

T.C
İSTANBUL KÜLTÜR ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

ZİHİNSEL YORGUNLUK BULGULARININ FİZYOLOJİK SİNYALLERE
DAYALI ANALİZİ

YÜKSEK LİSANS TEZİ

Şeyma DERDİYOK

2000007528

Anabilim Dalı: Bilgisayar Mühendisliği

Programı: Bilgisayar Mühendisliği

Tez Danışmanı: Doç. Dr. Fatma PATLAR AKBULUT

HAZİRAN 2023

T.C
İSTANBUL KÜLTÜR ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

ZİHİNSEL YORGUNLUK BULGULARININ FİZYOLOJİK SİNYALLERE
DAYALI ANALİZİ

YÜKSEK LİSANS TEZİ

Şeyma DERDİYOK

2000007528

Anabilim Dalı: Bilgisayar Mühendisliği

Programı: Bilgisayar Mühendisliği

Tez Danışmanı : Doç. Dr. Fatma PATLAR AKBULUT
Jüri Üyeleri : Prof. Dr. Güray YILMAZ
Dr.Öğr.Üyesi Ezgi DEMİRCAN TÜREYEN

HAZİRAN 2023

ÖNSÖZ

Tez çalışmam süresince bilgi ve deneyimlerinden yararlandığım, desteğini üzerimden hiç çekmeyen saygıdeğer tez danışmanım Doç. Dr. Fatma PATLAR AKBULUT'a, hayatımın her safhasında ve her anında yanımda olan babama, anneme, kardeşlerime ve yakın arkadaşlarıma sonsuz teşekkürlerimi sunarım.



İÇİNDEKİLER

ÖNSÖZ	i
KISALTMALAR	iv
ŞEKİLLER LİSTESİ	v
TABLolar LİSTESİ	vi
KISA ÖZET	vii
ABSTRACT	viii
1. GİRİŞ	1
2. KURAMSAL ÇERÇEVE	5
2.1 GENEL BİLGİLER	5
2.1.1. Zihinsel Yorgunluğun Tanımı	5
2.1.2. Zihinsel Yorgunluğun Nedenleri	5
2.1.3. Zihinsel Yorgunluğun Belirtileri	8
2.2. LİTERATÜR TARAMASI	9
2.2.1. Zihinsel Yorgunluğun Tespitinin Önemi	9
2.2.2. Zihinsel Yorgunluğun Tespitine Dayalı Çalışmalar	11
2.2.3. Zihinsel Yorgunluk ve Fizyolojik Sinyaller Arasındaki İlişki	14
3. GEREÇ VE YÖNTEMLER	16
3.1 Araştırma Tasarımı	16
3.1.1. Araştırma Soruları ve Hipotezler	16
3.1.2. Veri Toplama Yöntemleri	17
3.1.3. Örneklem Seçimi	20
3.2 Veriseti	20
3.2.1. Empatica E4 Verileri	20
3.2.2. NeuroSky MindWave (EEG) Verileri	21
3.3 Veri Ön işleme	22
3.3.1 Veri Toplama	22
3.3.2 Veri Entegrasyonu	23
3.3.3. Eksik Verilerin Tamamlanması	23
3.3.4. Veri Dönüştürme	23
3.3.5. Verisetinin Dengeli Hale Getirilmesi	24
3.3.6. Verilerin Etiketlenmesi	24
3.4 Zihinsel Yorgunluğun Derin Öğrenme Yöntemleri ile Tespiti	24
3.4.1. Derin Öğrenme Modelleri	24
3.5 Duygu Tanıma Sistemlerinden Transfer Öğrenme ile Zihinsel Yorgunluk Tespiti	30

3.5.1. DEAP Veriseti	31
3.5.2. Stres Veriseti	32
3.6 Model Performans Değerlendirmesi	32
3.6.1 Model Eğitimi ve Hiperparametre Ayarları	32
3.6.2 Modellerin Performansını Artırmaya Yönelik İşlemler	33
4. SONUÇLAR	34
4.1. Derin Öğrenme Performans Değerlendirmesi	34
4.2. Duygu Tanıma Sistemlerinden Transfer Öğrenme Performans Değerlendirmesi	37
4.2.1. Duygu Tanımlamada Uyarılma Şiddetinden Transfer Öğrenme Sonuçları	37
4.2.2. Fizyolojik Sinyal Tabanlı Stres Duygusundan Transfer Öğrenme Sonuçları	38
5. BULGULAR	40
5.1. İstatistiksel Bulgular	40
5.2. Fizyolojik Sinyal Bulguları	43
6. TARTIŞMA	49
7. SONUÇ	52
8. ÇALIŞMANIN SINIRLARI ve GELECEK PLANI	54
9. ETİK KURUL İZNİ	55
10. KAYNAKLAR	56

KISALTMALAR

1DCNN : Tek Boyutlu Evriřimli Sinir Ađları (One-Dimensional Convolutional Neural Networks)

ACC : İvmeölçer (Accelerometer)

BVP : Kan Hacmi Basıncı (Blood Volume Pressure)

BiGRU : Çift Yönlü Geçitli Tekrarlayan Ünite (Bidirectional Gated Recurrent Unit)

BiLSTM : Çift Yönlü Uzun Kısa Süreli Bellek (Bidirectional Long ShortTerm Memory)

CNN : Evriřimli Sinir Ađları (Convolutional Neural Networks)

DEAP : Duygu Analizi Veriseti (A Dataset for Emotion Analysis using Physiological Signals)

EDA : Elektrodermal Aktivite

EEG : Elektroensefalografi

EKG : Elektrokardiyogram

EOG : Elektrookülogram

GRU : Geçitli Tekrarlayan Ünite (Gated Recurrent Unit)

HR : Kalp Atımı (Heart Rate)

HRV : Kalp Atış Hızı Deđişikliği (Heart Rate Variability)

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

MF : Zihinsel Yorgunluk (Mental Fatigue)

PPG : Fotopletismografi (Photoplethysmography)

Resp : Solunum (Respiration)

TEMP : Sıcaklık (Temperature)

ŞEKİLLER LİSTESİ

Şekil 2. 1 : Zihinsel Yorgunluğun Sebeplerinin Süreçsel Oluşumu.....	7
Şekil 2. 2 : Zihinsel Yorgunluk Belirtilerinin Dört Temel Grupta İncelenmesi [11].....	9
Şekil 2. 3 : TÜİK 2009-2021 Yılları Arasında Meydana Gelen Ölüm İstatistikleri	10
Şekil 2. 4 : İş Kazalarının Sıklıkla Meydana Geldiği İlk 10 Sektör	10
Şekil 2. 5 : Zihinsel Yorgunluğun Tespitinde Kullanılan Genel Yöntemler.....	12
Şekil 3. 1 : Tez Çalışması İçin Belirlenen Yol Haritası	16
Şekil 3. 2 : Empatica E4 Akıllı Bileklik ve Mobil Uygulama Arayüzü.....	19
Şekil 3. 3 : NeuroSky MindWave EEG Cihazı ve Bilgisayar Uygulama Arayüzü (Emülatör)	20
Şekil 3. 4 : Önerilen LSTM Modeli	25
Şekil 3. 5 : Önerilen Bi-LSTM Modeli	26
Şekil 3. 6 : Önerilen GRU Model.....	27
Şekil 3. 7 : Önerilen Bi-GRU Modeli.....	28
Şekil 3. 8 : Önerilen 1DCNN Modeli.....	30
Şekil 4. 1 : 1DCNN Modelinin Doğruluk ve Kayıp Değer Grafiği-MEFAR_UP	35
Şekil 4. 2 : Örneklem Sıklığına Bağlı Model Doğruluk Performansları	35
Şekil 4. 3 : Örneklem Sıklığına Bağlı Modellerin Kayıp Değer Performansları	36
Şekil 5. 1 : Katılımcıların Eğitim Durumu Dağılımı.....	40
Şekil 5. 2 : Katılımcıların Sabah ve Akşam Zihinsel Yorgunluk Dağılımları	41
Şekil 5. 3 : CYÖ'ne Sabah Verilen Yanıtların Kişi Bazlı Dağılımı	42
Şekil 5. 4 : CYÖ'ne Akşam Verilen Yanıtların Kişi Bazlı Dağılımı	43
Şekil 5. 5 : Fizyolojik Sinyallerin Zihinsel Yorgunluk Dağılımları.....	44
Şekil 5. 6 : Fizyolojik Sinyallerin Zihinsel Yorgunluğu Belirlemede Etkisi	44
Şekil 5. 7 : EDA (üstteki) ve Dikkat-Attention (alttaki) Sinyallerinin Etkinlik Grafikleri	45
Şekil 5. 8 : Zihinsel Yorgun ve Yorgun Olmayan Durumlarda EDA Sinyalinin Değişimi ...	46
Şekil 5. 9 : Zihinsel Yorgun ve Yorgun Olmayan Durumlarda HR Sinyalinin Değişimi.....	47
Şekil 5. 10 : Zihinsel Yorgun ve Yorgun Olmayan Durumlarda Alpha2 Beyin Sinyalinin Değişimi.....	47
Şekil 5. 11 : Zihinsel Yorgun ve Yorgun Olmayan Durumlarda Gamma1 Beyin Sinyalinin Değişimi.....	48
Şekil 6. 1 : En İyi Modelin Karmaşıklık Matrisi.....	49
Şekil 6. 2 : Modelin Zihinsel Yorgunluğun Tespit Etmede Hassasiyet Eğrisi.....	49
Şekil 6. 3 : Modelin Belli Kesme Değerine Göre Pozitif (Zihinsel Yorgun) ve Negatif (Zihinsel Yorgun Değil) Sınıflandırma Yüzdesi	50

TABLÖLAR LİSTESİ

Tablo 1 : 1990 - 2019 Yılları Arasında Meydana Gelen Zihinsel Sağlık Problemlerinin Ülke Bazında Sıralaması [8].....	2
Tablo 2 : EEG Dalga Tipleri	15
Tablo 3 : Önerilen LSTM Modelindeki Birim Sayılarının Verisetlerindeki Dağılımı	26
Tablo 4 : Önerilen BiLSTM Modelindeki Birim Sayılarının Verisetlerindeki Dağılımı	27
Tablo 5 : Önerilen GRU Modeldeki Birim Sayılarının Verisetlerindeki Dağılımı	28
Tablo 6 : Önerilen Bi-GRU Modeldeki Birim Sayılarının Verisetlerindeki Dağılımı	29
Tablo 7 : Önerilen 1DCNN Modeldeki Birim Sayılarının Verisetlerindeki Dağılımı.....	30
Tablo 8 : Önerilen Tüm Derin Öğrenme Modellerinin Performans Sonuçları	36
Tablo 9 : Önceden Eğitilen DEAP GRU Modelinde Transfer Öğrenme Sonuçları	37
Tablo 10 : Önceden Eğitilen DEAP 1DCNN Modelinde Transfer Öğrenme Sonuçları	38
Tablo 11 : Önceden Eğitilen Stres LSTM Modelinden Transfer Öğrenme Sonuçları	38
Tablo 12 : Önceden Eğitilen Stres 1DCNN Modelinden Transfer Öğrenme Sonuçları	39
Tablo 13 : Rastgele Seçilen Gözlemin Sinyal Verilerinin Modele Katkısı (Model Başarısı %98 doğruluk).....	46
Tablo 14 : Makine Öğrenmesi Yöntemleriyle Yapılmış Önceki Çalışmalarla Önerilen Modellerin Karşılaştırılması	51

GENEL BİLGİLER

Enstitü	:	Lisansüstü Eğitim Enstitüsü
Dalı	:	Bilgisayar Mühendisliği Anabilim Dalı
Program	:	Bilgisayar Mühendisliği
Tez Danışmanı	:	Doç. Dr. Fatma PATLAR AKBULUT
Tez Türü ve Tarihi	:	Yüksek Lisans - Haziran 2023

KISA ÖZET

Zihinsel yorgunluk bulgularının fizyolojik sinyallere dayalı analizi

Şeyma DERDİYOK

Zihinsel yorgunluk uzun süreli bilişsel performansa dayalı ortaya çıkan psikofizyolojik bir durumdur. İş ve insan sağlığı açısından zararlı etkileri de olan zihinsel yorgunluk oluştuğu anda karar verebilme, seçim yapabilme, çözüm sunabilme, algılayabilme vb. bilişsel becerilerde azalma olur. Günlük yaşam kalitesini düşüren zihinsel yorgunluğun tanımlanması ve erken tespiti günümüz teknolojisiyle mümkündür. Bu erken tespit ile yorgunluğa dayalı ortaya çıkan zihinsel performans ve motivasyon düşüklüğü, konsantre olamama, reflekslerde azalma gibi olumsuz etkiler azaltılabilir. Bu çalışmada derin ve transfer öğrenme yaklaşımları ile zihinsel yorgunluk bulgularının tanımlanması için fizyolojik sinyallerin kullanımının ve uygulanabilirliğinin analizi yapılmıştır. Ayrıca kişilerin demografik bilgilerinin zihinsel yorgunluğu oluşturmadaki etkilerine bakılmıştır. Yaş ortalaması 29 olan 4 farklı meslek grubundan aktif çalışan 23 katılımcı belirlenmiştir. Katılımcıların rutin iş düzenlerine devam ettikleri esnada sabah ve akşam ayrı ayrı olmak üzere EEG, BVP, EDA, HR, TEMP, ACC fizyolojik sinyalleri kaydedilmiştir. Bu sinyalleri seçmedeki birincil neden bilişsel süreçlere olan duyarlılıkları ve altta yatan zihinsel yorgunlukla ilgili değişiklikleri yakalamadaki potansiyelleridir. Farklı frekans sıklığına sahip bu sinyallerle 1, 32 ve 64 Hz frekans aralıklarına örnekleme yapılarak 3 farklı veriseti oluşturulmuştur. Bu verisetleri oluşturulurken her 3 dakikada bir son 1 dakikalık örneklem seçilmiştir. Bu verisetleri önerilen derin öğrenme ve transfer öğrenme modelleriyle eğitilmiştir. Optimum sonuçlar 64 Hz örnekleme frekansına sahip veri kümesinde elde edilmiştir. Bu modellerden tek boyutlu evrişimsel sinir ağı %98 doğruluk oranı ile daha yüksek performans sergilerken, transfer öğrenme aşamasında tekrarlayan sinir ağı modellerinden LSTM %97, GRU %95 doğruluk oranı ile en iyi sınıflandırıcı olmuşlardır. Zihinsel yorgunluğu transfer öğrenme ile tespit etmede stres kökenli veriseti özelliklerinin duygu tanıma kökenli veriseti özelliklerinden daha baskın olduğu gözlemlenmiştir. Ayrıca örneklem sıklığı arttıkça modellerin sınıflandırma performansının arttığı; EDA sinyalinin zihinsel yorgunluğu tespit etmede daha belirleyici olduğu; çalışma süresi, uyku düzeni ve süresi gibi faktörlerin zihinsel yorgunluk oluşturmada doğrudan etkili olduğu gözlemlenen diğer sonuçlardır.

Anahtar Kelimeler: Zihinsel Yorgunluk, Derin Öğrenme, Transfer Öğrenme, EDA, 1DCNN

GENERAL INFORMATION

University	:	İstanbul Kültür University
Institute	:	Institute of Graduate Studies
Department	:	Computer Engineering Master's Program with Thesis
Programme	:	Computer Engineering Master's Program with Thesis
Supervisor	:	Assoc. Prof. Dr. Fatma PATLAR AKBULUT
Degree Awarded and Date	:	MA-June 2023

ABSTRACT

Analysis of signs of mental fatigue based on physiological signals

Şeyma DERDİYOK

The state of mental fatigue (MF) is a combination of psychological and physiological factors which are a result of long-term cognitive exertion. MF, that has adverse effects on both work and human health, can impede decision-making, choice-making, problem-solving, perception, and other cognitive abilities. Nowadays, it is possible through advanced technological means to identify and detect MF, which significantly reduces the quality of daily life. By detecting fatigue early, negative effects such as decreased mental performance and motivation, an inability to concentrate, and reduced reflexes, which are caused by fatigue, can be mitigated. In this study, an analysis was conducted on the utilization and feasibility of physiological signals for the identification of mental fatigue symptoms using deep and transfer learning approaches. Additionally, the impact of individuals' demographic information on the formation of MF has been examined. A total of 23 active participants were identified from four distinct occupational groups, with an average age of 29 years. During the participants' regular work, EEG, BVP, EDA, HR, TEMP, and ACC physiological signals were recorded separately in the morning and evening. The primary reason for selecting these signals lies in their potential to capture variations in cognitive processes and underlying MF. Three distinct datasets were formed by sampling at 1, 32, and 64 HZ intervals using signals possessing varying sample rates. During the creation of these datasets, a sample of the last minute was selected every three minutes. The present dataset has been trained using proposed deep learning and transfer learning models. The optimum results were achieved in the dataset with a sampling frequency of 64 Hz. Of the models examined, the one-dimensional convolutional neural network has demonstrated significantly higher performance, achieving a 98% accuracy rate. On the other hand, the recurrent neural network models, specifically LSTM and GRU, have exhibited outstanding classification performance during the transfer learning phase, achieving accuracy rates of 97% and 95%, respectively. The present analysis observes that stress-induced dataset characteristics tend to prevail over emotion recognition-related dataset characteristics in identifying MF through transfer learning. It has been observed that as the sample frequency increases, the classification performance of models also improves. Moreover, the analysis of EDA signals is more decisive in detecting MF. Factors such as work duration, sleep patterns, and duration have a direct impact on the creation of MF, as demonstrated by other findings.

Keywords: Mental Fatigue, Deep Learning, Transfer Learning, EDA, 1DCNN

1. GİRİŞ

Endüstri 1.0 zamanlarında birçok işin insan gücü ile yapılması, uzun süreli fiziksel aktivitelere maruz kalındığı için insanlarda fiziksel yorgunluğu ortaya çıkarmıştır. Ancak içinde bulunduğumuz zaman dilimini de kapsayan Endüstri 4.0 ile insan gücünün yerini makine gücü almış ve yenilerde aşına olduğumuz kavram olan zihinsel yorgunluk hayatımıza girmiştir [1], [2], [3]. Endüstri 4.0'a göre her bir farklı makinenin kullanılması gereken alanda yeni bir makine tasarımına ihtiyaç duyulur. Bu durum, insanı fiziksel eforun yanında bilişsel anlamda sarf edilen eforu da kullanmaya maruz bırakır. Bilişsel eforda kritik eşik aşıldığında insan vücudunun verdiği tepki, zihinsel yorgunluk ya da diğer adıyla mental yorgunluk olarak bilinir [4].

Günümüzün temel sorunlarından biri olan zihinsel yorgunluk literatürde uzun süreli bilişsel aktivitelere maruz kaldığımızda ortaya çıkan olgusal ve algılanan yorgunluk tipi olarak tanımlanır [5]. Yaşam kalitesini olduğundan aşağı çeken zihinsel yorgunluk; odaklanamama, depresif ruh hali, hatırlamada güçlük vb. gibi psikolojik sorunları da beraberinde getirir. Ayrıca düşünme, analiz etme, karar verme [6] gibi bilişsel becerilerin geçici olarak devre dışı kalmasına [7] neden olduğundan bilişsel performansı olumsuz etkiler ve bir takım zihinsel sağlık problemlerini ortaya çıkarır. 1990 ve 2019 yılları arasında dünya geneli zihinsel sağlık problemlerinin incelendiği bir çalışmaya göre +5.72 pp ile en fazla değişim yaşayan ülke Tablo 1'de görüldüğü üzere Filistin olmuştur. Bunu +5.68pp ile İran, +5.42pp ile Umman, +5.34pp ile Maldivler takip etmiştir. Listenin ilk sıralarında daha çok Orta Doğu ülkelerinin yer aldığı görülmüştür. Ülkemiz ise +3.83pp ile 14. Sırada yerini almıştır. Rusya, Çin, Japonya gibi gelişmiş ülkeler ise listenin son sıralarındadır. Bu tabloya göre zihinsel yorgunluğun ve buna bağlı gelişen sağlık problemlerinin ülkelerin gelişmişlikleri ile ters orantılı olduğu anlaşılmaktadır.

Tablo 1 : 1990 - 2019 Yılları Arasında Meydana Gelen Zihinsel Sağlık Problemlerinin Ülke Bazında Sıralaması [8]

Sıra	Ülke	1990	2019	Mutlak Değişim
1	Filistin	% 5.34	% 11.06	+5.72pp
2	İran	% 4.63	% 10.31	+5.68pp
3	Umman	% 4.99	% 10.41	+5.42pp
4	Maldivler	% 2.72	% 8.06	+5.34pp
5	Katar	% 8.48	% 13.67	+5.19pp
6	Kuveyt	% 7.81	% 12.23	+4.42pp
7	Bangladeş	% 1.97	% 6.10	+4.13pp
8	Suudi Arabistan	% 4.79	% 8.92	+4.00pp
9	Peru	% 3.4	% 7.4	+4.00pp
10	Jordan	% 6.3	% 10.2	+4.00pp
11	Irak	% 3.5	% 7.5	+4.00pp
12	Afrika (Orta ve Kuzey)	% 4.0	% 7.9	+4.00pp
13	Sudan	% 1.9	% 5.8	+3.9pp
14	Türkiye	% 4.32	% 8.2	+3.83pp
15	Nepal	% 1.8	% 5.5	+3.7pp
16	Nikaragua	% 3.6	% 7.3	+3.7pp
17	Butan	% 2.0	% 5.6	+3.7pp
18	Ekvator Ginesi	% 1.3	% 4.9	+3.5pp
19	Mısır	% 3.2	% 6.7	+3.5pp
20	Cezayir	% 4.3	% 7.8	+3.5pp

Zihinsel yorgunluğun ortaya çıkış sebepleri arasında günlük yaşam koşuşturması, artan sorumluluklar, yoğun iş temposu, yetersiz uyku ve beslenme, fiziksel aktivite azlığı, sürekli seçim yapma ve karar verme zorunluluğu, stres ve depresyon vardır. Maruz kaldığımız bu durumların günün erken saatlerinde kritik eşiği aşması, bilişsel becerilerin ve eforun azalmasına sebebiyet verir. İnsanın uyarılma mekanizmasını etkileyen zihinsel yorgunluk hissi bir süre sonra çevresel faktörlere cevap verebilmesini de güçleştirir [9]. Bu da insanın gelebilecek tehlikeleri önleyememe, karar verememe, muhakeme edememe gibi günlük yaşam faaliyetlerini yürütmesine engel olur. Bu faaliyetler insanı gün içinde ayakta tutan temel bileşenlerdir. Bu yüzden zihinsel yorgunluk üzerine araştırılması gereken ve hayatın bir parçası olan olgudur.

Zihinsel yorgunluk tıpkı fiziksel yorgunlukta olduğu gibi birkaç belirti gösterdikten sonra gün içinde insanın kendisini izleyerek tespit edebileceği karmaşık bir yorgunluk tipidir. İskelet ve kas sistemi aracılığıyla doğrudan ölçümlenemez. Sıklıkla karşılaşılan zihinsel yorgunluk belirtileri motivasyon ve dikkat eksikliği, tepki verme sürecinde gecikme, daha fazla iş hataları ya da daha az verimlilik, uykusuzluk, yeme-içme alışkanlığında değişiklik, hatırlamada güçlük, analiz-karar verme-uygulama becerilerinde düşüş, öfkeli ve sabırsız davranma, endişe-kaygı-depresif ruh halidir [10]. Ölçümlenemeyen bu belirtilerin çoğu, insan tarafından ortaya bir kaza ya da yanlışlık çıkana kadar fark edilemez. İnsanların duygularını da gizleyebileceği düşünüldüğünde zihinsel yorgunluğu tespit etmenin çok yönlü ele alınması gereken zorlu bir süreç olduğu anlaşılmaktadır.

