



NESNELERİN İNTERNETİ TABANLI SÜRÜCÜ DURUMU TESPİTİ

Ahmet SUSAR

YÜKSEK LİSANS TEZİ
BİLİŞİM SİSTEMLERİ ANA BİLİM DALI

GAZİ ÜNİVERSİTESİ
BİLİŞİM ENSTİTÜSÜ

MAYIS 2021

ETİK BEYAN

Gazi Üniversitesi Bilişim Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu,

bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Ahmet SUSAR

21/05/2021

NESNELERİN İNTERNETİ TABANLI SÜRÜCÜ DURUMU TESPİTİ
(Yüksek Lisans Tezi)

Ahmet SUSAR

GAZİ ÜNİVERSİTESİ
BİLİŞİM ENSTİTÜSÜ

Mayıs 2021

ÖZET

Sürücülerin yorgunluk, stres, uyku durumları ve benzeri fizyolojik durumlarının izlenmesi, yol güvenliğinin sağlanmasında önemli bir role sahiptir. Bu tez çalışmasında sürücü durumu tespitini sağlamak için hem çevrim dışı, hem de çevrim içi sistem önerilmektedir. Sürücülerde sürüş sırasında oluşan stres durumunu belirlemek için fizyolojik sinyaller kullanılmıştır. Fizyolojik sinyaller, elektrodermal aktivite (EDA) ve kalp hızı sinyallerinden oluşur. Önerilen çevrim dışı sistemde, hazırlanan deney ortamlarında 12 katılımcıdan, 20 oturumda alınan fizyolojik sinyaller ile veri kümesi oluşturulmuştur. Daha sonra veri kümesi makine öğrenmesi algoritmaları ile sınıflandırılarak çevrim dışı sürücü durumu tespiti sağlanmıştır. Veri kümesinin tamamının kullanıldığı çok katılımcıya ait veriler ile elde edilen sınıflandırma doğruluğu %80,1 olmuştur. Bunun yanında 5 farklı oturumda tek bir katılımcıdan alınan veriler ile elde edilen sınıflandırma doğruluğu %90 olarak bulunmuştur. Önerilen çevrim içi sistem ise nesnelerin interneti (Internet of Things - IoT) teknolojilerine dayanmaktadır. Çevrim içi sürücü durum tespiti ile sürücülerin fizyolojik sinyalleri gerçek zamanlı olarak uzaktan izlenebilir ve gerektiğinde çeşitli uyarılar oluşturulabilir. Bu tez çalışmasında önerilen çevrim dışı ve çevrim içi sistem ile sürücülerin stres durumları tespit edilebilmektedir. Bu sayede yol güvenliğine katkıda bulunulur. Ayrıca bu tezde son yıllarda popüler hale gelen IoT kavramı ve uygulama alanları incelenmiştir.

Bilim Kodu : 90541
Anahtar Kelimeler : Yapay öğrenme, nesnelerin interneti, sürücü durumu, fizyolojik sinyaller, yol güvenliği
Sayfa Adedi : 112
Danışman : Prof. Dr. Nursel AKÇAM

DRIVER STATUS DETECTION BASED ON INTERNET OF THINGS

(M. Sc. Thesis)

Ahmet SUSAR

GAZİ UNIVERSITY

INSTITUTE OF INFORMATICS

May 2021

ABSTRACT

Monitoring drivers' physiological conditions such as sleepiness, fatigue and stress has an important role in ensuring road safety. In this thesis, both offline and online systems are proposed to provide driver status detection. Physiological signals were used in order to detect the stress condition that occurs during driving in drivers. Physiological signals consist of electrodermal activity (EDA) and heart rate signals. In the proposed offline system, a dataset was constituted with physiological signals received in 20 sessions from 12 participants in the prepared experimental environments. Then, the dataset was classified with machine learning algorithms and offline driver status was detected. The classification accuracy obtained with multi-participant data using the entire dataset was 80.1%. In addition, the classification accuracy obtained with data from a single participant in 5 different sessions was found to be 90%. The proposed online system is based on the Internet of Things (IoT) technologies. With online driver status detection, drivers' physiological signals can be monitored remotely in real time and various alerts can be generated when necessary. In this thesis, with the proposed offline and online system, the stress conditions of the drivers can be detected. In this way, it contributes to road safety. Additionally, the IoT concept and its application areas, which have become popular in recent years, was examined in this thesis.

