki sistem durumu ve belirsizlik (hata kovaryansı) öngörülür. Ardından, güncelleme aşamasında, yeni ölçümler alınır ve bu ölçümler kullanılarak tahmin edilen durum düzeltilir. Ölçümle tahmin arasındaki fark, Kalman kazancı olarak adlandırılan bir katsayı kullanılarak değerlendirilir. Bu süreç, sistemin durumunu sürekli olarak güncelleyerek, verilerdeki gürültüye rağmen en doğru tahmini elde etmeyi sağlar (Çayıroğlu, 2012; Khodarahmi ve Maihmi, 2023).

Kalman filtresi, zaman serilerinin analizinde optimal çözüm sunan tahmin yöntemidir. Kalman filtresi, bir sistemin durumunu x_t vektörü ile tanımlar ve ölçülen veriler z_t

üzerinden tahmin eder. Bu tahmin işlemi, sistemin durumu ve ölçüm verileri üzerinden sürekli güncellenir (Khodarahmi ve Maihami, 2023).

$$x_k = F_{k-1}x_{k-1} + W_{k-1} \quad (1.9)$$

$$z_k = H_k x_k + V_k \quad (1.10)$$

Bu kısımda, F durum geçiş matrisi, H gözlem modeli (ölçüm matrisi), W_k sistem gürültüsü ve V_k ise ölçüm gürültüsü olarak tanımlanmıştır. Denklemlerde yer alan bu parametreler kullanılarak, Kalman filtresi z_k ölçümlerindeki gürültüye rağmen x_k durumunu tahmin eder ve k-1'e kadar tüm ölçümler mevcut olduğunda önceki durum ve hata kovaryansı aşağıdaki gibi hesaplanır:

$$x_k^- = F_{k-1}x_{k-1} \quad (1.11)$$

$$P_k^- = F_{k-1}P_{k-1}^+F_{k-1}^T + Q_k \quad (1.12)$$

Sonraki durum ve hata kovaryansı şu şekildedir:

$$\hat{x}_k = x_k^- + K_k(y_k - H_k x_k^-) \quad (1.13)$$

$$\hat{P}_k = (I - K_k H_k) P_k^- \quad (1.14)$$

Önceki tahminlerin değerleri kullanılarak durum ve kovaryans tahmin edildikten sonra Kalman optimal sonucu aşağıdaki gibi hesaplanır:

$$K_k = P_k^- H_k^T (H_k P_k^- H_k^T + R_k)^{-1} \quad (1.15)$$

Daha sonra durum tahmini Kalman optimal sonucu kullanılarak güncellenir:

$$\hat{x}_k = \hat{x}_k + k_k (z_k - H_k \hat{x}_k) \quad (1.16)$$

Son olarak kovaryans matrisi aşağıdaki gibi güncellenir: I birim matristir

$$P_k = (I - H_k \hat{x}_k) P_k \quad (1.17)$$

Kalman filtresinde, Q ve R deęerleri filtre performansını belirleyen önemli parametrelerdir. Ancak, bunların doğrudan bir hesaplama formülü yoktur; genellikle veri setine ve uygulamaya baęlı olarak deneysel veya istatistiksel yöntemlerle belirlenmektedir (Khodarahmi ve Maihami, 2023).

1.4.2 Kayan Pencere Yöntemi

Zaman serisi segmentasyonu, zamana baęlı deęişen verilerinin analizi ve araştırılması sürecinde temel bir bileşendir. Bu yöntem, sürekli bir zaman serisi verisini belirli bölümlere ayırarak her bir bölümü analiz edilebilir hale getirmeye odaklanır. Bu yöntem, özellikle karmaşık zaman serisi verilerindeki anlamlı örüntüleri veya özellikleri belirlemek, farklı durumları veya olayları tespit etmek ve çeşitli yapay zekâ modellerine girdi oluşturmak amacıyla kullanılır (Deldari vd., 2020). Literatürde farklı algoritmalar kullanılsa da çoęu zaman serisi segmentasyon algoritması kayan pencere, yukarıdan aşağıya ve aşağıdan yukarıya yöntemleri olmak üzere üç kategoride gruplandırılmıştır (Carmona-Poyata vd., 2021).

Sensör verilerinden elde edilen zaman serisi verileri, insan hareketlerinin dinamik ve sürekli doğası nedeniyle genellikle ayrıntılı analiz gerektirir. Bu tür verilerin analizi sırasında kayan pencere teknięi, hareketin kısa süreli örüntülerini ve özelliklerini belirlemek için yaygın bir şekilde tercih edilir (Kolaghassi vd., 2023; Su ve Gutierrez-Farewik, 2020; Zaroug vd., 2020).


Kayan pencere yöntemi, belirli bir zaman aralığını temsil eden küçük veri bölümleri (pencereler) oluşturarak bu segmentler üzerinde analiz yapılmasını sağlar. Her pencere, zaman serisinden belirli bir uzunluktaki ardışık veri noktalarını içerir ve bu pencere belirli bir kayma miktarıyla veri üzerinde ilerler. Bu yöntem, hem sürekli veri akışlarının işlenmesinde hem de belirli zaman aralıklarında anlamlı özelliklerin çıkarılmasında etkin bir yaklaşım sunar.

Sinyal segmentasyonunda önemli bir faktör, veri analizi ve modelleme için uygun pencere boyutunu seçmektir. Pencere boyutunun çok küçük olması, modelin gürültüye duyarlı olmasına ve önemli özelliklerin gözden kaçabilmesine neden olmaktadır. Çok büyük pencere boyutları ise, verinin zaman içindeki hızlı deęişimlerini kaybetmesine

yol açabilmektedir (Noor vd., 2017; Ma vd., 2020). Diğer bir önemli parametre ise kayma uzunluğudur. Kayma uzunluğu kavramı pencerenin bir sonraki pozisyona ne kadar ilerleyeceğini belirler (Kolaghassi vd., 2022).

Şekil 1.5'te zaman serisi $X = \{x_1, x_2, x_3, \dots, x_n\}$, toplam n veri noktasını içermektedir. Bu zaman serisi, kayan pencere yöntemi kullanılarak analiz edildiğinde, her bir pencere belirli bir uzunluk (k) ve kayma değeri (i) ile tanımlanmaktadır. Kayan pencereler, zaman serisinin ardışık alt bölümlerini temsil eder. Her bir pencere, k veri noktası içerir ve bir sonraki pencere başlangıcı bir öncekinin başlangıcından i kadar kaydırılır. Bu yöntemde, pencereler şunları ifade eder:

- İlk pencere, zaman serisinin x_1 ile başlayarak k veri noktasını içerir: $W_1 = \{x_1, x_2, \dots, x_k\}$
- İkinci pencere, zaman serisindeki başlangıç noktasını i kadar kaydırır ve $W_2 = \{x_{1+i}, x_{2+i}, \dots, x_{k+i}\}$
- Bu işlem, zaman serisinin sonuna kadar devam eder.



Şekil 1.5 Kayan pencere segmentasyonu gösterimi

2. LİTERATÜR TARAMASI

Foroutannia vd. (2022) alt ekstremite dış iskelet robotunun kalça eklemi pozisyonunu tahmin etmek ve bir sonraki adımda robotun gerekli yardımcı kuvvetlerini belirlemek için EMG sinyallerini kullanan bir derin öğrenme stratejisi önermişlerdir. Bu derin öğrenme stratejisi, dış iskelet robotunun gelecekteki aktif eklem pozisyonunu tahmin etmek için LSTM yapısını kullanmaktadır.

Gwon vd. (2024) endüstriyel robotlar için 300 milisaniye öncesindeki hareket niyetlerini tahmin edebilen bir CNN-LSTM modeli önermişlerdir. Bu çalışmada temsili bir kaldırma hareketi olan eğilip kalkma eylemindeki değişen hareket niyetlerine odaklanılmıştır. 24 sağlıklı katılımcıdan alınan EMG sinyalleri kullanılarak yapılan çalışmada %84,02'lik bir tahmin doğruluğu elde edilmiştir.

Moosavian vd. (2021) tanıttıkları RoboWalk kinematik modelinin bir sonraki adımını tahmin etmek için LSTM tabanlı bir derin öğrenme metodu sunmuşlardır. Çalışmada, 3B kamera hareket yakalama sistemi ile elde edilen kinematik veriler kullanılarak hareket modları belirlenmiş ve RoboWalk kinematik modeli oluşturulmuştur. Burada ortaya çıkan RoboWalk'un eklem yörüngesi, LSTM tahmin ağı girişi olarak kullanılmış ve insan yürüyüşünün bir önceki adımından elde edilen yörünge verileriyle bir sonraki adım %98,5 doğrulukla tahmin edilmiştir.

Kolaghassi vd. (2023) Serebral Palsili (SP) çocukların rehabilitasyonuna yönelik dış iskeletlerin kontrol mekanizmasında kullanılmak üzere, yürüyüş yörüngesinin bir sonraki adımının tahmin edilmesini sağlayan Tam Evrişimli Ağ (FCN, Fully Convolutional Network), LSTM, CNN ve Transformer olmak üzere dört derin öğrenme modeli önermişlerdir. Önerilen modellerin eğitilmesi ve değerlendirilmesi için sağlıklı ve SP'li çocukların yürüyüşlerinden elde edilen veri seti kullanılmıştır. Veriler, IMU kullanan eylemsizlik hareket yakalama sistemiyle toplanmış olup SP'li çocuklardan elde edilen tüm veriler yalnızca modellerin test edilmesi ve bir sonraki adımının tahmin edilmesi için kullanılmıştır.

Gutierrez-Farewik ve Su (2020) IMU sensörü aracılığıyla 12 sağlıklı denekten elde ettiği yürüyüş verilerini girdi olarak kullanan ve bir yürüyüş döngüsünün tahmin edilmesini sağlayan LSTM sinir ağı modeli önerdi. Önerilen model, alt ekstremite eklem açılarının 100-200 ms ilerisini tahmin etmek amacıyla geliştirilmiştir. (Gutierrez-Farewik ve Su, 2020).

Moghadam vd. (2024) çocuklarda, yürüyüş zaman serilerini tahmin etmek amacıyla, IMU sensörlerinden elde edilen alt ekstremite eklem kinematiği verilerini kullanarak Rastgele Orman (RF, Random Forest) ve CNN tabanlı yapay zekâ modellerinin uygulanabilirliğini değerlendirmişlerdir. Çalışmada, 12 sağlıklı çocuğun yürüyüş verileri kullanılmış ve RF ile CNN modelleri arasında benzer tahmin doğruluğu olduğu belirlenmiştir. RF modelinin performansı %90,5 doğruluk sağlarken, CNN modeli %89,3 doğruluk elde etmiştir.

