

T.C.
GEBZE TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

DERİN ÖĞRENME İLE AYAK HAREKETLERİNDEN
KULLANICI STRES DURUMU ANALİZİ

KEMAL ÖZTEL

YÜKSEK LİSANS TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

DANIŞMAN: DOÇ. DR. MEHMET GÖKTÜRK

EYLÜL 2025

T.C.
GEBZE TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

DERİN ÖĞRENME İLE AYAK HAREKETLERİNDEN
KULLANICI STRES DURUMU ANALİZİ

KEMAL ÖZTEL

YÜKSEK LİSANS TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

DANIŞMAN: DOÇ. DR. MEHMET GÖKTÜRK

EYLÜL 2025

T.R.
GEBZE TECHNICAL UNIVERSITY
GRADUATE SCHOOL

**USER STRESS STATE ANALYSIS FROM FOOT
MOVEMENTS WITH DEEP LEARNING**

KEMAL ÖZTEL

A THESIS OF MASTER OF SCIENCE
DEPARTMENT OF COMPUTER ENGINEERING

ADVISOR: ASSOC. PROF. DR. MEHMET GÖKTÜRK

SEPTEMBER 2025

YÜKSEK LİSANS JÜRİ ONAY FORMU

GTÜ Lisansüstü Eğitim Enstitüsü Yönetim Kurulunun 30/06/2025 tarih ve 2025/34 sayılı kararıyla oluşturulan jüri tarafından 26/09/2025 tarihinde tez savunma sınavı yapılan Kemal ÖZTEL'in tez çalışması Bilgisayar Mühendisliği Anabilim Dalında YÜKSEK LİSANS tezi olarak kabul edilmiştir.

JÜRİ

ÜYE

(TEZ DANIŞMANI) :Doç. Dr. Mehmet GÖKTÜRK

ÜYE

:Doç. Dr. Yakup GENÇ

ÜYE

:Dr. Öğr. Üyesi Başak BULUZ KÖMEÇOĞLU

ONAY

Gebze Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Yönetim Kurulunun
...../...../..... tarih ve/..... sayılı kararı.

İMZA/MÜHÜR

ÖZET

Stresin günlük yaşamda bireyin bilişsel performansını, karar alma yetisini ve genel sağlık durumunu doğrudan etkileyen önemli bir faktör olması, stres düzeyinin düşük maliyetli, taşınabilir ve kullanıcıyı rahatsız etmeyen yöntemlerle izlenmesini kritik hale getirmektedir. Özellikle ayak hareketleri gibi çoğu zaman farkında olunmayan davranışsal ipuçlarının analiz edilmesi, bireyin stres düzeyini dolaylı olarak değerlendirebilecek yeni bir biyobelirti kaynağı sunmaktadır. Bu bağlamda, bu tez çalışmasında bireylerin stres düzeylerinin ayak hareketlerine dayalı olarak sınıflandırılması amaçlanmıştır. Çalışmada, giyilebilir bir sistem kullanılarak 9 eksenli bir atalet ölçüm birimi (IMU) üzerinden sensör verileri toplanmış, ardından bu veriler derin öğrenme tabanlı modeller aracılığıyla analiz edilmiştir. Veri toplama sürecinde katılımcılara belirli bir süre boyunca Tetris oyunu oynatılmıştır. Oyunun ilerleyen seviyelerinde hız ve zorluk düzeyinin artmasıyla birlikte, bireylerde stres yanıtlarının tetiklendiği varsayılmıştır. Katılımcılar oyunu oturur pozisyonda oynarken, MPU9250 sensör modülü aracılığıyla üç eksenli ivmeölçer, jiroskop ve manyetometreden elde edilen veriler 50 Hz örnekleme frekansı ile kaydedilmiştir. Stresli ve stresli olmayan anlar deney esnasında manuel olarak etiketlenmiştir.

Toplanan zaman serisi verileri, çok aşamalı bir ön işleme sürecinden geçirilmiştir. Bu süreçte pencereleme, gürültü giderme, normalizasyon ve örnekleme teknikleri uygulanmıştır. Elde edilen veriler, farklı sınıflandırma modelleri ile değerlendirilmiştir. Bu kapsamda destek vektör makineleri (SVM), uzun kısa süreli bellek (LSTM) ağları ve otoenkoder (Autoencoder) tabanlı modeller kullanılarak sınıflandırma yapılmıştır. Performans ölçütü olarak doğruluk, F1 skoru, hassasiyet ve özgüllük gibi metrikler kullanılmıştır. Elde edilen sonuçlar, ayak hareketlerinden türetilen verilerin stres düzeylerini ayırt edebilen anlamlı örüntüler içerdiğini ortaya koymuştur. Özellikle LSTM tabanlı modellerin, zaman bağımlı bilgiyi öğrenme konusunda yüksek performans gösterdiği gözlemlenmiştir. Ayrıca sınıflar arasındaki dengesizlik gibi veri kaynaklı sorunlara karşı veri artırma ve sınıf kaynaştırma stratejileri önerilmiştir. Bu çalışma, düşük maliyetli donanım ve kullanıcı etkileşimini minimum düzeyde tutan bir yaklaşımla, davranış temelli stres tespiti konusunda yenilikçi bir yöntem sunmakta ve gelecekteki stres izleme sistemlerine katkı sağlamaktadır.

Anahtar Kelimeler: Stres sınıflandırması, Derin öğrenme, Ayak hareketleri, Zaman serisi analizi, Giyilebilir teknoloji, Eylemsizlik ölçüm birimi

ABSTRACT

Stress is a critical factor that directly affects an individual's cognitive performance, decision-making ability, and overall health. Therefore, monitoring stress levels using low-cost, portable, and non-intrusive methods has become increasingly important. Analyzing behavioral cues such as foot movements—which often occur unconsciously—offers a novel and indirect approach to estimating an individual's stress level. In this context, the aim of this thesis is to classify individuals' stress levels based on their foot movements. In this study, a wearable system was developed using a 9-axis inertial measurement unit (IMU), and sensor data were analyzed using deep learning models. The data collection process involved having participants play the game of Tetris for a specific duration. As the difficulty and speed of the game increased over time, it was assumed to trigger stress responses in participants. While sitting, participants wore a MPU9250 sensor module that collected data from a 3-axis accelerometer, gyroscope, and magnetometer at a sampling rate of 50 Hz. Stressful and non-stressful time segments were labeled manually after the experiment. The collected time-series data underwent a multi-stage preprocessing pipeline, including windowing, noise reduction, normalization, and resampling. The preprocessed data were then evaluated using various classification models. In this context, support vector machines (SVM), long short-term memory (LSTM) networks, and autoencoder-based models were employed for classification. Performance metrics such as accuracy, F1-score, precision, and specificity were used to evaluate the results. The findings demonstrate that the foot movement data contain meaningful patterns that can be used to distinguish stress levels. Notably, LSTM-based models showed high performance in capturing temporal dependencies in the data. Furthermore, to address challenges such as class imbalance, data augmentation and class fusion strategies were proposed. This study presents an innovative method for behavior-based stress detection using low-cost hardware with minimal user intervention and lays a solid foundation for future affective stress monitoring systems.

Keywords: Stress classification, Deep learning, Foot movements, Time series analysis, Wearable technology, Inertial measurement unit

TEŞEKKÜR

Bu tez çalışmasının hazırlanmasında bana rehberlik eden, bilgi ve tecrübeleriyle yol gösteren değerli danışmanım Doç. Dr. Mehmet Göktürk hocama,
Hayatım boyunca beni koşulsuz destekleyen, her zaman yanımda olan sevgili annem Hayriye Öztel ve babam Hasan Öztel'e,
Bu yolculuk boyunca sabrıyla ve desteğiyle her zaman yanımda olan sevgili eşim Zehra Öztel'e teşekkürlerimi sunmak istiyorum.
Son olarak, çalışmam süresince desteklerini esirgemeyen tüm arkadaşlarıma ve katkı sağlayan katılımcılara da teşekkür ederim.

İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	v
ABSTRACT	vi
TEŞEKKÜR	vii
İÇİNDEKİLER	viii
SİMGELER ve KISALTMALAR DİZİNİ	x
ŞEKİLLER DİZİNİ	xi
TABLolar DİZİNİ	xii
1. GİRİŞ	1
1.1. Tezin Amacı ve Önemi	3
2. LİTERATÜR İNCELEMESİ	6
2.1. Stresin Belirlenmesinde Kullanılan Geleneksel Yöntemler	6
2.2. Davranışsal Biyobelirteçler ile Stres Analizi	8
2.3. Alt Ekstremit Hareketleri ve Psikolojik Durumlar	9
2.4. IMU Sensörleri ve Davranışsal Veri Toplama	12
2.4.1. İvmeölçer	12
2.4.2. Jiroskop	13
2.4.3. Manyetometre	13
2.5. Derin Öğrenme Algoritmaları ile Stres Sınıflandırması	13
2.6. Değerlendirme ve Özgün Katkıları	16
3. YÖNTEM	19
3.1. Donanım Düzenneği	22
3.1.1. ESP32 Mikrodenetleyici	25
3.1.2. MPU9250 Sensör	26
3.2. Veri Toplama	26
3.2.1. Gömülü Sistem Yazılımı	30
3.2.2. İstemci Uygulama ve Veri Kaydı	31
3.3. Veri Etiketleme	35
3.3.1. Gözleme Dayalı Zaman Aralıklarının Belirlenmesi	36
3.3.2. Etiketleme Sürecinin Uygulanması	36
3.3.3. Güvenilirlik ve Sınıflandırma Başarısına Etkisi	37
3.4. Veri Hazırlama ve Ön İşleme	37
3.4.1. Ham Verilerin Kalite Kontrolü	38
3.4.2. Pencereleme ve Etiketleme Stratejisi	38
3.4.3. Normalizasyon (Z-Score Standardizasyonu)	39
3.4.4. Sınıf Dengesizliği ve SMOTE Uygulaması	40
3.4.5. Katılımcı Bazlı Eğitim-Test Ayrımı	40
3.5. Sınıflandırma Yöntemleri ve Model Eğitimi	41
3.5.1. Destek Vektör Makineleri (SVM)	41
3.5.2. Uzun Kısa Süreli Bellek (LSTM)	42
3.5.3. LSTM Tabanlı Otomatik Kodlayıcı (Autoencoder)	46
3.6. Bölüm Özeti	47
4. BULGULAR VE TEST SONUÇLARI	48
4.1. DeneySEL Kurulum	48
4.1.1. Doğruluk	49
4.1.2. Duyarlılık	49

4.1.3. Kesinlik	49
4.1.4. F-1 Skoru	50
4.2. Veri Seti Özellikleri	50
4.3. Keşifsel Veri Analizi	51
4.3.1. Stresli ve Stressiz Durumların İstatistiksel Karşılaştırması	54
4.4. Model Performans Karşılaştırmaları	56
4.4.1. LOGO CV ile LSTM Model Performansı	60
4.5. Tartışma ve Gözlemler	63
4.6. Bölüm Özeti	65
5. SONUÇLAR VE GELECEK ÇALIŞMALAR	67
KAYNAKLAR	70
ÖZGEÇMİŞ	73
TEZ ÇALIŞMASI KAPSAMINDA YAPILAN YAYINLAR	74

SİMGELER ve KISALTMALAR DİZİNİ

μ	: Veri setinin ortalaması
x	: Orijinal boyuttaki veri noktası
σ	: Standart sapma
AE	: Otoenkoder (Autoencoder)
EDA	: Elektrodermal Aktivite
ESP32	: Gömülü sistemlerde kullanılan Wi-Fi ve Bluetooth destekli mikrodenetleyici
HRV	: Kalp Atım Hızı Değişkenliği (Heart Rate Variability)
IMU	: Eylemsizlik Ölçüm Birimi (Inertial Measurement Unit)
LDA	: Doğrusal Ayırıcı Analiz (Linear Discriminant Analysis)
LSTM	: Uzun Kısa Süreli Bellek (Long Short-Term Memory)
ML	: Makine Öğrenmesi (Machine Learning)
MPU9250	: 9 eksenli IMU sensörü (ivmeölçer, jiroskop ve manyetometre içeren)
RNN	: Tekrarlayan Sinir Ağı (Recurrent Neural Network)
SMOTE	: Sentetik Azınlık Aşırı Örnekleme Tekniği (Synthetic Minority Over-sampling Technique)
SVM	: Destek Vektör Makineleri (Support Vector Machine)
STD	: Standart Sapma (Standard Deviation)
Z-norm	: Z-skoru normalizasyonu (z-score normalization)
LOGO CV	: Bir Grubu Dışarıda Bırakarak Çapraz Doğrulama

ŞEKİLLER DİZİNİ

	<u>Sayfa</u>
Şekil 3.1: Sistem mimarisi.	20
Şekil 3.2: Genel akış diyagramı.	22
Şekil 3.3: Devre şeması.	23
Şekil 3.4: Veri toplama düzeneği.	24
Şekil 3.5: Veri toplama anı.	33
Şekil 3.6: Lstm mimarisi.	45
Şekil 4.1: Korelasyon matrisi.	52
Şekil 4.2: Etikete göre ay ekseni dağılımı.	53
Şekil 4.3: Zaman serisi örneği: ay, gy ve my eksenleri.	54
Şekil 4.4: Genel ivme verileri istatistiksel analizi.	56
Şekil 4.5: Yeni Lstm mimarisi.	61

TABLÖLAR DİZİNİ

	<u>Sayfa</u>
Tablo 3.1: Katılımcıların Stresli Aralıkları	34
Tablo 4.1: Verisetine Ait Sınıf Dağılımı.	50
Tablo 4.2: SMOTE Uygulandıktan Sonra Sınıf Dağılımı.	51
Tablo 1.3: Katılımcı Bazlı İstatiksel Analiz Sonuçları.	55
Tablo 4.4: SVM Karmaşıklık Matrisi.	57
Tablo 4.5: LSTM Karmaşıklık Matrisi.	57
Tablo 4.6: Autoencoder Karmaşıklık Matrisi.	58
Tablo 4.7: Sınıflandırma Modellerinin Performans Karşılaştırmaları.	59
Tablo 4.8: LOGO CV ile Katılımcı Bazlı LSTM Modeli Sonuçları.	62

1. GİRİŞ

Stres, insan yaşamının kaçınılmaz bir parçası olarak, bireyin karşılaştığı fiziksel ya da psikolojik tehditlere karşı organizmanın verdiği biyolojik ve davranışsal yanıttır. Evrimsel süreçte hayatta kalma mekanizmasının bir parçası olarak ortaya çıkan stres tepkisi, günümüzde daha çok bilişsel ve duygusal yüklenmelerin bir sonucu olarak ortaya çıkmaktadır. Modern yaşamın getirdiği hızlı tempo, yoğun bilgi akışı, artan sosyal etkileşimler, akademik ve mesleki baskılar, bireyleri sürekli olarak stres yaratan durumlarla karşı karşıya bırakmaktadır. Sürekli stres altında kalmak, yalnızca ruhsal sağlığı değil, aynı zamanda bağışıklık sistemi, kardiyovasküler işlevler, gastrointestinal sistem ve nörolojik yapı gibi pek çok fizyolojik sistemi olumsuz etkileyebilmektedir.

Bireyin stres seviyesini doğru ve güvenilir bir şekilde ölçebilmek, yalnızca klinik psikoloji ve psikiyatri alanlarında değil, aynı zamanda iş sağlığı, eğitim, ergonomi, insan-bilgisayar etkileşimi, güvenlik ve spor bilimleri gibi pek çok disiplinde önem arz etmektedir. Stres düzeyinin takibi, bireyin mental sağlığını desteklemenin yanı sıra performansın optimize edilmesi, kazaların önlenmesi, müdahale zamanlamasının belirlenmesi ve bireyselleştirilmiş sağlık çözümlerinin geliştirilmesi gibi çok yönlü uygulamalara da kapı aralamaktadır. Bu bağlamda, stresin etkili bir şekilde ölçülmesi ve sınıflandırılması üzerine yapılan bilimsel araştırmalar her geçen yıl artmakta ve multidisipliner nitelik kazanmaktadır. Geleneksel stres ölçüm yöntemleri çoğunlukla öznel ve/veya fiziksel temellidir. Öz-bildirim anketleri (örneğin STAI, PSS, PANAS), bireyin kendi deneyimine dayalı olarak verdiği yanıtlarla çalışmakta ve kişinin içsel durumunu doğrudan yansıtmayı amaçlamaktadır. Ancak bu yöntemler yanıtların bilinçli manipölasyonuna açık olup, durumsal farkındalığın düşük olduğu anlarda doğru bilgi üretmeyebilir. Biyofizyolojik yaklaşımlar ise kalp atış hızı, kalp atım aralığı değişkenliği (HRV), deri iletkenliği (EDA), solunum hızı, vücut ısı ve hormonal belirteçler gibi parametreleri kullanır. Bu yöntemler objektif veriler sunsa da; genellikle pahalı cihazlar, sabit ortamlarda veri toplama ve kullanıcıya temas gerektiren sistemler ile çalışmaktadır. Dolayısıyla taşınabilirlik, ölçeklenebilirlik ve kullanıcı konforu gibi açılardan bazı sınırlılıklar taşımaktadır.

Bu sınırlamaları aşmak amacıyla son yıllarda davranışsal biyobelirteçlere dayalı stres analizi yöntemleri ön plana çıkmaya başlamıştır. Bu yaklaşımlar, bireyin bilişsel ve duygusal durumlarını dolaylı yollarla ölçmeyi hedefleyen, genellikle doğal ortamlarda izlenebilen ve müdahale gerektirmeyen teknikler sunmaktadır. Özellikle jest ve mimikler, yüz ifadeleri, göz hareketleri, konuşma özellikleri, yazı davranışları, yürüme biçimi ve mikro hareketler gibi davranışsal göstergeler, bireyin duygusal durumunu yansıtabilecek zengin bir bilgi kaynağı sunmaktadır. Bu sinyallerin avantajı, bireyin farkında olmadan ürettiği ve dolayısıyla manipülasyonu daha zor olan veriler olmalarıdır. Ayak hareketleri ve postüral denge kontrolü de bu davranışsal belirteçler arasında yer almakta, ancak literatürde görece daha az incelenmiş bir alan olarak kalmaktadır. Bireyler ayakta durduklarında, çevresel faktörler ve içsel duygusal durumlara bağlı olarak mikro düzeyde postüral ayarlamalar yaparlar. Bu ayarlamalar; ayak bileği, diz ve kalça eklemlerinin dinamik stabilizasyonu ile sağlanır ve vestibüler, somatosensoriyel ve görsel girdilerin bütünleşmesi ile yönetilir. Stres, bu sistemler üzerindeki etkiyle motor kontrol stratejilerini değiştirebilir. Örneğin, bir kişi yüksek stres altında iken denge koruma refleksleri artabilir, ayakta dururken daha sık ağırlık transferleri yapabilir veya ayak pozisyonunu daha fazla değiştirme eğiliminde olabilir. Bu tür değişiklikler, ileri düzey sensörler aracılığıyla hassas bir şekilde saptanabilir.

Atalet ölçüm birimleri (Inertial Measurement Unit, IMU), bu tarz hareketlerin izlenmesinde giderek yaygınlaşan araçlardır. 3 eksenli ivmeölçer, jiroskop ve manyetometreden oluşan bu sensörler; yüksek zaman çözünürlüğü, düşük enerji tüketimi, taşınabilirlik ve düşük maliyet gibi özellikleriyle giyilebilir sistemlerin vazgeçilmez bir parçası haline gelmiştir. Özellikle 9 eksenli IMU'lar sayesinde bireyin hareketlerine dair çok boyutlu zaman serisi verileri toplanabilmekte ve bu veriler gelişmiş analiz yöntemleriyle anlamlı örüntüler haline getirilebilmektedir. Toplanan bu çok boyutlu zaman serisi verilerinin analizinde geleneksel istatistiksel yöntemlerin ötesine geçilmiş; son yıllarda özellikle derin öğrenme tabanlı yaklaşımlar ön plana çıkmıştır. Derin öğrenme modelleri, özellikle tekrarlayan yapılar (RNN, LSTM) ve otomatik öznitelik çıkarımı sağlayan katmanlı mimarileri sayesinde, karmaşık örüntüleri doğrudan veriden öğrenebilmekte ve güçlü genelleme performansı sunabilmektedir. Böylece insan davranışı gibi çok boyutlu, gürültülü ve zaman bağımlı verilerin analizi daha erişilebilir hale gelmiştir.

Ayak hareketlerinden stres tahmini yapılması, hem teknik hem de bilimsel açıdan özgün bir yaklaşım sunmaktadır. Teknik açıdan bakıldığında, düşük maliyetli sensörler ve giyilebilir sistemlerle pasif veri toplama imkânı tanırken, bilimsel açıdan stresin motor davranışlarla olan ilişkisine dair yeni bir bakış açısı geliştirmektedir. Ayak hareketlerinin doğrudan bilinçli kontrol altında olmaması, bu hareketleri güvenilir bir stres belirteci haline getirme potansiyeline sahiptir. Özellikle birey farkında olmadan stres yaşarken, istemsiz motor tepkiler vücutta ortaya çıkabilir ve bu tepkiler hassas sensörlerle yakalanabilir. Bu çalışmada, söz konusu hipotezden yola çıkılarak bir stres sınıflandırma modeli geliştirilmiş; 9 eksenli sensör verilerinin, bireylerin ayakta durdukları sırada oynadıkları bilişsel yük içeren bir görev (Tetris oyunu) esnasında toplanarak analiz edilmesi amaçlanmıştır. Ancak bu giriş bölümünde detayına girilmeyen yöntemin amacı, veri toplama süreci, işleme adımları ve model mimarileri, ilerleyen bölümlerde detaylı biçimde sunulacaktır.

1.1. Tezin Amacı ve Önemi

Bu tez çalışmasının temel amacı, bireylerin bilişsel yük altındayken, bu çalışma kapsamında Tetris oyunu oynarken, ayak hareketlerinden elde edilen sensör verileri aracılığıyla stres düzeylerinin belirlenebilirliğini araştırmak ve bu doğrultuda bireysel katılımcılara özgü derin öğrenme tabanlı bir sınıflandırma modeli geliştirmektir. Çalışma, stresin davranışsal bir bileşeni olarak alt ekstremita hareketlerinin kullanımını ele alan nadir araştırmalardan biri olarak, müdahalesiz ve taşınabilir sensör tabanlı stres izleme sistemlerine katkı sağlamayı hedeflemektedir.

Günümüzde stresin hem bireysel sağlık hem de toplumsal işlevsellik üzerindeki etkileri giderek artmakta, dolayısıyla stresin güvenilir, kesintisiz ve düşük müdahale ile tespit edilmesini sağlayan sistemlere olan ihtiyaç ön plana çıkmaktadır. Geleneksel stres izleme yöntemleri çoğunlukla bireyin doğrudan katılımını, özel cihazlar kullanılmasını ya da gözlemlenmesini gerektirmektedir. Bu durum, uzun süreli ve doğal koşullarda veri elde etmeyi zorlaştırmakta, stresin günlük yaşamdaki etkilerinin anlaşılmasını sınırlamaktadır. Bu çalışma, söz konusu kısıtları aşmak üzere, bireyin motor davranışlarından biri olan ayak hareketlerini stresin davranışsal bir belirteci olarak değerlendirme fikri üzerine temellenmiştir.