Science Code : 90541

Key Words : Machine learning, internet of things, driver status, physiological signals, road safety

Page Number : 112

Supervisor : Prof. Dr. Nursel AKÇAM

TEŞEKKÜR

Çalışmalarım boyunca değerli vaktini bana ayırarak yardımcı olan ve katkılarıyla yol gösteren danışman hocam Prof. Dr. Nursel AKÇAM ile anlayış ve desteğini esirgemeyen aileme teşekkür ederim.



İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT.....	v
TEŞEKKÜR.....	vi
İÇİNDEKİLER	vii
ÇİZELGELERİN LİSTESİ.....	x
ŞEKİLLERİN LİSTESİ.....	xiii
RESİMLERİN LİSTESİ	xiv
SİMGELER VE KISALTMALAR.....	xv
1. GİRİŞ.....	1
2. İLGİLİ ÇALIŞMALAR.....	5
2.1. IoT ile İlgili Genel Çalışmalar	5
2.2. Yol Güvenliğine Yönelik Çalışmalar	8
3. AKILLI ŞEHİRLER İÇİN NESNELERİN İNTERNETİ (IoT) UYGULAMA ALANLARI.....	17
3.1. Nesnelerin İnterneti (IoT) Kavramı.....	17
3.2. Akıllı Şehirler.....	19
3.2.1. İmalat.....	21
3.2.2. Perakende	22
3.2.3. Sağlık	24
3.2.4. Taşımacılık.....	25
3.2.5. Diğer.....	28
4. ÖNERİLEN YÖNTEM	33
4.1. Kullanılan Araçlar.....	33

	Sayfa
4.1.1. Mikrodenetleyici kartları.....	33
4.1.2. Kablosuz internet bağlantısı modülü.....	35
4.1.3. Elektrodermal aktivite (EDA) sensörü	36
4.1.4. Kulak klipsli kalp hızı sensörü	37
4.1.5. Hafıza kartı modülü	37
4.2. Çevrim Dışı Sürücü Durumu Tespiti.....	38
4.2.1. Veri kümesi oluşturma süreci.....	38
4.2.2. Katılımcılar	39
4.2.3. Zuckerman–Kuhlman Kişilik Testi (ZKPQ).....	40
4.2.4. Dinlenme ortamı	41
4.2.5. Durumluk- Sürekli Kaygı Envanteri (STAI)	43
4.2.6. Simülasyon ortamı	45
4.2.7. Veri kümesi.....	46
4.2.8. Veri ön işleme.....	53
4.2.9. Verilerin sınıflandırılması	53
4.2.10. Sınıflandırma başarımları	55
4.3. Çevrim İçi Sürücü Durumu Tespiti	65
4.3.1. Sistem prototipi.....	66
4.3.2. IoT platformu ile fizyolojik verilerin uzaktan takibi ve depolanması	67
4.3.3. Trafikte anormal durumlar için uyarı sistemi.....	69
5. TARTIŞMA	73
6. SONUÇ VE ÖNERİLER.....	77
KAYNAKLAR	79
EKLER.....	91

	Sayfa
EK-1. Katılımcılardan alınan EDA sinyallerine ait grafikler	92
EK-2. Katılımcılardan alınan kalp hızı sinyallerine ait grafikler.....	102
ÖZGEÇMİŞ	112



ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 1.1. Ülkemizdeki trafik kazası istatistikleri	1
Çizelge 4.1. Arduino Uno Rev3 mikrodnetleyici kartının teknik özellikleri.....	34
Çizelge 4.2. Arduino Nano mikrodnetleyici kartının teknik özellikleri.....	35
Çizelge 4.3. Deneylere gönüllü olan katılımcılara ait bilgiler	39
Çizelge 4.4. Katılımcıların Durumluk Kaygı Ölçeğine ait ortalama puanlar	45
Çizelge 4.5. Dinlenme ve simülasyon ortamlarında alınan EDA sinyal bilgileri.....	50
Çizelge 4.6. Dinlenme ve simülasyon ortamlarında alınan kalp hızı sinyal bilgileri	51
Çizelge 4.7. Çok sürücülü veri kümesinde Bayes Ağları ile elde edilen sınıflandırmaya ait hata matrisi	56
Çizelge 4.8. Çok sürücülü veri kümesinde değerlendirme ölçütlerine göre Bayes Ağları ile elde edilen sınıflandırmaya ait başarımlar.....	56
Çizelge 4.9. Çok sürücülü veri kümesinde Naif Bayes ile elde edilen sınıflandırmaya ait hata matrisi	57
Çizelge 4.10. Çok sürücülü veri kümesinde değerlendirme ölçütlerine göre Naif Bayes ile elde edilen sınıflandırmaya ait başarımlar	57
Çizelge 4.11. Çok sürücülü veri kümesinde Lojistik Regresyon ile elde edilen sınıflandırmaya ait hata matrisi	57
Çizelge 4.12. Çok sürücülü veri kümesinde değerlendirme ölçütlerine göre Lojistik Regresyon ile elde edilen sınıflandırmaya ait başarımlar.....	57
Çizelge 4.13. Çok sürücülü veri kümesinde Yapay Sinir Ağları ile elde edilen sınıflandırmaya ait hata matrisi	58
Çizelge 4.14. Çok sürücülü veri kümesinde değerlendirme ölçütlerine göre Yapay Sinir Ağları ile elde edilen sınıflandırmaya ait başarımlar.....	58
Çizelge 4.15. Çok sürücülü veri kümesinde Destek Vektör Makineleri ile elde edilen sınıflandırmaya ait hata matrisi	58
Çizelge 4.16. Çok sürücülü veri kümesinde değerlendirme ölçütlerine göre Destek Vektör Makineleri ile elde edilen sınıflandırmaya ait başarımlar	58

Çizelge	Sayfa
Çizelge 4.17. Çok sürücülü veri kümesinde k-En Yakın Komşu ile elde edilen sınıflandırmaya ait hata matrisi	59
Çizelge 4.18. Çok sürücülü veri kümesinde değerlendirme ölçütlerine göre k-En Yakın Komşu ile elde edilen sınıflandırmaya ait başarımlar.....	59
Çizelge 4.19. Çok sürücülü veri kümesinde Karar Ağaçları Ormanı ile elde edilen sınıflandırmaya ait hata matrisi	59
Çizelge 4.20. Çok sürücülü veri kümesinde değerlendirme ölçütlerine göre Karar Ağaçları Ormanı ile elde edilen sınıflandırmaya ait başarımlar.....	59
Çizelge 4.21. Tek sürücülü veri kümesinde Bayes Ağları ile elde edilen sınıflandırmaya ait hata matrisi	60
Çizelge 4.22. Tek sürücülü veri kümesinde değerlendirme ölçütlerine göre Bayes Ağları ile elde edilen sınıflandırmaya ait başarımlar.....	60
Çizelge 4.23. Tek sürücülü veri kümesinde Naif Bayes ile elde edilen sınıflandırmaya ait hata matrisi	60
Çizelge 4.24. Tek sürücülü veri kümesinde değerlendirme ölçütlerine göre Naif Bayes ile elde edilen sınıflandırmaya ait başarımlar	61
Çizelge 4.25. Tek sürücülü veri kümesinde Lojistik Regresyon ile elde edilen sınıflandırmaya ait hata matrisi	61
Çizelge 4.26. Tek sürücülü veri kümesinde değerlendirme ölçütlerine göre Lojistik Regresyon ile elde edilen sınıflandırmaya ait başarımlar.....	61
Çizelge 4.27. Tek sürücülü veri kümesinde Yapay Sinir Ağları ile elde edilen sınıflandırmaya ait hata matrisi	62
Çizelge 4.28. Tek sürücülü veri kümesinde değerlendirme ölçütlerine göre Yapay Sinir Ağları ile elde edilen sınıflandırmaya ait başarımlar.....	62
Çizelge 4.29. Tek sürücülü veri kümesinde Destek Vektör Makineleri ile elde edilen sınıflandırmaya ait hata matrisi	62
Çizelge 4.30. Tek sürücülü veri kümesinde değerlendirme ölçütlerine göre Destek Vektör Makineleri ile elde edilen sınıflandırmaya ait başarımlar	62
Çizelge 4.31. Tek sürücülü veri kümesinde k-En Yakın Komşu ile elde edilen sınıflandırmaya ait hata matrisi	63
Çizelge 4.32. Tek sürücülü veri kümesinde değerlendirme ölçütlerine göre k-En Yakın Komşu ile elde edilen sınıflandırmaya ait başarımlar.....	63