Zaroug vd. (2020) yürüyüş sırasında insan alt ekstremite kinematiğinin gelecekteki yörüngelerini tahmin etmek amacıyla bir LSTM sinir ağı modeli önermiştir. Önerilen model, bir kodlayıcı ve bir kod çözücüyü içeren oto kodlayıcı LSTM sinir ağı mimarisine dayanmaktadır. LSTM modelinin giriş verileri, 6 sağlıklı erkek katılımcının 5 km/sn hızla yürüdükleri esnada, bir koşu bandında 3B hareket yakalama sistemiyle kaydedilen alt ekstremite pozisyon-zaman koordinatlarından oluşmaktadır. Elde edilen doğrusal ivme ve açısal hız verileri, alt ekstremite kinematiğinin birden fazla zaman adımındaki yörüngelerini tahmin etmek için kullanılmıştır. Sonuç olarak, baldır ve uyluk için tahmin edilen kinematik özellik değişkenleri, gelecekteki 60 ms'ye kadar tahmin edilebilmiştir.

Tablo 2.1 Literatürde yer alan çalışma sonuçlarının özeti

Yazarlar	Sensörler	Veri Kümesi	Model	Giriş Pencere Boyutu	Çıkış Pencere Boyutu	Hata Metriği	Sonuçlar
Moghadam vd. (2024)	IMU, kuvvet plakaları	17 sağlıklı çocuk katılımcı	RF, CNN	750 ms	-	NRMSE	RF: %9,5 CNN: %10,7
Gwon vd. (2024)	IMU, EMG	24 erkek katılımcı	CNN-LSTM	200 ms	300 ms	Doğruluk	%84,02
Kolaghassi vd. (2023)	IMU, 3B hareket yakalama sistemi	10 sağlıklı ve 11 SP'li çocuk katılımcı	CNN, FCN LSTM, Transformer	1000 ms	200 ms	MAE	CNN: 10,72° FCN: 10,03° LSTM: 9,36° Transformer: 10,31°
Kolaghassi vd. (2022)	3B hareket yakalama sistemi	Gillette Children's Speciality Healthcare Veritabanı	CNN, LSTM	50-1000 ms	8,33-200 ms	MSE, MAE	CNN: 0,061-0,138° LSTM: 0,019-0,095°
Ren vd. (2022)	3B hareket yakalama sistemi	CMU Graphics Lab Motion Capture Veritabanı	LSTM	-	-	RMSE	Sağ-sol kalça: 0,4662-0,4665 Diz: 0,3246-0,5037 Ayak bileği: 0,7416-0,5548
Moosavian vd. (2021)	Kuvvet plakaları, 3B hareket yakalama sistemi	5 sağlıklı ve 2 protez kullanıcısı katılımcı	LSTM	-	-	Doğruluk	%98,5
Zhu vd. (2021)	3B hareket yakalama sistemi	Sağlıklı erkek katılımcılar	CNN-LSTM	54-81 ms	60 ms	RMSE MAE	0,741 0,569
Jia vd. (2021)	3B hareket yakalama sistemi, EMG	Dört sağlıklı erkek denek	LSTM, RNN	200 ms	50 ms	RMSE	LSTM: 0,464° RNN: 2,523°
Su ve Gutierrez-Farewik (2020)	IMU, basınç sensörü	12 sağlıklı denekten	LSTM	10-30 zaman adımı	5 ve 10 zaman adımı	Doğruluk RMSE	Doğruluk: %92 RMSE: 0,80
Zaroug vd. (2020)	Hareket yakalama sistemi, GRF	6 sağlıklı katılımcı	LSTM	5-40 zaman adımı	5 ve 10 zaman adımı	MAE	Uyluk: 0,047 m/sn ² Bacak: 0,047 m/sn ² Uyluk: 0,028 °/sn Bacak: 0,024 °/sn
Zhou vd. (2020)	3B hareket yakalama sistemi	137 sağlıklı katılımcı	GRU	80 zaman adımı	68-84 zaman adımı	MAD	Ayak bileği: 1,49° Diz: 2,12° Kalça: 3,75°

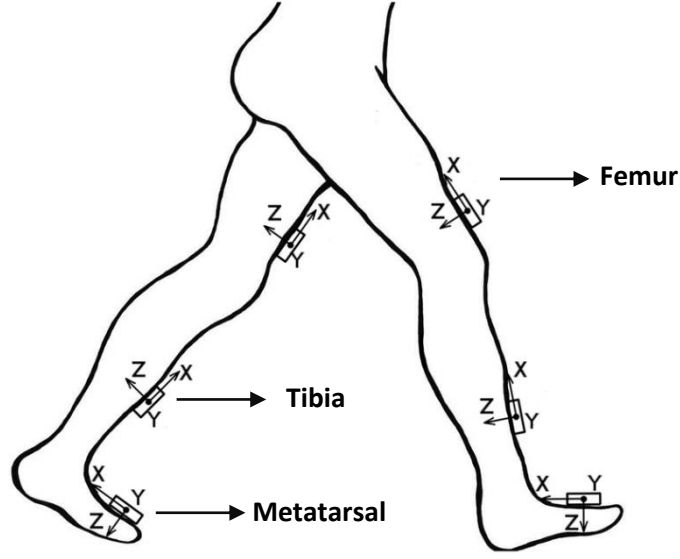
3. YÖNTEM

Bu tez çalışmasında, HuGaDB (Human Gait Database (İnsan Yürüyüşü Veri tabanı)) veri setinden alınmış IMU sensör verileri kullanılarak, alt ekstremitte dış iskelet robotlarının kontrol mekanizmasına yönelik RNN, LSTM ve GRU tabanlı bir kinematik yörünge tahmin modelleri geliştirilmiştir. Modeller, geçmiş yürüme verilerini kullanarak bir sonraki zaman adımını tahmin etmek üzere tasarlanmıştır. Farklı giriş ve çıkış pencere boyutlarıyla eğitilen modellerin performansı değerlendirilmiş ve pencere uzunluklarının tahmin doğruluğu üzerindeki etkisi incelenmiştir.

Çalışmamız, Python 3.9.12 kullanılarak kodlandı. Veri ön işleme prosesleri ve model eğitimleri için Os, NumPy, Pandas, Matplotlib, FilterPy, Sklearn, TensorFlow, Math kütüphaneleri kullanıldı.

3.1 Veri Seti

Çalışmamızda insan yürüyüşüne ait ayrıntılı kinematik verilerin yer aldığı HuGaDB veri seti kullanılmıştır (Chereshnev ve Kertesz-Farkas, 2017). HuGaDB veri seti, 4 kadın ve 14 erkek olmak üzere 18 sağlıklı yetişkinin sensör verisini içermektedir. Veriler, Şekil 3.1’de görüldüğü üzere sağ ve sol uyluklarda (femur), kaval kemiğinde (tibia) ve ayaklarda (metatarsal) bulunan altı adet giyilebilir IMU sensöründen oluşan bir vücut sensör ağından toplanmıştır. Her IMU sensörü, X,Y ve Z eksenlerinde doğrusal ivme ve açısal hız ölçümleri sağlamıştır. İvmeölçer (accelerometer) verileri $\pm 2g$ (g: yer çekimi ivmesi) çalışma aralığında ve jiroskop (gyroscope) verileri ise ± 2000 %/sn aralığında toplanmıştır. Veri toplama sırasında, sensörler 56,35 Hz ortalama örnekleme frekansı ile çalıştırılmış ve toplanan veriler, Bluetooth üzerinden bilgisayara aktarılmıştır. İvmeölçer ve jiroskop sinyallerini içeren ham veri dosyaları, int16 formatında saklanmıştır.



Şekil 3.1 IMU sensörlerinin yerleşimi (Chereshnev ve Kertesz-Farkas, 2017)

Veri dosyalarının ana gövdesi, doğrudan sensörlerden elde edilen sekmeyle ayrılmış ham, normalleştirilmemiş verileri içermektedir. Bu veriler, yer aldığı dosya biçiminde her sütunun bir sensöre; her bir satırın ise bir örneğe karşılık geldiği formatta ücretsiz olarak yayınlanmıştır.

3.2 Ön İşleme

Chereshnev ve Kertesz-Farkas (2017) HuGaDB veri setinde paylaştıkları verilerin, ivmeölçer ve jiroskoplardan elde edilmiş, int16 formatında ham sinyal verileri olduğunu bildirmişlerdir. Bu durumda ham verilere fiziksel anlam kazandırmak için birim dönüştürmeleri yapılması gerekmiştir. Yazarlar, çalışmada kullandıkları sensörlere ait bilgilere değinmiş ve birim dönüştürmeleri için gerekli fiziksel parametreleri yayınlamışlardır. Bu doğrultuda, ivmeölçer verileri, ham veriyi 32768'e bölüp 2g ile çarpılarak ivmeye (m/sn^2); ham jiroskop verileri ise 2000/32768 ile çarpılarak açısal hıza ($^{\circ}/sn$) dönüştürüldü. (Burada 32768 değeri 16 bitlik işaretli tam sayı için maksimum değerdir.)


IMU sensörlerinden elde edilen ham verilerin birçok gürültü ve hataya maruz kalması, sinyallerden anlamlı bilgi çıkarılmasını zorlaştırır ve tahmin algoritmalarının doğruluğunu olumsuz etkiler. Bundan dolayı sensör verilerindeki rastgele dalgalanmaları (gürültü) azaltmak ve hareketin asıl dinamiklerini temsil eden daha

pürüzsüz ve anlamlı sinyaller elde etmek için zaman serisi analizlerinde yaygın olarak kullanılan Kalman Filtresi yöntemi uygulanmıştır.