Teknoloji alanında meydana gelen gelişmelerin en çok insanı etkilediği bilinen bir gerçektir. Bilginin sürekli işlendiği, aktarıldığı ve üzerinde çıkarımlar yapıldığı akıllı sistemlerdeki artış, bilgi toplumunun en küçük birimi olan insanın bilişsel becerisini olabildiğince üst düzeyde tutmasını gerekli kılmıştır. Özellikle bünyesinde yüksek risk barındıran ve her şeyden önce güvenliği ön planda tutan iş alanlarında kalite ve verimlilik, çalışanın bilişsel gücüyle doğru orantılıdır. Çalışan ne kadar iyi düşünebilme, analiz edebilme, karar verebilme ve verdiği kararı hızlı uygulayabilme becerisine sahipse yapılan iş aynı oranda verimli ve istenilen ideal noktaya o kadar yakındır [11]. Bilişsel gücü etkileyen zihinsel yorgunluğu aza indirmek, tüm bu olumsuzlukları ortadan kaldırmak adına isabetli bir çözümdür. Bunun için de öncelikle tanımlanıp tespit edilmesinin büyük fayda sağlayacağı düşünülmüştür.

Zihinsel yorgunluğu tespit etmeye dayalı birçok çalışma yapılmıştır. Bu çalışmaların bir kısmı anket tabanlı yorgunluk değerlendirme ölçekleridir. Literatürde sıklıkla kullanılan ölçekler Chalder Yorgunluk Ölçeği [12], Bireysel Güç Kontrol Listesi Yorgunluk Ölçeği [13], Yorgunluk Etki Ölçeği [14], Düzenlenmiş Boru Yorgunluk Ölçeği [15], Yorgunluk Değerlendirme Ölçeğidir [16]. Bu ölçeklerde yer alan soruların bir kısmı fiziksel yorgunluğun tespitine dayalı sorular olurken bir kısmı da zihinsel yorgunluğu tespit etmek amaçlı oluşturulmuştur.

Anket tabanlı zihinsel yorgunluk ölçekleri bireylere özgü olduğu için yürütülen çalışmaların objektifliği açısından yeterli olmamıştır. Bu boşluğu doldurmak ve daha güvenilir sonuçlar almak için giyilebilir teknolojilerden faydalanılmıştır [17], [18], [19]. Giyilebilir teknolojiler özellikle insanda meydana gelen biyolojik ve fizyolojik her türlü değişimin teşhis ve takibi açısından büyük kolaylık sağlarlar. Bir aksesuar gibi takılarak ya da giyilerek kullanıldığı için hangi alan olursa olsun ergonomik açıdan elverişlidirler [20]. Bu cihazlardan elde edilen fizyolojik sinyaller aracılığıyla kişinin beyin aktiviteleri, kalp sağlığı, solunum performansı vb. takip edilip elde edilen bulgulara göre epilepsi, beyin lezyonu, çeşitli kalp ve akciğer rahatsızlıkları az maliyetle teşhis edilmiştir.

Son zamanlarda yapılan çalışmalarda biraz daha ötesi boyut ele alınarak insanda stres [21] vb. duygu durumunu tanımlama, ölçme ve belli başlı duygu tiplerini tespit etme uygulamaları fizyolojik sinyallerle yapılmıştır [22], [23]. Zihinsel yorgunluğun dışa vurum belirtilerine bakıldığında aslında bireyin duygu boyutunda yaşadığı değişim ya da dalgalanmalar olduğu da bilindiğine göre zihinsel yorgunluğun fizyolojik sinyallere dayalı tespit edilmesi ve gerekli önlemler alınabilmesi bu çalışma ile öngörülmüştür.

Bilişsel süreçlerin izlenmesi amacıyla yürütülen birçok çalışmanın ortak paydası incelendiğinde, ilk olarak nörofizyolojik ölçümlerle elde edilen verilerin zihinsel yorgunluğu tespit etmede kullanıldığına rastlanmıştır [7], [24], [25]. İkinci kategoride ise fizyolojik diğer sinyallerin olduğu görülmüştür. Bu kapsamda gerçekleştirilen öncü çalışmalarda kullanılan nörolojik ve biyolojik sinyalleri özetleyecek olursak beyin dalga hareketleri için elektroensefalografi (EEG) [26], kalp atım hareketleri için elektrokardiyogram (EKG) [18], [27], göz kırpması sıklığı, göz bebeği büyümesi, göz odaklanması gibi durumlar için elektrookülogram (EOG) [17], [28], [29], kas hareketleri ve deri iletkenliği için elektrodermal aktivite (EDA) [30] sinyalleridir.

Tez kapsamında zihinsel yorgunluk ile ilişkili bu bilgiler kullanılarak farklı meslek gruplarında aktif olarak çalışan bireylerde zihinsel yorgunluk bulgularını fizyolojik sinyallere dayalı analiz

etmek hedeflenmiştir. Şimdiye değin yapılan çalışmalardan farklı olarak belli bir çalışma ya da meslek grubuna odaklanmadan gerçek zamanlı ölçümler yapılmıştır. Her bir ölçümden önce katılımcılara literatürde sıklıkla tercih edilen yorgunluk ölçeklendirme anketi uygulanmıştır. Bu sayede çalışma güvenilirlik ve geçerlilik zemininde ilerlemiştir. Elde edilen veriler önerilen derin öğrenme yöntemlerinde kullanılmıştır. Bu yöntemler arasında özgün olan duyu yönelimli transfer öğrenme çalışmaları da yer almıştır. Bu çalışmanın kişi bağımsız gerçek zamanlı ölçüm dışında literatüre sosyal, ekonomik ve güvenlik boyutunda aşağıda listelenen katkıları sağlayacağı düşünülmüştür:

- Başta insan kaynağını korumaya yönelik olduğu için aynı zamanda uygulandığı iş alanının da güvenliği sağlanacaktır.
- İş verimliliği ve kalitesi korunduğu için işverenlerin bu alandaki maliyetleri azalacaktır.
- Düşük maliyetli ölçüm içerdiği için her meslek grubuna uyarlanabilecektir.
- Özellikle iş güvenliği ve sağlığı uzmanlarınca çok riskli görülen hava ulaşımı, deniz ulaşımı, karayolu ulaşımı, inşaat, madencilik vb. yerlerde insan faktörlü kazalar önlenebilecektir.
- Savunma sanayi alanı çalışanlarına da kolaylıkla uyarlanabileceğinden ulusal güvenliğe katkı sağlayacaktır.
- Giyilebilir sistemlere entegrasyonu halinde bireyler kendilerini gerçek zamanlı izleyebilecek ve zihinsel yorgunluklarının farkında olabileceklerdir.
- Fizik tedavi ve rehabilitasyon merkezindeki hasta bireylerin iyileşme sürecini kısaltacaktır.

Tezin kuramsal çerçeve başlığında zihinsel yorgunluğun literatürdeki tanımlarından, nedenlerinden, bulgularından, şimdiye kadar hangi yollarla ve nasıl tespit edildiğinden ve tespitinin neden önemli olabileceğinden bahsedilmiştir.

Gereç ve yöntemler kısmında araştırmanın hangi gereç ve yöntemlerle yapıldığından, veri toplama ve ön işleme adımlarından, önerilen derin ve transfer öğrenme modellerinden, modellerin performans değerlendirmesi için kullanılan metriklerden bahsedilmiştir. Ayrıca önerilen modellerin performanslarını artırmaya yönelik çalışmalar da bu başlık altında incelenmiştir.

Sonuçlar kısmında, gereç ve yöntemler bölümünde önerilen derin ve transfer öğrenme modellerinin doğruluk, kayıp değeri, özgüllük, hassasiyet ve F1 skorları aktarılmıştır.

Bulgular başlığı altında veri toplama prokolünde kullanılan anket sonuçlarının istatistiksel çıkarımları, zihinsel yorgunluk olduğu ve olmadığı durumlardaki fizyolojik sinyal bulguları incelenmiştir.

Tartışma bölümünde geçmiş çalışmalarla tez çalışmasının bulguları karşılaştırmalı olarak ele alınmıştır.

Son olarak ise çalışmanın özeti sunulmuş, hangi alanlara nasıl katkı sağlayabileceği tartışılmış ve çalışmada karşılaşılan sınırlamalar verilmiştir.

2. KURAMSAL ÇERÇEVE

Tezin kuramsal çerçeve başlığında zihinsel yorgunluğun literatürdeki tanımları ve nedenleri üzerinde durulmuştur. Zihinsel yorgunluk durumunda ortaya çıkan belirtiler dört temel boyutta aktarılmıştır. Zihinsel yorgunluğun neden tespit edilmesi gerektiğinden, şimdiye kadar hangi çalışmaların yapıldığından ve fizyolojik sinyallerle nasıl ilişkilendirildiğinden bu kısımda bahsedilmiştir.

2.1 GENEL BİLGİLER

Bu bölüm zihinsel yorgunluğun tanımını, nedenlerini ve belirtilerini içerir.

2.1.1. Zihinsel Yorgunluğun Tanımı

Uzun süreli fiziksel aktivite sonrası kasların yoğun uyarılması sonucu fiziksel yorgunluk meydana gelir. Buna benzer biçimde nöroloji bilimine göre uzun süreli periyotlarla beyin fonksiyonlarının sürekli uyarılmasına bağlı olarak meydana gelen yorgunluk [4], ya da psikoloji bilimine göre bireyin zihinsel ve duygusal kaynaklarının tükenmişlik hissiyle sonuçlandığı [31] yorgunluk, nöropsikoloji bilimine göre beyin işlevlerine aşırı yüklenme ve bilişsel kapasitenin aşırı kullanımı sonucu ortaya çıkan yorgunluk [32], zihinsel yorgunluk olarak tanımlanır. Tüm bu literatür tanımlarına göre zihinsel yorgunluğun bilişsel becerilerin işlevselliğinin yitirilmesi ya da çok düşük bilişsel performansla tepki verme olarak tanımlanması da mümkündür.

2.1.2. Zihinsel Yorgunluğun Nedenleri

İnsanın iş ve yaşam kalitesini olması gerekenden çok daha aşağıya çeken zihinsel yorgunluk, temelde insanın kötü ya da dengesiz dağılan iş ve yaşam alışkanlıklarına bağlı olarak ortaya çıkar. Aslında önlenabilir bir yorgunluk çeşidiyken göz ardı edildiği için baş edilemez boyutlara ulaşır. Araştırmalara göre zihinsel yorgunluğu meydana getirebilecek başlıca durumlar şöyle özetlenmiştir:

Stres: Günümüzün belli başlı problemlerinden olan stress, zihinsel yorgunluk oluşturmada potansiyeli en yüksek olgudur ve ne yazık ki insanın hayatının bir parçası olmuş vaziyettedir. İnsanın bedenini gelebilecek olası tehlikelere karşı koruma refleksi olarak bilinen stres; heyecanladığımız, endişe duyduğumuz ya da korktuğumuz tüm durumlarda vücudumuzda artış gösterir. Bir çeşit hormon olan stresin vücutta artışı, bireyi hızlı tepki vermeye ve çok daha hızlı düşünmeye sevk eder. Hem fiziksel hem de zihinsel olarak vücutta uzun süreli baskı hissettirdiği için fiziksel ve zihinsel yorgunluk meydana gelir. 2021 yılında yapılan bir çalışmada Covid-19 ve alt varyantlarının sağlık ve rehabilitasyon çalışanlarında meydana getirdiği strese bağlı tükenmişliğin ve zihinsel yorgunluğun etkileri incelenmiştir. Bu çalışmanın sonucu olarak iş stresi ölçeği, iş rolü belirsizliği, iş rolü uyumsuzluğu, iş rolü yükü ile tükenmişlik ve yorgunluk ölçeği değerlendirmelerinin birbiriyle pozitif korelasyon gösterdiği ortaya çıkarılmıştır. [33]

Yoğun İş Yükü: Bazı çalışma alanlarında bireyler, sayıca çok fazla olan insan popülasyonunun ihtiyaçlarını karşılayabilmek için özellikle hizmet sektöründe çalışanlar

yoğun, tempolu ve uzun süreli çalışmaya maruz kalırlar. Bu koşullar altında çalışmak bilişsel becerileri daha fazla kullanma anlamına gelir. Şöyle ki ara vermeksizin daha fazla düşünme, daha fazla odaklanma, daha fazla analiz etme ve problem çözme gerekeceği için kritik zihinsel yorgunluk eşiğine ulaşmak ve hatta geçmek gün içinde daha hızlı olur. Bu da artık çalışanın zihinsel anlamda yorgunluk hissetmesi demektir. Şehir içi toplu taşıma araç şoförlerinin toplam iş yüklerinin karşılaştırıldığı bir çalışmada zihinsel iş yükünün önem derecesi fiziksel iş yükünün önem derecesinden yüksek bulunmuştur. Bunda dikkat ve algı seviyesini yüksek düzeyde tutmanın gerekliliğinden kaynaklı gerginlik, motor becerilerini art arda kullanma, hafıza, anlık karar alıp uygulama, tüm bunları yaparken eş zamanlı insan faktörüyle de iletişim halinde olması gibi unsurların etkili olduğu saptanmıştır. [34]

Aynı Anda Birden Fazla İşle İlgilenmek: Bireylere göre farklılık gösterebilecek aynı anda birden fazla görevi yapmaya çalışmak ya da birden çok hedefe aynı anda ulaşmaya odaklanmak insan zihninin rotasının sürekli bir yerden başka bir yere geçiş yapması anlamına gelir. Çünkü insan zihni, birey her ne kadar aynı anda yapıyor gibi hissetse de sadece tek bir noktaya odaklanır. Bireyler bu odaklanma sürecini çok hızlı yaptıkları için aynı anda yapıyormuş hissine kapılırlar. Zihnin bu denli çoklu hareketi her bir yeni hedef için yeniden odaklanma, dikkat ve hatırlama gerektireceğinden kısa sürede aşırı doyma noktasına gelir ve yorgunluk başlar. 2020 yılında Nijerya’da konaklama hizmetleri veren bir işletmenin 44 çalışanından 39’unun katıldığı ve iş stresinin ve duygusal yorgunluğun ana sebeplerinin araştırıldığı bir çalışmada elde edilen bulgulara göre bir insanın yapabileceğinden daha fazla işi aynı anda yapmaya çalışmak zihinsel yorgunluğun birincil nedeni olarak gözlemlenmiştir [35] .


Düşünmede Aşırılık: Bilişsel aktivitelerimizin temeli olan düşünme eyleminde aşırıya kaçmak, zihinsel olarak yorgun hissedilmesinin başlıca nedenlerindendir. Olağan tüm durumlarda karar verirken, analiz ederken, bir problem çözerken, iletişim kurmaya çalışırken zihinsel olarak önce düşünme eylemi gerçekleştirilir. Bir de bu günlük rutinize olağan dışı durumlar da eklendiğinde aşırı düşünme ya da düşüncelere takılı kalmak zihinsel beceri ve performansı düşürür.

Sürekli Karar Verme-Seçim Yapma Durumu: Modern yaşam koşullarının getirdiği çok çeşitliliğe bağlı olarak zaman zaman karar vermede zorlanmalar yaşanır. Bir seçim yapıp karar verme sıklığı her geçen gün çoğalmaktadır. İnsan zihni kendisi için en doğru kararın ve seçimin ne olduğuyla ilgilendiğinden seçenekler çoğaldığında iş yükü artacağı için bu durum yorgunluğa sebebiyet verir. Bu yorgunluk sadece önemli seçim ya da kararları değil basit eylemlerimizi bile yapmada bize engel olur. Bünyesinde yüksek risk ve sık sık anlık karar verme durumları barındıran yerlerde çalışmak zorunda kalınması da zihinsel yorgunluğu tetikleyen bir başka unsurdur. 2016 yılında yapılan zihinsel yorgunluğun, futbol oyununa özgü karar verme ve bu kararın ne kadar doğru olduğunu ölçümleyen çalışmada iyi eğitilmiş 12 erkek oyuncunun futbola özgü karar verme becerileri izlenmiştir [36]. Yarım saatlik karar verme görevine tabi tutulan oyucularda zihinsel yorgunluk hızlı karar verme becerilerini azaltırken aynı zamanda verilen kararın da doğruluğunu benzer oranda olumsuz etkilemiştir ve düşürmüştür.

Depresyon: Depresyon çoğu zaman duygusal boyutlarda meydana gelen durum bozuklukları olarak bilinir ve toplum sağlığı açısından insanlar üzerinde en çok etki bırakan ruhsal rahatsızlıktır [37]. Son dönemlerde küresel pandeminin ve ekonomik krizin etkisiyle adını

sıkça duyurmaya başlamıştır. Başta sağlık olmak üzere ekonomik ve sosyal boyutta yıkıcı etkileri vardır. Örneğin; Dünya Sağlık Örgütü (DSÖ)'nün verilerine göre Covid-19 küresel salgını, depresyonun %25 oranda artmasına zemin hazırlamıştır [38]. Haziran 2022'de yayınlanan DSÖ Dünya Ruh Sağlığı Raporu'na göre 2019 yılından itibaren ruhsal bozukluk yaşayan bir milyar kişinin %15'inin çalışan kesim insanları olduğu rapor edilmiştir. Yine aynı raporda yer verilen Uluslararası Çalışma Örgütü'nün bilgi notuna göre depresyon ve depresyona bağlı olumsuzlukların dünya ekonomisine maliyeti yaklaşık bir trilyon amerikan doları olarak hesaplanmıştır [38]. Görüldüğü üzere aslında göz ardı ettiğimiz depresyonun ekonomi ve en önemlisi de ruh sağlığı üzerinde etkileri göz ardı edilemeyecek kadar yüksek. Depresif ruh hali bireyin düşünme, karar verme becerilerini olumsuz etkilerken değersiz, umutsuz, motivasyonsuz hissetmesine neden olduğu için zihinsel yorgunluğu meydana getiren bir diğer önemli unsur haline gelmiştir.

Bahsi geçen belli başlı bu nedenler temelde strese bağlı olarak birbirini tetikler ve Şekil 2.1'deki gibi bir döngü halinde devam eder. Yoğun çalışma temposu, artan sorumluluklar, anlık olarak sürekli karar vermeyi gerektiren oluşumlar bireyi aynı anda tüm işleri yapmaya zorlar, insanın çok fazla düşünmesine dolayısıyla stres altına girmesine ve stres ile baş edemediğinde de depresif ruhsal bozukluğa kadar varır. Meydana gelen depresyon yüzünden birey kendini değersiz hissetme, motivasyon eksikliği yaşama, yapılan iş/hedef/görev için kaygı ve korku duymaya başlar. Bulunduğu depresyona bağlı olarak odaklanmadığı işler birikir ve her zamankinden daha fazla yoğunluğun içinde kendini bulur. Sonuç olarak döngüde başladığı noktaya tekrar gelir ancak bu sefer daha fazla iş yüküyle karşı karşıya kalır. Şartlar ne olursa olsun, zihni olması gerektiğinden ya da yapabileceğinden çok daha fazla efora zorlamak kısa sürede yorgunluk durumunun oluşmasına neden olur.



Şekil 2. 1 Zihinsel Yorgunluğun Sebeplerinin Süreçsel Oluşumu

2.1.3. Zihinsel Yorgunluğun Belirtileri


Zihinsel yorgunluk belirtilerini Şekil 2.2'deki gibi dört grupta incelemek mümkündür [10]. Bu belirtiler uzun süreli bilişsel efor sarfettiğimiz dönemlerde kişiden kişiye farklılık gösterir. Bu belirtiler daha da yoğunlaşırsa kronik yorgunluk olmaya başlar ve geriye dönüşü neredeyse imkansız hal alır.

Zihinsel yorgunluğun insan duygularında meydana getirdiği en genel belirtiler incelendiğinde anlamlandırılmayan öfke ve sinirlilik hali, çevresel faktörlere karşı ilgisiz/duyarsız olma, aşırı ve takıntılı düşünmeden kaynaklı anksiyete ve ileri seviyede depresyon, iş ve sosyal yaşamda mod düşüklüğü ya da motivasyon eksikliği gibi belirtiler olduğu görülmektedir. Aslında bakıldığında önemsiz gibi görülen zihinsel yorgunluk, zamanında tespit edilip önlem alınmadığı için büyüyen sorun zincirine dönüşür.

Zihinsel yorgunluk sonucu oluşan fiziksel boyutta ortaya çıkan semptomlar zamansız gelen vücut ağrıları, uykusuzluk çekme, kronikleşmiş yorgunluk ya da yeme-içme alışkanlıklarında meydana gelen anormal değişimler olarak listelenir [39]. Bu etkiler zamanla ortaya çıktığı için bireyin kolaylıkla farketmemesine sebep olur. Sinsi bir ilerleme kaydeden zihinsel yorgunluk bu evreden sonra çok daha zor hale gelir.

Zihinsel yorgunluğun bir diğer etkilediği alan insan davranışlarında ortaya çıkardığı anomalilerdir. Bunlar düşünmedeki zorluklar ve fiziksel değişimler olmak üzere iki ana kategoride toplanır. Düşünmede zorluklar kafa karışıklığı, konsantrasyon problemleri, unutkanlık, hayal gücünde ve üretkenlikte eksiklik ya da hafızada kayıp gibi bulgulardır. Davranışsal boyuttaki fiziksel değişimler ise sindirim sistemi problemleri, baş ağrıları, kalp çarpıntısı ya da kiloda azalma/artma gibi değişimlerdir [24].

Zihinsel yorgunluk, insanın sosyal yaşamında da etkileri olan bir fenomendir. Bu etkiler iş ve özel yaşam olarak iki farklı gruba ayrılır. İş ya da çalışma anlamında görevlerin son yapılma tarihlerini kaçırmaya ya da işi zamanında bitirememeye, performansta düşüklük, isteksizlik ve iş yerinde bulunmama sıklığının artması gibi etkilerdir. Kişisel anlamda ise sosyal ortamlarda bulunmama isteği, özgüven eksikliği, insanlarla bağlantı kurmada zorluk gibi belirtilerdir.



Şekil 2. 2 : Zihinsel Yorgunluk Belirtilerinin Dört Temel Grupta İncelenmesi [11]


2.2. LİTERATÜR TARAMASI

Bu bölüm zihinsel yorgunluğun tespitinin önemini, tespitine yönelik çalışmaları ve fizyolojik sinyallerle ilişkisini içerir.

2.2.1. Zihinsel Yorgunluğun Tespitinin Önemi

Zihinsel yorgunlukla meydana gelen belirtilerin, gerek çalışma gerekse sosyal hayatta bireyin hayata tutunmasını sağlayan olgular olduğu görülmektedir. Meslek farketmeksizin bireyin içinde bulunduğu ağır yaşam ve iş koşulları kümülatif arttığında strese ve sonrasında hem fiziksel anlamda hem de zihinsel anlamda yorgunluğu ortaya çıkarır. 4857 Sayılı İş Kanunu'na göre çalışan bir bireyin ortalama 9 saati işyerinde geçer. Bu sayı günün neredeyse üçte birine denk gelir. Bu durumda zihinsel yorgunlukta aslında belirleyici nokta sahip olunan çalışma koşulları olduğu düşünülebilir.


Teknolojik gelişmelerin günden güne hızlandığı günümüz dünyasında işletmeler, tüketici ihtiyaçlarını daha hızlı tedarik etme felsefesinde evrimleşmeyi amaç edinmişlerdir. Bu geçişin artı noktaları kadar çalışanı ilgilendiren eksi yönleri de mevcuttur. Bazı işletmelerde özellikle hizmet sektörü gibi çalışma alanlarında olması gerekenden fazla iş yükü, aynı anda birden fazla işle meşgul olma süresi gittikçe artmaktadır. Bir de bunlara yapılan işin hangi boyutta tehlikeli olduğu ve durumsal farkındalığın hangi derecede önem arz ettiği yüksek risk barındıran çalışma şartları eklendiğinde çalışanın ve işin güvenliğini ön planda tutmak büyük önem taşır. Ülkemizde Türkiye İstatistik Kurumu'nun gerçekleştirdiği 2010-2021 yılları arasındaki mental ve davranış bozukluklarından kaynaklı erkek ve kadın ölümleri istatistiklerine göre her ne kadar tüm ölüm nedenlerine oranla düşük olsa da zihinsel ve davranışsal bozukluklardan kaynaklı ölümlerin ortalama 507 olduğu görülmüştür. Şekil 2.3'te görüldüğü üzere kadınlara kıyasla erkeklerdeki ölümler daha fazla olup en çok ölümler 2012 yılında gerçekleşmiştir.