Çizelge	Sayfa
Çizelge 4.33. Tek sürücülü veri kümesinde Karar Ağaçları Ormanı ile elde edilen sınıflandırmaya ait hata matrisi	63
Çizelge 4.34. Tek sürücülü veri kümesinde değerlendirme ölçütlerine göre Karar Ağaçları Ormanı ile elde edilen sınıflandırmaya ait başarımlar	63
Çizelge 4.35. Çok sürücülü ve tek sürücülü veri kümelerinde makine öğrenmesi algoritmalarına göre doğruluklar	64
Çizelge 5.1. Önerilen yaklaşımın yapılan benzer çalışmalarla kıyaslanması	73



ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 3.1. Akıllı şehirler için IoT uygulama alanları	20
Şekil 3.2. Dinamik şerit tahsisi yaklaşımı.....	27
Şekil 3.3. Akıllı ev alanına örnek bir senaryo.....	30
Şekil 4.1. Veri kümesi oluşturma sürecine ait blok diyagram	38
Şekil 4.2. Katılımcı 1’den 2. oturumda alınan EDA sinyal değerlerinin zamana göre değişimi.....	47
Şekil 4.3. Katılımcı 3’ten 1. oturumda alınan EDA sinyal değerlerinin zamana göre değişimi.....	47
Şekil 4.4. Katılımcı 1’den 4. oturumda alınan EDA sinyal değerlerinin zamana göre değişimi.....	48
Şekil 4.5. Katılımcı 11’den 1. oturumda alınan kalp hızı sinyal değerlerinin zamana göre değişimi	49
Şekil 4.6. Katılımcı 5’ten 1. oturumda alınan kalp hızı sinyal değerlerinin zamana göre değişimi	49
Şekil 4.7. Önerilen çevrim içi sürücü durumu tespiti için sistem mimarisi.....	65
Şekil 4.8. Çevrim içi sürücü durumu tespiti için iç mekân sürüş ortamında test edilen fizyolojik sinyallere ait grafikler	68

RESİMLERİN LİSTESİ

Resim	Sayfa
Resim 4.1. Arduino Uno Rev3.....	33
Resim 4.2. Arduino Nano	34
Resim 4.3. ESP8266 (ESP-01)	35
Resim 4.4. EDA sensörü.....	36
Resim 4.5. Kulak klipsli kalp hızı sensörü	37
Resim 4.6. Hafıza kartı modülü	37
Resim 4.7. Su videosundan görüntüler	42
Resim 4.8. Veri kümesi oluşturulurken fizyolojik sinyalleri toplamak için kullanılan donanım	43
Resim 4.9. Sürüş simülatöründen görüntüler.....	46
Resim 4.10. ARFF formatında örnek veri kümesi dosyası.....	52
Resim 4.11. Çevrim içi sürücü durumu tespitinde fizyolojik sinyalleri toplamak ve IoT platformuna iletmek için kullanılan donanım	66
Resim 4.12. Çevrim içi sürücü durumu tespiti için hazırlanan iç mekân sürüş ortamı ..	67
Resim 4.13. Anormal sürücü durumları tespitinde sürücüye iletilen uygulama bildirimleri	70
Resim 4.14. Anormal sürücü durumları tespitinde önceden belirlenen üçüncü kişiye iletilen SMS bildirimleri	71

SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler

Açıklamalar

g	Gram
Kb	Kilobayt
mA	Miliamper
MHz	Megahertz
mm	Milimetre
ms	Milisaniye
mW	Miliwatt
V	Volt

Kısaltmalar

Açıklamalar

ARFF	Öznitelik İlişkili Dosya Biçimi (Attribute-Relation File Format)
BM	Birleşmiş Milletler
CAN	Denetleyici Alan Ağı (Controller Area Network)
CSV	Virgülle Ayrılmış Değerler (Comma-Separated Values)
EDA	ElektroDermal Aktivite
EKG	ElektroKardiyoGram
EMG	Elektromiyogram (ElectroMyoGram)
GPS	Küresel Konumlama Sistemi (Global Positioning System)
GSR	Galvanik Deri Tepkisi (Galvanic Skin Response)
ICSP	Devre Üzerinde Seri Programlama (In Circuit Serial Programming)
IoT	Nesnelerin İnterneti (Internet of Things)