Sinir ağlarının performansını iyileştirmek ve eğitim sürecini hızlandırmak amacıyla, verilerin ölçeklendirilmesi veya standartlaştırılması gerekmektedir. Bu doğrultuda, her bir özelliğin minimum değeri 0 ve maksimum değeri 1 olacak şekilde Eşitlik 2.1'de belirtilen Min-Max normalizasyonu uygulanmıştır.

$$x' = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (2.1)$$

IMU verileri RNN, LSTM ve GRU modellerine beslenmeden önce, Şekil 3.2'de gösterilen kayan pencere tekniği (sliding window technique) kullanılarak 3B veri setine dönüştürülmüştür. Kayan pencere bir giriş penceresi, bir çıkış penceresi ve bir kayan boyuttan oluşmaktadır. Giriş penceresi (x_{in}), modelin tahmin yapabilmesi için kullanılan zaman adımlarını içermektedir. Kayan pencere boyutu, k zaman adımına denk gelir ve bu pencere giriş verisini ($x_{in} = \{ x_1, x_2, \dots, x_k \}$) oluşturur. Çıkış penceresi (y_{out}), modelin tahmin etmesi gereken değerleri içerir. Çıkış penceresi boyutu, z zaman adımına karşılık gelir ve $y_{out} = \{ x_{k+1}, x_{k+2}, \dots, x_{k+z} \}$ şeklinde ifade edilir. Giriş penceresi (x_{in}) ve buna karşılık gelen çıkış penceresi (y_{out}), bir eğitim örneği oluşturur. Bu, modelin öğrenme sürecinde kullanılacak giriş-çıkış eşleştirmesini sağlar.



Şekil 3.2 Kayan pencere yönteminin gösterimi

Kullanılan her bir model, farklı giriş-çıkış penceresi boyutları kullanılarak eğitilmiştir. Giriş penceresi boyutları 600, 800 ve 1000 ms olarak belirlenmiş ve bu süreler, verilerin kaydedildiği örnekleme frekansı dikkate alındığında sırasıyla 34, 46 ve 56 zaman adımına karşılık gelmiştir. Çıkış penceresi boyutları ise 6, 12 ve 17 zaman adımlarını temsil eden 100, 200 ve 300 ms sürelerini kapsamaktadır. Giriş ve çıkış penceresi boyutlarının tüm olası kombinasyonları değerlendirilmiş ve toplamda dokuz farklı kombinasyon oluşturulmuştur. Bu kombinasyonlar, yürüyüş yörüngelerinin tahmini konusunda literatürde önerilen değerler esas alınarak seçilmiştir. Ayrıca kayan pencere parametreleri belirlenirken, tam bir yürüyüş döngüsünü kapsayacak şekilde, 56,35 Hz'lik örnekleme oranı göz önünde bulundurulmuştur.

Literatürde, farklı pencerelerle yapılan çalışmalar bu seçimleri desteklemektedir. Kolaghasi vd. (2022) gelecekteki 200 ms'lik zaman adımlarını tahmin etmek için geniş bir giriş penceresi aralığı kullanmışlardır. Zaroug vd. (2020) alt ekstremite kinematik yörünge tahmini için 60 ms'ye denk gelen 10 zaman adımını tahmin etmiş ve bu süreçte 5-40 adımlık giriş penceresi aralıklarını incelemiştir. Gutierrez-Farewik ve Su. (2020) alt ekstremite kinematik yörüngelerini gelecekteki 200 ms ileriye dönük 10 zaman adımı için tahmin etmişlerdir. Jia vd. (2021) diz eklemının yürüyüş yörüngesini, 50 ms sonrası için öngörmüştür. Zhu vd. (2021) çıkış penceresi boyutu 9 zaman adımını kapsayan bir modelle 60 ms sonraki eklem açılarını tahmin etmeyi başarmışlardır.

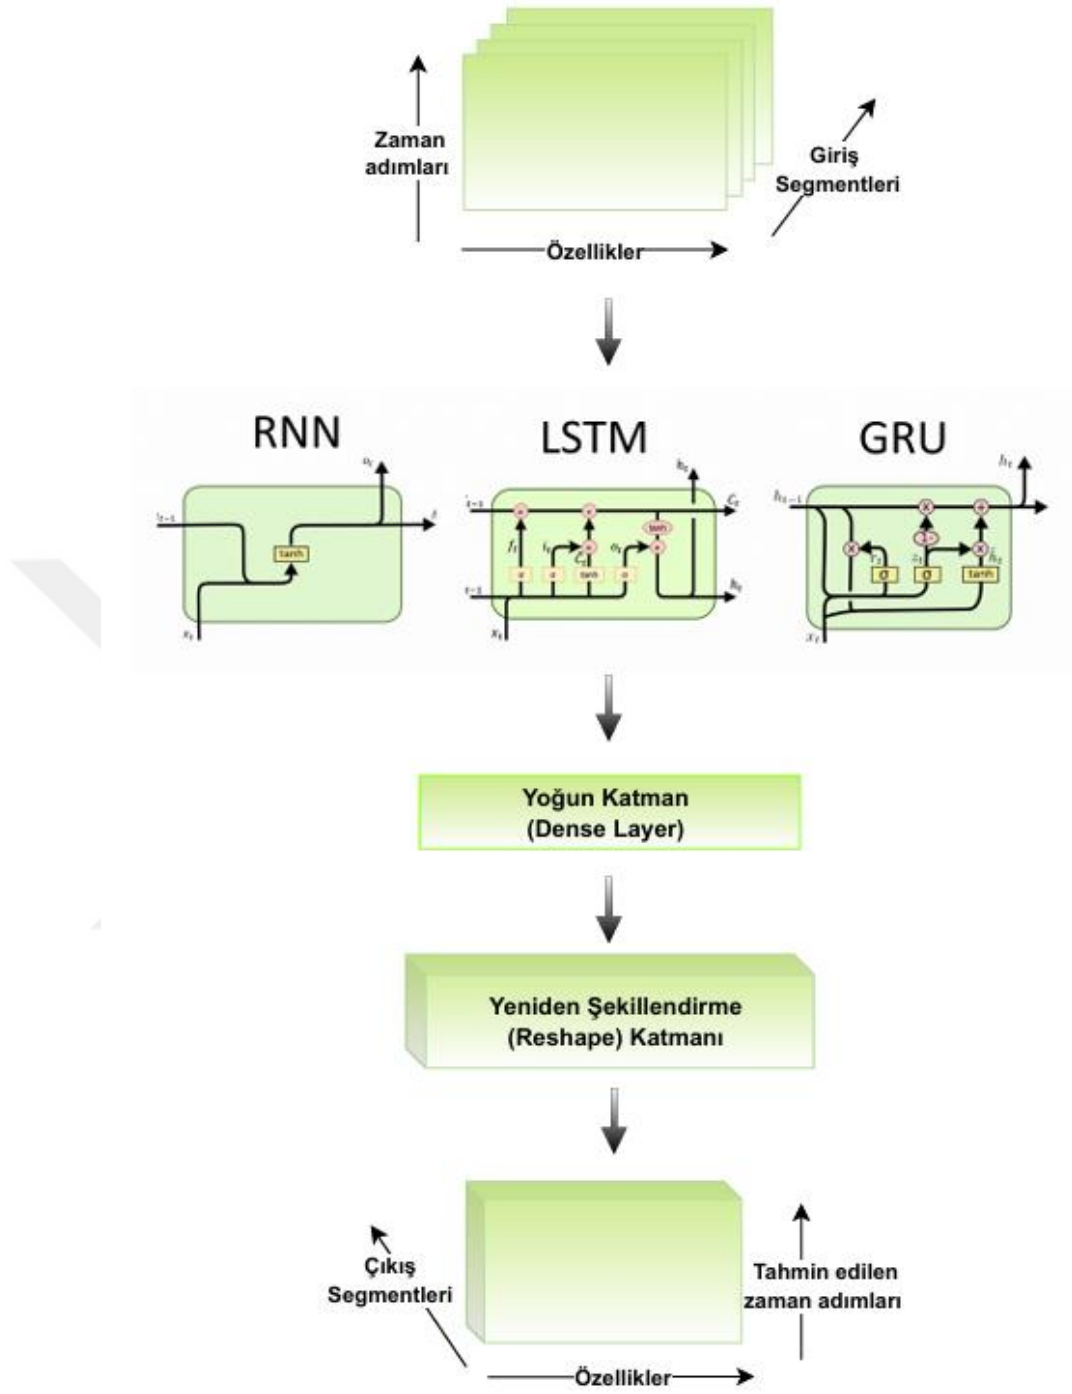
3.3 Model Mimarileri

Bu tez çalışmasında, insan yürüyüş hareketlerinin gelecekteki zaman adımlarının tahmin edilmesi amacıyla Tekrarlayan Sinir Ağı (RNN), Uzun Kısa Süreli Bellek (LSTM) ve Kapılı Tekrarlayan Birim (GRU) modelleri kullanıldı. Kullanılan modeller, zaman serisi verilerindeki ardışık bağımlılıkları öğrenmek ve bu bağımlılıklardan yola çıkarak geleceğe yönelik tahminler yapmak üzere yapılandırılmıştır. Model mimarileri, literatürde yer alan yöntemlere dayalı olarak optimize edilmiş ve farklı giriş ve çıkış pencere boyutları için performans değerlendirmesi yapılmıştır. Kullanılan tüm modellerin optimizasyonu için Ortalama Kare Hata (MSE, Mean Squared Error) kayıp fonksiyonu kullanılmıştır.

Modellerin giriş katmanları, kayar pencere yöntemiyle oluşturulan segmentlerden oluşmaktadır. Her bir modelin giriş katmanına verilen veri, 3 boyutlu bir tensör yapısındadır. Bu tensör, zaman serisi verisini temsil etmektedir ve “num_samples, time_steps, num_features” şeklinde modelin giriş verilerini oluşturmaktadır. Burada “num_samples” segmentasyon sonucunda oluşan giriş pencere sayısını, “time_steps” zaman adımı sayısını ve num_feature veri setindeki özellik (sütun) sayısını ifade etmektedir.

Segmentlere ayrılan veriler modellere beslenmeden önce %70 eğitim, %20 test ve %10 doğrulama (validasyon) verisi olacak şekilde bölünmüştür. Yürüme verileri için eğitim, test ve doğrulama setleri sırasıyla 12968, 3705 ve 1853 örnekten oluşmaktadır. Doğrulama verisi, modellerin eğitimi sırasında aşırı öğrenme (overfitting) yapmasını engellemek için kullanılmıştır. Tüm modellerin ağırlıklarını ve biaslarını güncelleyerek kayıp fonksiyonunu (loss) minimize etmek amacıyla Adam (Adaptive Moment Estimation (Uyarlanabilir Moment Tahmini)) optimizasyon algoritması kullanılmıştır. Modellerin hiperparametrelerini belirlemek için ise Izgara Arama (Grid Search) yöntemi kullanılmıştır. Bu yöntem, her bir hiperparametrenin tanımlanan değer aralıklarını birleştirerek tüm olası kombinasyonları oluşturmakta ve bu kombinasyonların her biri için model eğitimi gerçekleştirmektedir.