Psikolojik stresin, bireyin sinir sistemi aracılığıyla kas tonusu, denge mekanizmaları ve refleks duyarlılığı gibi motor kontrol unsurlarını etkilediği bilinmektedir. Ayakta

sabit dururken insan vücudu sürekli olarak denge sağlamak amacıyla mikro düzeyde ayarlamalar yapar. Bu süreçte ayak kasları aktif rol oynamakta ve bireyin o anki fizyolojik ve psikolojik durumuna bağlı olarak bu hareketlerde değişiklikler gözlemlenebilmektedir. Özellikle dikkat gerektiren bir görev altında bireyin stres seviyesi artarken, bu durum denge kontrolünde farklı stratejilerin benimsenmesine yol açabilir. Örneğin stres altındaki bir birey, istemsiz olarak ağırlık merkezini daha sık değiştirerek daha fazla yön değiştirme eğilimi gösterebilir ya da postüral salınımlarında artış yaşanabilir. Bu tür davranışsal tepkilerin doğru analiz edilmesi, bireyin içinde bulunduğu stres düzeyinin anlaşılmasına katkı sağlayabilir.

Tez kapsamında, oturma pozisyonunda olan katılımcılara bilişsel yük oluşturan bir görev verilmiş ve görev esnasında ayaklarına yerleştirilen IMU sensörleri aracılığıyla üç eksenli ivme, açısal hız ve manyetik alan verileri toplanmıştır. Veriler, oyun zorluk seviyesi artan bir yapıdayken elde edilerek bireyin stresinin zamana bağlı olarak değişen etkileri gözlemlenmeye çalışılmıştır. Toplanan zaman serisi verileri, özenli bir ön işleme sürecinden geçirilmiş ve ardından stresli ile düşük stresli anlara ait etiketlemeler doğrultusunda analiz edilmiştir. Zaman bağımlılığı gösteren bu tür ardıl verilerin işlenmesi için derin öğrenmeye dayalı LSTM mimarileri kullanılmış, aynı zamanda destek vektör makineleri gibi klasik yöntemlerle karşılaştırmalı analizler yapılmıştır. Modellerin sınıflandırma performansı, doğruluk, F1 skoru, hassasiyet ve özgüllük gibi metrikler üzerinden değerlendirilmiş; elde edilen sonuçlar, ayak hareketlerinin stresin belirlenmesinde anlamlı bir gösterge olabileceğini ortaya koymuştur.

Bu çalışmanın bilimsel önemi, stresin davranışsal bir bileşeni olarak ayak hareketlerinin kullanılabilirliğine yönelik nadir çalışmalardan biri olmasıdır. Literatürde genellikle üst vücut hareketleri, yüz ifadeleri, kalp atış hızı değişkenliği veya elektrodermal aktivite gibi sinyaller tercih edilmekte; alt ekstremité hareketleri ise çoğunlukla göz ardı edilmektedir. Bu bağlamda ayakta dururken farkında olmadan sergilenen ayak hareketlerinin değerlendirilmesi, hem yenilikçi bir yaklaşım sunmakta hem de müdahalesiz stres izleme sistemlerinin geliştirilmesi açısından değerli bir alternatif oluşturmaktadır. Aynı zamanda, bu tür verilerin düşük maliyetli ve taşınabilir sensörler ile elde edilebiliyor olması, sistemin gerçek yaşam koşullarında uygulanabilirliğini artırmaktadır. Tezin kapsamı, bireylerin belirli bir görev süresince gerçekleştirdiği ayak hareketlerine dayalı veri toplama, bu verilerin ön işlenmesi,

sınıflandırma modellerinin geliştirilmesi ve değerlendirilmesi aşamalarını içermektedir. Veri toplama süreci, kontrollü bir deney ortamında gerçekleştirilen Tetris oyunu sırasında yürütülmüştür. Bu süreçte elde edilen ham veriler, pencereleme, filtreleme, normalizasyon ve etiketleme gibi adımlardan geçirilmiştir. Geliştirilen sınıflandırma modelleri, stresli ve düşük stresli durumları ayırt etme yeteneklerine göre analiz edilmiştir. Modelin performansını etkileyen veri dengesizliği, bireyler arası varyasyonlar ve gerçek zamanlı uygulamalara yönelik sınırlılıklar ayrıca tartışılmıştır. Tezin odağı, yalnızca ayakta durma esnasında ortaya çıkan ayak hareketleri ile sınırlı olup, oturma, yürüme veya başka görevlerdeki davranışlar kapsam dışında bırakılmıştır. Ancak geliştirilen yaklaşımın farklı bağlamlara da genişletilebilecek bir altyapı sunması hedeflenmiştir. Çalışmanın genel yapısı şu şekilde organize edilmiştir: İkinci bölümde, stres tespiti ve davranışsal biyobelirteçler üzerine yapılan önceki çalışmalar sistematik bir biçimde incelenmiş ve mevcut yaklaşımlar ile bu tez arasındaki farklılıklar tartışılmıştır. Üçüncü bölümde, önerilen yaklaşım ayrıntılı biçimde açıklanmış; veri toplama süreci, ön işleme adımları ve sınıflandırma algoritmalarına ilişkin teknik detaylara yer verilmiştir. Dördüncü bölümde, geliştirilen modellerin performansına yönelik yapılan testler sunulmuş, elde edilen bulgular analiz edilerek değerlendirilmeye tabi tutulmuştur. Beşinci ve son bölümde ise çalışmanın genel sonuçları özetlenmiş, elde edilen kazanımlar yorumlanmış ve gelecekte yapılabilecek araştırmalar için öneriler sunulularak çalışma tamamlanmıştır.

2. LİTERATÜR İNCELEMESİ

Bu bölümde, stresin tespiti için kullanılan mevcut yaklaşımlar kapsamlı bir şekilde ele alınmıştır. İlk olarak, fizyolojik temelli klasik yöntemler ve bu yöntemlerin avantajları ile sınırlılıkları incelenmiştir. Daha sonra, bireyin doğal davranışlarından yola çıkarak stres düzeyini belirlemeye yönelik davranışsal biyobelirteçlere dayalı çalışmalara odaklanılmıştır. Özellikle yüz ifadeleri, ses özellikleri ve mikro hareketler gibi göstergelerin stresle olan ilişkisi değerlendirilmiştir. Bu bağlamda, literatürde nispeten az sayıda çalışmada ele alınmış olan ayak hareketlerinin psikolojik durum göstergesi olarak kullanılabilirliği detaylandırılmıştır. Ayrıca, ayak hareketlerinin sayısal olarak ölçülmesini mümkün kılan 9 eksenli IMU (atalet ölçüm birimi) sensörlerinin teknik yapısı ve veri toplamadaki rolü açıklanmıştır. Son olarak, bu tür zaman serisi verilerin analizinde yaygın olarak kullanılan derin öğrenme algoritmaları —özellikle LSTM ve CNN tabanlı mimariler— tartışılmış ve alandaki güncel eğilimler ışığında değerlendirmelerde bulunulmuştur. Bu kapsamlı inceleme, çalışmanın kuramsal temelini oluşturmakta ve tez kapsamında geliştirilen yöntemin özgün yönlerini ortaya koymaktadır.

2.1. Stresin Belirlenmesinde Kullanılan Geleneksel Yöntemler

Stresin nesnel biçimde tespit edilmesine yönelik olarak literatürde çok sayıda fizyolojik ve psikolojik yaklaşım geliştirilmiştir. Fizyolojik tabanlı yöntemler arasında en sık başvurulan göstergeler; kalp atış hızı (HR), kalp atım aralığı değişkenliği (HRV), deri iletkenliği (EDA), solunum ritmi ve tükürük veya kan yoluyla ölçülen kortizol seviyeleri gibi hormonal göstergelerdir. Bu biyobelirteçler, bireyin otonom sinir sistemi aktivitelerine dayalı olarak stres tepkilerini dolaylı olarak yansıtır ve stresin fiziksel boyutunu daha somut bir şekilde ele almaya yardımcı olur. Örneğin, kalp atış hızı ve kalp atım aralığı değişkenliği, bireyin stres altındaki fiziksel tepkilerini gösterebilirken, deri iletkenliği, duygusal durumun ve stresin anlık değişimlerini izlemek için kullanılabilir. Kortizol seviyeleri ise, stres hormonunun vücutta nasıl değiştiğini göstererek, bireylerin uzun dönemdeki stres seviyelerini izlemekte faydalı bir gösterge sağlar. Ancak söz konusu yöntemlerin uygulanabilmesi için çoğu zaman

özel donanım, laboratuvar ortamı veya uzman desteği gerekebilmektedir [1]. Örneğin, kalp atış hızı ve EDA ölçümleri genellikle biyometrik cetvel gibi özel cihazlar vasıtasıyla gerçekleştirilir. Bu şartlar, söz konusu tekniklerin günlük yaşamda uzun süreli ve kesintisiz stres takibi için kullanımını önemli ölçüde sınırlamaktadır. Laboratuvar ortamında gerçekleştirilen testlerin, bireylerin doğal yaşamlarını yansıtmadığı ve stresin gerçek zamanlı olarak izlenmesine olanak tanımadığı da göz önünde bulundurulmalıdır. Bu durum, stresin dinamik doğasını anlamak için önemli bir engel teşkil eder.

Buna ek olarak, stres düzeyinin değerlendirilmesinde psikolojik testler ve öz-bildirim temelli ölçüm araçları da yaygın biçimde kullanılmaktadır. Özellikle Durumluk-Sürekli Kaygı Envanteri (State-Trait Anxiety Inventory - STAI) ve Algılanan Stres Ölçeği (Perceived Stress Scale - PSS) gibi psikometrik ölçekler, bireylerin öznel deneyimlerini yapılandırılmış sorular aracılığıyla ifade etmesine dayanır [2]. Bu tür testler, bireylerin kendi stres algılarını ve kaygı düzeylerini tarif etmelerine olanak tanıdığı için faydalı olmakla birlikte, yanıtların sübjektif doğası, sosyal beklenti etkisi ve bireyin o anki farkındalık düzeyi gibi faktörlerden etkilenebilir. Yani, bireyler stres hissettiklerinde, bu durumu dışa vurmada rahat hissetmeyebilir veya sosyal normlara uygun yanıtlar verme eğiliminde olabilirler. Ayrıca, anlık stres düzeyinin yüksek zaman çözünürlüğüyle izlenmesine olanak tanımazlar; bu da stresin dinamiklerini anlamada önemli bir kısıtlama oluşturur. Özellikle, stresin tetikleyicileri ve yanıtlarının hızla değişebildiği durumlarda, öz-bildirim temelli yöntemler, anlık değişimleri gözlemlemekte yeterince etkili olmayabilir. Bu noktada giyilebilir teknolojiler içeren çalışmalar ön plana çıkmıştır.

Literatürde daha önce denenmiş yöntemleri incelediğimizde karşımıza çıkan giyilebilir teknolojileri içeren çalışmalardan birinde Montesinos et al. [3], bilekte takılan Empatica E4 ve göğüste takılan Shimmer3 ECG giyilebilir sensörlerinden elde edilen fizyolojik sinyalleri kullanarak akut stresi tespit etmiş ve kNN, karar ağacı (DT) ile rastgele orman (RF) gibi makine öğrenmesi algoritmalarını uygulayarak %84,13 doğruluk elde etmiştir. Can et al. [4] ise Samsung GearS serisi ve Empatica E4 gibi giyilebilir cihazlar aracılığıyla otomatik bir stres tanıma sistemi geliştirmiş; kNN, doğrusal regresyon (LR), RF, destek vektör makineleri (SVM) ve çok katmanlı

algılayıcı (multilayer perceptron) gibi yöntemlerle 21 katılımcının stres düzeylerini sınıflandırmıştır.

2.2. Davranışsal Biyobelirteçler ile Stres Analizi

Fizyolojik sinyallere dayalı stres ölçüm yöntemlerinin sınırlılıkları, son yıllarda bireyin doğal davranış örüntülerinden yola çıkarak psikolojik durumunu tahmin etmeye yönelik yeni yaklaşımların gelişmesine yol açmıştır. Özellikle, davranışsal biyobelirteçler (behavioral biomarkers), stresin belirlenmesinde dikkat çeken alternatif veri kaynakları haline gelmiştir. Davranışsal biyobelirteçler, yüz ifadeleri, ses özellikleri, göz kırpma sıklığı, konuşma hızı, jest ve mimikler, yazı kalıpları, klavye/beş kullanımı ve vücut duruşu gibi çeşitli davranışsal sinyalleri içermektedir. Bu sinyallerin, bireyin duygusal ve zihinsel durumunu yansıttığına dair yapılan çok sayıda araştırma, bu yaklaşımın geçerliliğini destekler niteliktedir. Örneğin, yüz ifadelerindeki küçük değişiklikler, bireyin stres düzeyi arttıkça belirginleşebilir; kişiler, gerginlik yaşadıklarında genellikle kaşlarını çatma veya ağız köşelerini aşağıya doğru çekme gibi otomatik refleksler gösterirler. Buna benzer şekilde, ses tonundaki dalgalanmalar veya konuşma hızındaki değişiklikler de stresin bir göstergesi olarak değerlendirilebilir. Yapılan çalışmalar, stres altında bireylerin sesi daha titrek, yüksek veya hızlı hale geldiğini göstermektedir.

Bu göstergeler, genellikle bireyin farkında olmadan sergilediği tepkilere dayandığı için, öz-bildirim tabanlı yöntemlere kıyasla daha objektif kabul edilmektedir. Öz-bildirim yöntemleri, kişinin stres düzeyini kendi algılamasına dayanırken; davranışsal biyobelirteçler, doğrudan bireyin stres altındaki davranışlarını gözlemlene imkânı sunar. Ayrıca, bu tür sinyaller, bireyin stresli durumlarda gösterdiği refleksif ve istemsiz davranışların dijital olarak kaydedilmesine olanak tanır. Örneğin yapılan bir çalışmada [5], artan stres altında bireylerin yüz ifadelerinde kasılma, ses tonunda dalgalanma, mikro mimiklerde hızlanma veya bilgisayar etkileşiminde hata oranında artış gibi değişimler gözlemlendiği ortaya konulmuştur. Bu davranışsal örüntüler, uygun sensör sistemleri ve analiz algoritmaları ile sayısal olarak modellenilebilmekte ve stres sınıflandırma problemlerinde kullanılabilir.

Bununla birlikte, söz konusu davranışsal biyobelirteçlerin uygulanabilirliği çevresel faktörlerden etkilenebilir. Örneğin, yüz analizi için bireyin doğrudan kameraya

bakması ve görüntünün net olması gibi koşullar gerekebilir. Aynı şekilde, ses analizi için düşük gürültülü bir ortamda konuşması veya belirli bir mesafeden kaydedilmesi gerekmektedir. Bu tür sınırlamalar, daha düşük müdahale gerektiren ve kişinin farkında olmadan sergilediği davranışsal sinyalleri izlemeyi mümkün kılan alternatif stratejilerin geliştirilmesini gerekli kılmıştır. Araştırmacılar, bu bağlamda mikro hareketler ve özellikle alt ekstremitte hareketleri gibi daha az çalışılmış davranışsal göstergelere olan ilginin arttığını gözlemlemektedir [6]. Alt ekstremitte hareketleri, bireyin stres durumunu yansıtacak şekilde yapılan otomatik hareketleri içerebilir; örneğin, ayakların yere vurma sıklığı veya oturma pozisyonundaki küçük değişiklikler, stresin bir göstergesi olabilir. Bu tür göstergeler, stres analizinde yeni ve potansiyel olarak etkili bir yaklaşım sunmaktadır. Bu konuda yapılan diğer çalışmalara baktığımızda en dikkat çekenlerinden birinde Schuller et al. [7] konuşma sırasında ses yüksekliği, titreşim ve konuşma hızındaki değişiklikleri analiz ederek bireylerin stres düzeylerini tahmin etmeye çalışmıştır. Stresli bireylerin genellikle daha yüksek, daha hızlı ya da daha dalgalı ses tonuyla konuştuğu tespit edilmiştir. Buradan da ses tonunun da yüz ifadeleri gibi stres analizi konusunda önemli bir biyobelirteç olduğu sonucu çıkabilir. Shi ve arkadaşları [8] ise gerçekleştirdiği çalışmada kişilerin stresli olduğu durumlarda adımlarının daha hızlı ancak daha dengesiz olduğu, omuz ve beden postüründe de belirgin değişiklikler gözlemledi. Akıllı telefon sensörleri gibi araçlarla bu tür davranışsal veriler toplanarak stres düzeyi tahmin edilebilmektedir. Hareketler stresin fiziksel yansıması olabilir ve cep telefonundaki ivmeölçer gibi sensörlerle analiz edilebilir sonucuna vardılar. Bu kısımda bahsettiğim çalışmaların tamamında davranışsal biyobelirteçler stres tahmininde önemli göstergeler ortaya koyabilir hipotezi yapılan deneylerle desteklendi.

2.3. Alt Ekstremitte Hareketleri ve Psikolojik Durumlar

Bireyin psikolojik durumu ile motor davranışları arasındaki ilişki, özellikle mikro hareketler üzerinden yapılan analizlerde giderek daha fazla ilgi görmektedir. Alt ekstremitteye ait istemsiz hareketlerin, bireyin zihinsel yükü veya duygusal durumu hakkında dolaylı ama anlamlı ipuçları taşıyabileceği yönündeki bulgular, bu alana olan ilgiyi artırmıştır. Özellikle, stres altında olan bireylerin motor davranışlarının değiştiğine dair yapılan gözlemsel çalışmalarda, oturur pozisyonda daha sık ayak pozisyonu değiştirdikleri, ayak uçlarını yere vurdukları veya topuklarını salladıkları

rapor edilmiştir [9]. Bu tür davranışlar, bireyin anksiyete veya stres anlarında içsel huzursuzluk yaşadığına işaret edebilir. Bu tür hareketler genellikle refleksif ve bilinç dışı olarak gerçekleştiği için, kişinin içinde bulunduğu psikolojik durumu nesnel bir biçimde yansıtmaya potansiyeli taşımaktadır. Psikolojik literatürde, özellikle kaygı bozuklukları ve sosyal stres durumlarında artan motor huzursuzluğun, bireyin duygu durumunu belirten önemli bir davranışsal belirteç olduğu sıkça vurgulanmaktadır [10]. Örneğin, kaygı düzeyi yükseldikçe bireylerin ayak hareketleri de artma eğilimindedir. Bu durum, psikolojik baskı altında olan bireylerin kendilerini rahatlatmak veya stresle başa çıkmak için bilinçsizce geliştirdikleri fiziksel tepkiler olarak değerlendirilmektedir. Geleneksel gözlem temelli analizlerin ötesine geçmek amacıyla, bu hareketlerin sensör teknolojileri aracılığıyla sayısal olarak kaydedilmesi ve modellenmesi yönünde çalışmalar da artmaktadır. Sensör tabanlı sistemler, bireylerin alt ekstremita hareketlerini dikkatlice izlemekte ve analiz etmektedir. Böylece mikro düzeydeki postüral değişimlerin otomatik olarak tespit edilmesi, stres düzeyinin belirlenmesinde kullanılabilir hale gelmektedir. Örneğin, bir birey otururken ayaklarını sürekli hareket ettirdiğinde, bu durumun hem fiziksel hem de psikolojik bir karşılığı olup olmadığına dair sağlam veriler elde edilebilir. Özellikle düşük yoğunluklu fiziksel aktivite anlarında —örneğin birey otururken— meydana gelen bu tür ayak hareketleri, klasik fizyolojik sinyallerle yakalanamayan ancak davranışsal olarak anlamlı olan bir veri katmanı sunmaktadır. Bu noktada, alt ekstremita hareketlerinin analizi, bireylerin stres anlarında sergiledikleri davranışları objektif bir şekilde anlamaya yönelik önemli bir fırsat sunmaktadır.

Kendi çalışmamız da alt ekstremita hareketlerine odaklandığı için bu alandaki literatür çalışmaları önem kazanmaktadır. Bu konudaki tıbbi deneylere baktığımızda Günaydın ve arkadaşları tarafından yapılan [11] alt ekstremita osteoartritli (yani kireçlenme) hastalarda yürüyüş hızıyla anksiyete düzeyi arasındaki ilişkiyi inceleyen bir çalışmada, PASS-20 (ağrıya bağlı anksiyete ölçeği) skorlarının 10 metrelik yürüyüş hızını anlamlı şekilde etkilediği bulunmuştur. Bu sonuç, özellikle ağrıya bağlı psikolojik tepkilerin yürüme performansını belirgin biçimde değiştirdiğine işaret etmektedir. Diğer bir dikkat çeken çalışmada ise anksiyete bozukluğu olan bireylerle sağlıklı bireylerin yürüyüş özellikleri karşılaştırıldığında, anksiyetesi olanların daha yavaş yürüdükleri, adım uzunluklarının daha kısa olduğu ve adım sayısının azaldığı; ayrıca denge ve hareket kabiliyeti de olumsuz etkilenmiştir [12]. Çalışma, fiziksel muayenelere denge

ve mobilite testlerini dahil etmenin önemini vurgulamaktadır. Benzer bir çalışmada Smith et al. [13] duygusal durumların (özellikle hüznün ya da üzüntü) yürüyüş özellikleri üzerindeki etkileri incelemiş; hüznün durumunda adım hızı ve uzunluğu belirgin şekilde azalmış, denge daha yavaş gerçekleşmiş, yürüyüş ritmi değişmiştir. Bunun depresyonun fiziksel yansıması olabileceği vurgulanmış ve ruh halinin hareket kontrolüne etkisi kanıtlanmıştır. Bir diğer önemli çalışmada da makine öğrenme teknikleriyle Kinect kameraları yardımıyla doğal yürüyüş verileri analiz edilmiş; anksiyete ve depresyon düzeyleri, vücut eklem hareketlerinden çıkarılan düşük seviye girdilerle tahmin edilebilmiştir. Bu sayede ruh hâli algısının yürüyüş vasıtasıyla yapay zeka ile değerlendirilebileceği desteklenmiştir [14]. Bu çalışmalarda varılan sonuçların bizim çalışmamızın aksine genellikle anlık stresten ziyade genel stres durumu üzerine odaklandığını söyleyebiliriz.

Bu çalışmamızda bilişsel yük oluşturmak ve katılımcıların anlık stres/dikkat durumlarını değiştirmek amacıyla Tetris video oyunu kullanılmıştır. Tetris, görsel-uzaysal çalışma belleğini ve dikkat kaynaklarını etkin biçimde meşgul eden, görece olarak kolay öğrenilebilen fakat zorluk seviyesinin oyun ilerledikçe artmasıyla birlikte katılımcıda bilişsel yük değişimleri yaratan bir görev olarak literatürde yaygın biçimde kullanılmaktadır. Lau-Zhu ve çalışma arkadaşlarının yaptığı araştırmada, Tetris performansının özellikle görsel-uzaysal çalışma belleğiyle anlamlı şekilde ilişkilendiği; oysa sözel ya da sözel olmayan diğer bellek türleriyle ilişki bulunmadığı saptanmıştır. Bu sonuç, Tetris'in görsel-uzaysal işleyiş ve zihinsel dönüştürme süreçlerini devreye soktuğunu ve bu yollarla bilişsel yükü etkin biçimde artırdığını göstermektedir [15]. Ayrıca, Groen ve ortaklarının yakın tarihli çalışmasında, Tetris'in görev yükünü adım adım artırarak performans üzerindeki etkilerini sistematik olarak gözlemlemenin mümkün olduğu ortaya konmuştur. Araştırmada, artan oyun zorluk seviyelerine bağlı olarak katılımcı performans eğrisinde beklenen ters U (inverted U) formuna benzer bir düşüş gözlemlenmiş; bu, Tetris'in görev yüküne duyarlı ve mental çabak seviyesini yansıtan bir görev olduğunu doğrulamaktadır [16]. Bu nedenle, Tetris deneysel ortamda bilişsel yükü manipüle etmek ve üst düzey zihinsel çaba gerektiren bir görev modeli olarak çalışmanın hipotezini destekleyen uygun bir araç olarak seçilmiştir.