Kısaltmalar**Açıklamalar**

IoV	Taşıtların İnterneti (Internet of Vehicles)
LDA	Doğrusal Diskriminant Analizi (Linear Discriminant Analysis)
MIT	Massachusetts Teknoloji Enstitüsü (Massachusetts Institute of Technology)
P2P	Eşler Arası (Peer to Peer)
PCA	Temel Bileşenler Analizi (Principal Component Analysis)
PPG	Fotopletismogram (PhotoPlethysmoGram)
PWM	Darbe Genişlik Modülasyonu (Pulse Width Modulation)
RBF	Radyal Bazlı Fonksiyon (Radial Basis Function)
RFID	Radyo Frekansı ile Tanımlama (Radio Frequency Identification)
SD	Dijital Güvenlik (Secure Digital)
SMS	Kısa Mesaj Servisi (Short Message Service)
STAI	Durumluk-Sürekli Kaygı Envanteri (State-Trait Anxiety Inventory)
TCP/IP	İletim Denetimi Protokolü / İnternet Protokolü (Transmission Control Protocol/Internet Protocol)
TENG	Triboelektrik Nanojeneratör (TriboElectric NanoGenerator)
TÜİK	Türkiye İstatistik Kurumu
USB	Evrensel Seri Veriyolu (Universal Serial Bus)
WEKA	Bilgi Analizi için Waikato Ortamı (The Waikato Environment for Knowledge Analysis)
WHO	Dünya Sağlık Örgütü (World Health Organization)
WSN	Kablosuz Sensör Ağı (Wireless Sensor Network)
ZKPQ	Zuckerman–Kuhlman Kişilik Testi (Zuckerman-Kuhlman Personality Questionnaire)

1. GİRİŞ

Hemen hemen her gün trafikte meydana gelen kazalar çok sayıda yaralanmalara ve ölümlere sebep olmaktadır. Dünya genelinde trafik kazalarında yaşamlarını kaybedenlerin sayısı 2000 yılında 1,15 milyon iken 2016 yılında 1,35 milyona yükselmiştir. Trafik kazaları, 5-29 yaş grubu için birinci sıradaki, tüm yaş grupları için sekizinci sıradaki ölüm nedeni olarak gösterilmektedir. Trafik kazalarında yaşanan ölümler ile ülkelerin gelir düzeyleri arasında da güçlü bir ilişki vardır. Yüksek gelirli ülkelerde ölüm oranı 100 bin kişide 8,3 iken düşük gelirli ülkelerde ölüm oranı 100 bin kişide 27,5'tir. Her yıl 50 milyon kadar insanın yaralanmasına da trafik kazaları neden olmaktadır [1].

Ülkemizdeki istatistikler ise, 2015-2019 yıllarına ait 5 yıllık süreçte her yıl ortalama 6 binden fazla insanın trafik kazalarında hayatını kaybettiğini göstermektedir. İstatistiklerde geçtiğimiz 2019 yılında meydana gelen 1.168.144 trafik kazasının 174.896 tanesi ölümlü/yaralanmalı olarak gerçekleştiği belirtilmektedir. Bu trafik kazalarında 5.473 kişinin vefat ettiği ve 283.234 kişinin de yaralandığı görülmektedir. Ülkemizdeki 2015-2019 yıllarına ait trafiğe kayıtlı araç, kaza, ölü ve yaralı sayılarının yer aldığı karayollarındaki trafik kazası istatistikleri Çizelge 1.1'de gösterilmektedir [2].

Çizelge 1.1. Ülkemizdeki trafik kazası istatistikleri [2]

Yıl	Trafiğe Kayıtlı Taşıt Sayısı	Toplam Kaza Sayısı	Ölümlü/Yaralanmalı Kaza Sayısı	Ölü Sayısı ¹	Yaralı Sayısı
2015	19.994.472	1.313.359	183.011	7.530	304.421
2016	21.090.424	1.182.491	185.128	7.300	303.812
2017	22.218.945	1.202.716	182.669	7.427	300.383
2018	22.865.921	1.229.364	186.532	6.675	307.071
2019	23.156.975	1.168.144	174.896	5.473	283.234

¹ Trafik kazasında kaza yerinde ölenler ile kaza sonrası sevk edildiği sağlık kuruluşunda kazaya bağlı olarak 30 gün içinde ölenlerin toplam sayısını ifade eder.