Şekil 2.3 : TÜİK 2009-2021 Yılları Arasında Meydana Gelen Ölüm İstatistikleri

Ülkemizde ve dünyada meydana gelen iş kazalarının kök analizinde ana etkenin insan faktörü olduğu bilinmektedir. Bunu çalışma sistemi, çalışılan yerin fiziki koşulları ve çevresel faktörler takip eder [40]. Ancak bazı çalışmalar kaza kök nedenin insana bağlı olduğundan daha da ileri giderek fiziksel ve özellikle zihinsel yorgunluğun birincil etmen olabileceğini savunmuşlardır [41]. Araştırmaya göre çalışanın algısında yorgunluktan kaynaklı meydana gelen kayma ve çevresel etkilere karşı geç yanıt verme durumu tespit edilebildiği takdirde birçok kazalar önlenabilir. Algıda meydana gelen olumsuz yöndeki bu değişimin altında yatan nedenler yetersiz uyku, fazla iş yükü, birden fazla işle ilgilenmek gibi faktörlerdir. Bu durumların en çok denk geldiği çalışma grupları vardiyalı çalışanlar, mevsimlik çalışanlar, çağrı merkezinde ve sağlık hizmetlerinde çalışan insanlardır. Bu sektörlerde öngörülebilir kazaları tahminleme ve önleme amaçlı birçok çalışma yapılmıştır [42], [43]. Araştırmaların odak noktası ise zihinsel yorgunluğa sebep olabilecek iş yükünün analiz edilmesidir.

İnsan faktörlü meydana gelen dünyadaki iş kazalarının sektörel tabanlı dağılımı genel olarak incelendiğinde ilk sıralarda üretim, tarım, ormancılık, balıkçılık faaliyetleri ve inşaat sektörü gelir [44]. İlk ondaki diğer sektörler Şekil 2.4'te olduğu gibidir.



Şekil 2.4 : İş Kazalarının Sıklıkla Meydana Geldiği İlk 10 Sektör

Şekil 2.4'ü destekler nitelikte olan ve ülkemizde meydana gelen iş kazalarının sektör bazlı dağılımını inceleyen araştırmalarda inşaat sektörünün ilk sırada yer aldığı görülür. Bunu ağır metal, maden, taşımacılık, sağlık sektörleri takip eder. Sektörlerin barındırdıkları risklerin CRITIC yöntemiyle saptanan ağırlıklar ile analiz etmeyi amaçlayan bir çalışmada, bahsi geçen bu sektörler iş sağlığı ve güvenliği açısından riskli bulunmuş öncü sektörlerdir [45]. CRITIC yöntemi, çok kriterli karar verme yöntemlerinden bir tanesidir ve araştırmada belirlenen 7 kriter üzerinden yapılan risk analizinde kendisinden faydalanılmıştır. Özetle insanın, günden güne büyüyen iş hacmini büyük ölçüde karşılayan en önemli kaynak ve aynı zamanda meydana gelen kazaların temel faktörü olduğu açıkça ortadadır.

Havacılık endüstrisinde insan faktörlü meydana gelen kazaların nedenlerine dair yapılan analiz ve sınıflandırma çalışmaları mevcuttur [46]. Sektörde sık kullanılan bu sistemde faktörler 4 seviyeli hata olarak kategorize edilmiştir [47]. Bu kategorilerden emniyetsiz davranışlar ve emniyetsiz davranışlara zemin hazırlayan koşullar incelendiğinde doğrudan zihinsel yorgunlukla ilişkili olduğu görülmüştür. Emniyetsiz davranışlar kategorisinde yer alan karar hataları ve algılama hataları doğrudan bilişsel performansa dayalı meydana gelen hatalar olduğu saptanmıştır. Benzer şekilde emniyetsiz davranışlara zemin hazırlayan koşullar kategorisinde kokpit ekibinin koşulları zihinsel yorgunlukta meydana gelebilecek olumsuz faktörleri içerdiği gözlemlenmiştir. Dikkat dağınıklığı, aceleci davranma, durumsal farkındalığın zayıflaması ya da kaybolması, görev doygunluğu gibi kötü zihinsel durumlar bu faktörlerdendir [48]. Bu gibi insan faktörlerini analiz ve sınıflandırma sistemleri proaktif olmadığı için kazaları önlemede geç kalma durumu ortadan kaldırılamamıştır. Zihinsel yorgunluğun tespitine dayalı çalışmaların bu tarz sistemlere giydirilmesi ile proaktif hale getirilme ve önceden tahminleme günümüz akıllı sistemleriyle mümkün olabilmektedir.

Yüksek risk barındırdığı için denizyolu taşımacılığı iş sağlığı ve güvenliği uzmanları tarafından çok tehlikeli iş olarak nitelendirilir. Ticaret ve iş hacmi bakımından ulusal ve uluslararası boyutta katkısı çok olan bu sektörün, sürdürülebilir faaliyet göstermesi önemlidir. Bu temel bakış açısı doğrultusunda limanlardaki iş kazalarının insan faktörlü hata nedenlerinin araştırıldığı bir çalışmada bilgisizlik ve eğitim eksikliğinden sonra dikkat dağınıklığı, yorgunluk, mesleki tükenmişlik gibi zihinsel yorgunluk belirtilerinin olduğu gözlemlenmiştir [49]. Araştırma sonucuna göre bilgidan sonra en önemli faktörün zihinsel durum farkındalığı olduğu görülmektedir.

Özetlemek gerekirse tüm iş kollarının ana kaynağı insan faktörüdür. Sürdürülebilir iş felsefesinde bu faktör ne kadar verimli olursa firmaya ekonomik anlamda o denli olumlu kazanımlar sağlar. Bu faktör fiziksel olduğu kadar zihinsel olarak da ayakta tutulmalıdır. Bu durum motivasyon ve işin başarılı sonuçlanması açısından kritik öneme sahiptir. Bu tez çalışması ile insanların olası zihinsel yorgunluğu meslek ya da sektör farketmeksizin tespit edilip birçok hasarın önüne geçilmesi hedeflenmiştir. Sektör bağımsız tüm iş kollarına uyarlanabileceği için güvenliğin birçok boyutta örneğin milli güvenlik, iş güvenliği, insan güvenliği vb. alanlarda yüksek seviyede tutulmasını sağlayacak ve başta sağlık olmak üzere ülke ekonomisini sürdürülebilir kılmada etken rol oynayacağı düşünülmüştür.


2.2.2. Zihinsel Yorgunluğun Tespitine Dayalı Çalışmalar

Zihinsel yorgunluk tek başına ele alınabilecek bir çalışma alanı değildir. Şekil 2.1.1'de olduğu üzere bu yorgunluk tipine sebep olabilecek birçok faktör söz konusu olduğu için çok yönlü ele

alınması gerekir. Bireyin uyku durumundan, motivasyonundan, iş yükünden, dikkat eksikliğinden etkilenir [28]. Tezin bu kısmı, zihinsel yorgunluğu ölçümlemek için şimdiye kadar yapılan çalışmaların genel özetini içerir.

2.2.2.1. Kullanılan Yöntemlere Göre

Literatürde zihinsel yorgunluğu tespit etme amaçlı yürütülen çalışmalar ya da metotlar üç genel başlık altında yürütülmüştür [50], [51]. Bunlar matematiksel tabanlı, kural tabanlı, makine öğrenmesi ve derin öğrenme modelleri ile kurulmuş metot ve tekniklerdir. Bu tekniklerde kullanılan algoritma ve yaklaşımlar Şekil 2.5'te özetlenmiştir.



Şekil 2. 5 : Zihinsel Yorgunluğun Tespitinde Kullanılan Genel Yöntemler

Matematiksel modeller çoğunlukla yorgunlukta bireyin uyku durumunun ne kadar etkili olduğu üzerine çalışılmış modellerdir. Uyku döngüsündeki herhangi bir kırılmanın performansa etkisi ölçülmüştür. Ayrıca yorgunluğun seviyesini belirlemede uyku süresi, uyanıklık süresi, uyku periyodu geçmişi ve insanın günlük faaliyetlerini bir düzen içerisinde yapmasını sağlayan biyolojik saati gibi özelliklerle ilişkisi incelenmiştir. Bu modelde ilk tasarlanan yaklaşım 2 süreç modelidir [52]. Çevresel gelişen olumlu ya da olumsuz durumlara karşı hemoastatik denge ve biyolojik saat aktiviteleri referans alınarak yorgunluk seviyesi ölçümlenmiştir. Bu model daha sonra 1995 yılında 3 Süreç Modeli verilen sistem olarak güncellenmiştir [53]. 3 süreç modeli sürücünün yorgunluk ve uyanıklık seviyesini uyku ve uyanıklık süresini temel alarak tahminlemeye çalışan bir sistemdir. Benzer durum pilotlarda da söz konusu olabileceği için bu iki model genişletilerek pilotlarda yine aynı parametreler kullanılarak yorgunluk seviyesi tahminleme modelleri geliştirilmiştir [54], [55]. Bu modelin ayırıcı noktası gerçek zamanlı verilerle test edilmesidir. Matematiksel modelli yaklaşımlar, uzun çalışma saatlerinin yoğun olduğu sektörlerde kullanılması uygun yaklaşımlardır. Akıllı sistemlerin gittikçe arttığı günümüz teknolojisinde araştırmaların daha derinleşmesi gerektiği düşünülerek farklı yöntemler geliştirilmiştir.

Zihinsel yorgunluğu tespit etmede uygulanabilirliği açısından daha kolay olan kural tabanlı yaklaşımlar da bulunmaktadır. Bu tür teknikler için bulanık çıkarım sistemleri (FIS) algoritmaları temel alınır [56]. Yorgunluk tespitinde doğru çıktı üretmek için bulanık kurallar ve üyelik fonksiyonları mevcuttur. Girdi olarak bireyin ağız ve göz durumu kullanılmış ve sistem normal, yorgun, tehlikeli olmak üzere üç farklı çıktı üretmiştir [57]. Göz durumu için göz kırpması, kapalı ve uykulu gibi sınıflandırma yapılırken ağız durumu normal ve esneyen ağız olarak sınıflandırılmıştır. Bir başka çalışmada bulanık çıkarım sistemi iki katmanlı tasarlanmış ve yine ağız ve göz durumu girdi olarak kullanılmıştır [58]. Kural tabanlı bulanık çıkarım sistemlerinin tercih edilmesinin en önemli sebebi verilerde paralel işlemler yapılmasının mümkün olmasıdır.

Makine öğrenmesi algoritmaları her alanda olduğu gibi zihinsel yorgunluk tespitine dayalı çalışmalarda da sıklıkla tercih edilmiştir. Kısa sürede yüksek doğrulama ve tahminleme sağlanır. Bu kategoride yapılan çalışmalar sıg ve derin modeller olarak tasnif edilmiştir [50]. Sıg modellerde tek bir gizli katmanı olan yapay sinir ağları ve destek vektör makineleri algoritmaları kullanılmıştır. Öğrenme prensibi bakımından tıpkı insan beyni gibi davranan yapay sinir ağları kendi içerisinde denetimli, denetimsiz ya da pekiştirmeli öğrenme mekanizması üzerine kuruludur. Daha kısa sürede yüksek performans verdiği için yorgunluk tespit sistemlerine dahil edilmiştir [59], [27]. Parametre olarak elektroensefalografi (EEG) [25], direksiyon tutuşu [60] belirlenip yapay sinir ağında eğitilmiştir. Bir başka çalışmada EEG verisi alfa, teta, beta ve delta bandına ayrıştırılıp yorgunluk tespit edilmeye çalışılmıştır [26].

Makine öğrenmesi tabanlı derin modellerde verilerden öznitelik çıkarma performansı daha yüksek olduğu için zihinsel yorgunluk tespit etmede tercih edilen diğer yöntemlerdir. Evrişimsel sinir ağları (CNN) bu çalışmalarda ilk kullanılan derin öğrenme tekniklerindendir [61]. Bireyin yüz ifadesi, esneme durumu ve ağız durumu parametre olarak evrişimsel sinir ağında eğitilerek yorgunluk tespit edilmeye çalışılmıştır [62], [63].

Matematiksel, kural ve makine öğrenmesi tabanlı geliştirilen bu yöntemler ile daha çok uyku durumu üzerinden fiziksel yorgunluk ve zihinsel yorgunluk ölçümlenmeye çalışılmıştır. Tez çalışmasında önerilen yaklaşım olarak, geleneksel makine öğrenmesi uygulamalarının şu an en çok tercih edilen yöntemleri olan derin ve transfer öğrenme yöntemleri kullanılmış, bu yöntemlerde hem beyin hem kalp hem de deri iletkenliğine dayalı sinyallerin tamamı işlenerek zihinsel yorgunluk tespit etme sistemi modellenmeye çalışılmıştır.

2.2.2.2. Kullanılan Girdilere Göre

Zihinsel yorgunluk bir yorgunluk tipi olarak biyolojik özelliklere göre, kullanılan araç ya da makine özelliklerine göre ve fiziksel özelliklere göre gruplandırılabilir [51]. Bazı çalışmalarda bu kategorilere ek olarak subjektif raporlama ve hibrit çalışmalar eklenmiştir [50].

Fiziksel özellikler temel alınarak geliştirilen sistemlerde yüz, göz, ağız ve başın bulunduğu farklı durumlar girdi olacak şekilde modellemeler önerilmiştir [29], [64]. Bu girdilerden esneme, göz hareketlerinde yavaşlık, göz kırpmada sıklık gibi çeşitli öznitelik çıkarımı yapılarak veri kümesi daha da genişletilmiştir.

Kullanılan araç ya da makineden elde edilen öznitelikler kullanılarak modellemeler yapılan çalışmalarda şeritten sapma durumu ya da basınç sensöründen elde edilen veriler

kullanılmıştır. Sapma ne kadar fazlaysa ya da basınç büyüklüğü ne kadar azsa yorgunluk durumu pozitif olarak saptanmıştır [50].

Bir diğer kategori ve aynı zamanda bu tez çalışmasının ana unsuru olan biyolojik veriler kullanılarak da zihinsel yorgunluk tespit edilmeye çalışılmıştır. Bu biyolojik veriler bireyin çeşitli organlarından alınan fizyolojik sinyal verileridir. Bu sinyallerden bir sonraki bölümde detaylıca bahsedilmiştir.

2.2.3. Zihinsel Yorgunluk ve Fizyolojik Sinyaller Arasındaki İlişki

Zihinsel yorgunluk temele inildiğinde insan duygu durumunun kritik eşiği aştığı yoğun seviyedir. Son yıllarda duygu analizine yönelik çalışmalarda fizyolojik sinyal verileri çokça tercih edilmiş ve edilmeye de devam etmektedir. Bu açıdan düşünüldüğünde yoğun duygu durumunun hissedildiği zihinsel yorgunluğun, duygu tanımlamada kullanılan fizyolojik sinyal verileriyle tespit edilmesi mümkündür. Literatürde buna benzer yapılan çalışmalar incelendiğinde en çok beynin fizyolojik aktivitesini ölçümleyen EEG, kalbin fizyolojik aktivitesini ölçümleyen EKG, PPG ve HRV, göz hareketlerini inceleyen elektromyogram (EMO) sinyallerinin kullanıldığı görülmüştür. Bu sinyaller ve nasıl kullanıldıkları sınıflandırılarak alt başlıklarda sunulmuştur.

2.2.3.1. Kalp Sinyali Tabanlı

Kalbin ritim, frekans, atış ritmi gibi elektriksel aktivitesinin kaydedildiği dalga formuna elektrokardiyografi (EKG) adı verilir. Bu sinyal kullanılarak çeşitli duygu durumlarının kalbe etkisi ölçümlendiği gibi zihinsel yorgunluk durumunda kalbin nasıl tepki verdiğini ölçümleyen çalışmalar da mevcuttur [65], [66]. Bu sinyal verisinden çıkarılan öznitelikler aracılığıyla zihinsel yorgunluğu tespit eden sistemlerde doğruluk daha da artırılmıştır. Bu öznitelikler kalp atış hızı (HR) ve bu hızdaki değişkenlik (HRV) parametreleridir. Yorgunluğun tespit edildiği durumlarda kalp atış hızındaki değişiklikliği gösteren parametrenin arttığı gözlemlenmiştir. EKG ölçümü vücuda giydirilen elektrotlarla sağlandığı için gerçek zamanlı ölçüm gerektiren durumlarda müdahale edilmesi gerektiğinde ölçümlemeyi ya da deney yapanı zorlayabilir. Bu durumu çözmek için EKG yerine fotopletismografi (PPG) sinyal verisi kullanılmıştır. Fotopletismografi kalbin elektriksel faaliyetlerini takip eden deri üzerindeki ışık şiddeti değişimlerini tutan sinyal verisidir. Kalp anomalileri tespitinde PPG'den alınan kalp atış hızı, kalp atış hızı değişikliği ve kan basıncı verileri kullanılmaktadır [67].

2.2.3.2. Beyin Sinyali Tabanlı

İnsan beyninde yapılan her bilişsel aktivite sonucu bir elektriksel alan meydana gelir. Bu elektriksel alanda oluşan faaliyetleri ölçümlemek için geliştirilen yöntemlerden bir tanesi de elektroensefalografidir (EEG). Bu ölçüm aracı gerek maliyeti gerekse insan vücuduna zararı bakımından diğer tekniklere [68], [69] göre sıklıkla tercih edilmektedir [70], [71]. Beynin fizyolojik yapısından daha çok işlevselliği hakkında bilgi verdiği için zihinsel yorgunluk oluştuğu durum saptanabilir. EEG'den yayılan dalgalar frekanslarına göre farklı dalga boylarında sınıflandırılır [72]. Bu dalgalar ve sahip olduğu frekans aralıkları Tablo 2'de gösterilmiştir. Bu dalga boyları dinlenme, uyku ya da göz kapalı durumlarında farklı salınım yaparak birbirlerinden ayırt edilebilirler. Örneğin; yoğun uyarılma ya da dikkat durumunda gama sinyalleri üretilirken, zihinsel aktivitelerin çok olduğu evrede beta sinyalleri üretilir. Yine uykuda değilken sakın evrede alfa sinyalleri belirginleşirken derin uykuda en yavaş dalga olan delta sinyalleri, normal uyku durumunda teta sinyalleri görünür hale gelir [73].

Tablo 2 : EEG Dalga Tipleri

Dalga Tipi	Frekans Aralığı (Hz)
Delta	0.5-4 Hz
Teta	4-8 Hz
Alfa	8-13 Hz
Beta	14-30 Hz
Gama	30-50 Hz

2.2.3.4. Göz Sinyal Tabanlı

Göz hareketleri ve davranışları bazı faktörlerden kolaylıkla etkilenebildiği için zihinsel yorgunluğun göz sinyalleri üzerinden tanımlanması ya da tespit edilmesi oldukça güçtür. Bununla birlikte gözle ilgili bazı göstergeler zihinsel yorgunluk bulguları ile paralellik gösterebilir. Ancak güvenilir bir çıkarım için diğer fizyolojik sinyallerle birlikte değerlendirilmesi gerektiği unutulmamalıdır. Zihinsel yorgunluğu göz sinyallerine bağlı tespit ve analiz etmeyi amaçlayan bazı çalışmalarda kullanılan metrikler göz kırpma hızı ve sıklığı, göz bebeğinin boyutunda meydana gelen değişiklikler, gözdeki anormal hareketlerdir. Zihinsel yorgunluk durumunda göz kırma hızında azalma ve seyrelme [74], otonom sinir sisteminden etkilendiği için göz bebeğinin boyutunda azalma, nesne takip edilmesi gerekli durumlarda göz hareketlerinde azalma gibi belirtiler gösterir [75]. Ancak başlı başına sadece göz ve buna bağlı hareket ve sinyalleri zihinsel yorgunlukla ilişkilendirmemek gerekliliği yine bu çalışmalarda aktarılan bir diğer husustur.

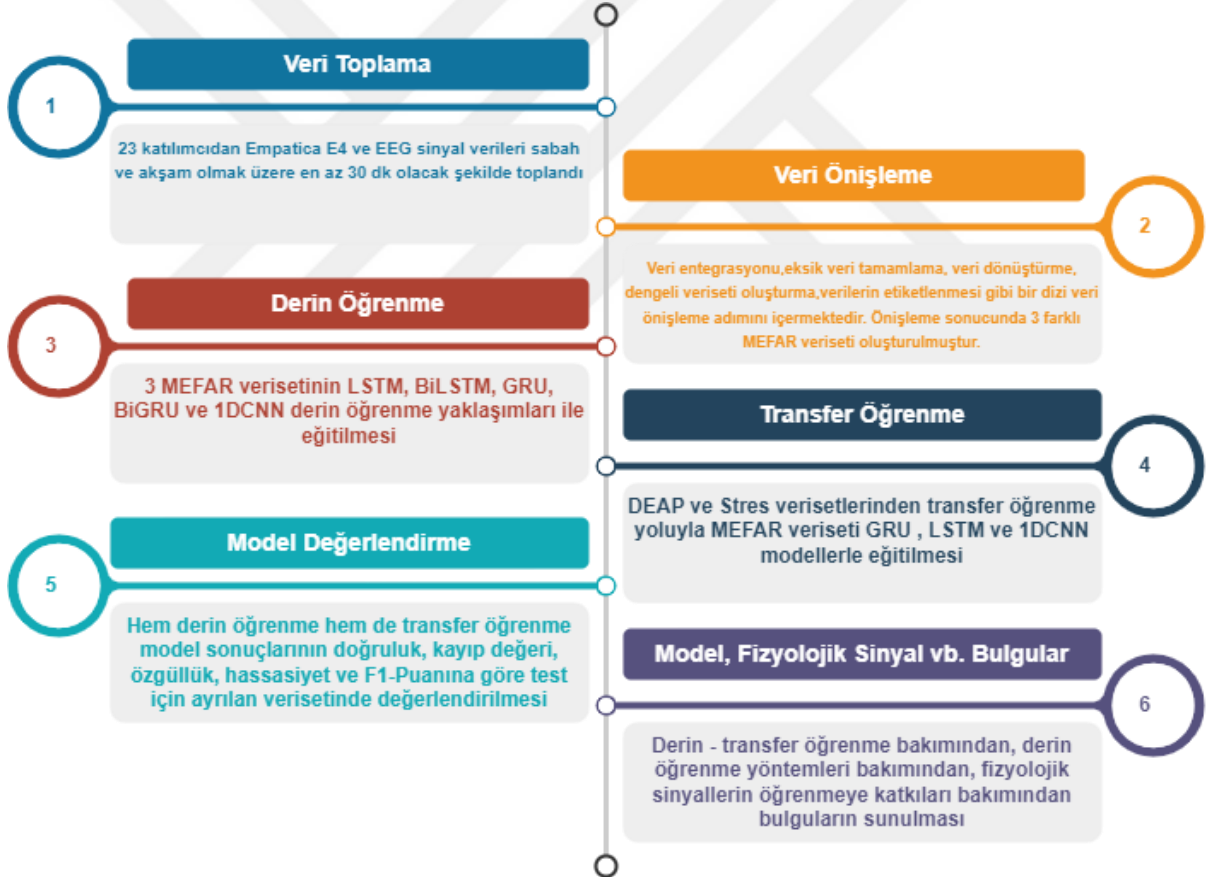
Kaynak taramasında elde edilen tüm bilgiler sentezlenerek tez çalışmasında hangi gereç ve yöntemlerin kullanılacağı belirlenmiştir. Bu çalışma için zihinsel yorgunluğun fizyolojik sinyal tabanlı analiz edilmesi, daha kolay ve uygulanabilir bulunmuştur. Toplanan sinyal verilerinin derin modeller ile eğitilmesi sığ modellere göre daha iyi sonuçlar ürettiği için derin öğrenme yöntemleri tercih edilmiştir. Ayrıca bir çeşit duygu olan zihinsel yorgunluğun tanımlanabilmesi için duygu tanıma sistemlerinde kullanılan verisetlerinden yararlanılarak transfer öğrenme yaklaşımları geliştirilmiştir.

3. GEREÇ VE YÖNTEMLER

Zihinsel yorgunluk bulgularının fizyolojik sinyallere dayalı analizine yönelik yapılan tez çalışmasının bu kısmında yapılacak araştırmaların tasarımından, veri toplama protokolünden, veri ön işleme adımlarından, uygulanan derin ve transfer öğrenme tekniklerinden, model performans ölçme metriklerinden bahsedilmiştir.