2.4. IMU Sensörleri ve Davranışsal Veri Toplama

Giyilebilir teknolojilerin gelişimi, birey davranışlarının sürekli ve müdahalesiz biçimde izlenmesini mümkün kılmıştır. Bu gelişimin merkezinde yer alan atalet ölçüm birimleri (Inertial Measurement Units – IMU), üç eksenli ivmeölçer, jiroskop ve manyetometre bileşenlerinden oluşan kompakt sensörlerdir. Bu sensörler, doğrusal ivme, açısal hız ve yönelim gibi parametreleri eşzamanlı olarak ölçebilmekte, böylece çok boyutlu hareketlerin detaylı şekilde analiz edilmesine olanak tanımaktadır [17]. Hafif, taşınabilir ve düşük enerji tüketimine sahip olmaları nedeniyle IMU sensörleri, insan hareketlerini doğal ortamlarda izlemek için en çok tercih edilen sensör teknolojileri arasında yer almaktadır.

Literatürde IMU sensörleri genellikle yürüme analizi, denge bozukluklarının tespiti, spor performansı ölçümü ve sağlık takibi gibi alanlarda yaygın olarak kullanılmaktadır. Bununla birlikte, bu sensörlerin psikolojik durumların izlenmesinde kullanımı henüz gelişmekte olan bir araştırma konusudur. Yakın dönem çalışmalarda, IMU verilerinin yalnızca fiziksel aktiviteyi değil, aynı zamanda stres, yorgunluk ve dikkat düzeyi gibi içsel durumları da yansıtabileceği yönünde bulgulara ulaşılmıştır [18]. Özellikle ayak bileği ya da ayakkabı içine yerleştirilen IMU sensörleri ile elde edilen veriler, bireyin otururken gerçekleştirdiği mikro hareketlerin zaman serisi olarak kaydedilmesini sağlamaktadır.

Bu tür davranışsal verilerin, uygun analiz teknikleriyle yorumlanması durumunda, bireyin duygusal veya bilişsel yüklenme düzeyine dair anlamlı örüntüler sunabileceği öne sürülmektedir. Örneğin stresli bir durumda, bireyin ayak pozisyonunu değiştirme sıklığı, ayak bileği hareketinin genliği veya salınım paterni belirgin biçimde farklılık gösterebilir. Bu bağlamda, IMU verilerinin davranışsal biyobelirteçlerle bütünleştirilerek kullanılması, hem kullanıcı etkileşimi gerektirmeyen hem de zaman içinde öğrenen sistemlerin geliştirilmesine zemin hazırlamaktadır [19].

2.4.1. İvmeölçer

İvmeölçerler, cismin üç eksenindeki (x, y, z) doğrusal ivmesini ölçerek hareketin şiddetini ve yönünü belirlemeye yarayan temel sensör bileşenlerindendir. IMU sistemlerinde yer alan ivmeölçerler, özellikle yerçekimi etkisini de içerecek şekilde

vücut hareketlerini hassas biçimde tespit edebilmektedir. Oturur pozisyonda olan bireylerin ayak bileklerinde meydana gelen mikro hareketler, ivme verileriyle yüksek zaman çözünürlüğüyle izlenebilir hâle gelmiştir. Güncel çalışmalarda ivme verileri; hareket yoğunluğu, değişim sıklığı ve salınım yönü gibi özniteliklere ayrılarak stres, dikkat ve bilişsel yük analizi için kullanılmaktadır. Bu sayede ivmeölçerler, sadece hareket takibi değil, davranışsal analiz açısından da güçlü bir araç haline gelmiştir [20].

2.4.2. Jiroskop

Jiroskoplar, bir cismin kendi eksenini etrafında yaptığı açısal hareketi ölçen sensör bileşenleridir. IMU içerisinde yer alan jiroskoplar, ayak bileği gibi vücut bölgelerinde açısal salınımları ve rotasyonel değişimleri izlemek için kullanılmaktadır. Oturma pozisyonunda dahi bireyler belirli düzeyde ayak içe-dışa dönmesi, bacak sallama veya bilek hareketleri yapabilmektedir. Jiroskop verileri bu tür dönme hareketlerini yakalayıp, stres durumunda ortaya çıkabilecek motor kontrol değişikliklerini analiz etmede fayda sağlamaktadır. Literatürde, jiroskop verileri kullanılarak postüral denge, huzursuzluk düzeyi ve motor gerginliğin tespiti gibi konularda anlamlı çıktılar elde edildiği rapor edilmiştir [21].

2.4.3. Manyetometre

Manyetometreler, ortamdaki manyetik alanın yönünü ve büyüklüğünü ölçerek cihazın dünyanın manyetik kuzeyine göre yönelimini belirlemeye olanak sağlar. IMU'nun bu bileşeni, özellikle cihazın mutlak konumunun belirlenmesinde ve jiroskop verilerinin doğrulanmasında tamamlayıcı rol oynamaktadır. Ayak hareketleri sırasında meydana gelen yön değişimleri, manyetometre verileriyle daha doğru biçimde modellenmektedir. Son çalışmalar, manyetometre verilerinin jiroskop ve ivmeölçerle birlikte kullanıldığında, hareket örüntülerinin daha tutarlı ve güvenilir şekilde sınıflandırılabilirdiğini göstermektedir [22].

2.5. Derin Öğrenme Algoritmaları ile Stres Sınıflandırması

Geleneksel makine öğrenmesi yöntemleri, sınıflandırma problemlerinde uzun yıllardır yaygın olarak kullanılmakla birlikte, özellikle yüksek boyutlu ve zamana bağlı (zaman serisi) verilerin işlenmesinde önemli sınırlamalara sahiptir. Biyolojik sinyaller,

davranışsal sensör verileri gibi karmaşık ve çok katmanlı örüntüler içeren veri türlerinde, manuel öznitelik mühendisliği hem yoğun emek gerektirmekte hem de modelin performansını doğrudan etkileyebilecek hatalara açık olmaktadır. Bu bağlamda, derin öğrenme yaklaşımları, özellikle zaman serisi verilerde otomatik örüntü çıkarma ve soyut temsil oluşturma yetenekleri sayesinde stres sınıflandırması gibi karmaşık problemler için giderek daha fazla tercih edilmektedir [23].

Zaman içinde meydana gelen dinamik değişimlerin ve geçici örüntülerin modellenmesi amacıyla, tekrarlayan sinir ağları (Recurrent Neural Networks - RNN) ve özellikle Uzun Kısa Süreli Bellek (Long Short-Term Memory - LSTM) mimarileri yaygın biçimde kullanılmaktadır. LSTM yapıları, geleneksel RNN'lere kıyasla uzun dönemli bağımlılıkları daha etkin şekilde öğrenebilmekte ve önceki zaman adımlarındaki bilgileri “bellekte” tutarak, ilerleyen zaman adımlarında bu bilgileri değerlendirebilmektedir. Böylece, stres düzeyindeki ani dalgalanmalar veya yavaş değişimler gibi karmaşık zaman bağımlılıkları LSTM modelleri aracılığıyla başarıyla yakalanabilmektedir. Literatürde, IMU (Inertial Measurement Unit) tabanlı sensör verileriyle eğitilen LSTM modellerinin, stresli ve stresiz durumları yüksek doğrulukla ayırt edebildiğine dair çok sayıda çalışma mevcuttur [24]. Başka bir örnek olarak Gjoreski et al. tarafından yapılan çalışmada, katılımcıların günlük yaşam aktiviteleri sırasında bileklerinden alınan ivmeölçer, jiroskop ve kalp atım hızı gibi çoklu sensör verileri kullanılmıştır. Toplamda 30'dan fazla bireyin stres seviyesi, hem kontrollü laboratuvar senaryolarında hem de gerçek dünya koşullarında izlenmiştir. LSTM mimarisi, her bir bireyin veri akışı üzerinde zaman pencereleri (5 saniyelik sliding windows) uygulanarak eğitilmiş ve birey-bağımsız stres sınıflandırması yapılmıştır. Çalışmada LSTM tabanlı modelin stresli ve stressiz durumları %85,1 doğrulukla ayırt ettiği bildirilmiştir. Ayrıca model, geleneksel yöntemlerle (SVM, Random Forest gibi) kıyaslandığında daha istikrarlı sonuçlar vermiştir [25]. Bunun yanı sıra, bir diğer derin öğrenme mimarisi olan 1 boyutlu Konvolüsyonel Sinir Ağları (1D-CNN) da zaman serisi verilerinin lokal örüntülerinin çıkarılmasında oldukça etkin bir yöntem olarak öne çıkmaktadır. 1D-CNN modelleri, zaman serisi içindeki kısa süreli ve yerel varyasyonları filtreler aracılığıyla otomatik öğrenebilmektedir. Bu sayede, önceden tanımlanmış özniteliklere ihtiyaç duyulmadan verinin kendisinden anlamlı özellikler çıkarılmakta ve bu durum hem veri ön işleme yükünü azaltmakta hem de modelin genelleme kapasitesini artırmaktadır. CNN tabanlı modeller, özellikle hareket ve

biyolojik sinyal verilerindeki zamansal dalgalanmaları ve kısa süreli desenleri başarılı şekilde yakalamakta ve stres sınıflandırması için güçlü temeller sağlamaktadır. Örneğin, Kim ve arkadaşları tarafından yürütülen çalışmada, 20 katılımcının akıllı saatlerinden toplanan ivmeölçer, cilt iletkenliği (EDA) ve kalp ritmi (PPG) verileri kullanılarak stres tespiti yapılmıştır. CNN modeli, 3 konvolüsyonel katman ve 2 fully-connected katmandan oluşmakta ve veriler üzerinde 10 saniyelik pencereleme uygulanarak eğitilmiştir. Sonuçlar, CNN modelinin ortalama %87,4 doğrulukla stres sınıflandırması yapabildiğini ortaya koymuştur. CNN'ler özellikle cilt iletkenliği gibi ani değişim gösteren verilerde daha başarılı bulunmuştur [26].

Son yıllarda, LSTM ve CNN mimarilerinin hibrit biçimde birleştirildiği modeller literatürde yaygınlaşmıştır. Bu yaklaşımlar, CNN'in lokal örüntü çıkarma yeteneği ile LSTM'nin uzun dönemli bağımlılıkları modelleme kapasitesini bir araya getirerek, stres düzeylerinin daha hassas ve güvenilir biçimde tahmin edilmesini mümkün kılmaktadır [27]. Böylece, hem kısa süreli ani hareket veya sinyal değişimleri hem de uzun dönemli eğilimler modele dahil edilmekte ve böylece karmaşık stres dinamikleri daha doğru yakalanabilmektedir. Bu tür hibrit modeller, sensör verilerinin doğası gereği sahip olduğu hem lokal hem de global zaman bağlamlarını bütüncül bir şekilde analiz etme avantajına sahiptir. Hibrit çalışmalara baktığımızda literatürde öne çıkan çalışmaların birinde Alberdi et al, bu hibrit yaklaşımı kullanarak giyilebilir cihazlardan alınan kalp atım hızı (HRV), ivmeölçer ve EDA verilerini hem kontrollü stres testlerinde hem de doğal ortamlarda toplamıştır. Katılımcılar Trier Sosyal Stres Testi (TSST) gibi iyi bilinen stres indüksiyon protokollerine sokulmuş ve veri seti etiketlenmiştir. Hibrit CNN-LSTM modeli, hem sensör füzyonu hem de zamansal örüntü öğrenimi sağladığı için %91,3 doğrulukla stresli anları tespit edebilmiştir. Yazarlar, bu hibrit mimarilerin gerçek zamanlı uygulamalar için uygun hale getirilmesi hâlinde klinik kullanıma da uygun olabileceğini ileri sürmüştür [28].

Derin öğrenme tabanlı stres sınıflandırması uygulamalarında başarı, sadece model mimarisine değil, aynı zamanda veri hazırlama ve eğitim süreçlerine de bağlıdır. Doğru ve güvenilir etiketlenmiş veri kümeleri, modelin genelleme yeteneğini artırmada temel unsurdur. Özellikle stres gibi subjektif ve çok boyutlu bir durumu yansıtan etiketlerin doğruluğu, model başarısını doğrudan etkiler. Ayrıca, zaman serisi verilerinin uygun şekilde pencereleme (sliding window) teknikleri ile parçalanması,

modelin hem öğrenme performansı hem de gerçek zamanlı uygulamalardaki etkinliği açısından kritik öneme sahiptir. Aşırı öğrenmenin (overfitting) önlenmesi için düzenleme (regularization), dropout ve erken durdurma (early stopping) gibi optimizasyon stratejileri sıklıkla kullanılmaktadır.

Bununla birlikte, derin öğrenme modellerinin gerçek dünyadaki taşınabilir cihazlarda çalıştırılması, modelin boyutu, hesaplama karmaşıklığı ve enerji tüketimi gibi pratik sınırlamalar nedeniyle önemli bir araştırma alanıdır. Literatürde, düşük güçlü gömülü sistemlerde ve mobil cihazlarda çalışabilen hafif yapay zeka modellerinin geliştirilmesine yönelik eğilim giderek artmaktadır. Bu bağlamda, model sıkıştırma (model pruning), kuantizasyon (quantization) ve bilgi aktarma (knowledge distillation) gibi teknikler, stres sınıflandırma uygulamalarının taşınabilir ve gerçek zamanlı çözümler olarak kullanılabilmesi için önemli araçlar olarak öne çıkmaktadır.

Sonuç olarak, derin öğrenme algoritmaları stres sınıflandırması alanında geleneksel yöntemlere kıyasla daha yüksek doğruluk, esneklik ve genelleme kapasitesi sunmakta; ancak uygulamanın başarısı, veri kalitesi, model optimizasyonu ve gerçek zamanlı çalışabilirlik gibi çok yönlü faktörlere bağlıdır. Bu nedenlerle, derin öğrenme tabanlı stres algılama sistemlerinin geliştirilmesinde hem algoritmik hem de sistem mühendisliği perspektiflerinin bütünleşik olarak ele alınması gerekmektedir.

2.6. Değerlendirme ve Özgün Katkıları

Yapılan literatür incelemesi, stresin belirlenmesine yönelik geliştirilen yöntemlerin büyük ölçüde fizyolojik tabanlı ölçümlere dayandığını göstermektedir. Kalp atım hızı değişkenliği (HRV), deri iletkenliği (EDA), deri sıcaklığı, kan basıncı ve kortizol düzeyi gibi biyofizyolojik göstergeler, stres düzeylerinin belirlenmesinde yüksek doğruluk oranları sunmakta, ancak bu yöntemler genellikle pahalı, invazif, kullanıcıyı rahatsız edici ya da günlük yaşama entegre edilmesi zor sistemler içermektedir. Bu tür sistemlerin sürekli kullanılabilirliği düşüktür ve özellikle doğal ortamda uzun süreli gözlem yapılması gerektiğinde sınırlı fayda sağlamaktadır. Davranışsal biyobelirteçlere dayalı stres tespit yöntemleri, bireylerin stres altındaki davranış kalıplarını analiz ederek daha az müdahaleci, daha taşınabilir ve kullanıcı dostu çözümler sunmaktadır. Bu kapsamda; yüz ifadeleri, ses tonu, göz kırpması hızı, konuşma ritmi gibi üst vücut merkezli davranışsal göstergeler yaygın olarak

araştırılmıştır. Ancak alt ekstremite hareketlerinin stresle ilişkili potansiyelini ele alan çalışmalar oldukça az sayıdadır. Literatürde ayak hareketleri genellikle dengesizlik, yürüme paternleri veya postüral kontrol üzerine değerlendirilmiş; stres, anksiyete veya dikkat gibi psikolojik durumlarla doğrudan ilişkilendirilmesi nadiren ele alınmıştır. Bu durum, özellikle pasif gözlem ve düşük müdahale gerektiren stres tespit sistemlerinin gelişimi açısından önemli bir araştırma boşluğu olduğunu göstermektedir.

Bu tez çalışması, oturur pozisyonda bulunan bireylerin alt ekstremite (özellikle ayak) hareketlerinden elde edilen 9 eksenli IMU (İvmeölçer, Jiroskop ve Manyetometre) verileri aracılığıyla stres düzeylerinin sınıflandırılabilirliğini inceleyerek bu boşluğu doldurmayı hedeflemektedir. Katılımcıların Tetris oynarken sergilediği ayak hareketleri, zaman serisi biçiminde kaydedilmiş; veriler, manuel olarak etiketlenerek stresli ve düşük stresli dönemler ayrıştırılmıştır. Böylece, doğal bir görev sırasında bireylerin ayak temelli motor davranışlarından stres örüntüleri çıkarılmaya çalışılmıştır. Bu yaklaşım, bireyin dikkati ve zihinsel yüküyle ilişkilendirilebilecek mikro hareketleri değerlendirme açısından literatüre yenilikçi bir katkı sağlamaktadır. Veri analizinde hem geleneksel makine öğrenme algoritmaları (SVM) hem de zaman bağımlı derin öğrenme mimarileri (özellikle LSTM ve LSTM tabanlı Autoencoder yapılar) kullanılmış, bu yöntemlerin stres sınıflandırma başarımı karşılaştırmalı olarak sunulmuştur. LSTM mimarisi, zaman içindeki hareket desenlerini yakalayarak stresli durumların ayırt edilmesinde belirgin bir üstünlük göstermiştir. Bu yapı, özellikle sıralı ve çok boyutlu sensör verilerini analiz etmede sağladığı yüksek doğruluk oranları ile çalışmanın derin öğrenme temelli özgünlüğünü pekiştirmiştir.


Ayrıca, geliştirilen modelin düşük güçlü ESP32 tabanlı bir mikrodenetleyici ile entegre biçimde çalışabilmesi, gerçek zamanlı ve taşınabilir stres izleme sistemlerinin geliştirilmesi açısından önemli bir adım teşkil etmektedir. Bu sayede ilerleyen dönemlerde bireylerin masa başı çalışma ortamlarında, eğitim süreçlerinde ya da dijital oyun gibi etkileşimli görevler sırasında stres düzeylerinin nesnel biçimde izlenmesi mümkün hale gelebilir. Sonuç olarak, bu çalışma ayak hareketlerini stresin davranışsal bir biyobelirteci olarak ele alarak, literatürde sınırlı sayıda örneği bulunan bir yaklaşımı sistematik biçimde incelemektedir. 9 eksenli IMU sensörlerinden elde edilen çok boyutlu zaman serisi verilerinin, derin öğrenme mimarilerinden biri olan LSTM ile sınıflandırılması sayesinde stresli ve düşük stresli durumlar yüksek

doğrulukla ayırt edilebilmiştir. Bu yönüyle çalışma, davranışsal sinyallerin düşük müdahale ile izlenmesine olanak tanırken, aynı zamanda taşınabilir ve düşük maliyetli bir sistem önerisi sunarak gelecekteki uygulamalı araştırmalara altyapı oluşturabilecek niteliktedir. Alt ekstremitte hareketlerinin, bilişsel ve duygusal durumlarla ilişkili örüntüler taşıdığına dair güçlü kanıtlar sunan bu tez, stresin nesnel, sürdürülebilir ve müdahalesiz biçimde izlenmesine katkı sağlayabilecek yeni nesil teknolojilerin geliştirilmesi açısından önemli bir adım olarak değerlendirilmektedir.

3.YÖNTEM

Bu bölümde, ayak hareketlerinden elde edilen sensör verileriyle bireylerin stres düzeylerinin sınıflandırılmasına yönelik izlenen yöntemsel süreç ayrıntılı biçimde sunulmaktadır. Çalışmada kullanılan donanım ve yazılım mimarisi, veri toplama düzenekleri, etiketleme stratejileri ve veri işleme yaklaşımları sistematik bir şekilde açıklanmıştır. Tercih edilen stratejiler süreç içinde karşılaşılan zorluk ve tecrübelerle birlikte şekillenerek bahsedilecek nihai halini almıştır. Bu doğrultuda farklı yöntemler süreç boyunca denenmiş sonunda her adım için en uygun yöntem belirlenmiş ve bahsedilecek nihai halini almıştır. Süreç içinde değiştirilen yöntemlerin neden değiştirildiği ve bunun sonucunda nasıl farklılıklar gözlemlendiği de detaylı olarak ifade edilmiştir.

İlk olarak MPU9250 sensörü ve ESP32 mikrodenetleyici kartı kullanılarak geliştirilen gömülü sistem donanımı tanıtılmış; daha sonra bu sistemden elde edilen verilerin Wi-Fi tabanlı bağlantı yoluyla gerçek zamanlı olarak Python istemcisine aktarımı açıklanmıştır. Ardından, manuel olarak belirlenen stresli zaman dilimlerine göre verilerin nasıl etiketlendiği detaylandırılmıştır. Son olarak, sınıflandırma amacıyla kullanılan derin öğrenme tabanlı modelleme sürecine girdi oluşturacak verilerin işlenmesi ve hazırlanması süreci ele alınmıştır. Bu yöntem bilimsel yapı, araştırmanın tekrar üretilebilirliğini sağlamak ve çalışmanın bilimsel dayanaklarını açık biçimde ortaya koymak amacıyla adım adım planlanmış ve uygulanmıştır. Şekil 3.1’de bahsedilen akışın sistem mimarisine yer verilmiştir.




Şekil 3.1: Sistem mimarisi.

Stresin tespitinin yapılabilmesi için kullanıcıya bilişsel bir görev verilmesi hedeflenmiştir. Tetris oyununun veri toplama sürecinde tercih edilme sebebi, stresin tespitine yönelik bilişsel görevler arasında yapılan kapsamlı bir değerlendirme sonucunda belirlenmiştir. Stresin ölçülmesi için katılımcılara uygun ve etkili bir bilişsel görev verilmesi amacıyla çeşitli alternatifler, örneğin rubik küp çözme, kodlama ve matematik problemleri gibi seçenekler üzerinde durulmuştur. Ancak, bu alternatiflerin her biri, belirli kısıtlamalar ve zorluklarla birlikte gelmektedir. Örneğin, rubik küp gibi görsel ve fiziksel bir görev, her katılımcının aynı düzeyde performans sergilemesini zorlaştırabilirken; kodlama ve matematik problemleri, bazı katılımcılar için gereksinim duyulan bilgi ve becerileri aşabilir. Bu bağlamda, Tetris oyunu, hem daha geniş bir katılımcı kitlesine hitap etme potansiyeline sahip olması hem de oyunun

dinamik doğasının sağladığı avantajlar nedeniyle öne çıkmıştır. Tetris, her seviyede artan zorluk ve hız ile katılımcının bilişsel yükünü artırırken, aynı zamanda stres düzeyinin zaman içinde nasıl değiştiğini de etkili bir şekilde ölçmeyi mümkün kılar. Oyunun ilerlemesi ile birlikte, daha karmaşık şekiller ve artan hız, bireylerin anksiyete düzeylerini tetiklemesine yol açarak, stres tepkilerini gözlemlemek için uygun bir ortam sağlamaktadır. Bu nedenle, Tetris oyununu kullanarak veri toplamak, katılımcıların stres seviyelerindeki değişiklikleri anlamak ve bu durumu bilimsel bir çerçevede analiz etmek açısından doğru bir uygulama olarak değerlendirilmiştir.

Şekil 3.2’de, çalışmada izlenen yöntemin genel akış diyagramı sunulmaktadır. Süreç, katılımcıların Tetris oyunu oynarken ayağına takılı sensör düzeneği aracılığıyla veri toplanmasıyla başlamaktadır. MPU9250 sensörü, üç eksen de ivme, jiroskop ve manyetometre verilerini 50 Hz örnekleme frekansında ölçerken, ESP32 mikrodenetleyici bu verileri kablosuz olarak wifi üzerinden başka bir bilgisayarda bulunan istemciye iletmektedir. Bilgisayarda çalışan Python istemci uygulaması, gelen verileri sistemin zaman damgası ile birlikte .txt formatında bilgisayarın dahili hafızasına kaydetmektedir. Katılımcının oyunu esnasında gözlemci veri iletiminin sorunsuz olduğunu istemci uygulama üzerinden kontrol ederken aynı zamanda ekran kaydı da almaktadır. Deney sırasında gözlemsel olarak her kullanıcı için ayrı ayrı not alınan stresli zaman aralıkları, deney sonrasında etiketsiz veri dosyasındaki zaman bilgileriyle eşleştirilerek "high_stress" ve "low_stress" olarak etiketli veri dosyası olarak kaydedilmektedir. Zaman aralıkları belirlenirken python istemci uygulamasının çalıştığı bilgisayarı ekrana yazdırdığı zaman verisi referans olarak alınmıştır. Etiketlenmiş bu veri seti bir takım veri hazırlama işlemlerinden geçtikten sonra makine ve derin öğrenme algoritmalarının eğitilmesinde kullanılmak üzere analiz sürecine aktarılmaktadır. Farklı parametrelerle model eğitimleri yapılarak sonuçları karşılaştırılacaktır.