Yol güvenliği, üzerinde çalışılması gereken küresel bir sorun olarak nitelendirilebilir. Birleşmiş Milletler (BM), 2030 yılına kadar dezavantajlı grupların ihtiyaçlarını gözeterek yol güvenliğini arttırmayı ve herkes için güvenli, erişilebilir, makul fiyatlı, sürdürülebilir ulaşım sistemlerinin kullanımını temin etmeyi amaçlamaktadır [3]. 2020 yılında gerçekleşen 140 ülkeden 1.700 temsilcinin katıldığı 3. Küresel Kara Yolu Güvenliği Bakanlar Konferansı, 2030 yılına kadar dünyada karayolu trafiğindeki ölümleri %50 oranında azaltmayı bir hedef olarak belirleyen "Stockholm Bildirisi" ile tamamlanmıştır [4].

Son 10 yılda ölümlü/yaralanmalı trafik kazalarında, kazaya sebep olan kusurların yaklaşık %90'ı sürücü kaynaklıdır [2]. Sürücü kaynaklı kusurların ortaya çıkmasında acelecilik, alkollü olarak trafiğe çıkmak, ihmal, uykulu olma, yorgunluk, stres gibi çeşitli durumlar etkilidir. Bu durumlardan bazıları sürüş esnasında kişilerin sağlığı, zindeliği ve fizyolojik yapısını olumsuz etkileyen ve çeşitli şekillerde tespit edilebilecek olumsuz durumlardır. Olumsuz durumları tespit edebilmek; sürekli dikkat isteyen sürüş eyleminde, gereken konsantrasyonun sağlanamaması halinde, olabilecek telafisi imkânsız kazaların önüne geçmek açısından gerçekten önemlidir.

Sürücü durumu tespiti, hayati derecedeki önemi nedeni ile üzerinde çalışılan önemli bir konu haline geldiği söylenebilir. Bazı araştırmalar sürücü durumu tespitinde uykululuk, yorgunluk ve stres gibi olumsuz durumların yalnızca birisini tespit etmeyi amaçlarken, bazı araştırmalar birden fazla durumu birlikte ele alır. Bunun yanında sürücü durumu tespiti farklı yaklaşımlar ile değerlendirilmektedir. Kimi araştırmalarda sürücü yüz ifadelerini ya da gözlerini takip eden görsel tabanlı yaklaşımlar; kimi araştırmalarda sürücülerdeki kalp hızı, solunum gibi fizyolojik sinyalleri takip eden yaklaşımlar; kimi araştırmalarda ise taşıt üzerine bağlı sensörler ile taşıt ve çevresel verilerin yer aldığı sürüş verilerini takip eden yaklaşımlar benimsenir. Ayrıca bazı araştırmalarda hibrit yaklaşımlar kullanılır. Farklı yaklaşımlar ile sürücülerdeki sürüş eylemini olumsuz etkileyebilecek durumların daha iyi anlaşılması ve sürücü durumunun tespitinde daha başarılı sonuçlara ulaşmak hedeflenmektedir.

Nesnelerin interneti (Internet of Things - IoT), neredeyse akla gelebilecek her nesnenin gerekli donanımlar ve yazılımlar sayesinde akıllı hale gelerek birbirleri ile veri iletişimi yapabilmesi sonucu oluşan ağ yapısıdır. IoT ile çok farklı alanlarda, çok sayıda uygulama geliştirilmektedir. Sürücü durumunun tespitinde de IoT kullanımı sürücülerini takip edebilecek sensörlere imkân tanır. Bu sensörler ile sürüş sırasında oluşabilecek anormal

durumlar algılanabilecek ve gerektiğinde uyarı verebilecek gerçek zamanlı sistemler geliştirilebilir. Ayrıca IoT kullanımı ile sürücü, taşıt ve yol gibi çeşitli verilerin uzaktan takibi de sağlanabilir. IoT'nin sürücü durumu tespitinde kullanımı, üzerinde çalışılmaya ihtiyaç duyulan fırsatlarla dolu bir alandır.

Bu tez çalışması; tez kapsamında oluşturulacak düşük stres ve sürüş stresini temsil eden iki sınıflı veri kümesi kullanılarak, makine öğrenmesi algoritmaları ile fizyolojik sinyallerdeki anormalliklere göre çevrim dışı sürücü durumunun tespitini sağlamayı ve IoT tabanlı çevrim içi sürücü durumu tespiti için bir yöntem önermeyi amaçlamaktadır.