3.1 Araştırma Tasarımı

Bu tezin amacı zihinsel yorgunluk bulgularını fizyolojik sinyallere dayalı geniş ölçekli analiz etmek ve toplanan sinyaller ile zihinsel yorgunluğu günümüz yapay zeka teknolojileri ile tanımlamaktır. Araştırma tasarımında, Şekil 3.1’de verilen yol haritasına bağlı kalınarak birtakım sorular ve hipotezler belirlenmiştir. Bu temel amaç doğrultusunda belirlenen araştırma soruları ve hipotezler, veri toplama yöntemleri ve örneklem seçimleri bu başlık altında incelenmiştir.



Şekil 3. 1 : Tez Çalışması İçin Belirlenen Yol Haritası

3.1.1. Araştırma Soruları ve Hipotezler

Tez çalışmasında cevap aranılacak araştırma soruları şu şekildedir:

- S1.** Zihinsel yorgunluğun kişinin yaş, cinsiyet, çalışma şekli, çalışma saati, egzersiz, uyku durumu gibi özelliklerle ilişkisi nedir?

- S2. Zihinsel yorgunluk, fizyolojik sinyalleri nasıl ve ne derece etkilemektedir?
- S3. Zihinsel yorgunlukta hangi fizyolojik sinyaller daha belirleyici olmaktadır?
- S4. Hangi sinyal frekans sıklığı zihinsel yorgunluğu tespit etmede daha belirleyicidir?
- S5. Zihinsel yorgunluk derin öğrenme teknikleri ile nasıl tanımlanmaktadır?
- S6. Transfer öğrenme teknikleri ile zihinsel yorgunluk tespitinin başarımları oranı nedir?

Tez çalışması kapsamında ortaya sürülen hipotezler şu şekildedir:

- H1. Çalışanın çalışma şekli, uyku durumu, çalışma saati zihinsel yorgunlukla doğrudan ilişkilidir.
- H2. Zihinsel yorgunluk bulgularının tespitinde Empatica E4 sinyalleri de etken faktördür.
- H3. Fizyolojik sinyalin saniyede örnek üretme sıklığının artması zihinsel yorgunluğun tespit edilmesinde başarı düzeyini artırır.
- H4. Son teknolojik yapay zeka yöntemleri ile zihinsel yorgunluk tespiti yüksek doğrulukla sağlanır.
- H5. Duygu tanıma sistemlerinde kullanılan verisetlerinden transfer öğrenme yapmak, zihinsel yorgunluk tespit etmedeki başarımları ve performansı artırır.

3.1.2. Veri Toplama Yöntemleri

Çalışmanın veri toplama yöntemi, yorgunluğu tespiti dayalı ölçek ve giyilebilir teknolojiler üzerinden sağlanmıştır. Bu aşamada demografik bilgi anketi ile birlikte yorgunluk değerlendirme anketi katılımcılara uygulanmıştır.

Demografik Bilgi Anketi

Tez çalışmasında katılımcılardan, zihinsel yorgunluğun farklı demografik gruplar arasında nasıl değişebileceğini anlamak amacıyla birtakım bilgiler toplanmıştır. Bu bilgilerden elde edilecek bulgular, zihinsel yorgunlukla ilgili eğilimleri ve risk faktörlerini belirlemede kullanılacaktır. Çalışmaya katılanlardan demografik ölçeklendirme yapabilmek için öncelikle birtakım verileri girmeleri beklenmiştir. Bu bilgiler şu şekildedir:

- Yaş
- Cinsiyet
- Eğitim durumu
- Meslek
- Çalışma şekli
- Çalışma saati
- Medeni hali

- Uyku durumunun düzenliliği
- Maaş skalası
- Kronik rahatsızlık durumu
- Sigara içme durumu
- Egzersiz düzenliliği
- Kaç saat uyuduğu

Yorgunluk Değerlendirme Ölçeği

Demografik bilgiler alındıktan sonra katılımcılara yorgunluk ölçeklendirmesinin yapılabilmesi için literatürde geçerlilik ve güvenilirlik testinin yapıldığı ve sıklıkla bu tür çalışmalarda kullanılan Chalder yorgunluk değerlendirme soruları yöneltilmiştir.

Chalder Ölçeği, 1993 yılında Trudie Chalder ve ekibi tarafından geliştirilmiş olup kronik yorgunluk sendromu teşhisi için kullanılan bir ölçek aracıdır. [76] Kronik yorgunluk sendromu (KYS), uzun süreli ve açıklanamayan aşırı yorgunluk, fiziksel aktivitelerden sonra halsizlik, uyku bozuklukları, hafıza sorunları, konsantrasyon güçlüğü, baş ağrısı ve kas ağrıları gibi semptomlarla karakterize bir hastalıktır. Chalder Ölçeği'nde, yorgunluk semptomlarının yaygınlığı ve şiddetini belirlemek için hazırlanmış bir dizi sorular yer alır. Sorular, kişinin günlük aktivitelerini, yorgunluk düzeyini, uykuya dalma zorluğunu, diğer semptomları içermekte olup zihinsel ve fiziksel yorgunluğu ölçmeye dayalı iki ana gruptan oluşur. Ölçekte yer alan soruların Türkçe'ye uyarlanmış hali aşağıda olduğu gibidir [5]:

- Yorgunlukla ilgili sorunlarınız var mı?
- Dinlenmeye ihtiyaç duyuyor musunuz?
- Kendinizi uykulu veya uyuşuk hissediyor musunuz?
- Bir şeye başlamakta sorun yaşıyor musunuz?
- Enerjinizde azalma hissediyor musunuz?
- Kaslarınızın kuvvetinde azalma hissediyor musunuz?
- Kendinizi güçsüz hissediyor musunuz?
- Konsantre olmakta zorlanıyor musunuz?
- Konuşurken diliniz sürçüyor mu?
- Konuşurken doğru sözcüğü bulmakta zorlanıyor musunuz?
- Hafızanız nasıl?

Bu sorulardan ilk 7'si fiziksel yorgunluk belirtilerini, son 4'ü zihinsel yorgunluk belirtilerini ölçmeye yöneliktir. Ölçeğin derecelendirilmesi 4'lü likert ölçeklendirmeyi içerir ve 0-3 arasında bir puan alır (0 puan her zamankinden daha az, 1 puan her zamanki kadar, 2 puan her

zamankinden daha fazla, 3 puan her zamankinden çok daha fazla olmak üzere). Ölçek değerlendirmesine göre 12 ve üzeri likert sonucu, bireyin fiziksel ve zihinsel anlamda yorgun olduğunu göstermektedir.

Yorgunluğu ölçmeyi ve tespit etmeye dayalı geliştirilen bu gibi ölçeklerde en önemli kısım geçerlilik ve güvenilirlik testlerinin yüksek doğrulukla yapılmış olmasıdır. Tez çalışmasında Chalder Yorgunluk Ölçeği'nin tercih edilmesinin birincil nedeni bu testlerden başarılı bir şekilde geçmiş olmasıdır. Ölçeğin geçerlilik ve güvenilirlik testi geliştirildiği ilk çalışmada değerlendirilmiştir. Daha sonraki yıllarda da Chalder ölçeğinin geçerlilik ve güvenilirliği birçok kez test edilmiştir [77], [78]. Bu ölçeğin Türkçe adaptasyonu en yenilerde Rıdvan Muhammet Adın ve arkadaşları tarafından yapılmıştır. Yapılan çalışmada ölçeğin Türkçe adaptasyonu ve genç yetişkin bireylerde psikometrik özelliklerinin incelenmesi amaçlanmıştır. Çalışma sonucunda Chalder Yorgunluk Ölçeği'nin Türkçe formunun genç yetişkinlerde geçerli ve güvenilir bir ölçme aracı olduğu bulunmuştur. [79]

Giyilebilir Cihazlardan Veri Aktarımı

Tez çalışması istatistik veri analizinin yanında asıl olarak fizyolojik sinyal analizini içermektedir. Katılımcılardan fizyolojik sinyalleri toplamak için 2 ayrı giyilebilir cihaz kullanılmıştır. Bunlar Empatica E4 akıllı bileklik ve NeuroSky MindWave EEG cihazlarıdır.


Empatica E4, bir giyilebilir sağlık teknolojisi cihazıdır. Kalp atış hızı, elektro-dermal aktivite, hareket, sıcaklık verileri gibi bir dizi biyolojik parametreyi ölçmek için tasarlanmıştır. Bu cihaz insanların sağlık ve performans verilerini izlemelerine [80], kaydetmelerine ve analiz etmelerine olanak tanır [81]. Veriler kablosuz olarak bir akıllı telefon uygulamasına veya bilgisayara aktarılarak analiz edilir. Bileklik ve uygulama arayüzü Şekil 3.2'de verilmiştir.



Şekil 3. 2 : Empatica E4 Akıllı Bileklik ve Mobil Uygulama Arayüzü

NeuroSky MindWave ise, insan beyin dalgalarını ölçmek ve bunları bir bilgisayar programına aktarmak için tasarlanmış bir EEG (Elektroensefalografi) cihazıdır. MindWave, beyin

dalgalarını algılamak için birkaç elektrot kullanır ve beyindeki sinir aktivitesinin frekansını ölçer. Bu frekanslar, meditasyon, dikkat, konsantrasyon gibi zihinsel durumların göstergeleri olarak kullanılırlar. MindWave, bir kafa bandı şeklindedir ve kablosuz olarak bir bilgisayara veya mobil cihaza bağlanabilir. Kullanılan EEG cihazı ve sinyal izleme emülatörü Şekil 3.3’de verilmiştir.



Şekil 3. 3 : NeuroSky MindWave EEG Cihazı ve Bilgisayar Uygulama Arayüzü (Emülatör)

3.1.3. Örneklem Seçimi

Tez çalışması kapsamında çalışmaya katılan bireylerin herhangi bir işte çalışıyor olması birincil ve tek koşuldur. Bu nedenle 18-40 yaş aralığındaki çalışan 23 katılımcı örneklem için seçilmiştir. Bu katılımcılar akademisyen, bilgisayar mühendisi, elektrik teknikeri ve mutfak çalışanı olmak üzere 4 farklı meslek grubundan oluşmaktadır.

3.2 Veriseti

Çalışma çerçevesinde akademisyen, bilgisayar mühendisi, elektrik teknikeri ve mutfak çalışanı olmak üzere 4 farklı meslek grubundan 23 çalışan bireye demografik bilgi anketi soruları, Chalder yorgunluk ölçme soruları yöneltilerek en az 30 en çok 36 dakika olacak şekilde fizyolojik sinyal ölçümü yapılmıştır. Empatica E4 akıllı bileklik sol bileklerine, NeuroSky MindWave EEG cihazı kafalarına giydirilmek suretiyle sinyal ölçümleri tamamlanmıştır. Bu veri toplama protokolü rutin çalışma düzenleri etkilenmeden kendilerine sabah ve akşam olmak üzere 2 defa uygulanmıştır. Her bir ölçümden önce katılımcılardan yorgunluk ölçme anketinde yer alan soruları anlık ruh hallerini göz önünde bulundurarak cevaplandırmaları istenmiştir. Bu ölçümler neticesinde elde edilen Empatica E4 ve EEG sinyal verileri birleştirilerek tüm veriseti oluşturulmuştur.

3.2.1. Empatica E4 Verileri

Empatica E4, bir giyilebilir sağlık teknolojisi cihazıdır ve birçok biyolojik parametreyi ölçebilir. Bu parametreler şunlardır:

BVP - Kan Basıncı : Kalp atış hızını ölçen sinyaldir. Stres ya da gerginlik seviyesinin fazla olması halinde meydana gelen kalp atış hızı değişimleri, bu sinyal ile tespit edilebilir. Bu sinyalin örnek aralığı 64 Hz'dir.

EDA - Cildin Elektriksel Aktivitesi : Cildin elektriksel aktivitesini ölçmek için kullanılan sinyal verisidir. Cilt yüzeyindeki direnç, terleme, stres, duygu durumu, fiziksel aktivite ve diğer faktörlere bağlı olarak değişebilir. Bu sinyal verisi ile stres veya duygu durumları ile ilgili ölçümler yapılabilir. Bu sinyalin örnek aralığı 4 Hz'dir.

ACC - İvmeölçer : Hareketi ve aktivite düzeyini ölçmek için kullanılan sinyal verisidir. Bu sinyal verileri sayesinde bireyin aktivite seviyesi, adım sayısı, hareketlilik durumları ölçülebilir. Bu sinyalin örnek aralığı 32 Hz'dir.

HR - Kalp Atımı : Kalbin dakikada kaç kez attığını ölçen sinyaldir. Bu sinyal verileri, bireyin fiziksel aktivite seviyesini ve genel sağlık durumunu takip etmek için kullanılır. Bu sinyalin örnek aralığı ise 1 Hz'dir.

TEMP - Vücut Sıcaklığı : Cildin yüzey sıcaklığını ölçmek için kullanılan sinyal verisidir. Bu sinyal verileri bireyin ne kadar stresli olduğunu, egzersiz ve sağlık durumunu takip etmek için kullanılır. Bu sinyalin örnek aralığı ise 4 Hz'dir.

3.2.2. NeuroSky MindWave (EEG) Verileri

NeuroSky MindWave, beynin elektriksel aktivitesini izlemek için geliştirilen bir tür beyin dalgası ölçüm cihazıdır. Bu cihaz, elektroensefalogram (EEG) sinyalleri ile bilişsel faaliyetleri ölçerek bireyin zihinsel durumlarını ve aktivitelerini takip etmeye olanak verir. EEG cihazından elde edilen tüm sinyallerin örnek aralığı aynı olup 1 Hz'dir. Bu cihazdan ölçülebilen sinyal verileri şunlardır:

Delta beyin dalgaları: Dinlenme ve derin uyku esnasında yüksek frekans oluşturan beyin dalgalarındandır. Zihinsel yorgunluk olduğu anda beyin kendini dinlenmeye çekme ihtiyacı hisseder. Tam bu noktada delta dalgaları yüksek salınım yaparlar. Frekans aralığı 0.5 ve 4 Hz'dir.

Theta beyin dalgaları: Uykuya geçiş esnasında yüksek frekans üreten beyin dalgası olarak karakterize edilmiştir. Bilinçaltı ve hayal kurma işlevlerinin sıklaştığı evrede bu dalgalar yüksek salınım yaparlar. Frekans aralığı 4-8 Hz'dir.

Alpha1 beyin dalgaları: Bilişsel açıdan rahatlama, esneme ve stres seviyelerinde düşme anında kendini gösteren ve alfa dalgalarının bir alt bölümü olan beyin dalgasıdır. Gözler kapalı pozisyonda daha çok karakterize edilmiş bu dalga tipinin frekans aralığı 8-10 Hz'dir.

Alpha2 beyin dalgaları: Bilişsel konsantrasyon ve dikkatle ilişkilendirilen ve alfa dalgalarının bir diğer alt bölümü olan beyin dalgasıdır. Alfa1 dalgalarının hemen ardından ortaya çıkan bu dalga tipinin frekans aralığı 10-12 Hz'dir.

Beta1 beyin dalgaları: Bilişsel eforun artmasıyla kendini belli eden beta dalgalarının bir türüdür. Bilişsel uyanıklık ve dikkatle karakterize olmuş bu beyin dalgasının frekans aralığı 12-15 Hz'dir.

Beta2 beyin dalgaları: Beta dalgalarının bir diğer türevidir. Bilişsel uyanıklık ve dikkatin yanı sıra hafızayla ilgili de bilgi çıkarımı yapılmasını sağlayan beyin dalgasıdır. Dolayısıyla bu dalgadaki yüksek frekanstan, daha yüksek zihinsel faaliyet yapıldığı anlaşılabılır. Frekans aralığı 15-18 Hz'dir.

Gamma1 beyin dalgaları: Dikkat, hafıza, problem çözme ve yeni bilgi öğrenme gibi bilişsel faaliyetlerle ilişkilendirilen gamma beyin dalgalarının bir türevidir. Frekans aralığı 30-40 Hz'dir.

Gamma2 beyin dalgaları: Gamma dalgalarının ikincil türevidir. Dikkat, hafıza, problem çözme ve yeni bilgi öğrenme gibi bilişsel performans esnasında gamma1 dalgalarından daha yüksek frekans oluşturan dalga tipidir. Aynı zamanda duygu düzenleme ile karakterize edilebilen bu dalgaının frekans aralığı 40-50 Hz'dir.

Attention: Bilişsel faaliyetlerde belli bir göreve ve alana odaklanıldığı esnada dikkat mekanizmaları devreye girer. Birey dikkati çeken bir uyarıcı ile uyarıldığında, bireyin dikkat seviyesini ölçen sayısal ifade üretir. Bu sayısal sonuç ile zihinsel faaliyetler takip edilerek ne kadar dikkatli ya da dağınık dikkate sahip olduğuna dair bilgi çıkarımı yapılır.

Meditation: Bireyin zihnini boşaltmak istediği, stresten uzaklaşmaya ve bilişsel netliği yakalamaya çalıştığı zihinsel faaliyetlerin tamamı meditasyon olarak bilinir. Meditasyon yapıldığı esnada beta ve gamma dalgalarındaki salınım azalırken, theta ve alfa dalgalarının salınımı artar. Bu değişimi izleyen EEG cihazı meditasyon derinliğini ölçen sayısal ifade üretir. Bu ifadenin belirginliği, beynin kendini dinlenmeye çektiğini ve yeni bir bilgi öğrenemeyeceğini yansıtarak zihinsel yorgunluk ile ilgili çıkarım yapılmasını sağlar.

3.3 Veri Önışleme

Yapay zekaya dayalı kullanılan birçok tekniğin ilk adımı olan veri önışleme birçok sebep bakımından veri analizi çalışmalarının en önemli basamağını oluşturur. Veri analizinde eğitilen veriler ne kadar kaliteliyse öğrenme o derece yüksek doğrulukla sonuçlanır. Veri kalitesini artırmak için ham verilerin içerdiği tutarsızlıklar, eksik değerler veya aykırı değerlerin verisetinden temizlenmesi gereklidir. Verilerin uygunluğu veri önışleme için gerekli bir diğer adımdır. Veriler bu doğrultuda dönüştürülmeli ve istenen formata biçimlendirilmelidir. Ayrıca veri önışlemeden geçirilen verilerin yapay öğrenmede hesaplama verimliliğini artırdığı ve daha iyi karar verebildiği birçok çalışmada deneyimlenmiştir. Tüm bu temel sebepler ışığında zihinsel yorgunluğun fizyolojik sinyal tabanlı analizinde başvuru olan veri önışleme adımları şu şekildedir:

3.3.1 Veri Toplama

Tez çalışmasında kullanılan fizyolojik sinyal verileri Empatica E4 akıllı bileklikten ölçülen sinyaller ile Neurosky MindWave EEG cihazından toplanan beyin sinyalleridir. Bileklikten ölçülen sinyaller E4 real-time mobil uygulaması üzerinden bulut ortamına ve cihaza kaydedilmiştir. Bulut ortamında kaydedilen bu sinyaller, ilgili bulut ortamında csv dosyası şeklinde tutulmuştur. EEG cihazından alınan beyin sinyalleri ise NeuroExperimenter masaüstü uygulaması aracılığıyla bilgisayar ortamında yine csv dosyası şeklinde kaydedilmiştir.

3.3.2 Veri Entegrasyonu

Zihinsel yorgunluğun fizyolojik sinyallere dayalı analizinde tüm sinyallerin birleştirilmesi veri önışlemenin ikinci basamağını oluşturmıştır. Araştırma kapsamında incelenecek bir diğer soru farklı fekans sıklıklarında zihinsel yorgunluk tespiti ne kadar doğruluk ve hassasiyette ölçümlendiğini görmektir. Bu soruya yanıt verebilmek adına tüm sinyal verileri 3 farklı frekans sıklığına göre birleştirilmiştir. Mevcut sinyaller içerisinde örnek aralığı en yüksek olan 64 Hz ile BVP sinyali olup en düşük örnek aralığı 1 Hz ile HR ve EEG sinyal verileridir. Bu aralıklara göre, tüm sinyallerden her 3 dakikada son bir dakikalık örneklem alınarak 3 farklı MEFAR [82] veriseti (mental fatigue analysis and recognition-zihinsel yorgunluk analizi ve tanıma) oluşturulmuştur:

MEFAR_DOWN: Frekans örnek aralığı 1 Hz'e göre uyarlanmış sinyallerin birleştirilmesi ile oluşturulan ilk verisetidir. Bu verisetinin oluşturulmasında örneklem aralığı 1 Hz'den büyük olan sinyal verilerinin o saniyeye karşılık gelen örneklemi seçilmiştir. Örneğin BVP sinyali için 64. satır seçilirken ACC sinyali için 32. satır, TEMP ve EDA için 4. satır seçilmiştir. Diğer sinyaller olduğu gibi alınmıştır.

MEFAR_MID: Frekans örnek aralığı 32 Hz'e göre uyarlanmış sinyallerin birleştirilmesi ile oluşturulan ikinci verisetidir. Örneklem sıklığı 32 Hz'den düşük olan sinyaller için üst örnekleme yapılırken, 32 Hz'den yüksek olan sinyallerde alt örnekleme yapılarak karşılıkları hesaplanmış ve birleştirilmiştir. Örneğin 4 Hz'lik EDA sinyali bu veriseti için aynı veriyi 8 kez tekrar ettirirken, aynı saniyelere denk gelen 64 Hz'lik BVP sinyalinin son 32 satırlık verisi seçilerek veriseti oluşturulmuştur.

MEFAR_UP: Frekans örnek aralığı 64 Hz'e göre uyarlanmış sinyallerin birleştirilmesi ile oluşturulan üçüncü verisetidir. Bu sıklıkta sadece BVP sinyali örneklem üretmektedir. Diğer Empatica E4 ve EEG sinyalleri aynı saniyelere denk getirebilmek için üst örnekleme yapılmıştır. Örneğin EDA ve TEMP sinyallerinin saniyede ürettiği veriler 16 kez tekrarlanırken, ACC sinyalleri 2 kez, HR ve tüm EEG sinyalleri 64 kez tekrar ettirilmiştir.

3.3.3. Eksik Verilerin Tamamlanması

Veri birleştirme aşamasında birebir saniye karşılığı oluşturmak tüm sinyaller için neredeyse imkansızdır. Bu da bazı verilerin eksik kalması anlamı taşır. Eksik verilerin tamamlanması noktasında bu tür sıralı sinyal verilerinden oluşan verisetlerinde daha çok tercih edilen enterpolasyon yöntemi kullanılmıştır. Enterpolasyon, verisetinde diğer gözlemlerin değerlerine dayalı olarak eksik değerleri tahmin eden yöntemdir. Birçok çeşidi olan enterpolasyon yönteminin lineer fonksiyonu bu çalışmada kullanılmıştır.

3.3.4. Veri Dönüştürme

Verileri daha uygun hale getirmek ve aynı skalaya indirgemek için normalizasyon yapılmıştır. Normalizasyon tekniklerinden asgari-azami normalizasyon tekniği bu çalışmada uygulanan

veri dönüştürme yöntemidir. Gözlemlerde pozitif skor üreten sinyaller (0-1) aralığına sıkıştırılırken negatif skor üreten sinyaller (-1,1) aralığına sıkıştırılmıştır.

3.3.5. Verisetinin Dengeli Hale Getirilmesi

Dengesiz dağılan veriseti, sınıflandırmaya dayalı öğrenme mekanizmalarında öğrenme doğruluğunu ve güvenilirliğini olumsuz yönde etkileyen unsurdur. Çalışmada yorgunluğu tespit etmek kadar yorgun olmama durumunun da doğrulukla tespit edilmesi analizin sağlıklı yapılabilmesi için gereklidir. Bu veri ön işleme adımında verisetini dengeli hale getirmek için azınlık sınıfı verilerinde yüksek örnekleme yapılmıştır.

3.3.6. Verilerin Etiketlenmesi

Bu çalışma fizyolojik sinyal tabanlı verilerinden bireylerin yorgun olup olmadığını analiz etme, sınıflandırma ve tanımlama amaçlı geliştirilmiştir. O nedenle her bir gözlemin sahip olduğu sınıf etiketi belirlenmelidir. Bu noktada gözlem öncesi katılımcılara yapılan Chalder Yorgunluk Ölçeği'nin 4'lü likert skorları zemin gerçekliği olarak kullanılmıştır. Bu likert sonuçlarına göre 12 ve üzeri skora sahip olan katılımcı hem fiziksel hem de zihinsel yorgun sayılır. Veriseti birleştirme aşamasında bu skorlar göz ününde bulundurularak her bir gözlem etiketlenmiştir.