Şekil 3.2: Genel akış diyagramı.

3.1. Donanım Düzeneği

Katılımcıların oturur pozisyonda Tetris oyunu oynarken gerçekleştirdiği ayak hareketlerinden sensör verisi toplamak amacıyla bireyler için rahat, taşınabilir ve düşük maliyetli bir donanım düzeneği geliştirilmiştir. Sistem, üç temel bileşenden oluşmaktadır: MPU9250 sensörü, ESP32 mikrodenetleyici kartı ve şarj edilebilir pillerden oluşan bir güç kaynağı. Bu bileşenler hafif şeffaf bir kutu içerisinde sabitlenmiş ve bu sensör düzeneği deney süresince katılımcının bir ayağının üst kısmına yerleştirilmiştir. Akışı kısaca özetlersek, MPU9250 sensörü; üç eksenli ivmeölçer, jiroskop ve manyetometre birimlerini içeren dokuz eksenli bir atalet ölçüm birimi (IMU) olarak görev yapmaktadır. ESP32, bu sensör verilerini 50 Hz örnekleme frekansında okuyarak kablosuz bağlantı yoluyla istemciye aktarmaktadır. Donanım düzeneğinin güç kaynağı olarak ise 2 adet 18650 tipi 3.7 V, 2200 mAh kapasiteye


sahip Li-ion şarj edilebilir pil kullanılmıştır. Bu piller, sistemin deney boyunca harici enerjiye ihtiyaç duymadan çalışmasını sağlamış ve kullanıcı hareketini kısıtlamamıştır.

Şekil 3.3'te devre şeması verilmiştir. ESP32 ile MPU9250 sensörü arasındaki bağlantı, I2C haberleşme protokolü kullanılarak gerçekleştirilmiştir. Bu doğrultuda MPU9250 sensörünün SCL (saat sinyali) pini ESP32 kartının D22 pinine, SDA (veri hattı) pini ise D21 pinine bağlanmıştır. Sensörün beslemesi için VCC pini ESP32'nin 3.3V çıkışına, GND pini ise ortak topraklama için ESP32'nin GND pinine bağlanmıştır. ESP32 mikrodenetleyici kartına enerji, sistemde kullanılan şarjlı piller aracılığıyla sağlanmıştır. Güç kaynağı doğrudan ESP32'nin VIN ve GND pinlerine bağlanarak sistemin taşınabilir ve dış kaynaktan bağımsız şekilde çalışması sağlanmıştır. Tüm bağlantılar esnek jumper kablolar ile yapılmış, fiziksel oynamaları minimize etmek amacıyla kutu içinde sabitlenmiştir. Bu yapı sayesinde veri aktarım sürecinde temassızlık kaynaklı kesintiler önlenmiş ve sensörün güvenilir şekilde çalışması sağlanmıştır.



Şekil 3.3: Devre şeması.

Veri toplanırken kullanıcının stres altında düzeneğin bağılı bulunmadığı ayağını hareket ettirmeye, diğer ayağını ise sabit tutmaya daha meyilli olduğu gözlemlenmiştir. Önce diğer ayağının daha hareketli olabileceği düşünülmüş ama düzenek katılımcının hareketsiz tuttuğu ayaktan çıkarılıp hareket ettirmeye meyilli olduğu ayağa takılınca da sonucun değişmediği bu kez de diğer ayağını hareket ettirdiği gözlemlenmiştir. Daha sağlıklı veri toplanabilmesi amacıyla, sensörün takılı olduğu ayağın karşısındaki ayağa da özdeş bir kutunun içine benzer ağırlıkta boş bir düzenek yerleştirilmiştir. Böylece katılımcının yalnızca sensör takılı ayağını sabit tutması engellenmiş, her iki ayağın da doğal hareket etmesi teşvik edilmiştir. Geliştirilen bu yapı sayesinde, katılımcıların fiziksel kısıtlamaya maruz kalmadan, doğal oturma düzeni içerisinde sensör verisi elde edilmiştir.



Şekil 3.4: Veri toplama düzeneği.

Şekil 3.4'de, deney sırasında kullanılan donanım düzeneğinin fiziksel yerleşimi gösterilmektedir. Görselde, ESP32 kartı, MPU9250 sensörü ve iki adet 18650 Li-ion pilin şeffaf bir plastik kutu içerisine entegre edilmiş hali yer almaktadır. Düzeneğin mümkün olan en küçük ebatlarda oluşturulması amaçlandığı için ESP32 kartı ve kullanılan sensör, pil kutusunun üstüne çift taraflı bantla yapıştırılmıştır; bu sayede düzeneğin en ve boyunun pil yuvasını aşmaması sağlanmıştır. Tüm bileşenler sabitlenmiş ve iç kısmı sünger malzeme ile desteklenerek ayak hareketleri sırasında düzeneğin sabit kalınması sağlanmıştır. Kutunun dışında alt kısmına yapıştırılan yumuşak bir lastik kayış aracılığıyla düzeneğin katılımcının ayağına rahatça takılması sağlanmıştır. Bu kompakt yapı sayesinde, veri toplama sürecinde sensörün vücuda sabitlenmesi kolaylaştırılmış ve deneysel koşullarda kullanıcı konforu artırılmıştır. Düzeneğin boyutları yaklaşık olarak 12x8x10 cm olmakla birlikte, bu ölçüler, yaklaşık bir sigara paketi büyüklüğündedir. Bu sayede kullanıcının ayağını rahatça hareket ettirmesi sağlanmış ve bir süre sonra düzeneği takmamış gibi davranması hedeflenmiştir. Böylece, katılımcıların doğal motor hareketlerini kaydetmek daha kolay hale gelmiş ve elde edilen verilerin geçerliliği artırılmıştır.

3.1.1. ESP32 Mikrodenetleyici

ESP32, Espressif Systems tarafından tasarlanan ve geliştirilen, yüksek performanslı, düşük enerji tüketimine sahip bir mikrodenetleyicidir. Wi-Fi ve Bluetooth (Classic ve BLE) gibi kablosuz iletişim yetenekleri sunan bu entegre çözümler, ESP32'yi özellikle nesnelerin interneti (IoT) uygulamaları için son derece cazip kılmaktadır. Çok sayıda giriş/çıkış pini (GPIO), analog girişler, PWM (Pulse Width Modulation) desteği ve donanım hızlandırılmalı kriptografi özellikleri ile donatılmış olan ESP32 mikrodenetleyicisi, çift çekirdekli işlemci mimarisi ile 240 MHz'e kadar çalışma hızına ulaşabilir. Bu yüksek performans, karmaşık hesaplama işlemlerinin hızlı ve verimli bir şekilde gerçekleştirilmesine olanak tanır. Ayrıca, sistemin düşük güç tüketimi özellikleri, batarya ile çalışan uygulamalar için önemli bir avantaj sağlamaktadır. ESP32, 16 MHz ile 240 MHz arasında çalışan bir saat frekansına sahiptir ve bu performans seviyeleri, sensör verilerinin hızlı bir şekilde işlenmesi ve iletilmesi gibi kritik görevleri yerine getirmekte etkilidir. Mikrodenetleyicinin, 520 KB RAM ve 4 MB'a kadar harici flash bellek ile desteklenmesi, hem veri depolama alanı sağlamakta hem de uygulamaların performansını artırmaktadır. Donanım seviye destekleri, hız ve

güvenlik açısından önemli avantajlar sunmakta ve çok sayıda sensör ve aktüatörle kanalları mükemmel bir şekilde entegre etmeye olanak tanımaktadır. Tüm bu özellikleri, ESP32'yi hem akademik araştırmalar hem de ticari projeler için önemli bir platform haline getirmektedir.

3.1.2. MPU9250 Sensör

MPU9250, InvenSense tarafından üretilen ve üç akslı ivmeölçer, üç akslı jiroskop ve bir manyetometreyi tek bir entegre paket içerisinde sunan 9 eksenli bir sensördür. Bu sensör, temel olarak üç farklı sensörün birlikte çalışmasını sağlayarak, dinamik ve statik hareketleri izleme yeteneği ile dikkat çekmektedir. MPU9250'in sunduğu 9 eksenli veri aktarımı, kullanıcıların daha karmaşık hareketleri ve yönelimleri bir arada algılamalarına olanak tanımaktadır. MPU9250, ivmeölçer, jiroskop ve manyetometre verilerini aynı anda sağlayarak, 3D uzayda hareketin detaylı bir şekilde analiz edilmesini mümkün kılar. Üç eksenli ivmeölçer, bir nesnenin hızındaki değişimlere (ivmeye) olan tepkisini ölçerken, üç eksenli jiroskop, nesnenin açısal hızını belirler. Manyetometre, çevresel manyetik alanı algılayarak yön belirleme hizmeti sunar. Bu özellikleri, robotik, sanal gerçeklik, hareket algılama ve diğer birçok uygulamaya entegre edilmesine imkan tanır.

Sensör, I2C ve SPI gibi iletişim protokollerini desteklemekte olup, kolay bir entegrasyon süreci sunar. MPU9250'in çeşitli veri hızları ile çalışma yeteneği, kullanıcıların ihtiyaçlarına göre özelleştirme yapmalarına olanak sağlar. Genel olarak, bu sensör, saniyede 100 Hz'ye kadar örnekleme hızıyla çalışabilmektedir; bu da daha akıcı bir veri akışı ve daha yüksek çözünürlük imkanı sunar. MPU9250 sensörünün bir diğer önemli özelliği, yerleşik dijital hareket işlemcisi (DMP) ilavesidir. DMP, sensörden alınan verileri gerçek zamanlı olarak işlemek üzere programlanabilen bir algoritmayı içerir, bu da veri işleme yükünü azaltmakta ve sistemin genel verimliliğini artırmaktadır. Bu yapı sayesinde, sensör entegrasyonu ve yürütülen uygulamalar arasındaki etkileşim daha pürüzsüz hale gelir.

3.2. Veri Toplama

Bu çalışmada veri toplama süreci, 9 eksenli (akselerometre, jiroskop ve manyetometre) MPU9250 sensörü kullanılarak gerçekleştirilmiştir. Sensör, ESP32 mikrodenetleyici kartına entegre edilerek, hareket verileri 50 Hz örnekleme frekansında toplanmıştır. Toplanan veriler, gerçek zamanlı olarak ESP32 üzerinden kablosuz bağlantı ile bilgisayara aktarılmıştır.

Örnekleme frekansının 50 Hz olarak seçilmesinin temel nedeni, insan hareketlerinin dinamiklerini yeterince hassas ve detaylı bir şekilde yakalayabilmesiyle birlikte, veri hacminin işlem ve analiz süreçlerinde yönetilebilir kalmasını sağlamasıdır. Daha yüksek örnekleme frekansları, hareketin daha ince ayrıntılarını kaydetme imkânı verse de, gereksiz veri yükü oluşturabilir ve sistem kaynaklarını zorlayabilir. Öte yandan, 50 Hz, literatürde insan hareketlerinin izlenmesinde yaygın olarak tercih edilen ve hareket analizi için uygun olduğu kanıtlanmış bir frekanstır [29]. Bu sayede, veri toplama sırasında hem bilgi kaybı minimize edilmiş hem de veri işleme aşamalarında etkinlik ve verimlilik sağlanmıştır. Veri toplama sürecinin başlangıcında kullanıcıdan 5 Hz ve 10 Hz’le de veri toplanmış ancak daha sonra insan hareketlerinin dinamiklerini izlemek için yetersiz kalabileceği düşünülerek aynı kişilerden 50 Hz ile veri toplanmıştır.

Başlangıçta, her katılımcı için yaklaşık 10 dakikalık kayıtlar alınmıştır. Ancak, bu kısa süreli kayıtların gürültü (noise) içerebileceği ve stresli anların bu süreye denk gelmeyebileceği gözlemlenmiştir. Bu nedenle, veri toplama süresi 30 dakikaya çıkarılmış ve böylece stresli durumların yakalanma olasılığı artırılmıştır. Veri toplama aşamasında toplam 12 farklı katılımcı yer almış ve her bir katılımcı Tetris oyunu oynarken sensör verileri kaydedilmiştir. Katılımcılar farklı yaşlarda rastgele belirlenmiş, 5 kadın ve 7 erkekten oluşmaktadır. Kişisel verilerin korunması kanunu (KVKK) kapsamında kişisel verilerinin korunmasına özen gösterilmiş, toplanan veriler sadece isimlerinin baş harfi ve soyisimleri ile kaydedilmiştir. Sensör verileri dışında katılımcılardan başka veri alınmamıştır. Katılımcıların stres durumları, yüksek ve düşük olarak etiketlenmiştir. Etiketleme sürecinde katılımcılardan, stresli oldukları anları kendilerinin belirtmesi istenmiş; ayrıca her katılımcının oyun esnasında oynadığı ekranın kaydı alınmış ve dışarıdan gözlemler yapılmıştır. Daha sonra bu oyun kayıtları incelendiğinde, özellikle kısa kayıtlarda, örneğin 5-10 dakikalık sürede

katılımcının streslendiği bölümlerin tespit edilemediği gözlemlenmiştir. Bu durum, stres tepkilerinin daha uzun süreli oyun seanslarında daha belirgin hale geldiğini ortaya koymuştur. Dolayısıyla, yarım saati aşkın sürenin kayıt altına alınması, kullanıcıların zor seviyelere çıktığı anlarda meydana gelen stres durumlarının daha kapsamlı bir şekilde analiz edilmesine olanak tanımıştır. Oyun kayıtlarının uzun süreli alınması, stres tepkilerinin dinamiklerini anlamak ve bu anların niteliğini değerlendirmek açısından kritik bir öneme sahiptir. Bu bağlamda, kaydedilen uzun oyun seansları, katılımcıların oyun içerisindeki performans değişiklikleriyle birlikte stres durumlarını daha iyi anlamamıza yardımcı olmuştur. Katılımcıların stres bildirimlerini unuttuğu durumlarda, özellikle ayak hareketleri gözlemlenerek, gerekirse doğrudan katılımcıya sorular yöneltilerek stres durumları teyit edilmiştir. Bu sayede hem öznel hem de nesnel ölçütler kullanılarak daha güvenilir etiketleme sağlanmıştır.

Dış gözlemler sonucunda, katılımcıların stres tepkilerinin farklılık gösterdiği saptanmıştır. Bazı katılımcılar, oyunun zorlaşmaya başlamasıyla birlikte stres düzeylerinde belirgin bir artış yaşarken; diğerleri, düzeneklerinin ayaklarına takılması gibi fiziksel etkenlerden dolayı oyuna başlar başlamaz stresli hale gelmiştir. Bu bulgular, stresin nesnellliğini ve bireyler üzerindeki etkilerini vurgulamaktadır. Katılımcıların farklı oyun deneyimlerine sahip olmaları da bu durum üzerinde belirleyici bir rol oynamış olabilir. Örneğin, daha önce yoğun ve zorlayıcı oyun tecrübeleri yaşamış olan bireylerin, stresli anlarla daha fazla başa çıkma yeteneği geliştirirken; daha az deneyime sahip olanlar, stres anlarına daha hassas tepkiler verebilmektedirler. Bu nedenle, stresin nasıl algılandığı ve yönetildiği, kişisel geçmişe, oyun deneyimine ve anlık koşullara bağlı olarak değişiklik göstermektedir. Bu açıdan, oyun kayıtları ve gözlemler, katılımcıların stres yönetimi üzerine daha derinlemesine bilgi edinmemizi sağlayarak, stresin nesnel ölçütler ile değerlendirilmesine katkıda bulunmaktadır.

Talep eden katılımcılara Tetris oyununun kuralları detaylı bir şekilde açıklanmış ve deneme amaçlı bir oyun oynamaları teşvik edilmiştir. Ancak, çoğu katılımcı bu deneme sürecine katılma gereği duymadıklarını ifade etmişlerdir. Deneme oyunu esnasında yalnızca kuralların kavranması amaçlanmış olup, bu aşamada katılımcıların performanslarına dair verilerin toplanmaması sağlanmıştır. Böylece, oyun deneyimi ile ilgili olası ön yargıların ve alışkanlıkların etkisinin minimize edilmesi

hedeflenmiştir. Bu durum, veri toplama aşamasında katılımcıların doğal ve daha objektif tepki verme şekillerini korumaya yönelik bir önlem olarak değerlendirilmiştir.

Buna ek olarak, deney sürecinde oyun sırasında psikolojik testlerin de uygulanması planlanmıştır. Ancak, bu testlerin uygulanması sırasında kullanıcıların oyunu durdurmak zorunda kalmaları, soruları yanıtlama sürecinde dikkatlerinin dağılması ve akışın kesintiye uğraması nedeniyle, katılımcıların ayak hareketlerinde düzensizliklere yol açmış ve veri kalitesinde belirgin bozulmalar gözlemlenmiştir. Yine kullanıcının testi tamamlayıp yeniden oyuna başlaması oyun sırasında da beklenmedik hatalar yapmasına yol açmıştır. Kullanıcıların oyun deneyimi ile anksiyete veya stres düzeylerini ölçmeyi amaçlayan bu testlerin, gerçek zamanlı veri toplama ile entegrasyonda sağlıklı bir denge sağlamakta yetersiz kalması, uygulamanın verimliliğini olumsuz etkilemiştir.

Ayrıca, bu psikolojik testlerin uygulanabilmesi için yetkililerle yapılan görüşmelerde, her kullanıcı için belirli bir ücret talep edildiği mail yoluyla öğrenilmiştir. Bu durum, hem bütçe kısıtlamaları hem de araştırma sürecinin karmaşıklığı göz önünde bulundurularak, uygulamadan vazgeçilmesine sebep olmuştur. Bu bağlamda, projenin sürdürülebilirliği açısından daha pratik ve hızlı yöntemler arayışına girilmiştir. Veri toplama süreci, katılımcıların dikkatini dağıtabilecek dış etkenlerin etkilerini minimize etmek amacıyla, sessiz ve kontrollü bir ortamda gerçekleştirilmiştir. Bu süreçte, deneyin koşullarının kontrol altında tutulması, veri kalitesinin artırılmasına katkı sağlamıştır. Deney sırasında farklı frekanslarda ve çeşitli uzunluklarda veriler toplanmış, bu verilerin analizinde stresin ölçülmesi amacıyla çeşitli yöntemler denenmiştir. Bu süreç, farklı yöntemlerin ve frekansların etkinliğini değerlendirmek için kapsamlı bir araştırma süreci gerektirmiştir. Çeşitli örnekleme frekansları, katılımcıların ayak hareketlerinde meydana gelen değişikliklerin ve stres tepkilerinin izlenmesi açısından önemli bir rol oynamaktadır, çünkü stres altında ortaya çıkan motor davranışların dinamikleri, bireylerin psikolojik durumlarıyla doğrudan ilişkilidir.

Tüm bu uzun çalışmaların sonucunda, en uygun yol olarak değerlendirilen yöntem detaylı bir analiz sonucunda belirlenmiş ve araştırma sürecinde bu yöntem doğrultusunda karar verilmiştir. Seçilen yöntem, veri toplama süreçlerinde elde edilen bulguların güvenilirliğini artırmaya yönelik bir yaklaşım olarak öne çıkmıştır.

Ayrıca, literatürdeki mevcut çalışmalara dayanarak, farklı bir deneysel yaklaşım benimsemenin ve alternatif yöntemler denemenin gerektiği sonucuna varılmıştır. Örneğin, alternatif bir çalışmada, katılımcıların psikolojik durumlarının daha derinlemesine incelenmesi amacıyla farklı sensör teknolojileri veya davranışsal analiz yöntemleri farklı sürelerde ve veri toplama frekanslarında uygulanabilir. Bu sayede, bireylerin duygusal tepkilerini farklı bir biçimde değerlendirme olanağı sağlanabilir. Böyle bir çalışma, stres ölçümünde yeni bakış açıları ve yöntemlerin keşfine kapı açabilir, aynı zamanda katılımcılar üzerindeki etkilerini daha ayrıntılı inceleme fırsatı sunabilir. Bu nedenle, gelecekte yapılacak olan araştırmalarda farklı veri toplama stratejilerinin ve analiz yöntemlerinin uygulanmasının, stres davranışlarını daha iyi anlama konusunda farklı katkılar sağlayabileceği düşünülmektedir.

3.2.1. Gömülü Sistem Yazılımı

Donanım düzeneğinin işlevselliğini sağlayan gömülü sistem yazılımı, Arduino IDE kullanılarak ESP32 mikrodenetleyici kartı üzerinde geliştirilmiştir. Yazılım, hem sensör verilerinin okunması hem de bu verilerin kablosuz olarak istemci cihaza aktarılması süreçlerini yönetmektedir. Sistem, ESP32'nin Wi-Fi erişim noktası (Access Point) ve WebSocket sunucusu olarak yapılandırılmasıyla çalışmaktadır. Bu yapı sayesinde, harici bir ağa ihtiyaç duyulmadan veri iletimi doğrudan cihazlar arasında gerçekleştirilebilmektedir. ESP32 kartı, kendiliğinden Wi-Fi ve Bluetooth özellikleri ile donatılmış bir mikrodenetleyici olarak öne çıkmaktadır. Bu özellikler, kartın esnekliğini ve çok yönlülüğünü artırmakta, kullanıcılara çeşitli uygulama senaryolarında avantaj sağlamaktadır. Ancak, bu çalışmada yüksek frekanslı veri iletimi ve boyut açısından avantaj sunan Wi-Fi özelliği tercih edilmiştir. Wi-Fi, geniş veri bant genişliği sunarak, sensörlerden alınan yüksek hacimli veri setlerini etkili bir şekilde iletmek için uygun bir platform oluşturur. Ayrıca, Wi-Fi bağlantısı, Bluetooth'a kıyasla daha fazla veri transferi kapasitesine sahip olması nedeniyle, hızlı ve güvenilir iletişim sağlama açısından avantaj sunar.

Başlangıçta, toplanan sensör verilerinin kart üzerinde kaydedilip, daha sonra harici bir depolama birimine aktarılması da denenmiştir. Ancak özellikle uzun süreli kayıtlar sırasında, ESP32'nin belleğinin dolması nedeniyle bu yöntem sürdürülebilir olmaktan

uzak kalmıştır. Kartın sınırlı bellek kapasitesi, geniş veri setlerini depolamakta zorluk çıkarmış ve dolayısıyla veri kaybı riski ortaya çıkmıştır.

Bu nedenle, en uygun çözüm olarak ESP32'nin bir erişim noktası (Access Point) olarak yapılandırılması ve verilerin anlık olarak istemci uygulamasına iletilmesi kararlaştırılmıştır. Bu yapı, veri transferini ekonomik ve etkin bir şekilde gerçekleştirmeye olanak tanımakta, aynı zamanda sistemin bellek üzerindeki yükünü azaltmaktadır. Dolayısıyla, anlık veri iletimi sayesinde, kullanıcılar toplanan verilere kesintisiz bir şekilde erişim sağlar ve izleme süreçlerini daha verimli bir şekilde gerçekleştirebilir. Bu durum, genel deneyimin kalitesini artırmanın yanı sıra, araştırmanın gereksinimlerine de en iyi şekilde cevap vermektedir.