Bu tez ile aşağıdaki çalışmalar yapılmaktadır.

- Farklı alanlardaki IoT uygulamalarını konu alan çalışmalar, yol güvenliği ile anormal sürüş durumlarının tespiti için yapılan çalışmalar kapsamında geniş bir literatür incelemesi sunulur.
- IoT uygulamaları bütünsel bir bakış ile ele alınarak akıllı şehir başlığı altında sınıflandırılır.
- Deney ortamlarında alınan fizyolojik sinyaller ile sürücü durumu veri kümesi oluşturulur.
- Oluşturulan veri kümesinin sınıflandırılmasında bazı popüler makine öğrenmesi algoritmaları ile çevrim dışı sürücü durumu tespiti sağlanır. Makine öğrenmesi algoritmalarının çevrim dışı sürücü durumu tespitindeki başarımları karşılaştırılır.
- Çevrim içi sürücü durumu tespiti için IoT tabanlı bir sistem önerilir.

Bu tez ile yapılan katkılar şunlardır: Çevrimdışı sürücü durumu tespiti için veri kümesi, çok sürücülü ve tek sürücülü olarak iki farklı şekilde sınıflandırmada kullanılır. Düşük stres ve sürüş stresini temsil eden iki stres sınıfının sınıflandırılmasında tek sürücülü veri kümesi ile elde edilen başarımların, çok sürücülü veri kümesi ile elde edilen başarımlara göre yüksek olması sürücü durumu tespitinde kişiselleştirilebilir sistemler geliştirilmesinin önemini kanıtlar. Ayrıca önerilen çevrim içi sürücü durumu tespiti ile sürücü verilerinin gerçek zamanlı olarak uzaktan takibi yapılabilir ve sürüş stresinin düşük ya da yüksek olduğu durumlarda uyarılar oluşturulabilir.

Bu tez; 2. bölümde mevcut durum ve güncel gelişmelerin yer aldığı ilgili literatür çalışmaları ile devam etmektedir. 3. bölümde, IoT uygulamalarına genel bir bakış sunulmuştur. 4.

bölümde çevrim dışı ve çevrim içi sürücü durumu tespiti için önerilen yöntem detaylı olarak açıklanmıştır. 5. bölümde önerilen yöntemin geçerliliği üzerine değerlendirmeler yapılmıştır. Son olarak 6. bölümde ise çalışmanın sonuçları ana hatlarıyla belirtilerek, gelecekteki çalışmalar için araştırma önerileri sunulmuştur.



2. İLGİLİ ÇALIŞMALAR

Bu bölüm iki başlık altında ele alınmaktadır. İlk olarak IoT'nin kullanıldığı sektörlerle yönelik yapılan ilgi çekici çalışmalar genel olarak incelenmektedir. İkinci bölümde ise yol güvenliğini sağlamak için yapılan bazı önemli çalışmalar anlatılmaktadır. Yol güvenliğini sağlamak için yapılan çalışmalarda, fizyolojik sinyaller ile sürücü durumlarını tespit etmeyi amaçlayan çalışmalar üzerinde durulmaktadır.

2.1. IoT ile İlgili Genel Çalışmalar

Stankovic (2014) araştırma sorularını belirlemek için IoT'nin dünyayı nasıl değiştireceğini inceleyen IoT vizyonunu sundu. Sonrasında ölçeklendirme, mimari, büyük veri oluşturma, sağlamlık, açıklık, güvenlik, gizlilik gibi çeşitli başlıklar altında araştırma sorularını tartıştı [5].

Wan ve diğerleri (2016) Endüstri 4.0 için kaynak yönetimini kolaylaştıran fiziksel altyapı, kontrol ve uygulama katmanları olmak üzere üç katmandan oluşan bir yazılım tanımlı endüstriyel IoT mimarisi önerdiler. Önerilen mimaride fiziksel altyapı katmanı her türlü cihazın bulunduğu katmandır. Kontrol katmanı, farklı uygulamalarda kullanmak için fiziksel altyapı katmanında bulunan cihazların gereksinimlerini ayarlar ve uygulama katmanı ile fiziksel altyapı katmanı arasındaki iletişimi gerçekleştirir. Uygulama katmanı, elde edilmiş olan verileri kullanarak sistem performansını iyileştirecek ve proje maliyetlerini düşürecek çeşitli uygulamalar tasarlamak için kullanılabilir. Ayrıca standardizasyon, pratik uygulamalar, veri güvenliği ve sistem güvenliği ile ilgili sorunlar ve muhtemel çözümleri yazarlar tarafından ele alınmıştır [6].