3.4 Zihinsel Yorgunluğun Derin Öğrenme Yöntemleri ile Tespiti

Günümüzde artık neredeyse tüm alanlarda karşımıza çıkan yapay zeka, insan zekası gerektirecek problem çözme, karar verme ya da algılama gibi meziyetlerin makineler tarafından yapılması temeline dayalıdır. Makine öğrenmesi ise çeşitli deneyimlerden, gözlemlerden ya da verilerden elde ettiği bilgilerle çıkarım yapan yapay zekanın bir alt alanıdır. Günlük hayat gözlemleri bazen kolay gibi görünse de çoğunlukla karmaşık yapılar içerir. Günümüzde artık bu karmaşık yapılardan öğrenmeyi kolaylıkla gerçekleştiren, tıpkı insan beyni gibi sinir ağı temelli olarak kurgulanan ve makine öğreniminin bir alt alanı olan derin öğrenme yapmaktadır. Derin öğrenmede geliştirilen algoritmalar görüntü tanıma, doğal dil işleme, robotik gibi birçok karmaşık problemi kolaylıkla çözebilecek yetkinliğe ulaşmış durumdadır. Bununla birlikte derin öğrenme, sağlık, finans ve ulaşım dahil olmak üzere birçok alanda önemli ilerlemelere yol açmıştır. Zihinsel yorgunluğun fizyolojik sinyal tabanlı analizi ve tanımlanması gözlemlerin içerdiği sinyal yoğunluğu bakımından karmaşık bir problemdir. Bu nedenle tezin genel amacına ulaşmak için derin öğrenme ve yöntemlerine başvurulmuştur. Tezin bu kısmında önerilen derin öğrenme modellerinden bahsedilmiştir.

3.4.1. Derin Öğrenme Modelleri


Derin öğrenme için geliştirilen birçok model ve sinir ağları oldukça fazladır. Tez çalışması kapsamında önerilen ve tasarlanan derin öğrenme modellerine alt başlıklarda değinilmiştir.

3.4.1.1 Uzun Kısa Süreli Bellek Modeli (LSTM)

Derin öğrenmede özellikle sıralı veriler için tasarlanmış sinir ağıları mevcuttur. Bu sinir ağlarından tekrarlayan sinir ağıları (RNN) elde edilen bilginin bir sonraki adıma aktarılmasına olanak verir. Böylelikle verilerin kendi içindeki bağımlılıkları tespit edilir. Ancak bu tekrarlayan sinir ağlarında bilgi, uzun süreli hafızada tutulamaz. Bu da veriler arasında bilginin tam aktarılmasını ve öğrenmeyi azaltır. Bu problemi ortadan kaldırmak için geliştirilmiş ve tekrarlayan sinir ağlarının bir alt türevi olan modele uzun kısa süreli bellek (LSTM) ismi verilmiştir. LSTM modeller kendi içerisinde bilgi akışının kontrol edilmesini, bilginin gerekli kısımlarının hatırlanılmasını ya da gereksiz kısımların unutulmasını sağlayan bir dizi kapı bulundurur. Bu modelin yapısında 3 farklı tipte kapı bulunur [83]. Bunlar:

- Giriş kapısı, mevcut giriş ve gizli durum verilerini alan kapıdır. Bu kapı ürettiği 0-1 arasındaki değere göre belleğe ne kadar yeni bilgi ekleneceğini belirler.
- Çıkış kapısı, alınan giriş verilerine göre yine 0-1 aralığında değer üretir. Bu değer bilginin ne kadarının bellekten çıkarılacağını gösterir.
- Unutma kapısı, alınan giriş verilerine göre ürettiği 0-1 aralığında skoru değerlendirir ve önceki adımdaki bilginin ne kadarının unutulması gerektiğini saptar.

Zihinsel yorgunluğun fizyolojik sinyal tabanlı analizi kapsamında tekrarlayan sinir ağ modellerinden yararlanılması daha uygun bulunmuştur. Çünkü bu sinyaller sıralı veri özelliği taşır. Sıralı verilerde öğrenme için en çok önerilen modeller tekrarlayan sinir ağıları modelleri olmuştur [84]. Tez çalışmasında sıfırdan kurgulanarak tasarlanan ve mimarisi Şekil 3.4’de verilen LSTM model ile 3 MEFAR veriseti Tablo 3’de verilen birim sayıları ile eğitilmiştir.



Şekil 3. 4 : Önerilen LSTM Modeli

Tablo 3 : Önerilen LSTM Modelindeki Birim Sayılarının Verisetlerindeki Dağılımı


Katman	MEFAR_DOWN	MEFAR_MID	MEFAR_UP
Giriş	17	17	17
LSTM-1	256	64	16
LSTM-2	256	128	32
LSTM-3	128	128	32
LSTM-4	64	64	16
Dense-1	64	64	32
Dense-2	32	32	16
Çıkış	1	1	1

3.4.1.2 Çift Yönlü LSTM Modeli

Çift yönlü LSTM modeller (Bi-LSTM) geleneksel LSTM modeli ile benzer çalışma yapısına sahiptir. Bu model yapısında giriş sırasını ileri yönde işleyen ve bu giriş verilerini geri yönde işleyen çift LSTM bulundurmaktadır. Bu iki LSTM yapısı sayesinde hem geçmiş hem de gelecekteki bağlamlardan bilgi yakalanabilir ve böylelikle öğrenme performansı artırılabilir. Bu modelin çalışma mekanizması şu şekildedir:

- İleri yönlü LSTM, giriş sırasını girdi olarak alır ve ileri yönde gizli durumları hesaplar.
- Geri yönlü LSTM, giriş sırasını girdi olarak alıp, gizli durumları geriye doğru hesaplar.
- Bi-LSTM modelinin çıktısı, ileri ve geri yönlü gizli durumların bir birleşimidir.

Tez çalışmasında ikinci olarak önerilen, mimarisi Şekil 3.5’de verilen ve 3 MEFAR veriseti için eğitilen derin öğrenme modeli Bi-LSTM modeli olmuştur. Bu modelin verisetlerinde kullanılan her bir katman için birim sayısı Tablo 4’te verilmiştir. Önerilen bu modelle fizyolojik sinyallerdeki bilgi akışının hem geçmiş hem gelecek bağımlılıklarının bulunup bulunmadığını gözlemlemek hedeflenmiştir.

**Şekil 3. 5 : Önerilen Bi-LSTM Modeli**


Tablo 4: Önerilen BiLSTM Modelindeki Birim Sayılarının Verisetlerindeki Dağılımı

Katman	MEFAR_DOWN	MEFAR_MID	MEFAR_UP
Giriş	17	17	17
Bi-LSTM-1	256	32	4
Bi-LSTM-2	256	64	8
Bi-LSTM-3	128	64	8
Bi-LSTM-4	64	32	...
Dense-1	64	64	16
Dense-2	32	32	8
Çıkış	1	1	1

3.4.1.3 Geçitli Tekrarlayan Ünite Modeli (GRU)

Tekrarlayan sinir ağları modellerinde (RNN) karşılaşılan kaybolan gradyan sorununu çözmek için geliştirilmiş bir diğer model de geçitli tekrarlayan ünite (GRU) modelidir. Tekrarlayan sinir ağlarının bir alt versiyonu olan bu modelde, bilgi aktarımının kontrolü geçiş mekanizmalarındadır. LSTM modeline benzer olarak iki kapısı mevcuttur. Bu kapılar sıfırlama ve güncelleme kapısı olarak bilinir. Sıfırlama kapısında bir önceki birimdeki gizli durumun ne kadarlık kısmının unutulacağı belirlenirken, güncelleme kısmında yeni giriş değerlerinin ne kadarının mevcut gizli duruma aktarılacağı belirlenir. GRU modeller de diğer tekrarlayan sinir ağları modelleri gibi sıralı verilerden oluşan verisetlerinin eğitiminde sıklıkla kullanılırlar. Bu nedenle analiz aşamasında önerilen bir diğer model olmuştur.

Fizyolojik sinyallere dayalı zihinsel yorgunluk problemine çözüm olarak geliştirilen ve Şekil 3.6'da gösterilen üçüncü model GRU modelidir. Modelin verisetlerinde kullanılan her bir katman için birim sayısı Tablo 5'te verilmiştir. Bu modelle belirlenen amaç, ilk adımda tasarlanan LSTM modelle hem zaman hem performans açısından karşılaştırmaktır.


**Şekil 3. 6 :** Önerilen GRU Model

Tablo 5 : Önerilen GRU Modeldeki Birim Sayılarının Verisetlerindeki Dağılımı

Katman	MEFAR_DOWN	MEFAR_MID	MEFAR_UP
Giriş	17	17	17
GRU-1	256	64	8
GRU-2	256	128	16
GRU-3	128	64	16
GRU-4	64	...	8
Dense-1	128	64	32
Dense-2	128	32	16
Çıkış	1	1	1

3.4.1.4 Çift Yönlü Geçitli Tekrarlayan Ünite Modeli (Bi-GRU)

Çift yönlü geçitli tekrarlayan ünite modeli (Bi-GRU) tıpkı LSTM ve Bi-LSTM modelleri arasındaki benzer durum gibi GRU modelinin bir varyantı olarak geliştirilmiş modeldir. Her bir gizli durum katmanında 2 tane GRU birimi bulunur. Bunlardan biri ilgili zaman diliminde ileri yönlü veriyi işlerken diğeri geri yönlü işler. Tezin dördüncü önerilen derin öğrenme modeli olup GRU modeli ile kıyaslanmak üzere deneylere eklenmiştir. Modelin mimarisi 3.7’de, katmanlardaki birim sayısı da Tablo 6’da verilmiştir. Aynı zamanda fizyolojik sinyal verilerinin geçmiş ve gelecekteki bağımlılıkları GRU tabanlı da test edilmiştir.



Şekil 3. 7 : Önerilen Bi-GRU Modeli

Tablo 6 : Önerilen Bi-GRU Modeldeki Birim Sayılarının Verisetlerindeki Dağılımı


Katman	MEFAR_DOWN	MEFAR_MID	MEFAR_UP
Giriş	17	17	17
Bi-GRU-1	64	16	4
Bi-GRU-2	128	32	8
Bi-GRU-3	128	16	4
Dense-1	128	16	32
Dense-2	128	...	16
Çıkış	1	1	1

3.4.1.5 Tek Boyutlu Evrişimli Sinir Ağları (1D-CNN)

Derin öğrenme yöntemlerinden olan bir diğer model de evrişimli ya da konvolüsyonel sinir ağları modelleridir. Bu sinir ağları problemin kendisine bağlı olmak kaydıyla tek boyutlu veya birden fazla boyutlu olabilir. Daha çok görüntü işleme, nesne tanımlama gibi çalışmalarda kullanılsada tek boyutlu yapıları olan ağ modellerinin zaman serisi gibi sıralı verisetlerinde de başarılı olduğu ortaya konmuştur [85]. Boyut farketmeksizin hemen hemen her evrişimli sinir ağlarında ortak olan katmanlar bulunur. Bu katmanlar şu şekilde özetlenir:

- Konvolüsyonel Katman, CNN modellerin en temel ve merkezi katmanıdır. Bu katman içinde bulundurduğu filtre ile giriş verilerinde hareket ederek lokal özelliklerin çıkarılmasında kullanılmaktadır. Her bir adımda giriş verisinde kaydırılarak ilerleyen bu filtre ile katmanın sonunda özellik haritası çıkarılır.
- Aktivasyon Katmanı, genellikle konvolüsyonel katmanından sonra gelen katmandır. Girdi olarak kullanılan verilerdeki karmaşıklığı modele işlevleştirmek için kullanılır. Bu işlevleştirme işlemi bir aktivasyon fonksiyonu aracılığıyla yapar. Veri tiplerine bağlı olmak kaydıyla sıklıkla sigmoid ve tanh fonksiyonlarını kullanır.
- Havuzlama Katmanı, aktivasyon katmanının çıktısını alt örneklem yapmak için eklenen katmandır. Özellik haritasının özetini çıkarmak amaçlı modele eklenir. Bunu haritanın boyutunu küçültürük yapar. Küçültme tekniğinde yerel değişkenler içinde en iyi temsil eden alt veri kümesi seçilir ve bir sonraki katmana aktarılır.
- Tamamen Bağlı Katman, bir önceki katmanın çıktısını çıktı alanına eşleyen ve problemin ana amacına uygun olarak sınıflandıran ya da bağımlı değişkenlerin bağımsız değişkene etkisini ölçen ve genellikle son aşama olan katmandır.

Karmaşık verilerin eğitildiği birçok durumda 1D-CNN modeller kullanılmıştır. Yukarıda ifade edilen katmanlar istenilen sırada ve sayıda probleme bağlı olarak kurgulanabilir. Veri içerisindeki yerel özelliklerin çıkarılması ve performansı artırma amaçlı bu tez çalışmasında beşinci model olarak tasarlanmıştır. Önerilen 1D-CNN mimarisi şekil 3.8’de, katmanlardaki birim sayısı dağılımı Tablo 7’de verilmiştir.



Şekil 3. 8 : Önerilen 1DCNN Modeli

Tablo 7 : Önerilen 1DCNN Modeldeki Birim Sayılarının Verisetlerindeki Dağılımı

Katman	MEFAR_DOWN	MEFAR_MID	MEFAR_UP
Giriş	17	17	17
Conv1D-1	64	8	8
Conv1D-2	64	8	8
Conv1D-3	64	8	8
Dense-1	128	32	32
Dense-2	128	16	16
Çıkış	1	1	1

3.5 Duygu Tanıma Sistemlerinden Transfer Öğrenme ile Zihinsel Yorgunluk Tespiti

Transfer öğrenme, kavram olarak bir problem için eğitilen bir modelin bir başka problemin eğitiminde kullanılabilmesini sağlayan makine öğrenimi tekniklerindendir. Bu teknik ile sıfırdan sinir ağı modeli tasarlamak gerekmediği için öğrenme süreci daha da hızlanır. Günümüzde daha çok yüksek performans gerektiren görüntü ve metin işleme uygulamalarında kullanılmıştır. Ancak benzer problemleri çözmeye dayalı geliştirilen her bir model için transfer öğrenme yapmak mümkündür. Transfer öğreniminin kullanılma amaçları genel olarak şu şekildedir:

- Özellik Çıkarımı, kaynak modelin eğitildiği sinir ağında öğrenilen özelliklerin hedef modele transfer edilmesidir. Sadece bu özelliklerin kullanılması ile hedef modelin öğrenimi daha hızlı bir şekilde sağlanabilir. Bu daha çok az sayıda gözlem içeren verisetlerinin eğitiminde kullanılır.

- İnce Ayarlama, önceden eğitilmiş kaynak modelin bazı özelliklerinin hedef modelin eğitiminde değiştirilip yeniden düzenleme yapmayı içerir. Transfer öğrenme yaklaşımlarının çoğunda bire bir alan eşleme yapılamadığından ince ayarlama yapılmaktadır.
- Alan Adaptasyonu, kaynak modelin başka bir alana özgü geliştirilen hedef modele aktarıldığı durumdur. Önceden eğitilmiş kaynak modelin hedef modele uyarlanmasıdır. Bu yaklaşıma ince ayarlama da dahil edilerek hedef modelin eğitiminin iyileştirilmesi beklenir.

Tez çalışmasının bu basamağında transfer öğrenme ile fizyolojik sinyal tabanlı zihinsel yorgunluk tespiti yapılabilir mi sorusuna cevap aranmıştır. Zihinsel yorgunluk insan fizyolojisinde en nihayetinde duygu durum değişikliğine sebep olabilecek bir olgudur. Buradan hareketle, transfer öğrenimi gerçekleştirilecek fizyolojik sinyal tabanlı duygu tanıma yönelimli problemlerde kullanılan verisetleri eğitilerek asıl çalışmaya transfer öğrenimi yapmak hedeflenmiştir. Literatürde bu amaçla toplanmış ve çok iyi öğrenme sağlanmış 2 farklı veriseti tespit edilmiştir. Veriseti belirlerken birinin EEG sinyal tabanlı diğerinin Empatica E4 akıllı bileklik sinyalleri tabanlı olmasına dikkat edilmiştir. Bunun sebebi transfer öğrenmenin zihinsel yorgunluğu tespit etmede hangi fizyolojik sinyal yönelimli daha iyi performans sergileyeceğini belirleyebilmek. Kullanılan verisetleri ve bu verisetlerinin eğitimi için hazırlanan modeller bu bölümün alt başlıklarında verilmiştir.

3.5.1. DEAP Veriseti

DEAP, duygu analizi çalışmaları için toplanmış EEG ve diğer fizyolojik sinyalleri içeren aynı zamanda literatürde en çok bilinen verisetidir [86]. Bu veriler 32 katılımcıya 40 farklı video içeriği izletildiği esnada alınan fizyolojik sinyal verileridir. Her bir katılımcıdan izledikleri video içeriklerinin kendilerinde meydana getirdiği duygu durumlarını 4 farklı kategoride oylamaları istenmiştir. Bu kategoriler:

- Değerlik (valence): Olumlu ya da olumsuz etkileme durumu (1den 9’a kadar)
- Uyarılma (arousal): Duyguların uyarılma şiddeti (1den 9’a kadar)
- Baskınlık (dominance): Videoların duygulardaki baskınlık düzeyi (1den 9’a kadar)
- Beğenme (liking): Videoları beğenme oranı (1den 9’a kadar)

Duygu analizi ve tanıma temalı yürütülen çalışmalar bu kategorilere göre sınıflandırma yapmışlardır. Bazı çalışmalarda sadece değerlik [87] ya da uyarılma kategorisine göre sınıflandırma yapılırken bir başka çalışmada hem değerlik hemde uyarılma durumlarının beraber olduğu kategorilere göre sınıflandırma yapılmıştır [88]. Zihinsel yorgunluğun tespitine dayalı bu tez çalışmasında duyguların uyarılma şiddetine göre sınıflandırılması ana çalışmaya daha yakın bulunmuştur. Buradan hareketle uyarılma (arousal) kategorisine göre sınıflandıran iki farklı model geliştirilmiştir. 1D-CNN ve GRU derin öğrenme modelleriyle DEAP veriseti uyarılma kategorisine göre sınıflandırılarak eğitilmiştir. Veri ön işleme esnasında sınıf etiketi uyarılma şiddetine göre yapılmıştır. Öyle ki uyarılma şiddeti 5 ve üzeri olan gözlemler yüksek uyarılma (1) olarak etiketlenirken 5’ten az olanlar düşük uyarılma (0) olarak etiketlenmiştir.

Veriseti test ve eğitim veriseti olarak ayrıldıktan sonra önerilen 1D-CNN ve GRU modelleri ile eğitilmiştir. Daha sonra bu modeller alan uyarlama ve ince ayarlama eklenerek zihinsel yorgunluğu tespit etmesi amacıyla 3 MEFAR verisetine transfer edilmiştir.

3.5.2. Stres Veriseti

Zihinsel yorgunluğun oluşum süreçlerinin temelinde stres kaynağının olduğu çalışmanın giriş kısmında aktarılmıştır. Bu yaklaşım doğrultusunda zihinsel yorgunluğun stres tabanlı da ölçümlenebileceği düşünülmüştür. Bu nedenle stres tabanlı veriseti üzerinden zihinsel yorgunluk analizine transfer öğrenme gerçekleştirilmiştir. Bulunan stres veriseti aslında bir füzyon verisetidir [21]. Yani stresi tespit etmek için görüntü, ses ve fizyolojik sinyal verilerinin tamamını kapsayacak şekilde oluşturulmuş verisetidir. Bu tez çalışmasında füzyon stres verisetinin sadece fizyolojik sinyal verileri kullanılmıştır.

Stres veriseti 20 katılımcının gün içerisinde belli aralıklarla mobil uygulama üzerinden stres durumunu ölçen soruları yanıtlaması ve bu esnada fizyolojik sinyal verilerinin kaydedilmesi ile oluşturulmuş verisetidir. Verilerin etiketlenmesi sorulara verdiği yanıtlara göre stresli (1) ve stressiz olarak (0) iki şekilde yapılmıştır.

Stres veriseti ilk olarak önerilen 1D-CNN ve LSTM modellerle eğitilmiştir. Modellerin özellikleri ve ağırlıkları transfer öğrenme yapmak amacıyla kaydedilmiştir. Kaydedilen modellere ince ayarlama yapılarak 3 MEFAR verisetine transferi gerçekleştirilmiştir.

3.6 Model Performans Değerlendirmesi

Her bir derin öğrenme çalışması önerilen modelin ya da modellerin performansını etkileyebilecek unsurları değerlendirmeyi içinde barındırır. Bu başlık altında önerilen derin ve transfer öğrenme modellerinde kullanılan hiperparametrelerden ve model performanslarını artırmaya yönelik yapılan işlemlerden bahsedilmiştir.

3.6.1 Model Eğitimi ve Hiperparametre Ayarları

Model değerlendirmede ele alınacak ilk husus çoğunlukla modelin hiperparametreleridir. Model yapılandırılmasında uygulanan ayarlamalar ya da parametreler hiperparametre olarak bilinir. Modellerin özelliklerini kontrol etmek amaçlı kullanılan hiperparametreler şu şekildedir:

- Epoch (döngü) sayısı: Bu parametre modelin kaç döngüde eğitileceğini gösteren parametredir. Önerilen modellerin tamamında aynı epoch sayısı belirlenmiş olup değeri 150'dir.
- Batch (yığın) boyutu: Modelde verilerin paralel işlenebilmesine imkan tanınır ve veri, gruplara/yığınlara ayrılır. Bu parametre her bir veri grubunun/yığınının boyutunu ifade eder ve işlem hızını ve süresini etkileyen bir parametredir. Önerilen modellerin tamamında aynı boyut kullanılmış olup değeri 100'dür.

- Aktivasyon Fonksiyonu: Modellerin her katmanında yer alan nöronların etkinleştirilmesi için kullanılır. Önerilen modellerde giriş ve gizli katmanlarda tanh fonksiyonu, çıkış katmanında sigmoid fonksiyonu kullanılmıştır.
- Optimizasyon Fonksiyonu: Model eğitiminde hiperparametrelerin güncellenme tekniğini ifade eden parametredir. Önerilen modellerde kullanılan optimizasyon fonksiyonu Adam olmuştur. Bu fonksiyon için belirlenen öğrenme oranı ise 0.0001'dir.
- Çekirdek Boyutu: kernel_size olarak bilinir. Çoğunlukla evrişimli sinir ağları ile ilişkilidir. Evrişimli sinir ağlarında, verilerin üzerinde bir filtre hareket ettirilerek konvolüsyon işlemi gerçekleştirilir. Bu hiperparametre, bahsi geçen filtre boyutunu ifade eder. Tezde önerilen evrişimli sinir ağları modellerinde kullanılan çekirdek boyutu 2'dir.
- Havuz Boyutu: pool_size olarak bilinir. Evrişimli sinir ağlarında özellik haritasının boyutunu azaltmak ve özellikleri daha belirgin hale getirmek için havuzlama işlemi yapılır. Havuzlama işleminin boyutunu bu parametre belirler. Tezde önerilen evrişimli sinir ağları modellerinde kullanılan havuz boyutu 2'dir.