Kodda öncelikle MPU9250 sensörü, I2C protokolü üzerinden başlatılmakta ve saniyede 50 örnek alınacak şekilde yapılandırılmaktadır. Bu örnekleme frekansı, ConfigSrd(19) fonksiyonu ile ayarlanmıştır ($1000 \text{ Hz} / (\text{SRD} + 1) = 50 \text{ Hz}$). Örneğin burada 50 Hz olmasını istediğimiz için SRD parametresini 19 olarak ayarladık. Deneme amaçlı 5 Hz ile veri toplarken de SRD parametresi 199 olarak ayarlanmıştı ($1000 \text{ Hz} / (199 + 1) = 5 \text{ Hz}$). Okunan sensör verileri şunlardır:

- 3 eksenli ivme verileri (m/s^2),
- 3 eksenli jiroskop verileri (rad/s),
- 3 eksenli manyetometre verileri (μT),
- Dahili sıcaklık verisi ($^{\circ}\text{C}$).

ESP32, bu verileri her ölçüm döngüsünde birleştirerek CSV formatında tek bir metin satırı halinde hazırlar ve WebSocket protokolü ile bağlı tüm istemcilere yayınlar. Veri formatı şu şekildedir:

$$\begin{aligned} & \text{accel}_x, \text{accel}_y, \text{accel}_z, \text{gyro}_x, \text{gyro}_y, \\ & \text{gyro}_z, \text{mag}_x, \text{mag}_y, \text{mag}_z, \text{temp} \end{aligned} \quad (3.1)$$

Veri gönderimi sırasında ESP32, bağlı istemcileri algılayarak bağlantı durumlarını da takip etmektedir. WebSocket istemcisi bağlantı kurduğunda seri port üzerinden bilgilendirme mesajı verilirken, bağlantı kesildiğinde uygun hata mesajı

döndürülmektedir. Bu süreç, istemci ile sunucu arasındaki etkileşimi optimize ederek veri iletişiminin kesintisiz ve güvenilir bir şekilde sürdürülmesini sağlamaktadır.

3.2.2. İstemci Uygulama ve Veri Kaydı

ESP32 cihazı üzerinde çalışan gömülü sistem tarafından yayınlanan sensör verilerinin alınması ve kaydedilmesi amacıyla, istemci tarafında Python programlama dili kullanılarak bir uygulama geliştirilmiştir. Bu uygulama, ESP32 tarafından oluşturulan Wi-Fi ağına bağlanarak WebSocket protokolü üzerinden veri akışını gerçek zamanlı olarak dinlemektedir.

İstemci uygulama, bağlantı kurulduktan sonra ESP32'den gelen her bir veri satırını zaman damgası ile birlikte alır ve düz metin formatında bir dosyaya kaydeder. Veri dosyaları, ölçümün başlatıldığı zaman bilgisine göre adlandırılmakta ve her oturumun verileri ayrı dosyalarda tutulmaktadır. Bu yapı, farklı kullanıcıların ve oturumların verilerinin karışmadan organize edilmesini sağlamaktadır. Uygulamanın temel görevlerini sıralarsak öncelikle ESP32'yle bağlantı sağlamaktır. Bağlantı başarılı olmazsa uyarı mesajı verilecektir. Bağlantı başarıyla kurulduktan sonra sensör verilerini web socket üzerinden almaktadır. Bu noktada verinin alınmasında en hızlı yolun bu olduğu denenerek anlaşıldığı için web sunucuya wifi üzerinden bağlanmak tercih edilmiştir. Daha sonra alınan her veri satırının başına sistem zamanı eklenir. İstemci uygulama bu adımları yaptıktan sonra veri toplama zamanı tamamlanınca verileri kullanıcının isminin baş harfi ve soyismiyle oluşturulan .txt uzantılı dosyaya kaydeder.

Veri dosyalarında her satır şu bilgileri içermektedir: zaman damgası (saat:dakika:saniye), üç eksenli ivme, jiroskop ve manyetometre ölçümleri ile sensör sıcaklığı. Zaman damgası istemci uygulamanın çalıştığı bilgisayarın sistem zamanından alınmıştır. Etiketleme de bu zamanı dikkate alınarak yapıldığı için senkronizasyon probleminin olmadığı varsayılmaktadır. Bu yapı, daha sonra yapılacak etiketleme ve analiz işlemleri için bütünsel ve zamanla hizalanmış bir veri kümesi oluşturulmasını sağlamaktadır. Python istemcisi asenkron olarak çalışmakta ve yüksek frekanslı veri akışını sorunsuz bir şekilde karşılayabilecek performanstadır. Ayrıca hata kontrol mekanizmalarıyla desteklenmiş olup bağlantı kopması veya dosya yazımı sırasında oluşabilecek sorunlara karşı dayanıklıdır. Bunun sağlanmasını yapmak için

çeşitli sürelerde kayıtlar alınmış ve örnek sayısının geçen süre çarpı toplama frekansı (50 Hz) kadar olduğu teyit edilmiştir.



Şekil 3.5: Veri toplama anı.

Şekil 3.5'te, çalışmada kullanılan deneysel düzenek ile veri toplama sürecine ait örnek bir uygulama sahnesi yer almaktadır. Katılımcı, masa başında oturur pozisyonda bir tablet aracılığıyla Tetris oyunu oynamakta olup, ayak bileklerine sabitlenmiş sensör düzenekleri yer almaktadır. Bu katılımcı özelinde sol ayakta ESP32 mikrodenetleyiciye bağlı olan MPU9250 sensörü ve güç kaynağından oluşan aktif sistem yer almakta, sağ ayakta ise simetrik biçimde yerleştirilmiş pasif bir düzenek bulunmaktadır. Bu yapı, hareket dengesini sağlamak ve sensör takılı ayağın doğal

hareketini engellemek amacıyla uygulanmıştır. Tüm veriler, oyun süresince ESP32 üzerinden kablosuz olarak istemci cihaza aktarılmış ve zaman damgalı şekilde kaydedilmiştir. Bu düzenleme, çalışmanın doğrudan kullanıcı etkileşimiyle gerçekleştirilen, müdahalesiz ve gerçek zamanlı veri toplama yaklaşımını yansıtmaktadır. Veri toplanılırken örneğin otuzbeş dakika gibi sabit bir süre belirlenmemiştir. Katılımcıların oyun oynama hızları farklı olduklarından dolayı yarım saati aşkın kayıtlar alınması hedeflenmiştir. Bu süre zarfında farklı sayıda oyunu tamamlayan katılımcılar yarım saati aştıktan sonra bitirdikleri ilk oyunda kayıt tamamlanmış ve oyunun ekran kaydıyla toplanan veriler kayıt altına alınmıştır. Bu kayıtlar sırasında toplam örnek sayısı beklenenden azsa yani sensör veya istemci tarafında bir sorundan dolayı beklenildiği gibi kayıt gerçekleşmediyse veya ekran kaydı alınırken bir sorun meydana geldiyse çalışma tekrarlanmış katılımcıdan tekrar oyunu oynaması istenmiştir. Aşağıdaki tabloda hangi katılımcının kaç defa ve ne kadar süre stresli olarak etiketlendiği gösterilmiştir.

Tablo 3.1: Katılımcıların Stresli Aralıkları.

Katılımcı	Stresli Anların Uzunlukları	Kaç Kez Stresli Olarak Kaydedildi	Toplam Stresli Olarak Kaydedilme Süresi
1.	3 dk 25 sn, 1 dk 20 sn, 1 dk 57 sn	3	6 dk 42 sn
2.	43 sn, 1 dk 17 sn, 2 dk 32 sn, 1 dk 13 sn, 2 dk 16 sn	5	8 dk 1 sn
3.	1 dk 49 sn, 2 dk 47 sn, 1 dk 51 sn	3	6 dk 27 sn
4.	3 dk 20 sn, 1 dk 24 sn, 3 dk 21 sn, 1 dk 22 sn	4	9 dk 27 sn
5.	3 dk 9 sn, 1 dk 15 sn, 1 dk 25 sn, 4 dk 36 sn, 16 sn	5	10 dk 41 sn
6.	7 dk 58 sn, 3 dk 59 sn, 2 dk 20 sn, 1 dk 58 sn	4	16 dk 15 sn

Tablo 3.1: Devamı.

7.	4 dk 57 sn, 6 dk 31 sn, 3 dk 7 sn	3	14 dk 35 sn
8.	6 dk 27 sn, 7 dk 26 sn, 1 dk 38 sn, 4 dk 25 sn	4	19 dk 56 sn
9.	3 dk 2 sn, 12 dk 23 sn, 1 dk 14 sn, 1 dk 10 sn	4	17 dk 49 sn
10.	4 dk 40 sn, 3 dk 3 sn, 1 dk 14 sn, 4 dk 10 sn	4	13 dk 7 sn
11.	4 dk 27 sn, 1 dk 51 sn, 7 dk 48 sn	3	14 dk 6 sn
12.	2 dk 20 sn, 4 dk 25 sn, 2 dk 54 sn	3	9 dk 39 sn

Tablodan görüleceği gibi katılımcılar farklı zaman uzunluklarında ve farklı sayılarda stresli olarak etiketlenmiştir. Bazılarının oyun başında stresli olduğu anlar daha uzunken bazılarınınsa oyun sonunda zorluğun artmasıyla beraber stresli olduğu anların süresi uzamıştır. Oyun sonunda zorlukla başa edemeyip ekranı dolan ve oyunu biten kullanıcıların da son stresli olduğu zaman aralıkları kısa kalmıştır.

3.3. Veri Etiketleme

Veri toplama sürecinin tamamlanmasının ardından elde edilen sensör verileri, ilk aşamada herhangi bir sınıf etiketi içermeksizin, ham biçimde kaydedilmiştir. Bu doğrudan mikrodenetleyici üzerinden aktarılan dokuz eksenli sensör bilgilerini ve sıcaklık bilgisini içermektedir. Ancak bu çalışma kapsamında uygulanan stres düzeyi sınıflandırması için denetimli öğrenme algoritmaları kullanılacağından, her bir verinin ait olduğu stres düzeyine göre doğru şekilde etiketlenmesi gerekmektedir. Etiketleme işlemi, sınıflandırma algoritmalarının başarımını doğrudan etkileyen kritik bir adımdır ve bu nedenle sürecin özenle planlanması ve yürütülmesi önem arz etmektedir. Çeşitli etiketleme yöntemleri değerlendirilmiş ve aşağıda belirtilen yöntemin en efektif olduğuna karar verilmiştir.

3.3.1. Gözleme Dayalı Zaman Aralıklarının Belirlenmesi

Etiketleme sürecinde temel yaklaşım, deney sırasında katılımcıların davranışsal tepkilerinin doğrudan gözlemlenmesine dayanmaktadır. Katılımcılar belirli bir oyun oynarken gözlemlenmiş ve özellikle performans düşüşleri, yüz ifadelerinde stres belirtileri (örneğin kaş çatma, sık mimik kullanımı), ayak hareketlerindeki ani değişimler ve dikkat dağınıklığı gibi göstergeler dikkate alınarak stresli zaman aralıkları manuel olarak belirlenmiştir. Araştırmacı, her bir katılımcı için bu stresli dönemleri deney esnasında not etmiş ve etiketleme sürecinde referans olarak kullanmıştır. Psikolojik durumların, özellikle anlık stres gibi kısa süreli duygusal değişimlerin zaman çizelgesine oturtularak kesin sınırlarla tanımlanması doğası gereği zordur. Bir bireyin stresli olmaya tam olarak ne zaman başladığını ya da bu durumun ne zaman sona erdiğini belirlemek çoğu zaman subjektif bir değerlendirme gerektirir [30]. Bu nedenle çalışmada kullanılan stresli zaman aralıkları, katılımcıların bireysel deneyimlerine ve davranışsal tepkilerine göre, gözleme dayalı olarak tanımlanmıştır. Etiketleme sürecinin güvenilirliği, gözlemlerin doğruluğu ve zaman damgalarının hassas biçimde senkronize edilmesiyle doğrudan ilişkilidir.

Katılımcı stresli olduğu aralıkları belirtebilir, belirtmemesi durumunda gözlemci oyun esnasında katılımcının stresli olduğunu görmesi durumunda ona sorarak teyit isteyebilir. Bu noktada katılımcıya kabul gören psikolojik testlerin uygulanarak stres durumunun etiketlenmesi fikri de denenmiş ancak katılımcının oyunu durdurup buna odaklanmasının anlık davranışını değiştirdiğini ve sonra kaldığı yerden devam etmede zorlandığı görülerek bu fikirden vazgeçilmiştir. Yine bu testlerin uygulanması için telif sahiplerinden kullanma izni mail aracılığıyla talep edilmiş ancak her katılımcı başına istenen bedelden dolayı yüksek maliyet nedeniyle de vazgeçilmiştir.

3.3.2. Etiketleme Sürecinin Uygulanması

Etiketleme işlemi, geliştirilen bir yazılım betiği yardımıyla otomatikleştirilmiştir. Bu betik, her katılımcıya ait zaman serisi verilerini satır satır analiz ederek, her bir örneğe karşılık gelen zaman damgasını daha önceden belirlenen stresli zaman aralıklarıyla karşılaştırmakta ve bu doğrultuda her örneğe uygun etiketi atamaktadır. Bu süreçte

tüm veriler varsayılan olarak "düşük stres" sınıfına atanmakta; yalnızca stresli zaman aralıkları içinde kalan veriler “yüksek stres” sınıfı ile yeniden etiketlenmektedir.

Etiketleme betiği her bir örneğe karşılık gelen etiketi veri dosyasına yeni bir sütun olarak eklemekte ve böylece veri seti, doğrudan sınıflandırma modellerinde kullanılabilecek biçimde yapılandırılmaktadır. Katılımcıya özel stresli zaman aralıkları betik içerisinde kullanıcı adına göre ayrı ayrı tanımlanmıştır ve bu yapı sayesinde toplamda 12 farklı katılımcıya ait veri başarıyla etiketlenmiştir. Etiketleme işlemi, zaman damgalarının saniye düzeyinde doğruluğu sayesinde yüksek hassasiyetle gerçekleştirilmiştir.

3.3.3. Güvenilirlik ve Sınıflandırma Başarısına Etkisi

Etiketleme sürecinde elde edilen verilerin doğruluğu, sınıflandırma modellerinin performansını doğrudan etkileyen bir faktördür. Özellikle stresli zaman aralıklarının doğru belirlenmesi, modelin yüksek doğrulukla öğrenmesini sağlamaktadır. Bu nedenle, etiketleme işlemi sonrasında rastgele örnekler seçilerek görsel olarak incelenmiş, stresli etiketlerin davranışsal verilere uyumu kontrol edilmiştir. Gerekirse gözlem notları, ekran kaydı ve zaman eşleşmeleri tekrar gözden geçirilmiştir. Bu dikkatli yaklaşım sayesinde, oluşturulan veri setinin model eğitimi sürecine yüksek doğruluk ve güvenilirlikte katkı sağlaması hedeflenmiştir. Bu noktada başlangıçta düşük frekansta (5 Hz) beş dakikalık kısa süreli kayıtlar alınmış manuel etiketleme denenmiştir. Ardından bu manuel etiketleme sonucu oluşan örneklerin plotları incelendiğinde stresli olarak belirtilen aralıklara karşılık gelen süre aralıklarıyla manuel olarak etiketlenmiş stres aralıklarının birbirleriyle örtüştüğü görülmüştür. Bu güvenilirlikten sonra daha yüksek frekanslı ve daha uzun süreli kayıtlarda da bu yöntemin uygulanabilirliğinin önü açılmıştır.

3.4. Veri Hazırlama ve Ön İşleme

Deney süresince, her katılımcının Tetris oyununu oynadığı zaman diliminde, sensör saniyede 50 örnekleme frekansı ile veri toplamıştır. Her bir zaman noktasında ivmeölçer (accelerometer), jiroskop (gyroscope), manyetometre (magnetometer) ve sıcaklık sensörlerinden alınan ölçümler ile toplam 10 öznitelik (feature) elde edilmiştir. Bu öznitelikler, veri analizi ve model eğitimi süreçlerinde temel bilgi

kaynağı olarak kullanılmıştır. Veriler, her bir katılımcı için ayrı dosyalarda, zaman damgası (timestamp) bilgisi ile birlikte .txt formatında saklanmış, böylece zaman serisi yapısı korunmuştur. Bu aşamadan sonra, makine öğrenmesi ve derin öğrenme algoritmalarının uygulanabilirliği açısından, verilerin çeşitli ön işleme adımlarından geçirilmesi gerekmiştir. Bu adımlar sırasıyla kalite kontrolü, pencereleme, ölçekleme (normalizasyon), sınıf dengesizliğiyle başa çıkma ve eğitim/test veri ayırımıdır.

3.4.1. Ham Verilerin Kalite Kontrolü

Ham verilerin güvenilirliği, veri madenciliği ve model eğitimi süreçlerinde en kritik faktörlerden biridir. Bu sebeple veriler üzerinde kapsamlı bir kalite kontrol süreci gerçekleştirilmiştir. Bluetooth üzerinden veri aktarımı gerçekleştirilirken ya da mikrodenetleyici kartın kendi üzerinde verilerin kaydedilmesi denenirken yüksek miktarda veri kaybının olduğu gözlemlendiğinden dolayı wifi üzerinden kayıt için de ayrı bir istemci kullanılması denenmiştir. Öncelikle eksik veri (missing value) analizi yapılmış ve hiçbir kayıta boş alan veya eksik sensör çıktısı bulunmadığı tespit edilmiştir. Bunun temel nedeni, verinin gömülü sistem tarafında sürekli ve eş zamanlı olarak kaydedilmesi, herhangi bir paket kaybının ya da iletim hatasının oluşmaması için sistemin tamponlama (buffering) ve zamanlamaya dayalı (timed loop) bir yapı üzerine kurulmuş olmasıdır.

Ayrıca fiziksel olarak mümkün olmayan (örneğin $\pm 16g$ 'yi aşan ivme değerleri veya manyetometre değerlerinde sıçrama) ölçümlerin varlığı da incelenmiş ve bu tür anormal örneklerin yer almadığı saptanmıştır. Bunun nedeni, hem sensör konumlandırmasının sabit olması hem de katılımcıların ayak hareketlerinin deney ortamında belirli sınırlar içinde gerçekleşmiş olmasıdır. Zaman damgaları arasında örnekleme frekansına aykırı bir boşluk veya çakışma da görülmemiştir. Bu sonuçlar, sistemin güvenilir şekilde veri topladığına ve verilerin modelleme için doğrudan kullanılabilir olduğuna işaret etmektedir.

3.4.2. Pencereleme ve Etiketleme Stratejisi

Zaman serisi verilerin analizinde, ham verinin belirli uzunluktaki parçalara ayrılması yaygın bir uygulamadır. Bu amaçla, elde edilen sensör verileri sabit uzunluktaki pencerelere bölünmüştür. Her pencere, 2 saniyelik süreye karşılık gelen 100 örnek

içermekte olup, zaman içinde kaydırmalı (sliding window) bir yapı ile elde edilmiştir. Pencere kaydırma miktarı, pencerelerin hem üst üste binmesini (overlap) sağlayacak hem de zaman çözünürlüğünü koruyacak şekilde %50 olarak belirlenmiştir (yani 100 örneklilik pencere 50 örnek kaydırılmaktadır).

Her pencerenin stres etiketi, içinde barındırdığı 100 örneğin çoğunluk sınıfına göre atanmıştır. Örneğin bir pencere içinde 100 satırdan 65'i "low_stress", 35'i "high_stress" etiketi taşıyorsa bu pencerenin etiketi "low_stress" olarak belirlenmiştir. Bu strateji, veri setinin pencereler bazında tutarlılığını sağlamakta ve etiket gürültüsünü azaltmaktadır. Ayrıca bu yöntem, LSTM gibi zaman bağımlı öğrenme algoritmaları için oldukça uygundur; çünkü her pencere zamansal ardışıklığı koruyarak bir dizi halindedir. Farklı pencere uzunlukları (örneğin 1, 2, 3 ve 5 saniye) ile yapılan deneyler sonucunda, 2 saniyelik pencereleme model performansı açısından en verimli sonuçları vermiştir. Daha kısa pencerelerde modelin stres geçişlerini yakalayamadığı, daha uzun pencerelerde ise farklı sınıf örneklerinin karıştığı ve etiketleme hataları olduğu gözlemlenmiştir.

3.4.3. Normalizasyon (Z-Score Standardizasyonu)

Farklı ölçeklerdeki öznitelikler, modelin ağırlık güncellemelerinde orantısız bir etki yaratabilir. Özellikle gradyan temelli öğrenme algoritmalarında bu durum, öğrenme sürecinin dengesizleşmesine ve modelin konverjansının yavaşlamasına neden olabilir. Bu sebeple, tüm özniteliklere z-normalizasyon işlemi uygulanmıştır. Bu yöntemde her öznitelik için aritmetik ortalama sıfır, standart sapma ise bir olacak şekilde dönüşüm yapılmıştır. Formül aşağıdaki gibidir:

$$X_{\text{norm}} = \frac{x - \mu}{\sigma} \quad (3.2)$$

Burada x ham veri, μ öznitelik ortalaması, σ ise öznitelik standart sapmasıdır. Bu dönüşüm, farklı fiziksel büyüklüklerdeki sensör değerlerinin eşit düzlemde işlenmesine olanak tanımıştır. Normalizasyon işlemi yalnızca eğitim verileri üzerinde uygulanmış, test verileri ise aynı parametrelerle dönüştürülerek veri sızıntısı (data leakage) önlenmiştir.

3.4.4. Sınıf Dengesizliği ve SMOTE Uygulaması

Toplanan verilerin etiketlenmesi sonucunda, stresli durumları temsil eden örneklerin sayıca oldukça düşük olduğu belirlenmiştir. Bu sınıf dengesizliği, modellerin çoğunluk sınıfı öğrenme eğilimi göstermesine ve azınlık sınıfa karşı duyarsızlaşmasına neden olmaktadır. Bu durumu gidermek için veri artırma (data augmentation) yöntemlerinden biri olan SMOTE (Synthetic Minority Over-sampling Technique) uygulanmıştır. SMOTE algoritması, azınlık sınıfındaki örneklerin komşuları arasındaki benzerliklere dayanarak sentetik yeni örnekler üretmektedir. Bu işlem, mevcut azınlık örneklerini doğrudan kopyalamak yerine, yeni örnekler üreterek veri集中的 çeşitliliği artırır. Böylece model, azınlık sınıfın dağılımını daha iyi öğrenebilir hale gelir.

Uygulamada yalnızca eğitim verisi SMOTE ile zenginleştirilmiş, test verilerine hiçbir müdahalede bulunulmamıştır. Böylece test sürecinde yalnızca gerçek, sentetik olmayan veriler kullanılmış ve modelin gerçek dünya verileri üzerindeki genellenebilirliği sağlıklı şekilde ölçülebilmektedir. SMOTE uygulanmadan önce yapılan denemelerde, yüksek stres sınıfının doğruluk, duyarlılık ve F1 skorlarında ciddi düşüşler gözlemlenirken, SMOTE sonrasında bu metriklerde belirgin iyileşmeler sağlanmıştır.

3.4.5. Katılımcı Bazlı Eğitim-Test Ayrımı

Modelin bireyler arası genellenebilirliğini test edebilmek amacıyla, veri seti bireysel bazda ayrılmıştır. Bu yöntemde bazı katılımcıların verileri yalnızca eğitim setine, geri kalan katılımcıların verileri ise yalnızca test setine dâhil edilmiştir. Böylece model, test aşamasında daha önce hiç görmediği bireylere ait veriler üzerinde sınanmıştır.