Bu çalışmada, hiperparametre optimizasyonu, katman sayısı (num_layers), gizli birim sayısı (hidden_units), grup boyutu (batch_size), epok sayısı (epochs) ve öğrenme oranı (learning_rate) değerlerinin tanımlandığı bir arama alanını kapsamıştır. Her bir kombinasyon için tüm modeller, eğitim verileri üzerinde eğitilmiş ve her modelin test seti üzerindeki performansı değerlendirilmiştir. Eğitim sürecinde, modellerin aşırı öğrenmesini önlemek amacıyla erken durdurma (early stopping) stratejisi uygulanmıştır. Bu strateji, doğrulama kaybının belirli bir sayıda epok boyunca iyileşme göstermediği durumda eğitim sürecini sonlandırmıştır. Ayrıca, her eğitim döngüsünde doğrulama kaybının en düşük olduğu model ağırlıkları, ModelCheckpoint mekanizması ile kaydedilmiştir. Bu süreç, en iyi hiperparametre kombinasyonunun ve ağırlıkların seçilmesini sağlamış, her bir modelin genel performansını optimize etmiştir.



Şekil 3.3 RNN, LSTM ve GRU modellerinin genel mimarisi

Şekil 3.3'te gösterildiği gibi kullanılan her bir modelin çıkışı, kayar pencere yöntemiyle oluşturulan giriş segmentlerine dayanarak gelecekteki zaman adımlarını tahmin etmek üzere tasarlanmıştır. Tüm modellerin çıkış katmanında, gizli katmanlarından elde edilen çıktı önce tam bağlantılı bir yoğun (dense) katmanına aktarılmıştır. Bu katman, tahmin edilmek istenen zaman adımları (output_steps) ile her

bir zaman adımına ait özelliklerin (num_features) çarpımına eşit boyutta bir vektör üretmektedir. Daha sonra bu vektör, bir Reshape katmanı aracılığıyla yeniden düzenlenerek nihai model çıktısı (num_samples, output_steps, num_features) boyutunda bir tensör olarak sunulmaktadır. Burada num_samples, çıkış segmentlerinin sayısını; output_steps, tahmin edilen zaman adımı sayısını; num_features ise her bir zaman adımında tahmin edilen özelliklerin sayısını ifade etmektedir.

3.4 Değerlendirme Ölçütleri

Regresyon modellerinin değerlendirilmesinde yaygın olarak kullanılan metrikler arasında Kök Ortalama Karesel Hata (RMSE, Root Mean Squared Error) ve Ortalama Mutlak Hata (MAE, Mean Absolute Error) bulunmaktadır. Bu metrikler, tahminlerin doğruluğunu ve gerçek değerlerden sapma miktarını sayısal olarak ifade etmektedir.

Bunun yanı sıra, Determinasyon Katsayısı (R^2 , Coefficient of Determination), modelin verilere ne kadar iyi uyduğunu ve tahmin gücünü ölçmek için kullanılan önemli bir metriktir. R^2 , modelin bağımsız değişkenler aracılığıyla bağımlı değişkeni ne kadar iyi açıkladığını gösterir.

Bu tez çalışmasında, RNN, LSTM ve GRU regresyon modellerinin performansı RMSE, MAE ve R^2 ölçütleri kullanılarak değerlendirilmiştir. Bu metrikler, modelin tahmin ettiği değerlerle gerçek değerler arasındaki farkı ölçerek, modelin tahmin başarısını sayısal olarak ortaya koymaktadır.

Kök Ortalama Karesel Hata (RMSE), model tarafından tahmin edilen değerler ile gerçek değerler arasındaki ortalama farkı ölçen bir performans metriğidir. Bu metrik, modelin hedef değerlerini ne kadar doğru bir şekilde tahmin edebildiğini (doğruluğunu) sayısal olarak ifade etmektedir. RMSE, Eşitlik 2.2’de yer alan formül kullanılarak hesaplanmaktadır:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \tilde{y}_i)^2} \quad (2.2)$$

Burada $(y_i - \tilde{y}_i)$, her bir tahminin hata değeri (tahmin edilen değer ile gerçek değer arasındaki fark) ve n , toplam gözlem sayısını ifade etmektedir.

Ortalama Mutlak Hata (MAE), tahminlerdeki hataların ortalama büyüklüğünü ölçen bir metrik olup, hataların yönlerini dikkate almaz. Bu metrik, tahmin edilen ve gerçek değerler arasındaki mutlak farkların ortalamasını temsil eder ve her bir sapmayı eşit şekilde ele alır. MAE'nin yüksek bir değere sahip olması, modelin düşük performansını; düşük bir değere sahip olması ise modelin yüksek doğrulukta çalıştığını göstermektedir. MAE, y_i gerçek (hedef) değerler, \tilde{y}_i model tarafından tahmin edilen değerler ve n toplam tahmin sayısı olmak üzere Eşitlik 2.3'te yer alan matematiksel ifade ile tanımlanmaktadır:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \tilde{y}_i| \quad (2.3)$$

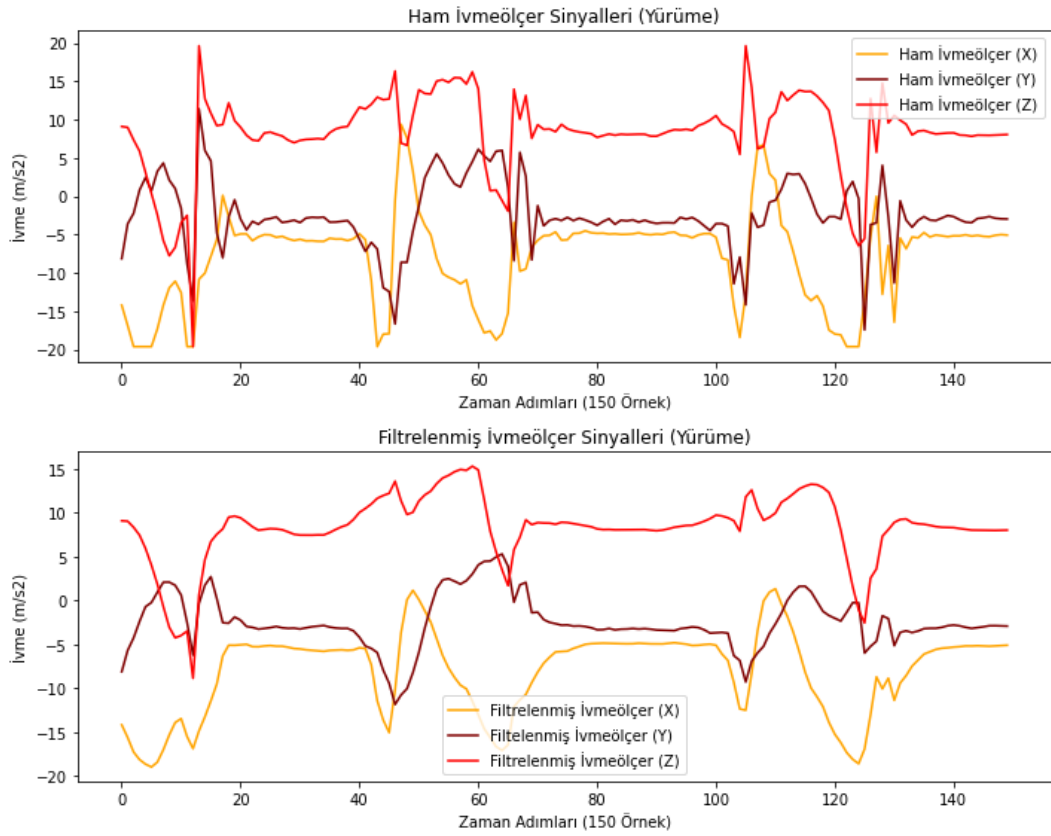
Determinasyon Katsayısı (R^2), bir modelin verilere ne kadar iyi uyum sağladığını ve gelecekteki sonuçları ne derece doğru tahmin edebildiğini ölçmek için kullanılan bir metriktir. Bu katsayı, bağımlı değişkendeki toplam varyansın ne kadarının bağımsız değişkenler tarafından açıklandığını değerlendirerek modelin doğruluğunu belirler. R^2 değeri, modelin hata karesi toplamı (RSS, Residual Sum of Squares) ile verinin toplam değişkenliği (TSS, Total Sum of Squares) arasındaki oran kullanılarak hesaplanır ve Eşitlik 2.4 ile ifade edilir.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \tilde{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (2.4)$$


Burada y_i gerçek değerleri, \tilde{y}_i modelin tahmin ettiği değerleri ve \bar{y} gerçek değerlerin ortalamasını ifade etmektedir. $\sum_{i=1}^n (y_i - \tilde{y}_i)^2$, tahmin hatasının karesinin toplamı; $\sum_{i=1}^n (y_i - \bar{y})^2$, verinin toplam değişkenliğidir. Determinasyon katsayısı, istatistiksel bir modelin sonuçlarının ne kadar iyi tahmin edildiğini ölçer ve 0 ile 1 arasında değişen bir değer üretir. Bir model tahmin yapmada ne kadar iyiyse, R^2 değeri 1'e o kadar yakın olacaktır.

4. BULGULAR

Sensör verilerinden elde edilen kinematik veriler ölçüm sürecinde çeşitli kaynaklardan gelen gürültülere maruz kalabilmektedir. Bu gürültülerin başlıca nedenleri, sensörlerin elektronik bileşenlerinden kaynaklanan rastgele hatalar, çevresel faktörlerin etkisi ve insan hareketlerinin dinamik doğasıdır. Sensörlerin titreşim, manyetik alan değişiklikleri ve ani hareket değişimleri gibi dış etkilere maruz kalması, sinyal doğruluğunu olumsuz yönde etkileyerek gerçek ölçümlere gürültünün karışmasına neden olabilmektedir. Bu nedenle, ham sinyallerin daha temiz ve analiz edilebilir hale getirilmesi amacıyla Kalman filtresi yöntemi uygulanmıştır. Şekil 4.1 ve 4.2’de Kalman filtresinin ham veriler üzerindeki etkisi gösterilmektedir.