3.6.2 Modellerin Performansını Artırmaya Yönelik İşlemler

Sınıflandırma temelli derin öğrenme çalışmalarında hedeflenen genel amaç, öğrenmenin ezberleme yapmadan yüksek doğrulukla, düşük kayıpla süreci tamamlayabilmesini sağlamaktır. Ancak toplanan veriler bu hedefe ulaşmada oldukça zorlayıcı yapıya sahiptirler ve model performansını aşağıya çekebilme potansiyeli barındırırlar. Düşük performans dışında istenilmeyen bir diğer durum da sistemin aşırı öğrenme yapmasıdır. Aşırı öğrenme modelin gerçek öğrenme yapmayıp, durumu ezberlemesidir. Bu durum araştırmanın güvenilirliğini azaltmaktadır. Tez çalışmasında kullanılan veriler sıralı veriler olduğu için aşırı öğrenme yapma olasılığı yüksektir. Önerilen modellerin aşırı öğrenme yapmadan güvenilirliğini, yüksek doğruluğunu sağlamak için performansını artırmaya yönelik yapılan işlemler şu şekildedir:

- Regülerizasyon: Modelin parametrelerinin büyüklüğünü sınırlayarak aşırı öğrenme riskini düşüren tekniklerden birisidir. Önerilen modellerde L2 regülerizasyon ve bazı birimlerin model eğitimi sırasında çıkarılmasına dayalı bırakma - dropout teknikleri kullanılmıştır.
- Çapraz doğrulama: Model performansının güvenilir zeminde değerlendirilmesi için önerilen modellerde uygulanan bir diğer tekniktir. Bu teknikte veriler eğitim, doğrulama ve test verileri olmak üzere üçe ayrılır. Eğitim seti ile model eğitilirken doğrulama setinde performansı ölçülerek en iyi hiperparametreler belirlenir. Test verilerinde ise bu hiperparametreler modelin performansını ölçmek için kullanılır. Önerilen modellerde k-fold (k kat) çapraz doğrulama yaklaşımı kullanılmıştır. K değeri olarak 5 belirlenmiştir.
- Erken durdurma: Modelde aşırı öğrenmeyi engellemeye dayalı uygulanan bir diğer teknik early stopping – erken durdurma tekniğidir. Bu teknik modelin doğrulama aşamasını takip ederek eğer gelişme göstermiyorsa öğrenmeyi durdurma yaklaşımı içerir. Böylelikle modelin aşırı uyum sağlamasının önüne geçmek hedeflenmiştir.

4. SONUÇLAR

Zihinsel yorgunluğun fizyolojik sinyal tabanlı analizi tez çalışmasında, son teknolojik derin öğrenme ve transfer öğrenme modelleri önerilmiştir. Bu modellerin sonuçları performans değerlendirme metrikleri şeklinde tezin bu kısmında aktarılmıştır. Bir sınıflandırma temelli derin öğrenme modelini değerlendirmek için sıklıkla tercih edilen metrikler; doğruluk, hassasiyet, özgülük, F1 puanı ve kayıp değer metrikleridir.


4.1. Derin Öğrenme Performans Değerlendirmesi

Farklı mesleklere sahip katılımcılardan toplanan fizyolojik sinyaller ile zihinsel yorgunluğu tespit etmek amaçlı birçok derin öğrenme modeli uygulanmıştır. Sıralı verilerin eğitiminde sıklıkla tercih edilen bu modeller, 3 farklı veri birleştirme tekniğiyle oluşturulan ve MEFAR ismi verilen verisetleri için eğitilmiştir.

Tekrarlı sinir ağlarının sıralı verilerde başarılı grafik ortaya çıkardığı bu tez çalışmasında da kanıtlanmıştır. Önerilen LSTM ve GRU modeller %96 doğruluk ve ortalama 0.12 kayıp değeri ile zihinsel yorgunluğu tespit edebilmiştir. Bu modellerde en az başarı oranı MEFAR_DOWN verisetinde elde edilirken en iyi başarı oranı MEFAR_UP verisetinde elde edilmiştir.


Fizyolojik sinyallerin hem geçmiş hem de gelecek bağlantılarını görebilmek için analiz çalışmalarına eklenen BiLSTM ve BiGRU modellerinin LSTM ve GRU modellerine nazaran daha yüksek doğruluk ve düşük kayıp değeri ortaya çıkardığı görülmüştür. Bu da çift yönlü tekrarlayan sinir ağlarının zihinsel yorgunluğu tespit etmede fizyolojik sinyallerdeki bilginin işlenmesini, geçmiş-gelecek arasında daha iyi aktarım yaptığını göstermektedir. Ayrıca bir önceki fizyolojik sinyal gözlemlerinin bir sonraki örnekleme ile arasındaki ilişkinin pozitif yönlü olduğu gözlemlenmiştir.

Genel olarak görüntü işleme, nesne tanıma amaçlı geliştirilen uygulamalarda daha iyi sonuç gösteren evrişimli sinir ağlarının sıralı fizyolojik sinyallerin işlenmesinde tekrarlayan sinir ağlarından daha yüksek başarı gösterdiği bu çalışmada ortaya konmuştur. Önerilen 1D-CNN modeli MEFAR_DOWN verisetini %86, MEFAR_MID verisetini %96, MEFAR_UP verisetini %98 doğruluk oranıyla sınıflandıran en iyi sınıflandırıcı olmuştur. Yine bu modelin diğer modellere nazaran daha hassas, özgül ve daha az kayıpla eğitimi tamamladığı gözlemlenmiştir. Modelin en iyi performans gösterdiği MEFAR_UP verisetinde ortaya çıkan doğruluk ve kayıp değer grafiği Şekil 4.1’de verilmiştir. Şekil 4.1’de geçen loss value kayıp değeri, accuracy doğruluğu, training loss eğitim setindeki kayıp değeri, training accuracy eğitim setindeki doğruluğu, validation loss doğrulama setindeki kayıp değeri, validation accuracy doğrulama verisetindeki doğruluğu ifade eder.




Şekil 4. 1 : 1DCNN Modelinin Doğruluk ve Kayıp Değer Grafiği-MEFAR_UP

Verisetleri bazında incelendiğinde genel başarı grafiğinde örneklem sayısı arttıkça model performansının da arttığı görülmüştür. Şekil 4.2’de gösterildiği üzere sıralı verisetinde örneklem sıklığı arttıkça modellerin doğruluk performans eğrileri artış göstermiştir. Ayrıca örneklem sıklığının fazla olması Şekil 4.3’de görüldüğü üzere modellerin daha az kayıpla sınıflandırma yapmasını sağlamıştır.



Şekil 4. 2 : Örneklem Sıklığına Bağlı Model Doğruluk Performansları



Şekil 4. 3 : Örneklem Sıklığına Bağlı Modellerin Kayıp Değer Performansları

Önerilen tüm derin öğrenme modellerinin 3 veriseti için elde edilen performans çıktıları Tablo 8’de verilmiştir.

Tablo 8 : Önerilen Tüm Derin Öğrenme Modellerinin Performans Sonuçları

Model-Veriseti	Doğruluk	Özgüllük	Hassasiyet	F1-Puanı	Kayıp Değeri
LSTM-MEFAR_DOWN	0.77	0.77	0.77	0.77	0.48
LSTM-MEFAR_MID	0.93	0.90	0.95	0.92	0.18
LSTM-MEFAR_UP	0.96	0.96	0.96	0.96	0.12
BiLSTM-MEFAR_DOWN	0.76	0.75	0.77	0.76	0.50
BiLSTM-MEFAR_MID	0.99	0.99	0.99	0.99	0.04
BiLSTM-MEFAR_UP	0.97	0.97	0.97	0.97	0.08
GRU-MEFAR_DOWN	0.69	0.63	0.73	0.67	0.57
GRU-MEFAR_MID	0.96	0.96	0.96	0.96	0.12
GRU-MEFAR_UP	0.96	0.96	0.96	0.96	0.13
BiGRU-MEFAR_DOWN	0.71	0.68	0.73	0.70	0.57
BiGRU-MEFAR_MID	0.95	0.96	0.93	0.95	0.17
BiGRU-MEFAR_UP	0.99	0.99	0.99	0.99	0.05
1DCNN-MEFAR_DOWN	0.86	0.87	0.86	0.86	0.32
1DCNN-MEFAR_MID	0.96	0.96	0.96	0.96	0.11
1DCNN-MEFAR_UP	0.98	0.98	0.98	0.98	0.07

4.2. Duygu Tanıma Sistemlerinden Transfer Öğrenme Performans Değerlendirmesi

Zihinsel yorgunluğun fizyolojik sinyal tabanlı analizi adlı tez çalışmasında, deneylerin ikinci ana basamağını transfer öğrenme oluşturmuştur. Derin öğrenme modelleri sıfırdan tasarlandığı ve en başta verisetlerinin ne kadar karmaşık yapıda olduğu deneyimlenmediği için hiperparametreleri ayarlayabilmek birçok deney tekrarı zorluğunu beraberinde getirmiştir. Bu zaman açısından maliyet demektir. Bu maliyeti en aza indirmek için transfer öğrenme tekniklerinden faydalanılmıştır.

Daha önce duygu ve stresten transfer öğrenme ile zihinsel yorgunluğun tespit edilmeye çalışıldığı bir başka çalışmaya rastlanmamıştır. Önerilen yaklaşım bu açıdan bakıldığında özgünlük değerine sahiptir. Duygudan ve stresten transfer öğrenme yapıldığında elde edilen sonuçlar şu şekildedir.

4.2.1. Duygu Tanımlamada Uyarılma Şiddetinden Transfer Öğrenme Sonuçları

DEAP veriseti, içerisinde EEG ve diğer fizyolojik sinyalleri bulunduran verisetidir. Katılımcıların izledikleri videoları, kendilerinde uyandırdıkları duygunun baskınlığını, uyarılma şiddetini ve olumlu etkisini oylayarak verilerin etiketlenme süreci tamamlanmıştır. Teze katkı sağlaması açısından bu DEAP veriseti uyarılma şiddetine göre sınıflandırılarak modellenmiştir. Modelleme için derin öğrenme yöntemlerinden evrişimli sinir ağları (1DCNN) ve geçitli tekrarlayan birim (GRU) modelleri kullanılmıştır.

GRU modelinde eğitilen DEAP verisetinde %86 doğruluk ve 0,30 kayıp değerine ulaşılmıştır. GRU model önceden eğitilmiş model olarak MEFAR verisetlerine aktarılacak üzere kaydedilmiştir.

Kaydedilen ve önceden eğitilen GRU modelin MEFAR verisetlerinin eğitimine aktarımında ilk katman ve son katman birim değerleri değiştirilerek ince ayarlama yapılmıştır. Aynı hiperparametreler ile 3 verisetinin eğitimi tamamlanmış ve test verisetinde performans çıktılarına bakılmıştır. Önceden eğitilen DEAP GRU modelin performans çıktıları Tablo 9’da verilmiştir.

Tablo 9 : Önceden Eğitilen DEAP GRU Modelinde Transfer Öğrenme Sonuçları

Veriseti	Doğruluk	Özgüllük	Hassasiyet	F1 Puanı	Kayıp Değeri
MEFAR_DOWN	0,91	0,9	0,91	0,9	0,22
MEFAR_MID	0,95	0,94	0,96	0,95	0,13
MEFAR_UP	0,95	0,96	0,95	0,95	0,13

Evrişimli sinir ağında (1DCNN) eğitilen DEAP verisetinde en fazla %72 doğruluk ve 0,55 kayıp değerine ulaşılmıştır. DEAP 1DCNN model önceden eğitilmiş model olarak MEFAR verisetlerine aktarılacak üzere kaydedilmiştir.

Kaydedilen ve önceden eğitilen DEAP 1DCNN modelin MEFAR verisetlerinin eğitimine aktarımında ilk katman, son katman birim değerleri değiştirilerek ve düzleştirme katmanından sonra 3 gizli derin katman eklenerek ince ayarlama yapılmıştır. Aynı hiperparametreler ile 3 verisetinin eğitimi tamamlanmış ve test verisetinde performans çıktılarına bakılmıştır. Önceden eğitilen DEAP 1DCNN modelin performans çıktıları Tablo 10’da verilmiştir.

Tablo 10 : Önceden Eğitilen DEAP 1DCNN Modelinde Transfer Öğrenme Sonuçları

Veriseti	Doğruluk	Özgüllük	Hassasiyet	F1 Puanı	Kayıp Değeri
MEFAR_DOWN	0,73	0,69	0,74	0,71	0,55
MEFAR_MID	0,86	0,84	0,87	0,86	0,33
MEFAR_UP	0,88	0,88	0,89	0,88	0,27

DEAP verisetinden transfer öğrenme gerçekleştirdiğimiz çalışmanın bu basamağında en iyi öğrenme tekrarlayan sinir ağı mimarisine sahip GRU modeli ile gerçekleşmiştir. Bu DEAP verisetinin özellikleri en iyi şekilde GRU model ile transfer edildiği anlamı taşır. DEAP veriseti içeriği ile MEFAR verisetlerinin içeriği benzer olup farklı alanlara hitap etmektedir. Bu çerçevede duygu tanıma yönelimli bir uygulamadan zihinsel yorgunluğu tanımlama uygulamasına uyarlama/adapte etme başarılı şekilde yapılmıştır.

4.2.2. Fizyolojik Sinyal Tabanlı Stres Duygusundan Transfer Öğrenme Sonuçları

Stres veriseti, Empatica E4 sinyal verilerini içeren ve verilerin stresli ya da stressiz olarak etiketlendiği bir verisetidir. İlk olarak bu veriseti hem LSTM hem de 1DCNN modeller ile eğitilmiştir. Bu modellerin seçilme nedeni stres duygusunun tanımlanmasında tekrarlayan sinir ağı ile evrimsel sinir ağlarının etkilerini görebilmektir. Her iki modelin eğitimi için derin öğrenme aşamasında tercih edilen aynı hiperparametreler kullanılmıştır.

LSTM modelinde eğitilen stres verisetinde %94 doğruluk ve 0,15 kayıp değerine ulaşılmıştır. LSTM model için elde edilen diğer metrik sonuçları sırasıyla hassasiyet %94, özgüllük %95, F1-Puanı %94 şeklindedir. Daha sonra MEFAR verisetleri için bu model kaydedilmiştir.

Kaydedilen ve önceden eğitilen LSTM modelin MEFAR verisetlerinin eğitimine aktarımında ilk katman ve son katman birim değerleri değiştirilerek ince ayarlama yapılmıştır. Aynı hiperparametreler ile 3 verisetinin eğitimi tamamlanmış ve test verisetinde performans çıktılarına bakılmıştır. Önceden eğitilen LSTM modelin performans çıktıları Tablo 11’da verilmiştir.

Tablo 11 : Önceden Eğitilen Stres LSTM Modelinden Transfer Öğrenme Sonuçları

Veriseti	Doğruluk	Özgüllük	Hassasiyet	F1 Puanı	Kayıp Değeri
MEFAR_DOWN	0,96	0,96	0,96	0,96	0,1
MEFAR_MID	0,97	0,96	0,97	0,97	0,1
MEFAR_UP	0,97	0,96	0,98	0,97	0,07

Evrişimli sinir ağında (1DCNN) eğitilen stres verisetinde %92 doğruluk ve 0,22 kayıp değerine ulaşılmıştır. 1DCNN model için elde edilen diğer metrik sonuçları sırasıyla hassasiyet %91, özgüllük %94, F1-Puanı %92 şeklindedir. Daha sonra MEFAR verisetleri için bu model kaydedilmiştir.

Kaydedilen ve önceden eğitilen 1DCNN modelin MEFAR verisetlerinin eğitimine aktarımında ilk katman, son katman birim değerleri değiştirilerek ve düzleştirme katmanından sonra 3 gizli derin katman eklenerek ince ayarlama yapılmıştır. Aynı hiperparametreler ile 3 verisetinin eğitimi tamamlanmış ve test verisetinde performans çıktılarına bakılmıştır. Önceden eğitilen 1DCNN modelin performans çıktıları Tablo 12’de verilmiştir.

Tablo 12 : Önceden Eğitilen Stres 1DCNN Modelinden Transfer Öğrenme Sonuçları

Veriseti	Doğruluk	Özgüllük	Hassasiyet	F1 Puanı	Kayıp Değeri
MEFAR_DOWN	0,91	0,91	0,91	0,91	0,24
MEFAR_MID	0,95	0,96	0,95	0,95	0,15
MEFAR_UP	0,97	0,97	0,98	0,97	0,1


Stres verisetinden transfer öğrenme gerçekleştirdiğimiz çalışmanın bu basamağında en iyi öğrenme tekrarlayan sinir ağı mimarisine sahip LSTM modeli ile gerçekleşmiştir. Stres verisetinin özellikleri en iyi şekilde LSTM model ile aktarılmıştır. Bu veriseti ile MEFAR verisetleri ortak paydada Empatica E4 verileri içerirler. Ancak MEFAR veriseti stres verisetine göre daha karmaşık yapıya sahiptir. Daha basitten daha karmaşık verileri öğrenmeye dayalı bu yaklaşım başarılı sonuçlar ortaya çıkarmıştır. Zihinsel yorgunluğun kaynağının strese bağlı gelişebileceği de kanıtlanmıştır.

5. BULGULAR

Zihinsel yorgunluk bulgularının fizyolojik sinyallere dayalı analiz çalışmasında 23 kişiden alınan beyin, kalp ve deri iletkenliği sinyalleri derin öğrenme ve transfer öğrenme modelleriyle eğitilerek zihinsel yorgunluk tanımlanmıştır. Katılımcılardan alınan demografik bilgi anketi, Chalder yorgunluk ölçeği değerlendirilmesi ve fizyolojik sinyal bulguları bu başlık altında incelenmiştir.

5.1. İstatistiksel Bulgular

4 farklı meslek grubundan 10 erkek 13 kadın toplam 23 katılımcının zihinsel yorgunluk bulguları incelenmiştir. Katılımcıların yaş ortalaması 29 olup eğitim durumları ilkokul mezunundan doktora mezununa kadar değişir. Eğitim durumlarının dağılım grafiği Şekil 5.1’de verilmiştir. Bu grafiğe göre katılımcıların büyük bir çoğunluğunu lisans mezunu oluşturmuştur.




Şekil 5. 1 : Katılımcıların Eğitim Durumu Dağılımı

Katılımcıların tamamı tam zamanlı çalışan olup günde ortalama 8,8 saat çalışmaktadırlar. %30’unun evli olduğu bu katılımcı grubunun %39’u düzenli uyku durumuna sahiptir. Diğer istatistiksel bilgileri şu şekildedir: %26’sı sigara içmekte, %8’i kronik rahatsızlığa sahip, %17’si düzenli ilaç kullanmakta, %39’u düzenli egzersiz yapmakta. Ölçümlerde katılımcıların en son geceki uyku süreleri ortalama 6,5 saat olmuştur

Yukarıda bahsedilen katılımcı profiline göre sigara-ilaç-kronik rahatsızlık bakımından değerlendirildiğinde sağlıklı bir kitle olduğu görülmektedir. Düzenli uyku durumları bulunmasa da uyku süreleri bakımından ortalama yetişkin bireyin uyku süresine eş durumdadır. Kadınların erkeklerden daha düzenli ve ortalama uyku süresine sahip olduğu gözlemlenmiştir.

Katılımcıların yorgunluk değerlendirme anketine göre verdikleri cevaplar yine anketin skora ilkelerine bağlı alınarak 4’lü likert ölçeğine göre hesaplanmıştır. Yorgunluk

değerlendirme sonuçlarına göre katılımcıların sahip olduğu zihinsel yorgunluk durumları Şekil 5.2’de verilmiştir. Bu grafiğe göre katılımcıların sabah durumlarına nazaran akşam daha çok zihinsel yorgunluk bulgularına sahip oldukları gözlemlenmiştir. Erkeklerin sadece %10’u sabah zihinsel yorgunken kadınların %38’i zihinsel yorgundur. Akşamsa erkeklerin %60’ında, kadınların %84’ünde zihinsel yorgunluk bulguları saptanmıştır. Bu da kadınların erkeklerden her durumda daha zihinsel yorgunluk hissettiğini göstermektedir.




Şekil 5.2 : Katılımcıların Sabah ve Akşam Zihinsel Yorgunluk Dağılımları

Katılımcılardan alınan tüm demografik bilgilerin birbirleriyle olan pozitif ve negatif korelasyonları da ayrıca incelenmiştir. Gerekli önışleme adımından sonra bu verilerin birbirleriyle olan ilişkilerine göre aşağıdaki çıkarımlara ulaşılmıştır:

- Ortalama uyku süresine sahip bireyin aynı zamanda düzenli uyku durumuna da sahip olduğu,
- Ortalama uyku süresine sahip bireylerin çoğunluğunun kadın olduğu,
- Kronik rahatsızlığı olan bireylerin aynı zamanda ve %87 ile düzenli ilaç kullandığı,
- Ortalama uyku süresine sahip bireylerin düzenli egzersiz yaptığı,
- Çalışma süresi arttıkça uyku düzeninin azaldığı,
- Düzenli egzersiz yapıldıkça zihinsel yorgunluk bulgularının azaldığı,
- Düzenli uyku durumunda zihinsel yorgunluk bulgularının azaldığı,
- Kronik rahatsızlık ve düzenli ilaç kullanımı arttıkça zihinsel yorgunluk bulgularının arttığı,
- Ortalama uyku süresi azaldıkça zihinsel yorgunluk bulgularının arttığı,
- Yaş, eğitim durumu, çalışma şekli ve maaş skalasının zihinsel yorgunlukla ilişkisinin bulunmadığı ortaya çıkarılmıştır.


Verilerin yorgun ve yorgun değil şeklinde etiketlenmesi için Chalder Yorgunluk Ölçeği’ne başvurulmuştur. Bu ölçek sonucuna göre katılımcıların büyük bir çoğunluğunun sabah

yorgunluk hissetmediği, akşamsa bunun tam tersi büyük bir çoğunluğunun yorgunluk hissettiği ortaya çıkmıştır. Chalder yorgunluk ölçeğinde yer alan sorulara sabahki ölçümlerde verilen yanıtların kişi sayısı bazlı dağılımları Şekil 5.3’de verilmiştir. Bu grafiğe göre yorgunluk skalasında her zamankinden daha az ve her zamanki kadar yanıtlarının yoğun olduğu görülmektedir. Detaylı inceleme yapıldığında konsantre olmakta zorlanma, konuşurken dilin sürçmesi ve doğru sözcüğü bulamama gibi zihinsel yorgunluk bulgularına, katılımcıların sırasıyla %43, %43 ve %56’sı her zamanki kadar yanıtını vermişlerdir. Hafızayla ilgili olan soruya yine kullanıcıların %73’ü her zamanki kadar yanıtı vermiştir.



Şekil 5. 3 : CYÖ'ne Sabah Verilen Yanıtların Kişi Bazlı Dağılımı

Akşam uygulanan yorgunluk ölçeğine göre zihinsel yorgunluk hissetme oranı hissetmeyenlere göre daha fazla olduğu saptanmıştır. Chalder Yorgunluk Ölçeği’nde yer alan sorulara akşamki ölçümlerde verilen yanıtların kişi sayısı bazlı dağılımları Şekil 5.4’de verilmiştir. Bu grafiğe göre yorgunluk skalasında her zamankinden daha fazla ve her zamanki kadar yanıtlarının yoğun olduğu görülmektedir. Detaylı inceleme yapıldığında konsantre olmakta zorlanma, konuşurken dilin sürçmesi ve doğru sözcüğü bulamama gibi zihinsel yorgunluk bulgularına katılımcıların ortalama %58’i her zamanki kadar, ortalama %22’si her zamankinden çok daha fazla yanıtını vermişlerdir. Hafızayla ilgili olan soruya yine katılımcıların her zamanki kadar yanıtı yaklaşık %4 puan gerilerken her zamankinden daha fazla yanıtı yaklaşık %6 puan artmıştır.




Şekil 5. 4 : CYÖ'ne Akşam Verilen Yanıtların Kişi Bazlı Dağılımı

Elde edilen sonuçlar gösteriyor ki gün içinde rutin çalışma düzeni olsa dahi akşam zihinsel yorgunluk hissedilme sıklığı fazladır. Yeterli uyku süresine ulaşamayan, uyku durumu düzenli olmayan, çalışma süresi normalden fazla olan bireylerde günün ilk saatlerinde zihinsel yorgunluk tespit edilmiştir. Katılımcılar aslında çalışma kanununda belirtilen ortalama saat süresinde çalışmaktalar. Ancak bu saat bireyin diğer durumları ile birleştiğinde zihinsel yorgunluğu önleyici bir değer olmadığı anlaşılmıştır. Zihinsel yorgunluk bazı bireylerde eşik değere çok yakın olduğu için diğer metriklerle bir araya geldiğinde ne yazık ki zihinsel yorgunluk seviyesini çok kısa sürede aşmıştır.