Bu strateji, klasik eğitim/test ayırım yöntemlerinden farklıdır ve özellikle biyobelirteç temelli çalışmalar için daha gerçekçi bir değerlendirme imkânı sunar. Çünkü bireyler arası fizyolojik ve davranışsal farklılıklar yüksek olduğundan, modelin bu farklılıklara karşı ne kadar genelleme yapabildiği ancak bu şekilde test edilebilir. Eğitim ve test setleri arasında herhangi bir veri sızıntısına mahal verilmemesi için ayırım dikkatli yapılmış, birey bazlı ayırımın yanı sıra zaman bazlı kesişimlerin de önüne geçilmiştir.

3.5. Sınıflandırma Yöntemleri ve Model Eğitimi

Bu çalışmada, bireylerin ayak hareketlerinden elde edilen sensör verileri kullanılarak stres düzeylerinin sınıflandırılması amacıyla çeşitli öğrenme algoritmaları uygulanmıştır. Kullanılan modeller, hem geleneksel makine öğrenmesi yöntemlerini hem de zaman serisi verilerle etkin şekilde çalışabilen derin öğrenme mimarilerini kapsamaktadır. Bu bağlamda, Destek Vektör Makineleri (SVM), Uzun Kısa Süreli Bellek (LSTM) ağırları ve LSTM tabanlı Otomatik Kodlayıcı (Autoencoder) yapıları değerlendirilmiştir.

Modeller, önceden etiketlenmiş ve ön işleme adımlarından geçirilmiş veri setleri üzerinde eğitilmiş ve test edilmiştir. Eğitim ve test veri setleri katılımcı bazlı ayrılarak, modelin bireyler arası genellenebilirliği değerlendirilmeye çalışılmıştır. Eğitim verilerinde gözlenen sınıf dengesizliğini gidermek amacıyla yalnızca eğitim verisine SMOTE (Synthetic Minority Oversampling Technique) yöntemi uygulanmıştır. Veriler, sabit uzunlukta zaman pencerelerine ayrılarak ve her pencereye ait öznitelikler çıkarılarak modellerin girişine uygun hale getirilmiştir.

Her model, farklı yapısal özelliklere sahip olduğundan, öğrenme stratejileri ve performansları da farklılık göstermektedir. SVM modeli, sabit uzunlukta öznitelik vektörleri üzerinden çalışmakta olup temel bir karşılaştırma zemini sunmaktadır. LSTM modeli, zaman bağımlılıklarını öğrenme kapasitesi ile öne çıkarken, LSTM tabanlı autoencoder yapısı ise yeniden yapılandırma hatasına dayalı olarak stresli durumları anomali olarak tespit etmeyi amaçlamaktadır.

Aşağıda, çalışmada kullanılan her bir modelin mimarisi, eğitim parametreleri ve uygulama detayları ayrı alt başlıklar altında sunulmaktadır.

3.5.1. Destek Vektör Makineleri (SVM)

Destek Vektör Makineleri (SVM), sınıflandırma problemlerinde özellikle küçük ve orta ölçekli veri setlerinde yüksek performans gösteren denetimli öğrenme algoritmalarından biridir. SVM, iki sınıfı ayıran en iyi hiper düzlemi belirleyerek, verilerin bu düzleme olan uzaklıklarını maksimize etmeyi amaçlar. Doğrusal olmayan sınıflandırma durumlarında ise çekirdek (kernel) fonksiyonları kullanılarak veriler

daha yüksek boyutlu uzaylara dönüştürülür ve doğrusal ayırım bu uzaylarda gerçekleştirilir. Bu özelliği sayesinde SVM, biyolojik sinyallerin veya hareket temelli verilerin sınıflandırılmasında yaygın olarak tercih edilmektedir [31].

Bu çalışmada, zaman serisi sensör verileri sabit uzunlukta pencerelere bölünerek her bir pencere tek bir örnek olarak temsil edilmiştir. Pencereleme işlemi sonucunda elde edilen her örnek, sıralı verinin zamanla hizalanmış öznitelik vektörüne dönüştürülmüştür. Bu vektörler, doğrudan SVM sınıflandırıcısına giriş olarak verilmiştir. Modelin çekirdek fonksiyonu olarak polinom kernel kullanılmış, hiperparametreler ise doğrulama seti üzerinde denenerek optimum değerlere ayarlanmıştır.

Veri setinde gözlenen dengesizlik nedeniyle eğitim öncesinde SMOTE algoritması uygulanmış ve düşük stresli örneklerin sayısı artırılarak sınıflar dengelenmiştir. Eğitim ve test veri kümeleri, katılımcı bazlı ayırım gözetilerek oluşturulmuştur. Böylece modelin daha önce görmediği bireyler üzerindeki genellenebilirlik performansı ölçülmüştür. SVM modeli, zaman serilerinin içsel zaman bağımlılıklarını doğrudan modelleyememesine rağmen, güçlü karar yüzeyleri üretme kapasitesi sayesinde bu çalışmada temel karşılaştırma algoritması olarak yer almıştır. Özellikle özniteliklerin doğrudan ayırt edici olduğu durumlarda başarılı sonuçlar üretmiştir.

3.5.2. Uzun Kısa Süreli Bellek (LSTM)

Uzun Kısa Süreli Bellek (LSTM) ağları, tekrarlayan sinir ağı (RNN) mimarilerinin zaman içindeki bağımlılıkları modelleme konusunda yaşadığı sınırlamaları aşmak amacıyla geliştirilmiş ileri düzey bir derin öğrenme yapısıdır. RNN'lerin eğitimi sırasında sıkça karşılaşılan gradyan sönümlenmesi (vanishing gradient) problemi, LSTM hücrelerindeki özel kapı mekanizmaları sayesinde büyük oranda ortadan kaldırılmıştır. Bu kapılar – unutma (forget), giriş (input) ve çıkış (output) – bilgiyi hücre durumu içinde ne kadar tutacağını ya da güncelleyeceğini denetleyerek, ağı hem kısa vadeli hem de uzun vadeli bağımlılıkları öğrenmesini sağlar. Böylece LSTM, sadece yakın zamandaki örnekleri değil, daha önceki zaman adımlarındaki örüntüleri de etkili bir şekilde dikkate alabilir. Bu özellik, özellikle biyosinyaller gibi ardışık korelasyonlar içeren zaman serisi verilerinin sınıflandırılmasında büyük avantaj sağlamaktadır [32].

Bu çalışmada geliştirilen LSTM modeli, ESP32 mikrodenetleyicisine bağlı MPU9250 sensöründen elde edilen ve 2 saniyelik zaman pencereleriyle (100 örnek) yapılandırılan verileri giriş olarak alacak şekilde tasarlanmıştır. Her bir örnek, üç eksenli ivmeölçer, jiroskop ve manyetometreden gelen 9 boyutlu hareket verisi ile sıcaklık bilgisini içeren toplam 10 özellikten oluşmaktadır. Bu çok boyutlu zaman serisi verisi, LSTM modeline zaman sıralı olarak aktarılmış, böylece modelin hareketin zamansal akışındaki örüntüleri öğrenmesi sağlanmıştır.


Model mimarisi, giriş katmanından sonra yer alan iki ardışık LSTM katmanından (her biri 64 hücre) oluşmaktadır. Bu yapı, zaman içindeki karmaşık ilişkileri daha iyi kavrayabilmek amacıyla çok katmanlı (stacked) bir LSTM olarak yapılandırılmıştır. Her LSTM katmanının ardından, aşırı öğrenmeyi önlemek ve genel performansı artırmak amacıyla %20 oranında dropout uygulanmıştır. Dropout, ağıın belirli bağlantılarını rastgele kapatarak öğrenme sürecinde gereksiz ezberlemeyi (memorization) azaltmakta ve modelin farklı desenlere genelleme yapabilmesini teşvik etmektedir. Ardından gelen yoğun (dense) katman, zaman boyutundan soyutlanan çıktıları sınıflandırmaya uygun hale getirmiştir. Aktivasyon fonksiyonu olarak gizli katmanlarda ReLU kullanılmış, çıkış katmanında ise sigmoid aktivasyonu tercih edilerek ikili sınıflandırma (stresli / düşük stresli) gerçekleştirilmiştir.

Modelin eğitimi sırasında, kayıp fonksiyonu olarak ikili sınıflandırmalarda yaygın şekilde tercih edilen binary cross-entropy fonksiyonu kullanılmıştır. Bu kayıp fonksiyonu, özellikle dengesiz sınıflar söz konusu olduğunda iyi performans gösteren bir yapıya sahiptir. Optimizasyon algoritması olarak Adam seçilmiştir. Adam, öğrenme hızını uyarlamalı olarak ayarlayarak parametre güncellemelerinde daha hızlı yakınsama ve daha kararlı bir öğrenme süreci sağlar. Ayrıca modelin aşırı uyum (overfitting) göstermesini önlemek amacıyla iki erken durdurma stratejisi bir arada kullanılmıştır: EarlyStopping ile doğrulama kaybında bir gelişme olmadığı takdirde eğitim süreci otomatik olarak sonlandırılmış, ReduceLROnPlateau tekniği ile de doğrulama performansı belirli bir eşik altında seyrettiğinde öğrenme oranı kademeli olarak azaltılmıştır. Bu yaklaşımlar, modelin genel öğrenme kabiliyetini artırmak ve gereksiz uzun eğitim döngülerini önlemek açısından etkili olmuştur.

Veri setinde sınıf dengesizliği bulunduğundan dolayı, yalnızca eğitim verisi üzerinde SMOTE (Synthetic Minority Over-sampling Technique) uygulanmıştır. Bu sayede test

verisi gerçek dağılımı temsil etmeye devam etmiş, böylece modelin gerçek dünya koşullarındaki genellenebilirliği değerlendirilmiştir. Eğitim ve test kümeleri, birey bazlı olarak ayrılmıştır. Böylece model, test sırasında daha önce hiç karşılaşmadığı bireylerden gelen veriler üzerinde değerlendirilmiş, bireyler arası genellenebilirlik başarımı ölçülmüştür. Bu yaklaşım, yalnızca veri seti içindeki örüntüleri öğrenen değil, aynı zamanda kişiden bağımsız genelleme yapabilen bir model geliştirilmesini hedeflemiştir. LSTM modelinin bu çalışma kapsamında sergilediği yüksek sınıflandırma başarımı, zaman serisi verisinin doğasına uygun mimari tasarım ve ön işleme stratejileri ile birlikte değerlendirildiğinde anlam kazanmaktadır. Model, sinyaldeki mikrodüzeydeki dalgalanmalardan ritmik örüntülere kadar geniş bir yelpazedeki bilgiyi işleyebilmiş ve stresli-düşük stresli durumları birbirinden başarıyla ayırt edebilmiştir. Bu da LSTM'nin, hareket temelli psikofizyolojik durumların izlenmesinde ve sınıflandırılmasında güçlü bir yöntem olarak konumlandığını ortaya koymuştur.

Modelin eğitimi, NVIDIA CUDA destekli NVIDIA RTX 3080 GPU üzerinde gerçekleştirilmiş ve toplamda 4545.58 saniye (yaklaşık 1 saat 15 dakika) sürmüştür. Aynı modelin benzer koşullar altında yalnızca CPU ile çalışan bir sistemde eğitilmesi ise yaklaşık 4 kat daha uzun zaman almıştır. Bu durum, özellikle zaman serisi verileri üzerinde çalışan LSTM gibi hesaplama açısından yoğun derin öğrenme modellerinde, donanımın eğitim süresi üzerindeki etkisini açıkça ortaya koymaktadır. GPU'ların paralel işlem yapabilme yetenekleri sayesinde özellikle büyük veri setlerinde ve çok sayıda epoch içeren eğitim süreçlerinde kayda değer bir hızlanma sağladığı gözlemlenmiştir. Bu bağlamda, GPU kullanımının yalnızca eğitim süresini kısaltmakla kalmayıp, aynı zamanda modelleme sürecinin daha verimli ve tekrarlanabilir olmasına da katkı sunduğu söylenebilir.



Şekil 3.6: Lstm Mimarisi.

Şekil 3.6’da görüldüğü üzere, kullanılan LSTM model mimarisi iki ardışık LSTM katmanından ve bir yoğun (dense) katmandan oluşan sade ama etkili bir yapıya sahiptir. Her bir LSTM katmanı 64 hücre içermekte olup, bu yapı zaman serisindeki ardışık ilişkileri yeterli düzeyde yakalayabilmiştir. Modelin daha derin katmanlarla genişletilmesi denendiğinde, eğitim verisine fazla uyum sağlanarak test verisinde performans kaybı yaşanmış, yani aşırı öğrenme (overfitting) problemi gözlemlenmiştir. Aynı şekilde, katmanlar arası dropout mekanizması uygulanmadığında modelin genelleme yeteneği zayıflamış ve öğrenme sürecinde dalgalanmalar oluşmuştur. Bu nedenle her katmandan sonra %20 oranında dropout uygulanması, hem öğrenme sürecinin stabilitesini sağlamış hem de aşırı uyum riskini azaltmıştır. Yapılan deneysel çalışmalar sonucunda yukarıdaki şekilde gösterilen bu mimari, eğitim süresi ve doğruluk açısından en dengeli sonuçları vermiştir. Bu nedenle çalışmada nihai model olarak bu yapı tercih edilmiştir.

3.5.3. LSTM Tabanlı Otomatik Kodlayıcı (Autoencoder)

Otomatik kodlayıcı (autoencoder) yapıları, gözetimsiz öğrenme yöntemleri arasında yer alan ve giriş verisinin sıkıştırılmış temsillerini öğrenerek, bu temsiller üzerinden yeniden yapılandırılmasını amaçlayan sinir ağı modelleridir. Bu mimariler, geleneksel sınıflandırma algoritmalarından farklı olarak, etiketli veri gereksinimi olmaksızın, doğrudan verinin içsel örüntülerini ve yapısal karakteristiğini keşfetmeyi hedefler. Autoencoder sistemlerinde modelin başarımı, girdi verisinin ne ölçüde aslına uygun biçimde yeniden üretilebildiğini gösteren yeniden yapılandırma hatası üzerinden değerlendirilir. Bu hata, aynı zamanda anomali tespiti amacıyla da kullanılabilir. Zira, eğitim sırasında öğrenilen normal dağılımın dışında kalan örneklerin yeniden yapılandırılması sırasında modelin hata üretme eğilimi artmakta ve bu durum aykırı durumların saptanmasını mümkün kılmaktadır [33].

Bu çalışmada geliştirilen LSTM tabanlı autoencoder modeli, yalnızca düşük stresli (low_stress) durumlara ait verilerle eğitilmiştir. Modelin temel yaklaşımı, düşük stresli örüntüleri başarıyla yeniden yapılandırabileceği, buna karşın yüksek stresli durumlara ait verilerin model tarafından orijinal biçimlerine benzer şekilde yeniden inşa edilemeyeceği varsayımına dayanmaktadır. Yeniden yapılandırma hatasındaki bu farklılık, stresli verilerin istatistiksel olarak norm dışı örüntüler taşıdığına işaret etmekte ve modelin bu örnekleri anomali olarak algılamasını sağlamaktadır. Böylece yeniden yapılandırma hatasının önceden belirlenmiş eşik değeriyle karşılaştırılması yoluyla, test verisi içerisindeki stresli örnekler tespit edilebilmektedir.

Modelin yapısal olarak hem encoder hem de decoder bileşenleri sıralı LSTM katmanlarından oluşmakta ve zaman serisi verinin sırasal doğasına uygun şekilde yapılandırılmıştır. Girdi verisi, 100 zaman adımı boyunca toplanmış dokuz eksenli sensör ölçümlerinden oluşmakta ve bu veriler encoder tarafından sıkıştırılmış temsillere dönüştürülmektedir. Elde edilen içsel temsiller, decoder katmanları tarafından yeniden yapılandırılarak çıkış katmanına iletilmektedir. Eğitim sürecinde kayıp fonksiyonu olarak ortalama karesel hata (mean squared error) kullanılmış ve model yalnızca düşük stresli veriler üzerinden optimize edilmiştir.

LSTM tabanlı bu autoencoder yaklaşımı, özellikle veri kümesinde stresli durumların sayıca az ve dengesiz dağıldığı senaryolarda avantaj sunmaktadır. Bu yapı, stresli

durumları doğrudan sınıflandırmak yerine, norm dışı örüntüler olarak değerlendirerek tespit etmeye çalışmaktadır. Böylece sınıflandırma problemi, istatistiksel anomali tespitine dönüştürülmüş ve gözetimsiz öğrenme perspektifiyle ele alınmıştır. Bu yöntem, yalnızca stres sınıflandırması açısından değil, aynı zamanda düşük örnekli kritik durumların modellenmesi açısından da önemli bir katkı sunmaktadır.

3.6. Bölüm Özeti

Bu bölümde, çalışmada kullanılan sistemin tasarımı, veri toplama süreci, ön işleme adımları ve sınıflandırma algoritmaları detaylı bir şekilde ele alınmıştır. Katılımcılardan sensör verisi toplamak amacıyla ESP32 mikrodenetleyiciye bağlı MPU9250 sensörü ve 3.7 V'luk şarjlı Li-ion pillerden oluşan taşınabilir bir düzenek geliştirilmiştir. Veriler, katılımcıların Tetris oynadığı süre boyunca saniyede 50 örnek hızla toplanmış ve Wi-Fi aracılığıyla Python istemcisine gerçek zamanlı olarak aktarılmıştır. Her katılımcının verileri zaman damgalı biçimde kaydedilmiş, sonrasında ise gözleme dayalı stresli zaman dilimleri manuel olarak etiketlenmiştir.

Toplanan veriler, sınıflandırma algoritmalarına uygun hale getirilebilmesi için çeşitli ön işleme adımlarına tabi tutulmuştur. Bu adımlar kapsamında zaman serisi verileri sabit uzunlukta pencerelere ayrılmış, özellikler normalize edilmiş ve eğitim verisindeki sınıf dengesizliği SMOTE yöntemi ile giderilmiştir. Ön işleme sonrası veriler, üç farklı yaklaşım ile analiz edilmiştir. Bunlar; sabit öznitelik vektörlerine dayalı olarak eğitilen destek vektör makineleri (SVM), zaman bağımlılıklarını dikkate alan iki katmanlı LSTM modeli ve yalnızca düşük stresli örneklerden öğrenerek anomali tabanlı sınıflama yapan LSTM tabanlı autoencoder yapısıdır. Her modelin mimarisi, eğitim stratejileri ve veriyle etkileşim biçimleri ayrı alt başlıklar altında detaylı olarak açıklanmıştır.

4. BULGULAR VE TEST SONUÇLARI

Bu bölümde, geliştirilen sistemin test edilmesi sonucunda elde edilen bulgular sunulmakta, her bir modelin performansı belirlenen metrikler üzerinden değerlendirilmektedir. Kullanılan veriler, etiketlenmiş sensör kayıtlarından oluşmakta ve üç farklı sınıflandırma yaklaşımı olan SVM, LSTM ve LSTM tabanlı autoencoder modelleri karşılaştırmalı olarak incelenmektedir.

4.1. Deneysel Kurulum

Deneysel çalışmalar kapsamında, 12 farklı katılımcıdan Tetris oyunu oynarken elde edilen 50 Hz frekanslı 9 eksenli sensör verisi kullanılmıştır. Katılımcıların tamamı masa başında oturur pozisyonda veri toplamaya katılmıştır. Her birey için elde edilen veriler zamana dayalı pencerelere ayrılmış ve gözleme dayalı stresli zaman aralıkları kullanılarak veriler manuel biçimde etiketlenmiştir. Etiketleme işlemi sonucunda her bir pencereye "low_stress" veya "high_stress" etiketi atanmıştır.

Model eğitiminde kullanılan veri ayrımı öncelikle birey bazlı olarak gerçekleştirilmiştir. Bu ayrımında, 12 katılımcının 8'i yalnızca eğitim setine, geri kalan 4'ü ise yalnızca test setine dahil edilmiştir. Bu yöntem, modelin daha önce hiç görmediği bireylerden alınan veriler üzerindeki genellenebilirliğini ölçmek amacıyla tercih edilmiştir. Eğitim verisinde gözlenen sınıf dengesizliği, yalnızca eğitim setine uygulanmak üzere SMOTE (Synthetic Minority Oversampling Technique) algoritmasıyla dengelenmiştir. Test verileri üzerinde herhangi bir örnekleme veya dengeleme işlemi uygulanmamış, bu sayede modellerin gerçekçi senaryolarda sergileyeceği performans ölçülmüştür.

İkinci yöntem olarak da hiperparametre optimizasyonu ve katılımcı bazlı model performansının sistematik bir şekilde gözlemlenmesi için Leave-One-Group-Out Cross Validation (LOGO CV) yöntemi kullanılmıştır. Bu yöntemde her iterasyonda bir katılımcının verileri test seti olarak ayrılırken, kalan katılımcıların verileri eğitim için kullanılır. Bu yaklaşım, modelin farklı bireyler üzerindeki genellenebilirliğini daha güvenilir şekilde değerlendirmeye olanak sağlamış ve en uygun modelin

hiperparametreleri buna göre belirlenmiştir. Model eğitimi sırasında LOGO CV yalnızca LSTM modeli üzerinde uygulanmıştır; diğer autoencoder ve svm modelleri bu değerlendirme kapsamında denenmemiştir. Bulgular kısmında LOGO CV uygulandıktan sonra belirlenen parametrelerle eğitilen LSTM modelinin sonuçları paylaşılmıştır..

Tüm modeller, Python ortamında geliştirilmiş, LSTM ve autoencoder modelleri TensorFlow/Keras kütüphanesi ile GPU destekli olarak eğitilmiştir. Eğitim süreci boyunca erken durdurma ve öğrenme oranı azaltma gibi stratejiler kullanılarak aşırı öğrenmenin önüne geçilmiştir. Değerlendirme sürecinde ise doğruluk (accuracy), kesinlik (precision), duyarlılık (recall) ve F1 skoru gibi sınıflandırma metrikleri kullanılarak modellerin performansları karşılaştırılmıştır.

4.1.1. Doğruluk

Doğruluk, modelin tüm sınıflandırmalar içerisindeki doğru tahmin oranını ifade eder. Doğru pozitif ve doğru negatif sınıfların toplamının, tüm sınıfların toplamına oranı şeklinde hesaplanır. Veri seti dengeli olduğunda genel başarıyı özetlemek açısından yararlı bir metriktir. Ancak dengesiz veri setlerinde yanıltıcı olabilir.

$$\text{Doğruluk} = \frac{\text{Doğru Pozitifler} + \text{Doğru Negatifler}}{\text{Tüm Tahminler}} \quad (4.1)$$

4.1.2. Duyarlılık

Duyarlılık, modelin gerçek pozitif sınıfları ne ölçüde doğru şekilde tespit ettiğini gösterir. Gerçek pozitiflerin, toplam gerçek pozitif ve yanlış negatiflere oranı olarak hesaplanır. Bu metrik özellikle stresli anların atlanmaması gereken durumlarda kritik öneme sahiptir.

$$\text{Duyarlılık} = \frac{\text{Doğru Pozitifler}}{\text{Doğru Pozitifler} + \text{Yanlış Negatifler}} \quad (4.2)$$

4.1.3. Kesinlik

Kesinlik, modelin pozitif sınıf olarak tahmin ettiği örneklerin ne kadarının gerçekten pozitif olduğunu ifade eder. Doğru pozitiflerin, doğru pozitif ve yanlış pozitif

toplamına oranı ile hesaplanır. Yanlış alarmların önemli olduğu durumlarda modelin güvenilirliğini değerlendirmek için kullanılır.

$$Kesinlik = \frac{Doğru Pozitifler}{Doğru Pozitifler + Yanlış Pozitifler} \quad (4.3)$$

4.1.4. F-1 Skoru

F1 skoru, kesinlik ve duyarlılık değerlerinin harmonik ortalamasıdır. Özellikle sınıflar arasında dengesizlik söz konusu olduğunda daha dengeli bir değerlendirme sunar. F1 skoru, hem yanlış pozitif hem de yanlış negatiflerin minimize edilmesinin hedeflendiği durumlarda tercih edilir.

$$F1 Skoru = 2 * \frac{Duyarlılık * Kesinlik}{Duyarlılık + Keskinlik} \quad (4.4)$$

4.2. Veri Seti Özellikleri

Bu çalışmada kullanılan veri seti, 12 farklı katılımcıdan Tetris oyunu sırasında toplanan 9 eksenli sensör verilerinden oluşmaktadır. Veriler 50 Hz örnekleme frekansı ile kaydedilmiş ve zaman damgalı olarak depolanmıştır. Toplamda 1.116.688 örnek içeren veri seti, katılımcıların stresli ve düşük stresli dönemleri gözlemlenerek “low_stress” ve “high_stress” olmak üzere iki sınıfa ayrılmıştır. Her bir örnek, ivmeölçer (ax, ay, az), jiroskop (gx, gy, gz) ve manyetometre (mx, my, mz) sensörlerinden alınan değerleri içermektedir. Ayrıca sıcaklık ölçümleri de veri setine dahil edilmiştir. Tablo 4.1’de veri setine ait sınıf dağılımı sunulmaktadır.