Şekil 4.1 Sağ ayak ivmeölçerden alınan referans yürüme sinyalleri



Şekil 4.2 Sağ ayak jiroskoptan alınan referans yürüme sinyalleri

Python 3.9’da kodlanan RNN, LSTM ve GRU mimarileri, RTX 2060 Süper ekran kart, Intel i5-14400F@2.5 GHz işlemci ve 64 GB RAM’e sahip bir kişisel bilgisayar ile eğitilmiş ve test edilmiştir. Modellerin hiperparametreleri, epok sayısı, grup boyutu, katman sayısı, gizli birim sayısı ve öğrenme oranı gibi parametreler dâhil edilerek ızgara arama (grid search) yöntemiyle optimize edilmiştir. Bu yöntem sayesinde tüm olası parametre kombinasyonları değerlendirilmiştir. Her bir model için arama yapılan hiperparametre değerleri Tablo 4.1’de gösterilmektedir. Eğitim sürecinin verimli ve etkili olması için ardışık 10 epok boyunca doğrulama kaybında iyileşme görülmediği takdirde erken durdurma stratejisi uygulanmıştır. Bu strateji sayesinde, gereksiz hesaplama sürelerinin önüne geçilmiş ve aşırı öğrenme engellenmiştir.

Tablo 4.1 Model hiperparametre optimizasyonu

Hiperparametreler	RNN Arama Alanı	LSTM Arama Alanı	GRU Arama Alanı
Katman sayısı	[1, 2]	[1, 2, 3, 4]	[1, 2, 3, 4]
Gizli birim sayısı	[16, 32, 64]	[32, 64, 128]	[32, 64, 128]
Grup boyutu	[16, 32]	[16, 32, 64]	[16, 32, 64]
Epok sayısı	[50, 100]	[60, 80, 100]	[60, 80, 100]
Öğrenme oranı	[0,01; 0,001; 0,0001]	[0,01; 0,001; 0,0001]	[0,01; 0,001; 0,0001]

RNN, LSTM ve GRU modelleri, farklı giriş ve çıkış pencere boyutu kombinasyonları ile eğitilmiştir. Bu süreçte toplamda 9 farklı pencere boyutu kombinasyonu kullanılmıştır. Bu kombinasyonlar, farklı zaman pencerelerinin model performansı üzerindeki etkilerini değerlendirmek ve en iyi tahmin doğruluğunu sağlayacak parametreleri belirlemek amacıyla seçilmiştir.

Giriş pencere boyutları, zaman serisi analizinde kullanılan farklı uzunlukları temsil etmek üzere 600 ms, 800 ms ve 1000 ms'ye karşılık gelen 34, 46 ve 56 zaman adımlarını oluşturmaktadır. Çıkış pencere boyutları ise gelecekteki zaman adımları için tahmin sürelerini ifade etmek amacıyla 6, 12 ve 17 zaman adımlarına karşılık gelen 100 ms, 200 ms ve 300 ms'lik süreler olarak belirlenmiştir. Her bir farklı giriş ve çıkış pencere boyutu kombinasyonu için, tüm modellerin en iyi hiperparametre değerleri optimize edilmiş ve bu değerler kaydedilmiştir. Bu işlem, modellerin her bir kombinasyonda maksimum performansa ulaşmasını sağlamak ve farklı pencere boyutlarının etkilerini sistematik bir şekilde analiz etmek amacıyla gerçekleştirilmiştir.

Modellerin performansı, Ortalama Mutlak Hata (MAE), Kök Ortalama Karesel Hata (RMSE) ve Determinasyon Katsayısı (R^2) kullanılarak değerlendirilmiştir. Farklı giriş-çıkış pencere boyutlarıyla eğitilen RNN, LSTM ve GRU modellerinin performans değerleri sırasıyla Tablo 4.2, Tablo 4.3 ve Tablo 4.4'te gösterilmektedir.

Tablo 4.2 Değişen giriş-çıkış pencere boyutları için RNN modelinin performansı

Giriş Pencere Boyutu	Çıkış Pencere Boyutu	Katman Sayısı	Gizli Birim Sayısı	Grup Boyutu	Öğrenme Oranı	Epok Sayısı	RMSE	MAE	R ²
34	6	2	64	16	0,001	100	0,108	0,074	0,747
46	6	2	64	32	0,001	100	0,110	0,076	0,743
56	6	2	64	16	0,001	100	0,111	0,077	0,737
34	12	2	64	32	0,001	100	0,122	0,086	0,674
46	12	2	64	16	0,001	100	0,122	0,086	0,676
56	12	2	64	32	0,001	100	0,124	0,088	0,671
34	17	2	64	32	0,001	100	0,126	0,089	0,655
46	17	2	64	32	0,001	100	0,130	0,092	0,640
56	17	2	64	32	0,001	100	0,131	0,093	0,636

Tablo 4.3 Değişen giriş-çıkış pencere boyutları için LSTM modelinin performansı

Giriş Pencere Boyutu	Çıkış Pencere Boyutu	Katman Sayısı	Gizli Birim Sayısı	Grup Boyutu	Öğrenme Oranı	Epok Sayısı	RMSE	MAE	R ²
34	6	2	128	16	0,001	60	0,095	0,063	0,814
46	6	2	128	16	0,001	100	0,098	0,065	0,804
56	6	2	128	16	0,001	80	0,101	0,068	0,795
34	12	2	128	16	0,001	60	0,106	0,070	0,765
46	12	2	128	16	0,001	100	0,123	0,074	0,752
56	12	2	128	16	0,001	80	0,111	0,075	0,745
34	17	2	128	16	0,001	80	0,112	0,075	0,737
46	17	2	128	16	0,001	60	0,113	0,076	0,722
56	17	2	128	16	0,001	100	0,115	0,078	0,714

Tablo 4.4 Değişen giriş-çıkış pencere boyutları için GRU modelinin performansı

Giriş Pencere Boyutu	Çıkış Pencere Boyutu	Katman Sayısı	Gizli Birim Sayısı	Grup Boyutu	Öğrenme Oranı	Epok Sayısı	RMSE	MAE	R ²
34	6	4	128	64	0,001	80	0,092	0,062	0,814
46	6	3	128	64	0,001	80	0,095	0,064	0,806
56	6	3	128	64	0,001	100	0,097	0,065	0,800
34	12	4	128	64	0,001	100	0,104	0,070	0,770
46	12	3	128	64	0,001	100	0,107	0,072	0,755
56	12	4	128	64	0,001	100	0,109	0,074	0,745
34	17	3	128	64	0,001	100	0,110	0,075	0,738
46	17	4	128	64	0,001	80	0,113	0,077	0,726
56	17	3	128	64	0,001	80	0,115	0,078	0,713

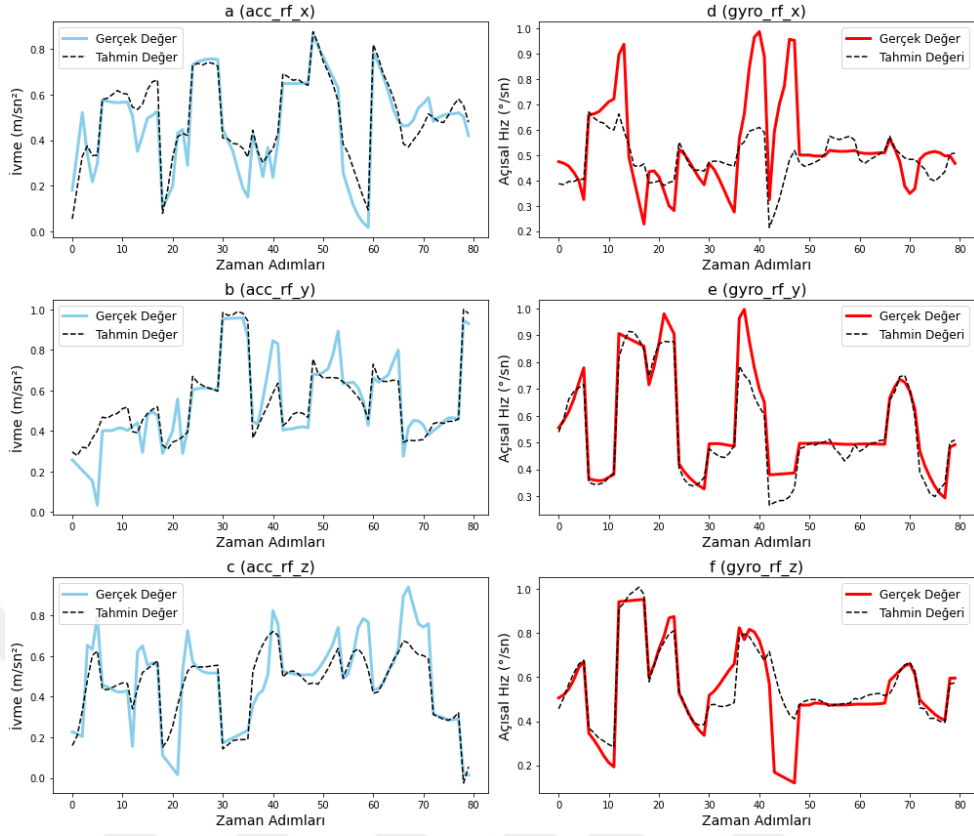
Çalışmada RNN, LSTM ve GRU derin öğrenme modellerinin, bir sonraki zaman adımını tahmin etme performansları değerlendirilmiştir. Bu değerlendirme sürecinde her bir model için en iyi performansı gösteren hiperparametre değerleri kaydedilmiştir. Genel olarak üç modelin karşılaştırılması sonucunda, kısa vadeli tahminlerde modellerin performanslarının uzun vadeli tahminlere kıyasla daha iyi sonuçlar verdiği gözlemlenmiştir. Çıkış pencere boyutu arttıkça tahmin hatalarının arttığı ve model doğruluğunun düştüğü gözlemlenmiştir. Bu durum, daha uzun vadeli tahminlerde hata birikiminin artabileceğini ve kısa vadeli tahminlerin daha güvenilir olduğunu göstermektedir.

Elde edilen bulgular, hareket tahmini problemlerinde RNN modelinin düşük doğruluk sergilediğini buna karşın LSTM ve GRU modellerinin ise daha başarılı olduğunu ortaya koymaktadır. RNN modeli, diğer modellere kıyasla genel olarak daha yüksek RMSE ve MAE değerlerine sahiptir. Özellikle çıkış pencere boyutu 17 olduğunda R² değeri 0,655 ile en düşük değere ulaşmaktadır. Bu durum, RNN modelinin uzun sekanslı verilerde hataların birikmesine daha yatkın olduğunu göstermektedir. LSTM modeli, RNN modeline kıyasla daha düşük RMSE ve MAE değerleri sunmakta ve daha yüksek R² skorlarına ulaşmaktadır. Bu durum, LSTM'nin uzun süreli bağımlılıkları daha iyi yakalayarak daha başarılı tahminler yaptığını göstermektedir.