5.2. Fizyolojik Sinyal Bulguları

Bu çalışmada hem beyin hem kalp sinyalleri tabanlı zihinsel yorgunluk bulguları tanımlanmaya çalışılmıştır. Katılımcılara sabah ve akşam uygulanan ölçümlerde elde edilen fizyolojik sinyaller zihinsel yorgun ve zihinsel yorgun değil şeklinde etiketlenmiştir. Etiketlenen sinyallerin dağılımları Şekil 5.5'de verilmiştir. Buna göre neredeyse dengeli bir veriseti oluşturulduğu görülmüştür.



Şekil 5. 5 : Fizyolojik Sinyallerin Zihinsel Yorgunluk Dağılımları


Elde edilen fizyolojik sinyaller zihinsel yorgunluk bazında uygulanan yorgunluk ölçeğiyle uyumluluk göstermiştir. Toplanan bu fizyolojik sinyallerin zihinsel yorgunluğu tanımlamadaki etkileri incelendiğinde Empatica E4 akıllı bileklikten alınan sinyallerin beyin sinyallerinden biraz daha baskın olduğu tespit edilmiştir. Zihinsel yorgunluğu belirlemedeki en etkin 2 sinyal, cilt tepkilerini ölçümleyen EDA, kalp atış hızını gösteren HR verileri olmuştur. Stresi ve diğer duygusal değişiklikler ile karakterize olan EDA sinyali bu çalışmada zihinsel yorgunlukla ilişkisi en yüksek olan sinyal verisi olmuştur. Beyin sinyalleri nispeten daha az belirleyici olsa da meditasyon ve Alpha2 sinyal verileri beyin sinyalleri içerisinde zihinsel yorgunluğu tespit etmede daha etkin başarı göstermiştir. Bu da zihinsel yorgunluk çeken bireyin yeni bir bilgiyi öğrenemeyeceğini, dikkatinin azaldığını ve kendini dinlenmeye çektiğini gösterir. Zihinsel yorgunluğu tespit etmede diğer sinyal verilerinin etkisi Şekil 5.6’de verilmiştir.



Şekil 5. 6 : Fizyolojik Sinyallerin Zihinsel Yorgunluğu Belirlemede Etkisi

Zihinsel yorgunluğu belirlemede en baskın olan EDA ve en baskın olmayan dikkat (Attention) sinyallerinin bireysel bağımlılık (dependence) grafikleri Şekil 5.7 ‘de verilmiştir. Yine bu

şekle göre EDA'nın ne kadar baskın, dikkatin ne kadar daha az baskın olduğu anlaşılmakta. Zihinsel yorgunluğun iki faktörlü tespitinin doğrulukla yapıldığı görülmüştür.




Şekil 5. 7 : EDA (üstteki) ve Dikkat-Attention (alttaki) Sinyallerinin Etkinlik Grafikleri

Fizyolojik sinyallerin zihinsel yorgunluk durumunu belirlemedeki katkıları da incelenmiştir. Rastgele seçilen bir gözlemin zihinsel yorgunluk durumunun %98 başarı oranı ile tahmin edildiği bir modelde en belirgin katkıyı Empatica E4 bileklik sinyallerinin sağladığı görülmüştür. Bu gözlemde elde edilen tüm fizyolojik sinyallerin değerini ve öğrenmeye ne kadar katkı sağladığını en yüksekten en düşüğe doğru gösteren bilgiler Tablo 13'de verilmiştir.

Tablo 13 : Rastgele Seçilen Gözlemin Sinyal Verilerinin Modele Katkısı (Model Başarısı %98 doğruluk)

Sinyal	Sinyal Değeri	Katkısı
EDA	0,36	37,36%
HR	0,31	4,24%
AccZ	0,32	2,75%
AccY	-0,02	2,18%
AccX	-0,42	0,92%
BVP	-0,10	0,69%
Beta2	0,07	0,19%
Alpha2	0,00	0,18%
Gamma2	0,06	0,13%
Alpha1	0,01	0,04%
Delta	0,02	0,01%
Attention	0,54	-0,05%
Theta	0,02	-0,06%
Gamma1	0,05	-0,10%
Beta1	0,02	-0,10%
Meditation	0,71	-0,16%


Zihinsel yorgunluk durumu oluştuğunda ve oluşmadığında EDA sinyalinin değişim grafiği Şekil 5.8’de verilmiştir. Bu grafiğe göre zihinsel yorgun hissedildiğinde cilt tepkisinin belirgin bir şekilde artış yaptığı görülmüştür.



Şekil 5. 8 : Zihinsel Yorgun ve Yorgun Olmayan Durumlarda EDA Sinyalinin Değişimi


Zihinsel yorgunluğu belirlemede en etkili ikinci sinyal kalp atımı sinyaliydi. Bu sinyal zihinsel yorgunluk oluştuğunda yorgunluk oluşmadığı duruma göre Şekil 5.9’da verildiği üzere daha

yüksek seviyede seyretmektedir. Bu sonuç stres ve duygu değişikliklerinin zihinsel yorgunluk üzerinde ne denli etkili olduğunu kanıtlar.




Şekil 5. 9 : Zihinsel Yorgun ve Yorgun Olmayan Durumlarda HR Sinyalinin Değişimi

Beyin sinyalleri açısından ulaşılan diğer bulgular da yorgunluk ölçeğiyle uyumluluk göstermiştir. Örneğin; alpha2 beyin dalgası stres düzeylerinin düşürülmesi ve zihinsel rahatlama ile ilişkilendirilir. Birey ne kadar stresli ya da zihinsel olarak rahat değilse bu dalga seviyesi yüksek frekans oluşturur. Bunu destekler nitelikte elde edilen bulguya göre alpha2 beyin dalgası zihinsel yorgunluk oluştuğunda Şekil 5.10'da verildiği üzere daha yüksek değerler üretmiştir.



Şekil 5. 10 : Zihinsel Yorgun ve Yorgun Olmayan Durumlarda Alpha2 Beyin Sinyalinin Değişimi

Beyin sinyallerinden olan Gamma1 beyin dalgaları; bireyde dikkat, hafıza, öğrenme, yaratıcılık ve problem çözme ile ilgilidir. Bu beyin dalgalarının yüksek seviyede elde edilen ölçümü, zihinsel performansın yüksek olduğu anlamına gelir. Zihinsel yorgunluk oluşan bir gözlemde bu dalga tipinin daha az seviyelerde olduğu Şekil 5.11’de verilen grafikten anlaşılmaktadır. Bu grafiğe göre Gamma1 sinyali, zihinsel yorgunluk olmadığında daha yüksek değerler üretmiştir.




Şekil 5. 11 : Zihinsel Yorgun ve Yorgun Olmayan Durumlarda Gamma1 Beyin Sinyalinin Değişimi


Çalışma süresi, uyku durumu ve süresi vb. diğer faktörlere bağlı olarak gelişen zihinsel yorgunluk bulgularında en iyi gösterge stres ve duygu değişimlerine duyarlı olan cilt tepkisi parametresi yani EDA sinyali olmuştur. Bunu zorlu ve bir o kadar stresli koşullarda daha çok ortaya çıkan yüksek kalp atımı (HR) da doğrulamıştır. Zihinsel yorgunluk tanımında olduğu üzere zihinsel performansın gerilediği, bilişsel aktivitelerin azaldığı beyin sinyallerinden de anlaşılmıştır. Zihinsel olarak yorgunken yeni bir bilginin öğrenilemeyeceği ve beynin bilişsel algıları kapattığı meditasyon seviyesinin yüksekliği ile uyumluluk göstermiştir. Ayrıca dikkat seviyesinin düşük gözlemlenmesi zihinsel yorgunlukta konsantrasyonun azalması durumunu doğrulamıştır.

6. TARTIŞMA


Çalışmanın genel amacı, fizyolojik sinyallere dayalı olarak zihinsel yorgunluk bulgularını analiz ve tespit etmektir. Bunun için derin ve transfer öğrenme yöntemlerinden yararlanılmış ve yüksek performansla zihinsel yorgunluk tespit edilebilmiştir. %98 oranında doğruluk başarı ve 0.17 kayıp değeriyle elde edilen en iyi modelin karmaşıklık matrisi Şekil 6.1’de, hassasiyet eğrisi Şekil 6.2’de, sınıflandırma grafiği Şekil 6.3’de verilmiştir. Bu şekillere göre önerilen bu model zihinsel yorgunluğu hem pozitif hem de negatif durumlar için yüksek doğrulukla sınıflandırabilmiştir. Ayrıca zihinsel yorgunluk durumu arttıkça modelin doğru tahminleme hassasiyetinin de arttığı ölçümlenmiştir.



Şekil 6. 1 : En İyi Modelin Karmaşıklık Matrisi



Şekil 6. 2 : Modelin Zihinsel Yorgunluğu Tespit Etmede Hassasiyet Eğrisi



Şekil 6.3 : Modelin Belli Kesme Değerine Göre Pozitif (Zihinsel Yorgun) ve Negatif (Zihinsel Yorgun Değil) Sınıflandırma Yüzdesi

Şekil 6.3’de ifade edilen ‘1.0’ zihinsel yorgun, ‘0.0’ zihinsel yorgun değil anlamlarına gelmektedir.

Zihinsel yorgunluğu tanımlamak için önerdiğimiz modellerde kullanılan fizyolojik sinyallerden Empatica E4 sinyallerinin, EEG sinyallerinden biraz daha etkin olduğu görülmüştür. Birçok çalışmada EEG sinyallerinin etkinliği vurgulanırken [67], [89], bu çalışma ile EDA ve HR sinyalleriyle de zihinsel yorgunluğu belirlemenin mümkün olabildiği tespit edilmiştir. Bu sonuç aktivite farkındalığının zihinsel yorgunluk ile değerlendirildiği bir çalışma ile uyumluluk göstermiştir [90]. Bu çalışma ile nispeten giyimi zor olan EEG cihazına alternatif olarak akıllı bileklik ile de zihinsel yorgunluk başarılı bir şekilde tanımlanabilmektedir. Bu durum çalışmanın gerçek hayata uyarlanabilmesini kolay kılmıştır.

Bu çalışmada derin öğrenme ve transfer öğrenme yaklaşımları öne sürülmüştür. Özellikle tekrarlayan sinir ağları yöntemlerinden olan LSTM ve GRU yöntemleri hem derin öğrenme hem de transfer öğrenme aşamasında yüksek performans göstermiştir. Zihinsel ve fiziksel yorgunluğun birlikte tespit edilmeye çalışıldığı birçok çalışmada da LSTM modelleri sıklıkla kullanılmıştır [91], [92]. Ayrıca bu çalışmanın, derin öğrenme yaklaşımlarının geleneksel makine öğrenmesi yöntemleriyle zihinsel yorgunluğu tespit etmeye çalışan diğer çalışmalardan biraz daha iyi performans sergilediği görülmüştür. Yapılan diğer çalışmalar ile önerilen derin ve transfer öğrenme modellerinin karşılaştırma sonuçları Tablo 14 ‘de verilmiştir.

Tez çalışmasında derin öğrenme yöntemlerinin tercih edilmesinin sebebi benzer çalışmalarda az kullanımından kaynaklı oluşan boşluğu doldurabilmektir. Ancak daha önce geleneksel makine öğrenmesi ile yapılmış çalışmaların daha az veri kümesiyle yapıldığı unutulmamalıdır. Derin öğrenme yaklaşımlarının diğer makine öğrenmesi modellerine nispeten biraz daha maliyetli olması benzer çalışmalarda tercih edilmemesinin bir diğer nedenidir. Ayrıca kullanılan verisetleri sinyallerden öznitelik çıkarımı yapıp daha sade veri kümesine büründürüldüğü için de sığ modellerin kullanılmasının daha doğru bir yaklaşım olduğu düşünülmüştür.

Tablo 14 : Makine Öğrenmesi Yöntemleriyle Yapılmış Önceki Çalışmalarla Önerilen Modellerin Karşılaştırılması

Yapılan Çalışmalar	Kullanılan Sinyaller	Doğruluk Değeri (%)
[89]	EEG, HR, EDA	90,00
[67]	EKG, BVP, EEG, Resp	84,60
[93]	EKG, EDA	79,00
[94]	EKG, Resp, EDA, TEMP	84,60
Önerilen Derin Öğrenme	EEG, EDA, BVP, HR, TEMP, ACC	98,00
Önerilen Transfer Öğrenme	EEG, EDA, BVP, HR, TEMP, ACC	96,00

Fizyolojik sinyal toplama süreci katılımcı bağımlı çalışma olduğu için genelde oluşturulan verisetleri boyutu az olmaktadır. Küçük boyutlu verisetlerinde başarımlar az olacağı için transfer öğrenme ile bu sorunun ortadan kaldırılması sağlanabilir. Bu çalışmada da çalışılan alanın dışındaki kaynaklardan transfer öğrenme gerçekleştirilmiştir. Duygu tanımda sıklıkla kullanılan DEAP verisetinden ve stres tanıma için oluşturulan Stres verisetinden transfer öğrenme yapılmıştır. Transfer öğrenme yapılan çalışmalarda daha çok transfer bileşen analizi gerçekleştirilmiştir [95], [96]. Ancak bu tez çalışmasında daha önce çalışılmamış alan adaptasyonu içeren transfer öğrenme yaklaşımı önerilmiştir. Diğer çalışmalarda %75'i geçmeyen başarımlar, tezde önerilen transfer öğrenme yaklaşımı ile %96'ya kadar çıkarılmıştır.

7. SONUÇ

Tez çalışmasında zihinsel yorgunluk bulgularının fizyolojik sinyal tabanlı analizi gerçekleştirilmiştir. Yorgunluk ölçeğine göre gözlemlerin yapıldığı bu çalışmada yaş ortalaması 29 olan 10 erkek 13 kadın toplam 23 katılımcıdan yaklaşık olarak 1518 dakikalık fizyolojik sinyal ölçümü yapılmıştır. Ölçümler Empatica E4 akıllı bileklik ve NeuroSky MindWave EEG cihazları ile sabah ve akşam olacak şekilde planlanmıştır. Toplanan veriler Chalder yorgunluk değerlendirme sorularına verilen yanıtlara göre zihinsel yorgun ve zihinsel yorgun değil şeklinde etiketlenmiştir. Örneklem sıklığına göre 3 farklı boyutta veriseti oluşturulmuştur. Bunun nedeni örneklem sıklığının, zihinsel yorgunluğu sınıflandırmadaki etkisinin ne boyutta olduğunu gözlemlemektir. Bu verisetlerine “zihinsel yorgunluğu tanımlama”nın İngilizce karşılığı “mental fatigue recognition” kelimelerinin kısaltması olan MEFAR öneki verilmiştir.

Literatürde yapılan çoğu çalışmada geleneksel makine öğrenmesi yöntemleri zihinsel yorgunluğu sınıflandırmak için kullanılmıştır. Zihinsel yorgunluk tanımının fizyolojik sinyal tabanlı yapmayı amaçlayan bu tez çalışmasında, son teknolojik derin öğrenme yaklaşımlarından yararlanılmıştır. Bu alanda çokça tercih edilen derin öğrenme ve transfer öğrenme yöntemleri tercih edilmiştir. Çalışmadan elde edilen sonuçlar derin öğrenme ve transfer öğrenme yöntemlerinin zihinsel yorgunluğu tanımlamada etkinliğini kanıtlamıştır. İlk olarak sıfırdan kurgulanan LSTM, Bi-LSTM, GRU, Bi-GRU ve 1DCNN derin öğrenme yaklaşımlarıyla verilerin eğitimi yapılmıştır. 3 MEFAR verisetinde ortalama en yüksek başarı evrişimli sinir ağıyla (1DCNN) elde edilmiştir. 1DCNN modeli, 3 verisetinde sırasıyla %86, %96 ve %98 doğruluk oranıyla eğitimi tamamlamıştır.

Çalışmanın bir diğer önemli basamağı transfer öğrenme ile zihinsel yorgunluğun tanımlamasının yapılabilmesiydi. Araştırmalar sonucu transfer öğrenme gerçekleştirilecek iki farklı alanlara hitap eden veriseti belirlenmiştir. Bunlardan ilki EEG sinyal tabanlı duygu tanımlama çalışması için toplanan ve düzenlenen DEAP verisetiydi. İkincisi stresin tanımının fizyolojik sinyal tabanlı (Empatica E4 sinyalleri ile) yapıldığı Stres verisetiydi. Kökeninde bir duygu olan zihinsel yorgunluğun hem beyin hem Empatica E4 sinyalleri kökenli tanımını yapabilmek ve toplanan bu hibrit sinyaller setinin hangi sinyal yönelimli daha iyi tanımlanabildiğini gözlemlemek amaçlanmıştır. Elde edilen sonuçlar stres verisetinden daha iyi transfer öğrenme yapıldığını göstermiştir. Her iki veriseti önerilen 1DCNN ile transfer öğrenme yapıldığında stres verisetinden MEFAR verisetlerine aktarılan özellikler ortalama %94, DEAP verisetinde aktarılan özellikler ortalama %82 doğrulukla zihinsel yorgunluğu sınıflandırabilmişlerdir. Buradan zihinsel yorgunluğun bir duygudan ziyade daha çok stres yönelimli bir olgu olduğu çıkarılmıştır. Duygu tanıma ve stres kökenli analiz amaçlı modellenen transfer öğrenmede, en iyi performansı tekrarlayan sinir ağı modelleri göstermiştir. Stres verisetinde LSTM model, DEAP verisetinde GRU model ile sırasıyla ortalama %96 ve %93 doğruluk oranı elde edilmiştir.

Analiz çalışmaları fizyolojik sinyallerin yanı sıra hem yorgunluk ölçeği hem demografik bilgi tabanlı olarak da yürütülmüştür. Bireyin çalışma süresi, uyku durumu ve günde kaç saat uyuduğu doğrudan zihinsel yorgunluk ile bağlantılı bulunmuştur. Çalışma süresi arttıkça, uyku durumu düzeni bozuldukça ve uyku süresi kısaldıkça zihinsel yorgunluk bulgularında artış

olduğu gözlemlenmiştir. Ayrıca erkeklere göre kadınların, elektrik teknisyenlerine göre akademisyenlerin daha çok zihinsel yorgunluk hissettiği ortaya çıkarılmıştır.

Beyin sinyallerinden çok deri ve kalp sinyal verileri zihinsel yorgunluğu tespit etmede biraz daha belirleyici olmuştur. Ancak burada kullanılan cihazların yetkinliği de unutulmamalıdır. Daha kapsamlı bir EEG ya da akıllı bileklik cihazı eşliğinde farklı sonuçlar elde edilebileceği göz önünde bulundurulmalıdır. Kullanılan cihazlar ile zihinsel yorgunluk hissedildiği durumlarda EDA ve HR sinyalleri daha yüksek frekans oluşturmıştır. Bu da cilt tepkisinin, stresin, gerginliğin ve duygu durumu değişikliğinin zihinsel yorgunluk durumunda daha fazla olduğu anlamına gelir. Beyin sinyalleri açısından değerlendirildiğinde; zihinsel yorgunluk durumunda bireyin kendini dinlenme moduna çektiği, yeni bir bilgiyi öğrenemediği, zihinsel fonksiyonların azaldığı meditasyon ve gamma1 sinyallerinden anlaşılmıştır. Zihinsel yorgunluk çeken bireyin meditasyon frekans değerleri yüksekken, gamma1 frekans değerleri daha düşük kalmıştır.

Sonuç olarak bu tez çalışması derin ve transfer öğrenme ile zihinsel yorgunluğun tanımlanmasının mümkün olabildiğini kanıtlar nitelikte bir çalışma olmuştur. Hem EEG hem kalp hem deri iletkenliği sinyallerinin bir arada kullanılması geçmiş çalışmalarla uyumluluk göstermiştir. Önerilen derin ve transfer öğrenme modelleri ile zihinsel yorgunluk tanımlanabilmiştir. Evrişimli sinir ağlarının daha önce iyi performansla duygu tanımadaki başarısı bu çalışma ile yine ortaya konulmuştur. Geçmiş çalışmalarda uygulanan transfer öğrenme yaklaşımlarından farklı olarak, bu tez çalışmasında duygu ve stres tanıma yönelimli verisetlerinden alan adaptasyonu içeren transfer öğrenme yapılarak daha kısa sürede yüksek performanslı sınıflandırıcı model tasarlanmıştır. Transfer öğrenme ile duygu ve stres tanıma gibi farklı alanlardan alan adaptasyonu uygulanarak zihinsel yorgunluğun tanımının yapılması mümkün kılınmıştır. Gelecekteki araştırmalar bakımından incelendiğinde, zihinsel yorgunluğu tanımlamanın gerekli olduğu ağır sanayi, inşaat, hizmet, ulaşım gibi sektörlerde bu çalışmanın entegrasyonu halinde insan faktörlü kazaların, ölümlerin ve güvenlik zaafiyetlerinin çok çok önüne geçilmesi düşünülmektedir. Birçok sektör çalışanının bilişsel performansı takip edilerek gerekli iyileştirmeler yapılabilir. Giyilebilir cihazlara işlendiğinde bireyler kendi sağlık verilerini anlık takip edebilir, farkında olmadıkları zihinsel yorgunluklarını kolaylıkla tespit edebilirler. Rehabilitasyon merkezinde kullanıldığında hastaların iyileşme sürecini hızlandırabilir. Ayrıca toplanan veriseti bu alanda yapılan araştırmalara kaynak sağlayacağı için zihinsel yorgunluğu tespit etme çalışmalarına farklı bir boyut kazandıracaktır.

8. ÇALIŞMANIN SINIRLARI ve GELECEK PLANI

Tez çalışmasının yürütüldüğü esnada birkaç sınırlandırma ile karşılaşmıştır. En önemli ve birincil etmen çalışmaya davet edilen katılımcıların zaman ayırmak istememesidir. Cihazların invazif olmadığı, sadece anket ve cihaz giyme için 1 dakika süre ayırmaları kendilerine ifade edilmiştir. Buna rağmen sınırlı sayıda katılımcı ikna edilebilmiştir. Çalışmanın bir diğer sınırlandırması cihazların deney ortamından ayrılmaması durumuydu. Katılımcılardan, cihazlarla bluetooth üzerinden haberleşme sağlandığı için belli bir mesafeye kadar uzaklaşmamaları talep edilmiştir. Bu durum bazı meslek grubu çalışanlarının rutin iş düzenini kısıtladığı için çok fazla yer değişikliği yapan bireyler çalışmadan çıkarılmak zorunda kalmıştır. Tüm bu sınırlandırmaların çözümlenebildiği deney ortamı sağlandığı takdirde çok fazla meslek grubu çalışanları ile yorgunluğun tanımlanması ve tespit edilmesi daha güvenilir sonuçlarla sağlanacağı düşünülmektedir.

Çalışmada yapılan deneyler sayılan bu sınırlandırmaların olumsuz etkilerini en aza indirilmiş ortamlarda yapılmıştır. Derin ve transfer öğrenme yaklaşımlarının detaylı olarak test edildiği ve incelendiği bu çalışma ile, fizyolojik sinyaller kullanılarak zihinsel yorgunluğun tespitine ilişkin büyüyen araştırma grubuna katkı sağlayacağı öngörülmektedir. Önerilen yöntemler giyilebilir cihazlara veya bilişsel olarak bireyleri asiste eden sistemlere entegre edilebilir. Bu sistem, zihinsel yorgunluğun gerçek zamanlı izlenebilirliğini mümkün kıldığı gibi yorgunluğa bağlı meydana gelen olumsuz etkilere karşı da erken uyarı sistemi olarak rol oynayabilir.

9. ETİK KURUL İZNİ

Bu tez çalışmasının bireylerden veri toplanması için gerekli etik kurul izni bulunmaktadır. Bu izin İstanbul Kültür Üniversitesi Etik Kurulu'nun 05.05.2023 tarihli 2023/66 numaralı kararı ile alınmıştır.