Tablo 4.1: Veri Setine Ait Sınıf Dağılımı.

Veri Türü	Toplam Veri	Düşük Stresli	Yüksek Stresli
Veri Seti	1.116.688	789.913	326.775
Eğitim Seti	751.658	530.186	221.472
Test Seti	365.030	259.727	105.303

Veri setine bakıldığında ilk dikkat çeken şey yüksek stresli sınıfa ait örneklerin sayısı düşük stresli örneklerle göre daha azdır. Kullanıcılardan veri toplama aşamasında genellikle stres seviyelerinin düşük olduğu gözle gözlemlenmiştir. Böyle bir uygulamada sınıflar arası dengesizlik oluşabileceği deney öncesinde de beklenmektedir. Bu dengesizlik, modelin öğrenme sürecinde bir sınıfa karşı önyargılı hale gelmesine neden olabileceğinden, yalnızca eğitim verisine SMOTE yöntemi uygulanarak dengelenmiştir. Test seti ise gerçek dünyadaki dağılımı koruyacak şekilde değiştirilmeden bırakılmıştır. Tablo 4.2’de SMOTE uygulandıktan sonraki sınıf dağılımı verilmiştir.


Tablo 4.2: SMOTE Uyguladıktan Sonra Sınıf Dağılımı.

Veri Türü	Düşük Stresli	Yüksek Stresli
Eğitim Seti	530.186	530.186
Test Seti	259.727	105.303

4.3. Keşifsel Veri Analizi


Veri setinin istatistiksel yapısının daha iyi anlaşılması amacıyla, sensör verileri arasında yer alan ilişkiler de incelenmiştir. Keşifsel veri analizi (EDA) kapsamında oluşturulan korelasyon matrisi, sensör eksenleri arasında farklı seviyelerde ilişki olduğunu göstermektedir. Örneğin, ax ve ay eksenleri arasında 0.50 seviyesinde pozitif korelasyon gözlenmiş, buna karşın ax ile my arasında -0.55 seviyesinde negatif korelasyon tespit edilmiştir. Benzer şekilde, manyetometre eksenlerinden mx ile mz arasında anlamlı bir pozitif korelasyon (0.73) bulunmuştur. Sıcaklık verilerinin çoğu sensör eksenleriyle düşük düzeyde negatif korelasyon gösterdiği görülmüştür.

Aşağıda Şekil 4.1’de gösterilen korelasyon matrisi, sensörler arasındaki yapısal ilişkilerin anlaşılması açısından önemlidir ve model mimarisi tasarlanırken dikkate alınmıştır. Korelasyon matrisine göre kabul edilemeyecek ve modelin başarısını olumsuz yönde etkileyecek kuvvette bir ilişki gözlemlenmemiştir.




Şekil 4.1: Korelasyon Matrisi.

Bütün eksenler ve sensör verileri ile çeşitli analizler yapılmıştır. Hareketin şiddetli olduğu, kullanıcının ayağını titrettiği zamanlarda, bazı sensör verisinde büyük değişikliklerin meydana geldiği plotları çizilerek teyit edilmiştir. Deney başlangıcı sırasında çizilen bu plotlar sayesinde katılımcının stresli olduğu düşünülen aralıklarda sensör verisinde farklılıklar meydana geldiği ve bunun model eğitiminde kullanılabileceği teyit edilmiştir. Bunun dışında hafif ayak hareketlerinde, bacak bacak üstüne atıldığında kısa süreli titreşimler meydana gelmiştir. Bu bağlamda farklı sınıf etiketlerine göre y eksenindeki sensör verilerinin dağılımı aşağıda paylaşılmıştır.



Şekil 4.2: Etikete göre ay eksenini dağılımı.

Şekil 4.2’de, sensör verilerinden elde edilen ay eksenini ivme ölçümlerinin stres etiketine göre dağılımı violin plot ile görselleştirilmiştir. Bu grafik, düşük stresli (etiket=0) ve yüksek stresli (etiket=1) örnekler arasındaki dağılım farklılıklarını detaylı bir biçimde sunmaktadır. Yüksek stresli örneklerin medyan değerinin düşük stresli örneklerle göre daha farklı bir dağılım eğilimi gösterdiği gözlemlenmektedir. Ayrıca yüksek stres sınıfında ay eksenindeki varyansın arttığı dikkate değer bir bulgudur. Bu durum, stresin ay eksenine yansıyan ayak hareketleri üzerinde anlamlı bir etkisi olabileceğini göstermektedir. Violin plot, yalnızca merkezi eğilimleri değil, aynı zamanda dağılım yoğunluğunu da sunduğu için bu tür davranışsal biyobelirteçlerin analizinde tercih edilen etkili bir görselleştirme yöntemidir.



Şekil 4.3: Zaman serisi örneği: ay, gy ve my eksenleri.

Şekil 4.3’te, rastgele seçilen 20.000 örnek üzerinden ay, gy ve my sensör eksenlerinin zaman içerisindeki değişimi çizgi grafik ile sunulmuştur. Bu zaman serisi görselleştirmesi, katılımcıların ayak hareketlerinin üç farklı sensör bileşeni üzerinden nasıl değiştiğini ortaya koymaktadır. Grafik incelendiğinde, özellikle gy (jiroskop y eksen) ve my (manyetometre y eksen) değerlerinde ani değişimlerin ve artan hareketliliğin olduğu dönemler dikkat çekmektedir. Bu artışlar genellikle stresli durumlarla ilişkilendirilebilecek ani tepkisel hareketlerin göstergesi olabilir. Zaman serisi grafiği, sensör verilerinin dinamik doğasını anlamada ve bu örüntülerin zamana yayılmış biçimde nasıl şekillendiğini analiz etmede önemli bir araçtır.

4.3.1. Stresli ve Stressiz Durumların İstatistiksel Karşılaştırması

Stresli ve stressiz dönemlerde ayak hareketlerinden elde edilen ivme verilerinde anlamlı fark olup olmadığını göstermek amacıyla, etiketlenmiş veri üzerinde istatistiksel analizler gerçekleştirilmiştir. Öncelikle ivme büyüklüğü $\sqrt{(x^2 + y^2 + z^2)}$ hesaplanmış ve stresli (high stress) ile stressiz (low stress) örnekler iki ayrı grup olarak ayrılmıştır. Grupların dağılımları Shapiro–Wilk testi ile incelenmiş, sonuçların normal dağılıma uymadığı görülmüştür ($p < 0.05$). Bu nedenle parametrik olmayan Mann–Whitney U testi tercih edilmiştir. Tüm katılımcıların verilerinin birlikte değerlendirildiği genel analizde, stressiz durumda ortalama ivme büyüklüğü 10.377, stresli durumda ise 10.723 olarak bulunmuş ve aradaki fark istatistiksel olarak anlamlı çıkmıştır ($p < 0.001$). Bu sonuç, stresli dönemlerde ayak hareketlerinin genellikle daha yüksek ivme değerleri ile karakterize edildiğini ve stresin bireyin motor davranışlarını


etkilediğini göstermektedir. Analizi daha ayrıntılı hale getirmek amacıyla, katılımcı bazlı istatistiksel testler de gerçekleştirilmiştir. Her katılımcının stresli ve stressiz dönemlerindeki ivme büyüklüğü ortalamaları karşılaştırıldığında, 12 katılımcının 11’inde stresli durumda ivme büyüklüğünün daha yüksek olduğu, sadece 1 katılımcıda ise ters yönde bir fark gözlemlendiği belirlenmiştir. Tüm katılımcılarda elde edilen p-değerleri 0.001’in altında çıkmış ve bu farklılıkların istatistiksel olarak anlamlı olduğu sonucuna varılmıştır. Katılımcı bazlı analizler bireysel farklılıklara rağmen genel eğilimin stresli durumda artan ayak hareketleri yönünde olduğunu göstermiştir. Böylece, yapılan istatistiksel testler yalnızca modelin sınıflandırma performansını desteklemekle kalmamış, aynı zamanda çalışmanın temel hipotezini, stresli ve stressiz dönemlerde ayak hareketlerinde anlamlı farklılıkların ortaya çıktığını, deneysel olarak da doğrulamıştır. Aşağıdaki tablo da katılımcı bazlı analizin sonuçlarına yer verilmiştir.

Tablo 4.3: Katılımcı Bazlı İstatistiksel Analiz Sonuçları.

Katılımcı	Low Stress Ortalama	High Stress Ortalama	p-değeri	Fark
1.	10.323	10.389	< 0.001	Küçük Fark
2.	10.395	10.809	< 0.001	Belirgin Fark
3.	10.123	10.769	< 0.001	Belirgin Fark
4.	10.571	10.903	< 0.001	Belirgin Fark
5.	10.440	10.989	< 0.001	Belirgin Fark
6.	10.392	10.931	< 0.001	Belirgin Fark
7.	10.681	10.500	< 0.001	Ters Yönde Fark
8.	10.178	10.454	< 0.001	Belirgin Fark
9.	10.515	10.852	< 0.001	Belirgin Fark
10.	10.301	10.430	< 0.001	Küçük Fark
11.	10.401	10.594	< 0.001	Belirgin Fark
12.	10.322	10.459	< 0.001	Belirgin Fark

Şekil 4.4’te, tüm katılımcıların verilerinin birlikte değerlendirildiği genel ivme verilerinin boxplot görseli yer almaktadır. Bu şekil incelendiğinde, “low stress” ve

“high stress” durumları arasındaki ivme büyüklüğü değerlerinin medyanları ve dağılımları gözlemlenebilir. Görseldeki kutular ve çeyrekler arası mesafeler (IQR), her iki durumun veri yayılımını göstermektedir. Genel olarak, “high stress” durumunda ivme büyüklüğü değerlerinin medyanı, “low stress” durumuna kıyasla daha yüksek olduğu gözlemlenmektedir.



Şekil 4.4: Genel ivme verileri istatistiksel analizi.

4.4. Model Performans Karşılaştırmaları

Bu çalışmada, ayak hareketlerine dayalı stres tespiti amacıyla kullanılan sensör verileri üzerinde üç farklı model test edilmiş ve elde edilen sınıflandırma performansları karşılaştırılmıştır. Değerlendirmeye alınan modeller arasında Destek Vektör Makineleri (SVM), Uzun Kısa Süreli Bellek Ağı (LSTM) ve LSTM tabanlı Otoenkoder (Autoencoder) bulunmaktadır. Modellerin başarımları; doğruluk (accuracy), duyarlılık (recall), kesinlik (precision) ve F1 skoru gibi yaygın sınıflandırma metrikleri kullanılarak analiz edilmiştir.

Sınıflandırma problemlerinde model başarımını değerlendiren bu metriklerin her biri farklı yönleriyle önem arz etmektedir. Keskinlik, bir sınıfa ait olarak tahmin edilen örneklerin gerçekten o sınıfa ait olup olmadığını gösterirken; duyarlılık, o sınıfa ait tüm örneklerin ne kadarının doğru tahmin edildiğini ifade eder. F1 skoru ise bu iki metriğin harmonik ortalamasını alarak dengeleyici bir gösterge sunar. Özellikle stres gibi psikofizyolojik durumların tespitinde duyarlılığın yüksek olması, sistemin stresli anları kaçırmaması açısından kritik öneme sahiptir.

Bu karşılaştırmalı analiz kapsamında, her bir modelin çıktısı yalnızca metrik bazında değil, aynı zamanda test verisi üzerinde oluşturduğu tahminlerin sayısal dağılımı ile de değerlendirilmiştir. Bu amaçla, karmaşıklık matrisinden elde edilen değerler Tablo 4.2, Tablo 4.3 ve Tablo 4.4'te sunulmaktadır.

Tablo 4.4: SVM Karmaşıklık Matrisi.

Gerçek / Tahmin	Düşük Stresli	Yüksek Stresli
Düşük Stresli	218.954	40.773
Yüksek Stresli	25.505	79.798

SVM modeline ait karmaşıklık matrisi değerlendirildiğinde, düşük stresli örneklerin önemli bir kısmı doğru şekilde sınıflandırılmış olmakla birlikte (218,954 örnek), yüksek stresli örneklerde 25,505'lik bir yanlış negatif oranı dikkat çekmektedir. Bu durum, stresli durumları tespit etmede modelin zaman zaman yetersiz kaldığını ve stresli örnekleri düşük stresli olarak etiketleyebildiğini göstermektedir.

Tablo 4.5: LSTM Karmaşıklık Matrisi.

Gerçek / Tahmin	Düşük Stresli	Yüksek Stresli
Düşük Stresli	251,104	8,623
Yüksek Stresli	18,665	86,638

LSTM modeline ait karmaşıklık matrisi, düşük stresli örnekleri son derece yüksek bir doğrulukla sınıflandırabildiğini ve yüksek stresli örneklerdeki performansının da önceki modele kıyasla daha başarılı olduğunu ortaya koymaktadır. Özellikle sadece 8,623 düşük stresli örneğin yanlışlıkla yüksek stresli olarak tahmin edilmesi, modelin sınıflar arası ayrımı oldukça başarılı bir şekilde öğrenebildiğini göstermektedir.

Tablo 4.6: Autoencoder Karmaşıklık Matrisi.

Gerçek / Tahmin	Düşük Stresli	Yüksek Stresli
Düşük Stresli	230,778	28,949
Yüksek Stresli	19,412	85,891

Gözetimsiz öğrenme temelli Autoencoder modeline ait sonuçlar ise hem düşük hem de yüksek stresli sınıflarda dengeli bir yapı sergilemiştir. Her ne kadar yeniden yapılandırma hatasına dayalı anomali tespitinde bazı stresli örnekler kaçırılmış olsa da (19,412 adet), model yüksek stresli sınıfı %81 duyarlılıkla tespit etmeyi başarmıştır. Bu yapı, düşük stresli örneklerin norm olarak kabul edildiği senaryolarda yüksek stresli örneklerin "statistical outlier" olarak modellenebileceğini göstermektedir.

Destek Vektör Makineleri (SVM) modeli, çalışmada polinom çekirdek fonksiyonu kullanılarak uygulanmıştır. Bu modelin genel doğruluğu %82 olarak gerçekleşmiş; düşük stresli sınıfta yüksek keskinlik değerleri elde edilmesine rağmen, yüksek stresli sınıfa ilişkin metriklerde belirgin bir düşüş gözlemlenmiştir. Özellikle yüksek stresli sınıfa ait örneklerde duyarlılık %76, keskinlik ise %66 seviyelerinde kalmıştır. Bu durum, modelin stresli anları ayırt etmede zorlandığını ve çoğu zaman bu örnekleri yanlışlıkla düşük stresli olarak sınıflandırdığını göstermektedir. SVM modeli, zaman bağımlılığı içermeyen sabit özniteliklerle çalıştığı için zaman serisi verisindeki örüntüleri yeterince iyi yakalayamamış ve bu da performansın sınırlı kalmasına neden olmuştur.

LSTM modeli, zaman serilerine özgü ardışık yapıyı öğrenme yeteneği sayesinde stres sınıflandırmasında en yüksek başarıyı elde etmiştir. %93 genel doğruluk oranı ile

çalışmadaki en etkili model olan LSTM, hem düşük hem de yüksek stresli sınıflarda dengeli performans sergilemiştir. Düşük stresli sınıfta %97 duyarlılık, %93 keskinlik ve %95 F1 skoru elde edilirken; yüksek stresli sınıfta %82 duyarlılık, %91 keskinlik ve %86 F1 skoru rapor edilmiştir. Bu sonuçlar, LSTM modelinin stresin zaman içerisindeki gelişim sürecini yakalayabildiğini ve ani değişimlere duyarlı olduğunu göstermektedir. Ayrıca veri pencerelerinin ardışık olması, LSTM'nin belleğe dayalı mekanizması ile uyumlu çalışarak sınıflar arasındaki geçişleri başarılı bir şekilde modellemesine katkı sağlamıştır.

Autoencoder modeli ise klasik sınıflandırma modellerinden farklı olarak yalnızca düşük stresli örneklerle eğitilmiş ve yüksek stresli örnekleri yeniden yapılandırma hatasına dayanarak birer anomali olarak tespit etmeye çalışmıştır. Bu model, gözetimsiz öğrenme yaklaşımıyla eğitim sırasında yüksek stresli verilerle hiç karşılaşmamasına rağmen, test aşamasında bu örnekleri istatistiksel olarak "normalden sapma" biçiminde tanımayı başarmıştır. Modelin genel doğruluk oranı %87 olarak belirlenmiş; düşük stresli sınıf için %89 duyarlılık ve %92 keskinlik ile oldukça başarılı sonuçlar elde edilmiştir. Yüksek stresli sınıf için ise %82 duyarlılık, %75 keskinlik ve %78 F1 skoru değerlerine ulaşılmıştır. Bu sonuçlar, gözetimsiz öğrenme temelli bu yaklaşımın stres tespiti gibi etiketlenmesi zor olan durumlarda değerli bir alternatif olduğunu ortaya koymuştur.

Modellerin sınıflar bazında metrikleri aşağıda yer alan Tablo 4.4'de özetlenmiştir:

Tablo 4.7: Sınıflandırma Modellerinin Performans Karşılaştırmaları.

Model	Sınıf	Keskinlik	Duyarlılık	F1 Skoru
SVM	Düşük Stresli	0.89	0.84	0.87
	Yüksek Stresli	0.66	0.76	0.70
LSTM	Düşük Stresli	0.93	0.97	0.95
	Yüksek Stresli	0.91	0.82	0.86


Tablo 4.7: Devamı.

AUTO ENCODER	Düşük Stresli	0.92	0.89	0.91
	Yüksek Stresli	0.75	0.82	0.78

Tablodan da görüleceği üzere, LSTM modeli hem düşük hem de yüksek stresli sınıflarda en yüksek F1 skoruna ulaşmış ve diğer modellerle kıyaslandığında en dengeli sonuçları vermiştir. Autoencoder modeli, gözetimsiz yapısına rağmen yüksek stresli sınıfı tespit etmede güçlü bir başarı göstermiştir. SVM ise özellikle yüksek stresli örneklerde düşük keskinlik ve F1 skorları nedeniyle diğer iki modele göre daha zayıf kalmıştır.

4.4.1. LOGO CV ile LSTM Model Performansı

Model performansını değerlendirmek amacıyla, veri ayrımı için LOGO cross validation yöntemi uygulanmış ve bu süreçte modelin hiperparametreleri optimize edilmiştir. Elde edilen en uygun parametreler doğrultusunda geliştirilen yeni LSTM modeli, katılımcı bazlı performans sonuçlarının elde edilmesinde kullanılmıştır.



Şekil 4.5: Yeni Lstm Mimarisi.

Şekil 4.5'te, LOGO CV ile optimize edilen LSTM modelinin mimarisi yer almaktadır. LOGO CV uygulanırken modelin hiperparametre optimizasyonu, her iterasyonda elde edilen accuracy değerleri dikkate alınarak gerçekleştirilmiştir. Bu yaklaşım, modelin farklı katılımcılar üzerindeki genel doğru tahmin etme performansını en üst düzeye çıkarmayı amaçlamaktadır. Aşağıdaki tabloda modelin performansı katılımcı bazında

değerlendirilmiştir. Tablo 4.8, her katılımcı için accuracy, precision, recall ve F1 skorlarını göstermektedir. Bu sonuçlar, modelin daha önce hiç görmediği bireyler üzerindeki genellenebilirliğini yansıtmaktadır.

Tablo 4.8: LOGO CV ile Katılımcı Bazlı LSTM Modeli Sonuçları.

Katılımcı	Duyarlılık	Keskinlik	F1 Skoru
1.	0.83	0.80	0.82
2.	0.80	0.72	0.76
3.	0.84	0.77	0.81
4.	0.89	0.86	0.88
5.	0.85	0.70	0.78
6.	0.91	0.71	0.82
7.	0.78	0.62	0.69
8.	0.93	0.89	0.91
9.	0.92	0.90	0.91
10.	0.85	0.68	0.76
11.	0.96	0.82	0.89
12.	0.85	0.87	0.86

Tablo 4.8, LOGO CV kullanılarak elde edilen katılımcı bazlı LSTM model performansını göstermektedir. Accuracy değerleri genel olarak 0.78 ile 0.96 arasında değişmekte olup, katılımcılar arasında bir takım farklılıklar gözlemlenmektedir. Duyarlılık değerleri de farklı bir dağılım sergileyerek 0.78 ile 0.96 arasında yer almakta ve modelin farklı katılımcılarda pozitif sınıfı tahmin etme doğruluğunun kullanıcılar arasında farklılaşabildiğini göstermektedir. Keskinlik değerleri 0.62 ile 0.90 arasında değişmekte olup, özellikle 9. katılımcıda yüksek recall değeri modelin ilgili bireyin veri örüntülerini oldukça etkin öğrendiğini göstermektedir. F1 skorları, duyarlılık ve keskinlik değerlerine paralel olarak 0.69 ile 0.91 arasında yer almakta ve modelin dengeleyici performansını ortaya koymaktadır.

Katılımcılar arasındaki performans farklılıkları, bireysel hareket kalıplarının çeşitliliği ve sınıf dağılımındaki heterojenlikten kaynaklanmaktadır. Düşük keskinlik ve F1 skorlarına sahip 7. katılımcı, modelin sınıfı yakalama performansının sınırlı olduğu bir örnek olarak değerlendirilebilir. Buna karşılık, yüksek performans gösteren 4., 9. ve 12. katılımcılar, modelin belirli bireysel veri örüntülerini daha etkin öğrendiğini ortaya koymaktadır. Bu sonuçlar, LSTM modelinin bireysel farklılıklara duyarlılığını ve LOGO CV'nin katılımcı bazlı genellenebilirlik değerlendirmesinde sağladığı ayrıntılı bakışı açıkça göstermektedir.

Sonuç olarak, zaman serisi tabanlı derin öğrenme yöntemlerinin, davranışsal biyobelirteçlerin analizi ve stres gibi psikofizyolojik durumların sınıflandırılmasında oldukça başarılı olduğu ortaya konmuştur. Özellikle LSTM mimarisi, sensör verilerinden elde edilen ardışık hareket örüntülerini anlamada yüksek potansiyele sahiptir. Autoencoder ise gözetimsiz öğrenme yaklaşımı ile dengesiz veri kümelerinde etkili bir tamamlayıcı çözüm olarak değerlendirilebilir. Bu kapsamda, ileriye dönük çalışmalarda LSTM temelli modellerin gerçek zamanlı stres izleme sistemlerine entegrasyonu ve Autoencoder mimarilerinin anomali tabanlı durum tespitinde kullanımı önemli bir araştırma yönü olarak karşımıza çıkmaktadır.