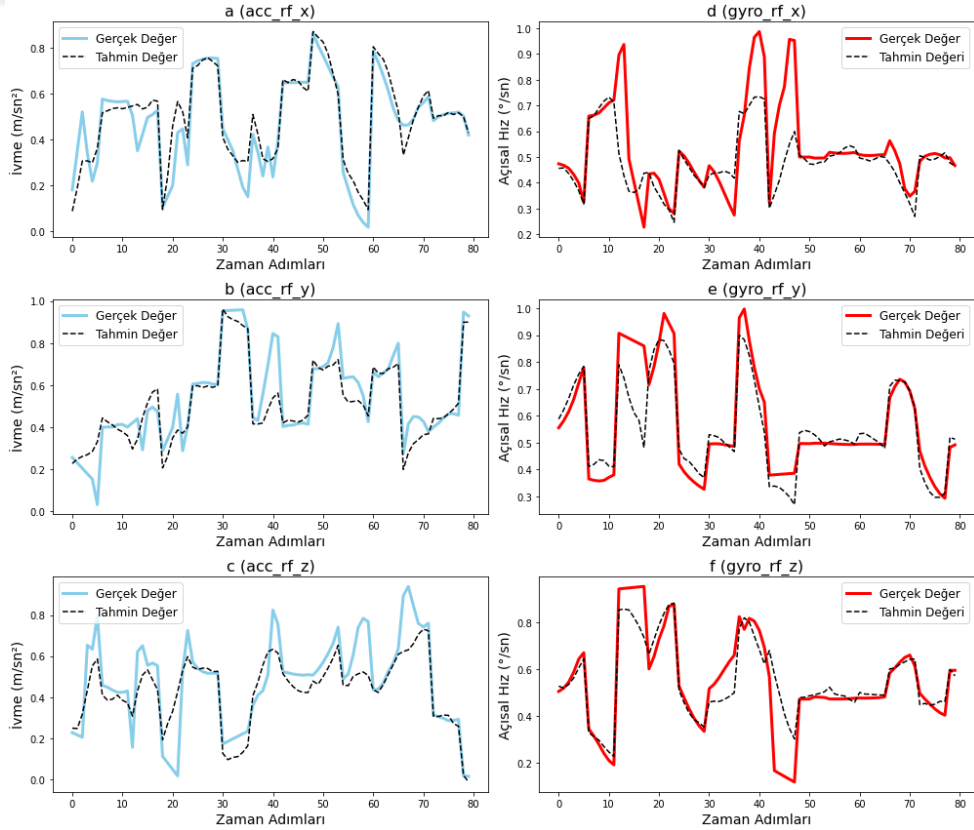
LSTM ve GRU modelleri, RMSE, MAE ve R^2 metrikleri açısından genellikle benzer performans sergilemiştir. Ancak daha ayrıntılı bir inceleme yapıldığında, GRU modelinin genel olarak LSTM'ye kıyasla daha düşük RMSE ve MAE değerleri sergilediği görülmektedir

Determinasyon katsayısı (R^2) açısından değerlendirildiğinde, her iki modelin en yüksek 0,814 değerine ulaştığı görülmektedir. Bu, LSTM ve GRU modellerinin bağımlı değişkendeki varyansın %81,4'ünü açıklayabildiğini göstermektedir. Ancak çıkış penceresi uzunluğu arttıkça (12 ve 17 zaman adımını tahmin etmede), her iki modelde de R^2 değerinde belirgin bir düşüş yaşanmıştır. Bu durum, uzun vadeli tahminlerde modelin veriye olan uyumunun azaldığını ve hata payının arttığını göstermektedir. R^2 açısından modeller arasında belirgin bir fark olmaması, genel uyum açısından iki modelin de benzer seviyede olduğunu göstermektedir.

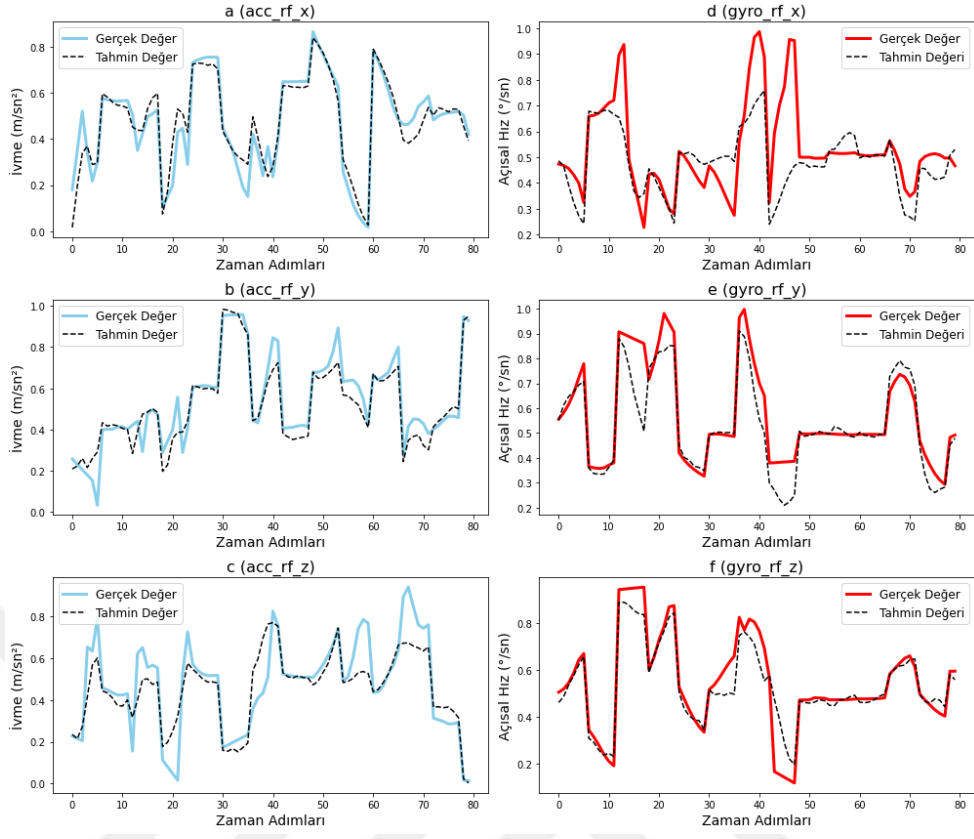
RNN, LSTM ve GRU modellerinin 34 giriş ve 6 çıkış pencere boyutuyla eğitilmesi sonucu, test veri seti üzerindeki tahminleri ile gerçek verilerin karşılaştırıldığı grafikler sırasıyla Şekil 4.3, Şekil 4.4 ve Şekil 4.5'de verilmiştir. Şekillerdeki a, b ve c grafikleri sırasıyla sağ ayak ivmeölçerden alınan X, Y ve Z eksen verilerini; d, e ve f grafikleri ise sağ ayak jiroskoptan alınan X, Y ve Z eksen verilerini ifade etmektedir. Genel olarak, GRU modeli LSTM ile benzer bir doğruluk seviyesi sunarken, daha düşük hata değerleri ve daha verimli bir öğrenme süreci ile öne çıkmaktadır. Bu bulgular, GRU'nun hareket tahmini problemlerinde güçlü bir alternatif olarak değerlendirilebileceğini göstermektedir.



Şekil 4.3 RNN modelinin gerçek ve tahmin edilen değerler ile karşılaştırılması



Şekil 4.4 LSTM modelinin gerçek ve tahmin edilen değerler ile karşılaştırılması



Şekil 4.5 GRU modelinin gerçek ve tahmin edilen değerler ile karşılaştırılması

5. TARTIŞMA

Bu tez çalışmasında, insan yürüme aktivitesinin bir sonraki zaman adımındaki referans yörüngelerini tahmin etmek amacıyla, zaman serisi verilerinin analizi ve tahmininde yaygın olarak kullanılan RNN, LSTM ve GRU modelleri kullanılmıştır. Her bir model, farklı giriş ve çıkış pencere boyutlarıyla eğitilmiş ve her eğitim sürecinde en iyi hiperparametreler kaydedilmiştir. Kolaghasi vd. (2022) en iyi hiperparametre kombinasyonunu bulmak için 72 zaman adımı boyutunda bir giriş penceresi ve 12 zaman adımı genişliğinde bir çıkış penceresi kullanarak modeli eğitmiş ve bulduğu hiperparametre sonuçlarına göre farklı pencere kombinasyonlarının model performansını ölçmüştür. Gutierrez-Farewik ve Su (2020), 5 ve 10 zaman adımına denk gelen pencere boyutları için model performansını değerlendirmiş ancak kullandıkları parametreleri belirtmemişlerdir. Yapılan literatür taramalarında farklı giriş ve çıkış pencere boyutları için detaylı hiperparametre optimizasyonu bulgularına rastlanılmamıştır. Zaroug vd. (2020) elde ettiği bulgular neticesinde çalışmada kullanılan hiperparametrelerin model üzerindeki etkilerini araştırmak için daha fazla çalışma yapılması gerektiğini vurgulamıştır.

Yetişkinlerde ortalama yürüyüş döngüsü süreleri, yürüme hızına bağlı olarak değişmekte olup yavaş, normal ve hızlı yürüme hızları için sırasıyla 0,89 m/sn, 1,16 m/sn ve 1,50 m/sn arasındadır (Maqbool vd., 2024). Mevcut tez çalışmasında, normal bir yürüyüş döngüsünün yaklaşık %25'ine karşılık gelen 17 zaman adımına (300 ms'ye denk gelmektedir) kadar yörünge tahmini yapılmış ve farklı giriş-çıkış pencere boyutlarının tahminler üzerindeki performansı değerlendirilmiştir.

Sonuçlar, GRU model performansının RNN ve LSTM'den daha iyi olduğunu göstermektedir. Aynı zamanda RMSE, MAE ve R² performans metrikleri göz önüne alındığında, GRU ve LSTM modellerinin benzer hata oranlarına ve doğruluk seviyelerine sahip oldukları görülmektedir. Ancak, giriş ve çıkış penceresi boyutlarının artmasıyla birlikte LSTM modelinin daha kararlı bir performans sergilediği gözlemlenmektedir. Daha uzun vadeli bağımlılıkların bulunduğu ve daha büyük model yapılarına ihtiyaç duyulan farklı senaryolarda, LSTM'nin avantajı daha

belirgin hale gelebilir. Hesaplama maliyetleri göz önüne alındığı durumdaysa, GRU, LSTM'ye kıyasla daha verimli bir alternatif sunmaktadır.