10. KAYNAKLAR

- [1] E. Özel ve Ü. Hacıoğlu, «Examining the relationship between burnout and job satisfaction of flight crew: An analysis on the critical fatigue risk factors in the aviation industry,» *International Journal of Business Ecosystem & Strategy*, cilt 3, no. 1, 2021.
- [2] H. Said ve C. Tanova, «Workplace bullying in the hospitality industry: A hindrance to the employee mindfulness state and a source of emotional exhaustion,» *International Journal of Hospitality Management*, cilt 96, p. 102961, 2021.
- [3] X. Li, Z. Mai, L. Yang ve J. Zhang, «Human Resource Management Practices, Emotional Exhaustion, and Organizational Commitment – With the Example of the Hotel Industry,» *Journal of China Tourism Research*, cilt 16, no. 3, pp. 472-486, 2020.
- [4] P. Qi, H. Ru, L. Gao, X. Zhang, T. Zhou, Y. Tian, N. Thakor, A. Bezerianos, J. Li ve Y. Sun, «Neural Mechanisms of Mental Fatigue Revisited: New Insights from the Brain Connectome,» *{Engineering}*, cilt 5, no. 2, pp. 276-286, 2019.
- [5] R. M. Adın, «Chalder Yorgunluk Ölçeği'nin Türkçe'ye uyarlanması ve genç yetişkin bireylerde psikometrik özelliklerinin incelenmesi,» 2019.
- [6] S. Harris ve S. R. Bray, «Effects of mental fatigue on exercise decision-making,» *Psychology of Sport and Exercise*, cilt 44, pp. 1-8, 2019.
- [7] A. Ishii, M. Tanaka ve Y. Watanabe, «Neural mechanisms of mental fatigue,» *Reviews in the Neurosciences*, cilt 25, no. 4, pp. 469-479, 2014.
- [8] S. Dattani, H. Ritchie ve M. Roser, «Mental Health,» *Our World in Data*, 2021.
- [9] T. G. Monteiro, C. Skourup ve H. Zhang, «A Task Agnostic Mental Fatigue Assessment Approach Based on EEG Frequency Bands for Demanding Maritime Operation,» *IEEE Instrumentation & Measurement Magazine*, cilt 24, no. 4, pp. 82-88, 2021.
- [10] V. Parekh, D. Shah ve M. Shah, «Fatigue detection using artificial intelligence framework,» *Augmented Human Research*, cilt 5, no. 1, pp. 1-17, 2020.
- [11] H. Uysal ve G. Ofluoğlu, «İş Sağlığı ve Güvenliği Açısından Zihinsel Yorgunluğun İş Motivasyonuna Etkisi The Effect of Mental Fatigue on Job Motivation in terms of Occupational Health and Safety.,» *Yönetim ve Çalışma Dergisi*, cilt 2, no. 2, pp. 118-130, 2018.
- [12] M. Cella ve T. Chalder, «Measuring fatigue in clinical and community settings,» *Journal of psychosomatic research*, cilt 69, no. 1, pp. 17-22, 2010.
- [13] J. Vercoulen, «The checklist individual strength,» *Gedragstherapie*, cilt 32, pp. 131-136, 1999.

- [14] J. D. Fisk, P. G. Ritvo, L. Ross, D. A. Haase, T. J. Marrie ve W. F. Schlech, «Measuring the Functional Impact of Fatigue: Initial Validation of the Fatigue Impact Scale,» *Clinical Infectious Diseases*, cilt 18, no. Supplement_1, pp. S79-S83, 1994.
- [15] B. F. Piper, S. L. Dibble, M. J. Dodd, M. C. Weiss, R. E. Slaughter ve S. M. Paul, «The revised Piper Fatigue Scale: psychometric evaluation in women with breast cancer,» *Oncology nursing forum*, cilt 25, pp. 677-684, 1998.
- [16] H. J. Michielsen, J. D. Vries ve G. L. V. Heck, «Psychometric qualities of a brief self-rated fatigue measure: The Fatigue Assessment Scale,» *Journal of Psychosomatic Research*, cilt 54, no. 4, pp. 345-352, 2003.
- [17] J. Li, H. Li, W. Umer, H. Wang, X. Xing, S. Zhao ve J. Hou, «Identification and classification of construction equipment operators' mental fatigue using wearable eye-tracking technology,» *Automation in Construction*, cilt 109, p. 103000, 2020.
- [18] S. Huang, J. Li, P. Zhang ve W. Zhang, «Detection of mental fatigue state with wearable ECG devices,» *International Journal of Medical Informatics*, cilt 119, pp. 39-46, 2018.
- [19] B. M. G. Rosa ve G. Z. Yang, «A Flexible Wearable Device for Measurement of Cardiac, Electrodermal, and Motion Parameters in Mental Healthcare Applications,» *IEEE Journal of Biomedical and Health Informatics*, cilt 23, no. 6, pp. 2276-2285, 2019.
- [20] A. Adem, E. Çakıt ve M. Dağdeviren, «NÖROERGONOMİ ÇALIŞMALARINA YÖNELİK BİR LİTERATÜR ARAŞTIRMASI,» *Ergonomi*, cilt 2, no. 2, pp. 131-136, 2019.
- [21] G. Doğan, F. Patlar Akbulut, Ç. Çatal ve A. Mishra, «Stress Detection Using Experience Sampling: A Systematic Mapping Study,» *International Journal of Environmental Research and Public Health*, cilt 19, no. 9, p. 5693, 2022.
- [22] J. Domínguez-Jiménez, K. Campo-Landines, J. Martínez-Santos, E. Delahoz ve S. Contreras-Ortiz, «A machine learning model for emotion recognition from physiological signals,» *Biomedical Signal Processing and Control*, cilt 55, p. 101646, 2020.
- [23] L. Shu, J. Xie, M. Yang, Z. Li, Z. Li, D. Liao, X. Xu ve X. Yang, «A review of emotion recognition using physiological signals,» *Sensors*, cilt 18, no. 7, p. 2074, 2018.
- [24] M. Tanaka, A. Ishii ve Y. Watanabe, «Effects of mental fatigue on brain activity and cognitive performance: a magnetoencephalography study,» *Anat Physiol*, cilt 4, pp. 1-5, 2015.
- [25] A. Vuckovic, V. Radivojevic, A. C. Chen ve D. Popovic, «Automatic recognition of alertness and drowsiness from EEG by an artificial neural network,» *Medical engineering & physics*, cilt 24, no. 5, pp. 349-360, 2002.
- [26] L. King, H. Nguyen ve S. K. L. Lal, «Early driver fatigue detection from electroencephalography signals using artificial neural networks,» %1 içinde

International Conference of the IEEE Engineering in Medicine and Biology Society, New York, NY, USA, 2006.

- [27] M. Patel, S. Lal, D. Kavanagh ve P. Rossiter, «Applying neural network analysis on heart rate variability data to assess driver fatigue,» *Expert systems with Applications*, cilt 38, no. 6, pp. 7235-7242, 2011.
- [28] T. Bafna ve J. P. Hansen, «Mental fatigue measurement using eye metrics: A systematic literature review,» *Psychophysiology*, cilt 58, no. 6, p. e13828, 2021.
- [29] B. Mandal, L. Li, G. S. Wang ve J. Lin, «Towards detection of bus driver fatigue based on robust visual analysis of eye state,» *IEEE Transactions on Intelligent Transportation Systems*, cilt 18, no. 3, pp. 545-557, 2017.
- [30] D. Aras, S. Yiğit, S. Kayam, E. Arslan ve F. Akça, «BİLİŞSEL YORGUNLUĞUN EGZERSİZ VE SPOR PERFORMANSINA ETKİLERİ,» *SPORMETRE Beden Eğitimi ve Spor Bilimleri Dergisi*, cilt 18, no. 1, pp. 1-32, 2020.
- [31] Y. Yang ve J. A. Hayes, «Causes and consequences of burnout among mental health professionals: A practice-oriented review of recent empirical literature,» *Psychotherapy*, cilt 57, no. 3, p. 426, 2020.
- [32] J. A. Yeow, P. K. Ng, K. S. Tan, T. S. Chin ve W. Y. Lim, «Effects of stress, repetition, fatigue and work environment on human error in manufacturing industries,» *Journal of Applied Sciences*, cilt 14, no. 24, pp. 3464-3471, 2014.
- [33] D. Sönmez ve F. Çağlayan, «Salgın Hastalıklar Sonrasında Fizyoterapi ve Rehabilitasyon Bölümü Çalışanlarında İş Stresinin Tükenmişlik Üzerindeki Etkisinin Belirlenmesi ve İstanbul Özel Rehabilitasyon Merkezlerinde Uygulama.,» *Uluslararası Hukuk ve Sosyal Bilim Araştırmaları Dergisi*, cilt 4, no. 1, pp. 12-32, 2022.
- [34] T. Adar ve E. Kılıç Delice, «Şehir içi toplu taşıma şoförlerinin toplam iş yüklerinin fiziksel ve zihinsel iş yükü ölçütlerine göre yeni bir yaklaşımla karşılaştırılması,» *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, cilt 26, no. 1, pp. 254-267, 2020.
- [35] O. F. Afuye, «Job Stressors and Emotional Exhaustion of Food and Beverage Employees of Selected Hotels in Lagos, Nigeria.,» *Journal of Women in Technical Education and Employment*, cilt 1, no. 2, pp. 58-67, 2020.
- [36] M. R. Smith, L. Zeuwts, M. Lenoir, N. Hens, L. M. S. de Jong ve A. J. Coutts, «Mental fatigue impairs soccer-specific decision-making skill,» *Journal of sports sciences*, cilt 34, no. 14, pp. 1297-1304, 2016.
- [37] A. Peterson, J. Chen ve M. Karver, «“It's not serious”: A threat-based model to help-seeking for depression,» *Journal of Psychiatric and Mental Health Nursing*, cilt 26, pp. 108-13, 2019.

- [38] W. H. Organization, «World mental health report: transforming mental health for all,» World Health Organization, 2022.
- [39] J. V. Cutsem, S. Marcora, K. De Pau, S. Bailey ve R. M. & B. Roelands, «The effects of mental fatigue on physical performance: a systematic review,» *Sports medicine*, cilt 47, no. 8, pp. 1569-1588, 2017.
- [40] M. Kaplan ve M. Çallı Kaplan, «TÜRKİYE'DE ÇALIŞANLARIN DEMOGRAFİK ÖZELLİKLERİNİN İŞ KAZALARINA ETKİLERİNİN ANALİZİ,» *Journal of Management and Economics Research*, cilt 17, no. 2, pp. 74-89, 2019.
- [41] A. Taşdelen ve A. Özpinar, «The impacts of mental and physical fatigue of employees on the perception level and the risk of accident,» *Avrupa Bilim ve Teknoloji Dergisi*, pp. 195-205, 2020.
- [42] M. A. Hogervorst, A.-M. Brouwer ve J. B. F. V. Erp, «Combining and comparing EEG, peripheral physiology and eye-related measures for the assessment of mental workload,» *Frontiers in neuroscience*, cilt 8, p. 322, 2014.
- [43] M. S. Evans, D. Harborne ve A. P. Smith, «Developing an objective indicator of fatigue: An alternative mobile version of the Psychomotor Vigilance Task (m-PVT),» %1 içinde *In International Symposium on Human Mental Workload: Models and Applications*, 2018.
- [44] L. Surienty ve L. Lay Kheng Khor, «The Strategic Role of Safety Advice Towards Safety Participation in OSHMS in Malaysian Manufacturing Firm,» *Journal of Occupational Safety and Health*, cilt 14, no. 2, 2017.
- [45] S. Elmas Atay ve S. Kuzu Yıldırım, «İş Sağlığı ve Güvenliği Açısından Sektörlerin Risk Düzeylerinin CRITIC Tabanlı Gri İlişkisel Analiz Yöntemiyle Sıralanması,» *Selçuk Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, cilt 47, pp. 181-193, 2022.
- [46] D. A. Wiegmann ve S. A. Shappell, «Applying the human factors analysis and classification system (HFACS) to the analysis of commercial aviation accident data,» 2001.
- [47] K. Dönmez ve S. Uslu, «İnsan Faktörleri Analiz ve Sınıflandırma Sistemi'nin (HFACS) literatürde yaygın kullanımının değerlendirilmesi,» *Journal of Aviation*, cilt 2, no. 2, pp. 156-176, 2018.
- [48] D. Kelly ve M. Efthymiou, «An analysis of human factors in fifty controlled flight into terrain aviation accidents from 2007 to 2017,» *Journal of safety research*, cilt 69, pp. 155-165, 2019.
- [49] M. Yorulmaz ve A. & Taş, «Limanlardaki İş Kazalarında İnsan Kaynaklı Hata Nedenlerinin AHP Yöntemiyle Değerlendirilmesi: Kocaeli Liman Bölgesinde Bir Uygulama,» *International Academic Social Resources Journal*, cilt 7, no. 34, pp. 193-202, 2022.

- [50] G. Sikander ve S. Anwar, «Driver Fatigue Detection Systems: A Review,» *IEEE Transactions on Intelligent Transportation Systems*, cilt 20, no. 6, pp. 2339-2352, 2018.
- [51] R. Hooda, V. Joshi ve M. Shah, «A comprehensive review of approaches to detect fatigue using machine learning techniques,» *Chronic Diseases and Translational Medicine*, 2021.
- [52] A. Borbely, «A two process model of sleep regulation,» *Human neurobiol*, cilt 1, no. 3, pp. 195-204, 1982.
- [53] T. Åkerstedt ve S. Folkard, «Validation of the S and C components of the three-process model of alertness regulation,» *Sleep*, , cilt 18, no. 1, pp. 1-6, 1995.
- [54] A. J. Belyavin ve M. B. Spencer, «Modeling performance and alertness: the QinetiQ approach,» *Aviation, space, and environmental medicine*, cilt 75, no. 3, pp. A93-A103, 2004.
- [55] S. R. Hursh, D. P. Redmond, M. L. Johnson, D. R. Thorne, G. Belenky, T. J. Balkin, W. F. Storm, J. C. Miller ve D. R. Eddy, «Fatigue models for applied research in warfighting,» *Aviation, space, and environmental medicine*, cilt 75, no. 3, pp. A44-A53, 2004.
- [56] S. Cateni ve V. Colla, «Fuzzy inference system for data processing in industrial applications,» *Fuzzy Inference System—Theory and Applications*, pp. 215-240, 2012.
- [57] M. S. Devi ve P. R. Bajaj, «Fuzzy based driver fatigue detection,» %1 içinde *IEEE International Conference on Systems, Man and Cybernetics*, Istanbul, Turkey, 2010.
- [58] T. Azim, M. A. Jaffar ve A. M. Mirza, «Fully automated real time fatigue detection of drivers through fuzzy expert systems,» *Applied Soft Computing*, cilt 18, pp. 25-38, 2014.
- [59] R. Sayed ve A. Eskandarian, «Unobtrusive drowsiness detection by neural network learning of driver steering,» *Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering*, cilt 215, no. 9, pp. 969-975, 2001.
- [60] F. Friedrichs ve B. Yang, «Drowsiness monitoring by steering and lane data based features under real driving conditions,» %1 içinde *18th European Signal Processing Conference*, Aalborg, Denmark, 2010.
- [61] Y. Lecun ve Y. Bengio, *Convolutional networks for images, speech, and time series*, New Jersey: The handbook of brain theory and neural networks, 1995.
- [62] M. Hajinoroozi, Z. Mao ve Y. Huang, «Prediction of driver's drowsy and alert states from EEG signals with deep learning,» %1 içinde *In 2015 IEEE 6th international workshop on computational advances in multi-sensor adaptive processing (CAMSAP)*, Cancun, 2015.

- [63] W. Zhang, Y. L. Murphey, T. Wang ve Q. Xu, «Driver yawning detection based on deep convolutional neural learning and robust nose tracking,» %1 içinde *IEEE*, Killarney, 2015.
- [64] A. A. R. Nawal Alioua, «Driver's fatigue detection based on yawning extraction,» *International journal of vehicular technology*, 2014.
- [65] C. Goumopoulos ve N. Potha, «Mental fatigue detection using a wearable commodity device and machine learning,» *Journal of Ambient Intelligence and Humanized Computing*, pp. 1-19, 2022.
- [66] P. Melillo, M. Bracale ve L. Pecchia, «Nonlinear Heart Rate Variability features for real-life stress detection. Case study: students under stress due to university examination,» *Biomedical engineering online*, cilt 10, no. 1, pp. 1-13, 2011.
- [67] M. Zanetti, T. Mizumoto, L. Faes, A. Fornaser, M. De Cecco, L. Maule, M. Valente ve G. Nollo, «Multilevel assessment of mental stress via network physiology paradigm using consumer wearable devices,» *Journal of Ambient Intelligence and Humanized Computing*, cilt 12, no. 4, pp. 4409-4418, 2021.
- [68] X. Zhang, S. A. Huettel, A. O'Dhaniel, H. Guo ve L. Wang, «Exploring common changes after acute mental stress and acute tryptophan depletion: Resting-state fMRI studies,» *Journal of psychiatric research*, cilt 113, pp. 172-180., 2019.
- [69] J. A. Arrighi, M. Burg, I. S. Cohen, A. H. Kao, S. Pfau, T. Caulin-Glaser, B. L. Zaret ve R. Soufer, «Myocardial blood-flow response during mental stress in patients with coronary artery disease,» *The Lancet*, cilt 356, no. 9226, pp. 310-311, 2000.
- [70] A. Saidatul, M. P. Paulraj, S. Yaacob ve M. A. Yusnita, Analysis of EEG signals during relaxation and mental stress condition using AR modeling techniques, *IEEE*, 2011.
- [71] B. Hu, H. Peng, Q. Zhao, B. Hu, D. Majoe, F. Zheng ve P. Moore, «Signal quality assessment model for wearable EEG sensor on prediction of mental stress,» *IEEE transactions on nanobioscience*, cilt 14, no. 5, pp. 553-561, 2015.
- [72] R. Katmah, F. Al-Shargie, U. Tariq, F. Babiloni, F. Al-Mughairbi ve H. Al-Nashash, «A review on mental stress assessment methods using EEG signals,» *Sensors*, cilt 21, no. 15, p. 5043, 2021.
- [73] A. B. Uşaklı, «Fizyolojik sinyallerin askerî amaçlı kullanılabilirliği: elektroensefalografi ve yakın kızılaltı spektroskopisi örnekleri,» *Politeknik Dergisi*, cilt 21, no. 4, pp. 895-900, 2018.
- [74] B. Mahanama, Y. Jayawardana, S. Rengarajan, G. Jayawardana, L. Chukoskie, J. Snider ve S. Jayarathna, «Eye movement and pupil measures: A review,» *Frontiers in Computer Science*, cilt 3, p. 733531, 2022.

- [75] T. G. Monteiro, G. Li, C. Skourup ve H. Zhang, «Investigating an integrated sensor fusion system for mental fatigue assessment for demanding maritime operations,» *Sensors*, cilt 20, no. 9, p. 2588, 2020.
- [76] T. Chalder, G. Berelowitz, T. Pawlikowska, L. Watts, S. a. W. D. Wessely ve E. Wallace, «Development of a fatigue scale,» *Journal of psychosomatic research*, cilt 37, no. 2, pp. 147--153, 1993.
- [77] J. F. Wiborg, H. Knoop, M. Stulemeijer, J. B. Prins ve G. Bleijenberg, «How does cognitive behaviour therapy reduce fatigue in patients with chronic fatigue syndrome? The role of physical activity,» *Psychological medicine*, cilt 40, no. 8, pp. 1281--1287, 2010.
- [78] R. Cairns ve M. Hotopf, «A systematic review describing the prognosis of chronic fatigue syndrome,» *Occupational medicine*, cilt 55, no. 1, pp. 20--31, 2005.
- [79] R. M. Adın, A. N. Ceren, A. F. B. Yeliz Salcı, K. Armutlu ve Ç. A. Kuru, «Dimensionality, psychometric properties, and population-based norms of the Turkish version of the Chalder Fatigue Scale among adults,» *Health and Quality of Life Outcomes*, cilt 20, no. 1, pp. 1--16, 2022.
- [80] S. Gashi, L. Alecci, E. Di Lascio, M. E. Debus, F. Gasparini ve S. Santini, «The role of model personalization for sleep stage and sleep quality recognition using wearables,» *IEEE Pervasive Computing*, cilt 21, no. 2, pp. 69--77, 2022.
- [81] H. Stuyck, L. Dalla Costa, A. Cleeremans ve E. Van den Bussche, «Validity of the Empatica E4 wristband to estimate resting-state heart rate variability in a lab-based context,» *International Journal of Psychophysiology*, cilt 182, pp. 105--118, 2022.
- [82] Ş. Derdiyok ve F. P. Akbulut, «Physiological Signals Based Mental Fatigue Analysis & Recognition: MEFAR,» *Mendeley Data*, 23 5 2023. [Çevrimiçi]. Available: <https://data.mendeley.com/datasets/z3g26tphnv/3>. [Erişildi: 24 5 2023].
- [83] S. Hochreiter ve J. Schmidhuber, «Long short-term memory,» *Neural computation*, cilt 9, no. 8, pp. 1735--1780, 1997.
- [84] T. Umematsu, A. Sano ve R. W. Picard, «Daytime data and LSTM can forecast tomorrow's stress, health, and happiness,» %1 içinde *2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, IEEE, 2019, pp. 2186--2190.
- [85] S. Derdiyok ve F. P. Akbulut, «Biosignal based emotion-oriented video summarization,» *Multimedia Systems*, pp. 1--14, 2023.
- [86] S. Koelstra, C. Muhl, M. Soleymani, J.-S. Lee, A. Yazdani, T. Ebrahimi, T. Pun, A. Nijholt ve I. Patras, «Deap: A database for emotion analysis; using physiological signals,» *IEEE transactions on affective computing*, cilt 3, no. 1, pp. 18--31, 2011.

- [87] L. Abdel-Hamid, «An efficient machine learning-based emotional valence recognition approach towards wearable eeg,» *Sensors*, cilt 23, no. 3, p. 1255, 2023.
- [88] P. Pandey ve K. Seeja, «Subject independent emotion recognition system for people with facial deformity: an EEG based approach,» *Journal of Ambient Intelligence and Humanized Computing*, cilt 12, pp. 2311--2320, 2021.
- [89] K. Masood ve M. A. Alghamdi, «Modeling mental stress using a deep learning framework,» *IEEE Access*, cilt 7, pp. 68446--68454, 2019.
- [90] M. A. U. Alam, «ctivity-Aware Deep Cognitive Fatigue Assessment using Wearables,» %1 içinde *2021 43rd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)*, IEEE, 2021, pp. 7433--7436.
- [91] A. Jaiswal, M. Z. Zadeh, A. Hebri ve F. Makedon, «Assessing Fatigue with Multimodal Wearable Sensors and Machine Learning,» *rXiv preprint arXiv:2205.00287*, 2022.
- [92] M. Su, W. Li, F. Peng, W. Zhou, R. Zhang ve Y. Wen, «EEG-Based Mental Fatigue Detection Using CNN-LSTM,» %1 içinde *022 16th ICME International Conference on Complex Medical Engineering (CME)*, IEEE, 2022, pp. 302--305.
- [93] D. Huysmans, E. Smets, W. De Raedt, C. Van Hoof, K. Bogaerts, I. Van Diest ve D. Helic, «Unsupervised learning for mental stress detection-exploration of self-organizing maps,» *Proc. of Biosignals 2018*, cilt 4, pp. 26--35, 2018.
- [94] E. Smets, P. Casale, U. a. L. B. Grossekathofer, W. De Raedt, K. Bogaerts, I. Van Diest ve C. Van Hoof, «Comparison of machine learning techniques for psychophysiological stress detection,» %1 içinde *Pervasive Computing Paradigms for Mental Health*, Italy, Springer, 2015, p. Pervasive Computing Paradigms for Mental Health.
- [95] Y. Liu, Z. Lan, J. Cui, O. Sourina ve W. Muller-Wittig, «EEG-based cross-subject mental fatigue recognition,» %1 içinde *2019 International Conference on Cyberworlds (CW)*, IEEE, 2019, pp. 247--252.
- [96] Y. Liu, Z. Lan, J. Cui, O. Sourina ve W. Muller-Wittig, «Inter-subject transfer learning for EEG-based mental fatigue recognition,» *Advanced Engineering Informatics*, cilt 46, p. 101157, 2020.
- [97] A. Wiehler, F. Branzoli, A. I. M. F. ve M. Pessiglione, «A neuro-metabolic account of why daylong cognitive work alters the control of economic decisions,» *Current Biology*, cilt 32, no. 16, pp. 3564-3575., 2022.