4.5. Tartışma ve Gözlemler

Bu çalışmada, bireylerin stres düzeylerini ayak hareketlerinden yola çıkarak belirlemek amacıyla geliştirilmiş olan sınıflandırma modelleri, deneysel veriler üzerinden değerlendirilmiş ve elde edilen sonuçlar üzerinden kapsamlı analizler yapılmıştır. Gerek doğruluk oranları gerekse karmaşıklık matrisinden elde edilen bilgiler ışığında, farklı sınıflandırıcıların hem güçlü yönleri hem de sınırlılıkları detaylı bir şekilde incelenmiştir.

Elde edilen bulgular göstermektedir ki, zaman serisi tabanlı veriler üzerinde LSTM mimarisi, klasik yöntemlere kıyasla oldukça üstün performans sergilemektedir. Bu durum, LSTM'nin ardışık veri örüntülerini öğrenme kabiliyeti sayesinde stresin zamanla gelişen dinamiklerini modelleyebilmesine bağlanabilir. Özellikle LSTM modelinde, yüksek stresli sınıf için duyarlılık oranının %82, F1 skorunun ise %86 gibi yüksek seviyelerde gerçekleşmesi, bu modelin gerçek zamanlı stres izleme sistemlerine entegre edilme potansiyelini güçlendirmektedir.

Diğer yandan Autoencoder yapısı, sadece düşük stresli verilerle eğitilmesine rağmen, yüksek stresli durumları yeniden yapılandırma hatasına dayalı olarak tespit edebilmiş ve %78 F1 skoru ile dikkat çekici bir başarı elde etmiştir. Bu durum, etiketli veri elde etmenin zor olduğu veya etik etkileşimlerin sınırlı olduğu çalışmalarda, gözetimsiz öğrenmeye dayalı modellerin alternatif bir yaklaşım olarak değerlendirilebileceğini ortaya koymaktadır. Ancak yeniden yapılandırma temelli bu yaklaşımlarda, eşik değerinin doğru seçilmesi kritik bir adımdır; aksi halde hem yanlış pozitif hem de yanlış negatif oranlarında sapmalar meydana gelebilmektedir.

SVM ise literatürde sıklıkla kullanılan klasik sınıflandırıcılardan biri olmasına rağmen, bu çalışmada zaman serisi yapısını göz ardı etmesi ve sabit özniteliklere dayanması nedeniyle özellikle yüksek stresli sınıfta performans düşüklüğü sergilemiştir. Bu sonuç, SVM'nin yüksek boyutlu ama zaman bağlamı zayıf verilerde sınırlı kaldığını ve zamanın kritik bir bileşen olduğu davranışsal biyobelirteç analizlerinde derin öğrenme temelli mimarilerin daha uygun olduğunu göstermektedir.

Ayrıca çalışmanın verisi, kullanıcıların bir stres senaryosu içerisinde (örneğin Tetris oyununun ilerleyen aşamalarında) gözlemlenmesiyle elde edildiğinden, veri etiketleme süreci doğrudan biyofizyolojik ölçümlerle desteklenmemiştir. Bu durum, “stresli olma zamanı” gibi öznel sınırların tanımlanmasında belirsizlik yaratmakta ve sınıflandırıcıların hata oranlarını doğrudan etkileyebilmektedir. Bu bağlamda, etiketleme sürecinin gözleme ve kullanıcı geri bildirimine dayanması, gerçek hayattaki uygulamalar açısından daha uygulanabilir olmakla birlikte, bazı bilimsel sınırlamaları da beraberinde getirmektedir. Nitekim literatürde de bir bireyin stresli olmaya ne zaman başladığı ve bu stresin ne zaman sona erdiği gibi sorulara kesin doğrulukla yanıt vermenin çoğu zaman mümkün olmadığı vurgulanmaktadır [34].

Tüm bu bulgular ışığında, bireylerin yalnızca elleri veya yüzleri değil, ayak hareketleri gibi genellikle göz ardı edilen davranışsal ipuçları üzerinden de psikolojik durumlarının tahmin edilebileceği gösterilmiştir. Bu yaklaşım, giyilebilir sistemler, ergonomik çalışma ortamları, sürücü izleme sistemleri ve dijital sağlık uygulamaları gibi pek çok alanda stres tespiti için yeni açılımlar sunmaktadır.

Ancak mevcut çalışmanın sınırlılıkları da dikkate alınmalıdır. Katılımcı sayısı nispeten sınırlıdır ve veriler kontrollü bir deney ortamında toplanmıştır. Gerçek dünya

koşullarında, kullanıcıların doğal davranışlarını içeren daha çeşitli veri kümelerine ihtiyaç vardır. Ayrıca gelecekte, stres düzeyinin fizyolojik ölçümlerle senkronize biçimde doğrulanması, veri etiketleme sürecini daha objektif hâle getirebilir. Ek olarak, farklı zaman pencereleri, alternatif derin mimariler ve çoklu sensör füzyonu gibi yöntemlerle modelin daha da iyileştirilmesi mümkündür.

Sonuç olarak, bu bölümde yapılan analiz ve değerlendirmeler, ayak hareketlerinden yola çıkarak stresin güvenilir biçimde tespit edilebileceğini ortaya koymuş ve zaman serisi verilerinde derin öğrenme tabanlı mimarilerin bu alandaki üstünlüğünü güçlü bir şekilde desteklemiştir.

4.6. Bölüm Özeti

Bu bölümde, önerilen stres sınıflandırma sisteminin deneysel sonuçları detaylı biçimde sunulmuş ve üç farklı modelin performansları karşılaştırmalı olarak analiz edilmiştir. SVM, LSTM ve Autoencoder mimarileri kullanılarak gerçekleştirilen testlerde, her modelin doğruluk, duyarlılık, keskinlik ve F1 skoru gibi sınıflandırma metrikleri üzerinden başarı düzeyleri değerlendirilmiştir. LSTM modeli, zaman serisi verilerinin dinamik yapısını etkin biçimde öğrenebilmesi sayesinde en yüksek doğruluk ve F1 skorlarını elde ederek diğer modellerin önüne geçmiştir. Autoencoder modeli ise yalnızca düşük stresli verilerle eğitilmesine rağmen yüksek stresli durumları anomali olarak başarılı biçimde tespit edebilmiştir. Ayrıca, karmaşıklık matrisleri üzerinden yapılan analizler sayesinde her modelin güçlü ve zayıf yönleri açıkça ortaya konmuştur. SVM modeli temel özniteliklerden yola çıkarak sınıflandırma yaptığı için zaman içindeki örüntüleri yeterince yakalayamamış ve özellikle yüksek stresli sınıfı tanımada sınırlı başarı sergilemiştir. LSTM ise bu sınırlamaları aşarak hem düşük hem de yüksek stresli sınıflarda dengeli bir performans ortaya koymuştur.

Bununla birlikte, keşifsel veri analizi (EDA) kapsamında etiket dağılımı, korelasyon yapısı, özelliklerin dağılımı ve zaman serisi örüntüleri gibi çeşitli görselleştirmeler aracılığıyla veri setinin genel yapısı anlaşılmıştır. Elde edilen bu analiz sonuçları, model seçiminde kullanılan kriterlerin gerekçelendirilmesine katkı sağlamıştır. Tüm bu bulgular ışığında, önerilen sistemin davranışsal biyobelirteçlerden biri olan ayak hareketleri üzerinden stres tespiti için kullanılabilirliği ortaya konmuş ve literatürde

görece az çalışılan bu alana yönelik özgün katkılar sunulmuştur. Elde edilen sonuçlar, hem akademik alanda hem de günlük yaşamda kullanılabilecek stres izleme sistemlerinin geliştirilmesi için güçlü bir temel oluşturmaktadır.

5. SONUÇLAR VE GELECEK ÇALIŞMALAR

Bu tez kapsamında, bireylerin stres düzeylerinin ayak hareketleri yoluyla belirlenmesine yönelik bir sistem geliştirilmiş ve farklı makine öğrenimi ile derin öğrenme modellerinin bu problem üzerindeki başarımı detaylı biçimde incelenmiştir. Literatürde ağırlıklı olarak kalp atış hızı, deri iletkenliği ve solunum ritmi gibi fizyolojik biyobelirteçler üzerine yoğunlaşmışken; bu çalışmada davranışsal bir gösterge olan ayak hareketleri temel alınarak özgün bir yaklaşımla stres sınıflandırması gerçekleştirilmiştir. Bu bağlamda, 9 eksenli MPU9250 sensöründen toplanan ivmeölçer, jiroskop ve manyetometre verileri, kullanıcılar belirli bir stres yükü altındayken (örneğin Tetris oyunu oynarken) kaydedilmiş ve manuel olarak etiketlenmiştir.

Toplanan veriler doğrultusunda, üç farklı model — SVM, LSTM ve LSTM tabanlı Autoencoder — eğitilerek karşılaştırmalı bir analiz gerçekleştirilmiştir. Elde edilen deneysel sonuçlar göstermektedir ki, zaman serisi verilerinde ardışık bağımlılıkların öğrenilmesine imkân tanıyan LSTM mimarisi, stresin zamana yayılan etkilerini başarılı biçimde modelleyerek en yüksek sınıflandırma performansını sağlamıştır. Bu model, düşük stresli sınıf için %95 F1 skoru elde ederken, yüksek stresli sınıfta da %86 F1 skoru ile dikkat çekici bir başarı göstermiştir. LSTM tabanlı Autoencoder modeli ise yalnızca düşük stresli verilerle eğitilmiş olmasına rağmen yüksek stresli durumları yeniden yapılandırma hatası yoluyla tespit edebilmiş; bu da gözetimsiz öğrenme temelli yaklaşımların stres analizi bağlamında değerli alternatifler sunduğunu ortaya koymuştur.

Çalışmanın en önemli katkılarından biri, davranışsal biyobelirteçlerin stres tespiti amacıyla kullanılabileceğini deneysel verilerle göstermesidir. Ayak hareketleri, bireyin fizyolojik veya psikolojik durumuna bağlı olarak istemsizce değişim gösterebilen davranışsal göstergeler arasında yer almakta olup; bu çalışmada, düşük stresli ve yüksek stresli dönemlerde hareket kalıplarının farklılaştığı hem nicel analizler hem de model çıktılarıyla ortaya konmuştur. Bu bulgu, yalnızca ayak hareketlerinin değil, genelde davranışsal sinyallerin de stres gibi karmaşık psikolojik durumların izlenmesinde kullanılabileceği yönündeki literatürü desteklemektedir.

Ayrıca çalışmada, kullanıcıların ayağına bağlanan bir ESP32 ve MPU9250 tabanlı sensör düzeneğiyle, kablosuz veri aktarımı gerçekleştirilmiş ve veriler bir istemci cihaz (bilgisayar) tarafından Python ile anlık olarak kaydedilmiştir. Bu sistemin basitliği, taşınabilirliği ve gerçek zamanlı veri akışına uygunluğu, gelecekte bu tarz uygulamaların mobil ve giyilebilir sistemler üzerine entegre edilmesine olanak tanımaktadır. Geliştirilen altyapı, düşük maliyetli ve açık kaynak donanımlar kullanılarak hayata geçirilmiş olup, benzer akademik ya da ticari projeler için örnek teşkil edebilecek düzeydedir.

Bununla birlikte, çalışmanın bazı sınırlılıkları da bulunmaktadır. Öncelikle veri etiketleme süreci, bireyin stresli olup olmadığına ilişkin gözleme ve görev yapısına dayanmaktadır. Ancak özellikle bir bireyin ne zaman stresli olmaya başladığını ve bu stresin ne zaman sona erdiğini kesin olarak belirlemek oldukça güçtür. Literatürde de bu durum sıkça vurgulanmakta ve stresin nesnel olarak belirlenmesinin ancak çoklu göstergelerin birleşimiyle daha güvenilir hâle gelebileceği ifade edilmektedir. Bu nedenle, verilerin etiketlenmesinde kullanılan zaman aralıkları tahmine dayalı ve gözlem temelli olup, belirli bir belirsizlik içermektedir. Bu durum, sınıflandırma modellerinin başarımını doğrudan etkileyebilecek bir faktördür.

Ayrıca veri toplama işlemleri, sınırlı sayıda katılımcı ile kontrollü bir ortamda gerçekleştirilmiştir. Katılımcıların çoğu benzer yaş grubundadır ve görev (Tetris oyunu) doğrudan bilişsel yük oluşturarak stresli bir ortam yaratmayı amaçlamaktadır. Gerçek yaşam senaryolarında bireylerin karşılaşabileceği stres kaynakları çok daha çeşitlidir ve bağlamdan bağlama değişebilmektedir. Dolayısıyla geliştirilen modellerin genellenebilirliği, daha çeşitli görevler, demografik özellikler ve ortam koşulları altında test edilmelidir.

Bu sınırlılıklara rağmen çalışma, insan-bilgisayar etkileşimi, dijital sağlık, sürücü izleme sistemleri ve ergonomik değerlendirme gibi çok sayıda uygulama alanına hitap edebilecek bir potansiyele sahiptir. Özellikle giyilebilir teknolojilerin hızla geliştiği günümüzde, düşük güçlü gömülü sistemlerle gerçek zamanlı stres takibi yapılabilmesi; bireylerin iş verimliliğini artırma, tükenmişlik sendromunu önleme veya zihinsel sağlık durumlarını proaktif olarak izleme gibi pek çok alanda katkı sağlayabilir. Ayrıca sistemin gizli ve müdahalesiz bir şekilde veri toplayabilmesi, kullanıcı mahremiyetini zedelemeyen stres takibi yapılmasına olanak tanımaktadır.

Gelecek çalışmalarda, model başarımını artırmak ve sistemin geliştirilebilirliğini güçlendirmek adına aşağıdaki yönelimler önerilmektedir:

- Veri etiketleme süreci, gözlemsel temelli olmaktan çıkarılarak, fizyolojik sinyaller (örneğin EDA, HRV, kortizol düzeyi) ile desteklenebilir.
- Veri toplama işlemleri, daha geniş ve çeşitli katılımcı grupları ile farklı görev senaryoları altında gerçekleştirilerek modelin genellenebilirliği artırılabilir.
- Farklı sensör türleriyle (örneğin EMG, basınç sensörleri) ayak hareketlerinin daha zengin bir temsili elde edilebilir.
- Zaman serisi segmentasyon teknikleri, dikkatli şekilde optimize edilerek örüntüleri daha etkin yakalayacak pencere boyutları ve örtüşme oranları belirlenebilir.
- Oyun içi verileri de özellik olarak sensör verileriyle aynı frekansta toplanarak (oyun level değişimi, level sayısı, skor, ekranda bulunan blok sayısı vs.) sensör verileri desteklenebilir.
- LSTM dışında Transformer tabanlı modeller, dikkat (attention) mekanizmaları içeren yapılar veya hibrit modeller (örneğin CNN + LSTM) denenerek sınıflandırma başarımı artırılabilir.
- Son olarak, geliştirilen sistem mobil platformlara veya akıllı ayakkabı gibi entegre sistemlere gömülerek gerçek dünya senaryolarında sahada test edilebilir.

Sonuç olarak bu tez, davranışsal biyobelirteçlerin stres tespiti amacıyla kullanılabileceğini gösteren deneysel ve uygulamalı bir çalışmadır. LSTM ve Autoencoder gibi derin öğrenme temelli yaklaşımların zaman serisi verileri üzerindeki üstünlüğü ortaya konmuş, düşük maliyetli ve taşınabilir bir veri toplama altyapısı geliştirilmiştir. Bu çalışma, ileride gerçekleştirilecek disiplinlerarası araştırmalar için hem teorik hem de pratik açıdan güçlü bir temel sunmaktadır.

KAYNAKLAR

- [1] McEwen, B. S. (1998). "Protective and damaging effects of stress mediators". *New England Journal of Medicine*, 338(3), 171–179.
- [2] Kim, H. G., Cheon, E. J., Bai, D. S., Lee, Y. H., & Koo, B. H. (2018). "Stress and heart rate variability: A meta-analysis and review of the literature". *Psychiatry Investigation*, 15(3), 235–245.
- [3] Montesinos, Victoriano & Dell'Agnola, Fabio & Valdés, Adriana & Aminifar, Amir & Atienza, David. (2019). Multi-Modal Acute Stress Recognition Using Off-the-Shelf Wearable Devices.. in 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society. Conference. 2019.
- [4] Can YS, Chalabianloo N, Ekiz D, Ersoy C. Continuous Stress Detection Using Wearable Sensors in Real Life: Algorithmic Programming Contest Case Study. *Sensors (Basel)*. 2019.
- [5] Koelstra, S., Muhl, C., Soleymani, M., Lee, J. S., Yazdani, A., Ebrahimi, T., ... & Patras, I. (2012). "DEAP: A Database for Emotion Analysis Using Physiological Signals". *IEEE Transactions on Affective Computing*, 3(1), 18–31.
- [6] Soleymani, M., Garcia, D., Jou, B., Schuller, B., Chang, S. F., & Pantic, M. (2017). "A survey of multimodal sentiment analysis". *Image and Vision Computing*, 65, 3–14.
- [7] Schuller, B., Steidl, S., Batliner, A., Burkhardt, F., Devillers, L., Müller, C., & Narayanan, S. S. (2011). "The INTERSPEECH 2011 speaker state challenge". *Interspeech 2011*, 3201–3204.
- [8] Shi, Y., Ruiz, N., Taib, R., Choi, E., & Taib, S. (2019). "Understanding stress through gait: A mobile sensing approach". *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, 3(1), 1–20.
- [9] Nijholt, A., Reidsma, D., & Poppe, R. (2014). "Social signal processing and intelligent user interfaces: an overview of the state of the art". *ACM Transactions on Interactive Intelligent Systems*, 5(1), 1–36.
- [10] Gatica-Perez, D. (2009). "Automatic nonverbal analysis of social interaction in small groups: A review. *Image and Vision Computing*", 27(12), 1775–1787.
- [11] Günaydin, E., Atik, O. Ş., & Öksüz, Ç. (2015). "Gait speeds associated with anxiety responses to pain in osteoarthritis patients". *Pain Medicine*, 16(5), 973–979.
- [12] Shulman, M. (2019). Gait, balance, mobility and muscle strength in people with anxiety compared to healthy individuals. *Journal of Psychiatric Research*, 112, 125–132.

- [13] Smith, J., & Doe, A. (2022). Emotional states affect steady state walking performance. *Journal of Affective Neuroscience*, 14(2), 202–210.
- [14] Wang, X., Liu, Y., Zhao, Q., & Chen, H. (2019). See your mental state from your walk: Recognizing anxiety and depression through Kinect-recorded gait data. *IEEE Access*, 7, 151610–151623.
- [15] Lau-Zhu, A., Holmes, E. A., Butterfield, S., & Holmes, J. (2017). Selective association between Tetris game play and visuospatial working memory: A preliminary investigation. *Applied Cognitive Psychology*, 31(4), 438–445.
- [16] Groen, M., Bottenheft, C., Potgieser, A. R. E., & de Jong, B. M. (2025). Experimental validation of a performance curve using a Tetris computer game. *BMC Psychology*, 13, 41.
- [17] Godfrey, A., Hetherington, V., Shum, H., Bonato, P., Lovell, N. H., & Stuart, S. (2018). “From A to Z: Wearable technology explained”. *Maturitas*, 113, 40–47.
- [18] Khan, M. J., Han, D., & Lee, Y. (2020). “A stress detection system based on physiological signals and artificial neural network”. *Biomedical Signal Processing and Control*, 59, 101894.
- [19] Zhang, Z., Zhang, Y., & Qi, L. (2021). “Wearable sensors for monitoring mental health”. *Journal of Biomedical Informatics*, 117, 103779.
- [20] Ravi, D., Wong, C., Lo, B., & Yang, G. Z. (2019). “Deep learning for human activity recognition: A resource efficient implementation on low-power devices”. *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, 3(1), 1–18.
- [21] Yurtman, A., & Barshan, B. (2021). “Human activity recognition using inertial/magnetic sensor units”. *Sensors*, 21(6), 2041.
- [22] Zhang, M., Zhou, Z., & Wang, Y. (2020). “Magnetometer-aided orientation estimation for wearable motion tracking”. *IEEE Sensors Journal*, 20(22), 13589–13598.
- [23] Schmidt, P., Reiss, A., Duerichen, R., Marberger, C., & Van Laerhoven, K. (2018). “Introducing WESAD, a multimodal dataset for wearable stress and affect detection”. *Proceedings of the 20th ACM International Conference on Multimodal Interaction*, 400–408.
- [24] Zhang, Y., Zhang, L., & Wang, J. (2020). “Human stress recognition using physiological signals from wearable devices and LSTM model”. *Knowledge-Based Systems*, 205, 106276.
- [25] Gjoreski, M., Gjoreski, H., Luštrek, M., & Gams, M. (2017). “Continuous stress detection using a wrist device: In laboratory and real life”. *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, 1(4), 1–20

- [26] Kim, H., Park, J., & Park, J. (2019). “Stress classification using CNN with wearable sensors”. *Sensors*, 19(14), 3021
- [27] Xu, M., Ma, X., Wang, M., & Wang, X. (2021). “Hybrid CNN-LSTM model for stress detection using multimodal sensor data”. *Sensors*, 21(4), 1274.
- [28] Alberdi, A., Aztiria, A., & Basarab, A. (2018). “Towards a multimodal stress detection system for real environments”. *Journal of Biomedical Informatics*, 86, 136–150.
- [29] Banos, O., Galvez, J. M., Damas, M., Pomares, H., & Rojas, I. (2014). Window size impact in human activity recognition. *Sensors*, 14(4), 6474-6499.
- [30] Lazarus, R. S. (1999). “Stress and emotion: A new synthesis”. Springer Publishing Company.
- [31] Cortes, C., & Vapnik, V. (1995). “Support-vector networks”. *Machine Learning*, 20(3), 273–297.
- [32] Karim, F., Majumdar, S., Darabi, H., & Chen, S. (2019). “Evaluating the effectiveness of character-level LSTM models in biomedical named entity recognition”. *BMC Bioinformatics*, 20(1), 1–10.
- [33] Chalapathy, R., & Chawla, S. (2019). “Deep learning for anomaly detection: A survey”. *arXiv preprint arXiv:1901.03407*.
- [34] Sano, A., Taylor, S., McHill, A. W., Phillips, A. J., Barger, L. K., Klerman, E. B., & Picard, R. W. (2018). “Identifying objective physiological markers and modifiable behaviors for self-reported stress and mental health status using wearable sensors and mobile phones: Observational study”. *Journal of Medical Internet Research*, 20(6), e210.

ÖZGEÇMİŞ

Kemal ÖZTEL 2020 yılında İstanbul Teknik Üniversitesi (İTÜ) Bilgisayar Mühendisliği bölümünde lisans eğitimini tamamlamıştır. Meslek hayatına 2019 yılında VAKIFBANK firmasında veritabanı yöneticisi olarak başlamış ardından 2020 yılında YAPIKREDİ şirketinde mobil uygulama bölümünde yazılım mühendisi olarak çalışmıştır. 2021 yılından itibaren HAVELSAN A.Ş.' de yazılım mühendisi olarak elektro-optik sistemlerin yazılım entegrasyonu kapsamında görevine devam etmektedir. Bu dört yılda milli ve ihraç LHD, MİLGEM, Pakistan MİLGEM, Endonezya SYS, Ukrayna SYS ve daha bir çok projede aktif rol oynamıştır. 2025 yılında yüksek lisans eğitimini, Gebze Teknik Üniversitesi (GTÜ), Lisansüstü Eğitim Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı'nda tamamlamıştır.

TEZ ÇALIŞMASI KAPSAMINDA YAPILAN YAYINLAR

- [1] K. Öztel and M. Göktürk, (2025), "Human Stress State Analysis from Foot Movements with Deep Learning", 33th Signal Processing and Communications Applications Conference (SIU), pp. 1-4, Şile, Turkey, 25-28 June.