Bu çalışmada kullanılan HuGaDB veri seti, Gutierrez-Farewik ve Su (2020)'nun ve Zaroug vd. (2020)'nin çalışmasında kullanılan veri setinin aksine sadece koşu bandında kaydedilmiş verilerle sınırlı değildir. Koşu bandında yürüyüş, genellikle sabit hızda ve kontrollü bir ortamda gerçekleştiğinden doğal yürüyüş davranışlarını sergilemeyecektir. Çalışmada kullanılan veri seti, günlük hayatta daha sık karşılaşılan yürüyüş örüntülerini temsil ettiğinden gerçek dünya uygulamalarına daha yakın bir sonuç verdiği düşünülmektedir. Sonuçlarımız, benzer şekilde sağlıklı katılımcıların yürüme verilerinin kullanıldığı çalışmalarla (Jia vd., 2021; Ren vd., 2022; Su ve Gutierrez-Farewik, 2020; Zaroug vd., 2020; Zhu vd., 2021) kıyaslandığında, daha iyi performans sergilediği görülmektedir.

Mevcut çalışma, 14 erkek ve 4 kadın sağlıklı katılımcının yürüme verileri ile sınırlıdır. Gelecek çalışmalarda, bu yaklaşımın uygulanabilirliğini doğrulamak için daha fazla katılımcının yer alması gerekmektedir. Ayrıca veri seti, sağlıklı ve genç katılımcılar ile sınırlı kalmamalı ve yürüyüş bozukluğu bulunan bireylerin verileri de çalışmaya dâhil edilmelidir.

6. SONUÇ VE ÖNERİLER

Bu tez çalışması, rehabilitasyon alanında kullanılan dış iskeletlerin kontrol mekanizmalarına yönelik bir çözüm geliştirmeyi amaçlamaktadır. Çalışmada, insan yürüyüşü verilerinden elde edilen referans yörüngeleri kullanarak, bir sonraki zaman adımının doğru bir şekilde tahmin edilmesi için RNN, LSTM ve GRU mimarilerinin kısa ve orta vadeli tahminlerdeki etkinliğini değerlendirilmiştir. Yürüyüş verilerindeki dinamiklerin anlaşılması ve tahmin edilmesi konusunda her bir modelin kısa ve orta vadeli zaman dilimlerinde nasıl performans gösterdiği analiz edilmiştir.

Elde edilen sonuçlar RNN modelinin, LSTM ve GRU'ya kıyasla daha düşük performans sergilediğini göstermektedir. Genel olarak, GRU ve LSTM modelleri benzer performans göstermiş, ancak uzun vadeli bağımlılıkların öğrenilmesi gerektiğinde LSTM'nin daha kararlı sonuçlar ürettiği gözlemlenmiştir. Kısa vadeli giriş-çıkış pencere boyutları için GRU'nun hata oranları LSTM'ye kıyasla çok küçük farklarla daha düşüktür, ancak bu fark belirgin bir avantaj göstermemektedir. Dolayısıyla, GRU modelinin genel olarak RNN ve LSTM'den daha iyi olduğu kesin sonucuna varmak yanıltıcı olabilir. Sonuç olarak, her iki modelin de kullanım amacına ve uygulamanın gereksinimlerine göre farklı avantajlar sunduğu söylenebilir. LSTM'nin uzun vadeli bağımlılıkları öğrenme yeteneği, özellikle rehabilitasyon ve dış iskelet robotları gibi uygulamalarda kritik bir faktör olabilirken, GRU'nun hızlı eğitimi ve verimli parametre kullanımı, zaman ve kaynak kısıtlamaları altında önemli bir avantaj sağlayabilir.

Gelecekteki çalışmalar, yürüyüş bozukluğu bulunan hastalardan elde edilecek yürüme verilerinin de veri setine entegre edilmesini hedeflemelidir. Bu tür bir genişleme, dış iskeletlerin kontrol stratejilerini kişiselleştirme ve rehabilitasyonda bireye özel çözümler sunma potansiyelini artırabilir. Özellikle, yürüyüş bozukluklarına sahip bireylerin hareket örüntülerinden öğrenilen bilgiler, bu bireyler için optimize edilmiş dış iskelet kontrol stratejilerinin geliştirilmesine katkı sağlayabilir. Ayrıca veri setinin genişletilmesi LSTM ve GRU modellerinin performansı hakkında daha etkili sonuçlar verebilir.

KAYNAKLAR

- Akerblom Svensson, J., & Gullberg Carlsson, J. (2021). Analysis of comparative filter algorithm effect on an IMU.
- Allemand, Y., Stauffer, Y., Clavel, R., & Brodard, R. (2009). Design of a new lower extremity orthosis for overground gait training with the WalkTrainer. *In 2009 IEEE International Conference on Rehabilitation Robotics* (pp. 550-555).
- Bodur, B. E., Erdoğanoğlu, Y., & Sel, S. A., “Effects of robotic-assisted gait training on physical capacity, and quality of life among chronic stroke patients: A randomized controlled study”, *Journal of Clinical Neuroscience*, 120, 129-137, (2024)
- Caldas, R., Fadel, T., Buarque, F., & Markert, B. (2020). Adaptive predictive systems applied to gait analysis: A systematic review. *Gait & posture*, 77, 75-82.
- Cayıroğlu, İ. (2012). Kalman filtresi ve programlama. *Fen ve Teknoloji Bilgi Paylaşımı*, 1.
- Chereshnev, R., & Kertesz-Farkas, A. (2018). Hugadb: Human gait database for activity recognition from wearable inertial sensor networks. *In Analysis of Images, Social Networks and Texts: 6th International Conference*, (pp. 131-141).
- Cho, K., Merriënboer B., Bahdanau, D., & Bengio, Y. (2014). On the properties of neural machine translation: Encoder-decoder approaches. *ArXiv Preprint arXiv:1409.1259*.
- Daachi, M. E., Madani, T., Daachi, B., & Djouani, K. (2015). A radial basis function neural network adaptive controller to drive a powered lower limb knee joint orthosis.
- Deldari, S., Smith, D. V., Sadri, A., & Salim, F. (2020). Espresso: Entropy and shape aware time-series segmentation for processing heterogeneous sensor data. *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, 4(3), 1-24.
- Duan, J., Xiong, J., Li, Y., & Ding, W. (2024). Deep learning based multimodal biomedical data fusion: An overview and comparative review. *Information Fusion*, 102536.
- Farina, D., Jiang, N., Rehbaum, H., Holobar, A., Graimann, B., Dietl, H., & Aszmann, O. C. (2014). The extraction of neural information from the surface EMG for the control of upper-limb prostheses: emerging avenues and challenges. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 22(4), 797-809.

- Foroutannia, A., Akbarzadeh-T, M. R., & Akbarzadeh, A. (2022). A deep learning strategy for EMG-based joint position prediction in hip exoskeleton assistive robots. *Biomedical Signal Processing and Control*, 75, 103557.
- Gholap, R., Thorat, S., & Chavan, A. (2022). Review of current developments in lower extremity exoskeleton systems. *Materials Today: Proceedings*.
- Gwon, M. S., Woo, J. H., Sahithi, K. K., & Kim, S. H. (2024). Continuous Intention Prediction of Lifting Motions Using EMG-Based CNN-LSTM. *IEEE Access*, 12, 42453-42464.
- Hamid, H., Naseer, N., Nazeer, H., Khan, M. J., Khan, R. A., & Shahbaz Khan, U. (2022). Analyzing classification performance of fNIRS-BCI for gait rehabilitation using deep neural networks. *Sensors*, 22(5), 1932.
- Hartog, D. D., Harlaar, J., & Smit, G. (2021). The Stumblemeter: design and validation of a system that detects and classifies stumbles during gait. *Sensors*, 21(19), 6636.
- He, Y., Xu, Y., Hai, M., Feng, Y., Liu, P., Chen, Z., & Duan, W. (2024). Exoskeleton-assisted rehabilitation and neuroplasticity in spinal cord injury. *World Neurosurgery*.
- Hu, B., Rouse, E., & Hargrove, L. (2018). Benchmark datasets for bilateral lower-limb neuromechanical signals from wearable sensors during unassisted locomotion in able-bodied individuals. *Frontiers in Robotics and AI*, 5, 14.
- Isezaki, T., Kadone, H., Nijjima, A., Aoki, R., Watanabe, T., Kimura, T., & Suzuki, K. (2019). Sock-type wearable sensor for estimating lower leg muscle activity using distal EMG signals. *Sensors*, 19(8), 1954.
- Jia, L., Ai, Q., Meng, W., Liu, Q., & Xie, S. Q. (2021). Individualized gait trajectory prediction based on fusion LSTM networks for robotic rehabilitation training. In *2021 IEEE/ASME International Conference on Advanced Intelligent Mechatronics (AIM)* (pp. 988-993).
- Khan, A., Sohail, A., Zahoor, U., & Qureshi, A. S. (2020). A survey of the recent architectures of deep convolutional neural networks. *Artificial intelligence review*, 53, 5455-5516.
- Khan, R. A., Naseer, N., Qureshi, N. K., Noori, F. M., Nazeer, H., & Khan, M. U. (2018). fNIRS-based Neurorobotic Interface for gait rehabilitation. *Journal of neuroengineering and rehabilitation*, 15, 1-17.
- Khodarahmi, M., & Maihami, V. (2023). A review on Kalman filter models. *Archives of Computational Methods in Engineering*, 30(1), 727-747.
- Kim, Y. W., Joa, K. L., Jeong, H. Y., & Lee, S. (2021). Wearable IMU-based human activity recognition algorithm for clinical balance assessment using 1D-CNN and GRU ensemble model. *Sensors*, 21(22), 7628.

- Kolaghassi, R., Al-Hares, M. K., Marcelli, G., & Sirlantzis, K. (2022). Performance of deep learning models in forecasting gait trajectories of children with neurological disorders. *Sensors*, 22(8), 2969.
- Kolaghassi, R., Marcelli, G., & Sirlantzis, K. (2023). Deep learning models for stable gait prediction applied to exoskeleton reference trajectories for children with cerebral palsy. *IEEE Access*, 11, 31962-31976.
- Lajeunesse, V., Vincent, C., Routhier, F., Careau, E., & Michaud, F. (2016). Exoskeletons design and usefulness evidence according to a systematic review of lower limb exoskeletons used for functional mobility by people with spinal cord injury. *Disability and Rehabilitation: Assistive Technology*, 11(7), 535-547.
- Lana, E. P., Adorno, B. V., & Tierra-Criollo, C. J. (2015). Detection of movement intention using EEG in a human-robot interaction environment. *Research on Biomedical Engineering*, 31(4), 285-294.
- Li, W., Ma, Y., Shao, K., Yi, Z., Cao, W., Yin, M., & Wu, X. (2024). The Human–Machine Interface Design Based on sEMG and Motor Imagery EEG for Lower Limb Exoskeleton Assistance System. *IEEE Transactions on Instrumentation and Measurement*, 73, 1-14.
- Lin, W., Su, C., An, Z., Li, Z., Jing, Q., Zhang, S., & Wang, F. (2024). GRU-Based Prediction of Muscle Activation Using IMU Data: Integrating VR for Rehabilitation Assessment. In *2024 IEEE 14th International Conference on CYBER Technology in Automation, Control, and Intelligent Systems (CYBER)* (pp. 599-604).
- Liu, J., He, Y., Yang, J., Cao, W., & Wu, X. (2022). Design and analysis of a novel 12-DOF self-balancing lower extremity exoskeleton for walking assistance. *Mechanism and Machine Theory*, 167, 104519.
- Luo, J., Zhang, C., Si, W., Jiang, Y., Yang, C., & Zeng, C. (2024). A Physical Human–Robot Interaction Framework for Trajectory Adaptation Based on Human Motion Prediction and Adaptive Impedance Control. *IEEE Transactions on Automation Science and Engineering*.
- Ma, C., Li, W., Cao, J., Du, J., Li, Q., & Gravina, R. (2020). Adaptive sliding window based activity recognition for assisted livings. *Information Fusion*, 53, 55-65.
- Mahmood, I., Rahman, M. Z. U., & Dehghani-Sanij, A. A. (2023). Modelling and analysis of orthoses generated whole-body vertical vibrations impact on limb stability and compliant dynamics in a ramp gait. *Biomedical Signal Processing and Control*, 79, 104163.
- Manna, S. K., Azhar, M. H. B., & Greace, A. (2023). Optimal locations and computational frameworks of FSR and IMU sensors for measuring gait abnormalities. *Heliyon*.

- Maqbool, H. F., Mahmood, I., Ali, A., Iqbal, N., Seong, J. T., Dehghani-Sanij, A. A., & Awad, M. I. (2024). Gait Asymmetrical Evaluation of Lower Limb Amputees using Wearable Inertial Sensors. *Heliyon*.
- Martinez-Hernandez, U., Awad, M. I., & Dehghani-Sanij, A. A. (2022). Learning architecture for the recognition of walking and prediction of gait period using wearable sensors. *Neurocomputing*, 470, 1-10.
- Mienye, I. D., Swart, T. G., & Obaido, G. (2024). Recurrent neural networks: A comprehensive review of architectures, variants, and applications. *Information*, 15(9), 517.
- Mohammadi Moghadam, S., Ortega Auriol, P., Yeung, T., & Choisne, J. (2024). 3D gait analysis in children using wearable sensors: feasibility of predicting joint kinematics and kinetics with personalized machine learning models and inertial measurement units. *Frontiers in Bioengineering and Biotechnology*, 12, 1372669.
- Moosavian, S. A. A., Kiani, A., Akbari, V., Nabipour, M., & Ghanaat, S. (2021). RoboWalk trajectory planning based on the human gait prediction using LSTM. *In 2021 9th RSI International Conference on Robotics and Mechatronics (ICRoM)* (pp. 433-438).
- Negi, S., Sharma, S., & Sharma, N. (2021). FSR and IMU sensors-based human gait phase detection and its correlation with EMG signal for different terrain walk. *Sensor Review*, 41(3), 235-245.
- Noor, M. H. M., Salcic, Z., Kevin, I., & Wang, K. (2017). Adaptive sliding window segmentation for physical activity recognition using a single tri-axial accelerometer. *Pervasive and Mobile Computing*, 38, 41-59.
- Pancholi, S., Wachs, J. P., & Duerstock, B. S. (2024). Use of artificial intelligence techniques to assist individuals with physical disabilities. *Annual Review of Biomedical Engineering*, 26.
- Park, JS and Kim, CH (2022). Gait analysis based on ground reaction force and its application to gait impairment assessment: New indices for measuring walking behavior. *Sensors*, 22 (19), 7558.
- Ragni, F., Archetti, L., Roby-Brami, A., Amici, C., & Saint-Bauzel, L. (2021). Intention prediction and human health condition detection in reaching tasks with machine learning techniques. *Sensors*, 21(16), 5253.
- Ren, B., Zhang, Z., Zhang, C., & Chen, S. (2022). Motion trajectories prediction of lower limb exoskeleton based on long short-term memory (LSTM) networks. *In Actuators* (Vol. 11, No. 3, p. 73).
- Reynolds, H. L., Hanafy, M. A., Jones, J., Harris, D., & Popa, D. O. (2024). Comparative Study of One-Handed vs Two-Handed EEG Intent Recognition for Applications in Human-Robot Interaction. *In Proceedings of the 17th*

International Conference on Pervasive Technologies Related to Assistive Environments (pp. 496-503).

- Sethi, D., Bharti, S., & Prakash, C. (2022). A comprehensive survey on gait analysis: History, parameters, approaches, pose estimation, and future work. *Artificial Intelligence in Medicine*, 102314.
- Shen, T., Afsar, M. R., Zhang, H., Ye, C., & Shen, X. (2018). Development of a Motorized Robotic Walker Guided by an Image Processing System for Human Walking Assistance and Rehabilitation. In *Dynamic Systems and Control Conference* (Vol. 51890, p. V001T07A009).
- Shi, Y., Zhang, Y., Li, Z., Yuan, S., & Zhu, S. (2023). IMU/UWB fusion method using a complementary filter and a Kalman filter for hybrid upper limb motion estimation. *Sensors*, 23(15), 6700.
- Su, B., & Gutierrez-Farewik, E. M. (2020). Gait trajectory and gait phase prediction based on an LSTM network. *Sensors*, 20(24), 7127.
- Suzuki, K., Mito, G., Kawamoto, H., Hasegawa, Y., & Sankai, Y. (2007). Intention-based walking support for paraplegia patients with Robot Suit HAL. *Advanced Robotics*, 21(12), 1441-1469.
- Tang, C., Xu, Z., Occhipinti, E., Yi, W., Xu, M., Kumar, S., & Occhipinti, L. G. (2023). From brain to movement: Wearables-based motion intention prediction across the human nervous system. *Nano Energy*, 108712.
- Tao, W., Liu, T., Zheng, R., & Feng, H. (2012). Gait analysis using wearable sensors. *Sensors*, 12(2), 2255-2283.
- Terrier, P. (2020). Gait recognition via deep learning of the center-of-pressure trajectory. *Applied Sciences*, 10(3), 774.
- Torrealba, R. R., Udelman, S. B., & Fonseca-Rojas, E. D. (2017). Design of variable impedance actuator for knee joint of a portable human gait rehabilitation exoskeleton. *Mechanism and Machine Theory*, 116, 248-261.
- Veneman, J. F., Kruidhof, R., Hekman, E. E., Ekkelenkamp, R., Van Asseldonk, E. H., & Van Der Kooij, H. (2007). Design and evaluation of the LOPES exoskeleton robot for interactive gait rehabilitation. *Transactions on neural systems and rehabilitation engineering*, 15(3), 379-386.
- Xiang, L., Gu, Y., Gao, Z., Yu, P., Shim, V., Wang, A., & Fernandez, J. (2024). Integrating an LSTM framework for predicting ankle joint biomechanics during gait using inertial sensors. *Computers in Biology and Medicine*, 170, 108016.
- Wang, C., Kim, Y., Lee, S. H., Sung, N. J., Min, S. D., & Choi, M. H. (2020). Activity and safety recognition using smart work shoes for construction worksite. *KSII Transactions on Internet and Information Systems (TIIS)*, 14(2), 654-670.

- Wu, J., Huang, J., Wu, X., & Dai, H. (2023). A novel graph-based hybrid deep learning of cumulative GRU and deeper GCN for recognition of abnormal gait patterns using wearable sensors. *Expert Systems with Applications*, 233, 120968.
- Wu, X., Yuan, Y., Zhang, X., Wang, C., Xu, T., & Tao, D. (2021). Gait phase classification for a lower limb exoskeleton system based on a graph convolutional network model. *IEEE Transactions on Industrial Electronics*, 69(5), 4999-5008.
- Yen, Y. L., Ye, S. K., Liang, J. N., & Lee, Y. J. (2023). Recognition of walking directional intention employed ground reaction forces and center of pressure during gait initiation. *Gait & Posture*, 106, 23-27.
- Young, A., Ferris, D.P. (2017). State of the Art and Future Directions for Lower Limb Robotic Exoskeletons. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 25(2), 171-183.
- Zaroug, A., Lai, D. T., Mudie, K., & Begg, R. (2020). Lower limb kinematics trajectory prediction using long short-term memory neural networks. *Frontiers in Bioengineering and Biotechnology*, 8, 362.
- Zhang, T., Tran, M., & Huang, H. (2018). Design and experimental verification of hip exoskeleton with balance capacities for walking assistance. *IEEE/ASME Transactions on mechatronics*, 23(1), 274-285.
- Zhou, F., Wang, R., Su, H., & Xu, S. (2022). A human activity recognition model based on wearable sensor. In *2022 9th International Conference on Digital Home (ICDH)* (pp. 169-174).
- Zhou, Z., Liang, B., Huang, G., Liu, B., Nong, J., & Xie, L. (2020). Individualized gait generation for rehabilitation robots based on recurrent neural networks. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 29, 273-281.
- Zhu, C., Liu, Q., Meng, W., Ai, Q., & Xie, S. Q. (2021). An attention-based CNN-LSTM model with limb synergy for joint angles prediction. In *2021 IEEE/ASME International Conference on Advanced Intelligent Mechatronics (AIM)* (pp. 747-752). IEEE.
- Zhu, Z., Liu, L., Zhang, W., Jiang, C., Wang, X., & Li, J. (2024). Design and motion control of exoskeleton robot for paralyzed lower limb rehabilitation. *Frontiers in Neuroscience*, 18, 1355052.
- Zoss, A. B., Kazerooni, H., & Chu, A. (2006). Biomechanical design of the Berkeley lower extremity exoskeleton (BLEEX). *IEEE/ASME Transactions on mechatronics*, 11(2), 128-138.