Rehman ve diğerleri (2019) endüstriyel IoT sistemlerinin gelişmesini sağlayacak yeni teknolojileri, algoritmaları ve teknikleri; büyük veri analizi açısından araştırdılar ve tasarladıkları taksonomiye sundular. Yazarlar mevcut literatürdeki ilgili vaka çalışmalarını incelediler. Ayrıca daha sonra gerçekleştirilecek araştırmalara yön vermek amacıyla gelecekteki teknolojiler, araştırma zorlukları ve çeşitli fırsatlar hakkında tartıştılar. Endüstriyel IoT sistemleri konseptinin hala gelişmekte olduğunu, büyük veri analizinin endüstriyel IoT sistemleri ile tam entegrasyonu ve uygulamasının henüz bulunmadığını

belirttiler [7].

Z. Meng ve diğerkleri (2018) IoT özellikli imalat endüstrisinde ürün yaşam döngüsü yönetim sürecini kısaca anlatarak önceki bazı araştırmalara değindiler. Önceki araştırmaların bilgi modellemesine odaklandığı belirtilen çalışmada, çeşitli teknik zorlukların araştırmalara yansımadağı ifade edildi. Bu yüzden çalışmada ürün tanımlaması, süreç modellemesi, veri bütünleştirme ve veri paylaşımı incelendi. Önerilen yöntem dijital gıda üretim hattında uygulandı ve sunulan yöntemin avantajları gösterildi. Bununla birlikte yaşam döngüsü veri yönetimi sürecinde; veri erişimi, kimlik doğrulama, veri bütünleştirme ve veri paylaşımı için güvenlik yapılarının önemli olduğı vurgulandı [8].

Frank ve diğerkleri (2019) Endüstri 4.0 için bir kavramsal çerçeve önerdiler. Bu çerçeve IoT, bulut bilişim, büyük veri ve analitikten oluşan temel teknolojiler ile akıllı tedarik zinciri, akıllı üretim, akıllı çalışma ve akıllı üründen oluşan ön uç teknolojilerden oluşur. Yazarlar tarafından tarım, madencilik, gıda ve enerji gibi çok sayıda alanda faaliyet gösteren 92 imalat şirketi incelendi. Akıllı üretimin Endüstri 4.0'da merkezi bir role sahip olduğı belirtildi [9].

L. Liu ve diğerkleri (2018) yapay zekâya ve IoT'ye dayanan personelsiz akıllı bir perakende alışveriş sistemi önerdiler. Personelsiz perakende alışveriş sisteminin uygulanabilirliğini belirlemek için gerçekleştirilen çalışma, 10 farklı tipte stok ünitesi ile 11.000 görüntüden oluşan veri kümesini içermektedir. Geliştirilen sınıflandırma modeli test veri kümesi üzerinde uygulandığında en yüksek %98,7 doğruluk elde edildi [10].

Kamble ve diğerkleri (2019) gerçekleştirdikleri çalışmada Hindistan'da perakende mağazalarında IoT uygulamasının benimsenmesinin önündeki engelleri tespit etmeyi ve engeller arasındaki nedensel ilişkiyi araştırmayı amaçladılar. Mevcut literatür incelenerek yönetmelik eksikliği, standardizasyon eksikliği, mimari sorunları, yüksek enerji tüketimi, yüksek maliyetler, internet altyapısı eksikliği gibi on iki potansiyel engel tanımlanmıştır. Bu engeller arasındaki nedensel ilişkiyi araştırmak için hibrit bir metodoloji kullanıldı [11].

Fagerstrøm ve diğerkleri (2020) bir perakende market alışverişinde IoT hizmetlerinin etkisini araştırdılar. Akıllı telefon uygulaması ile gerçekleştirilen çalışmada; fiyat, son kullanma tarihi, kalite göstergeleri ve teklifler olmak üzere dört değişken incelendi. Son kullanma tarihi, kalite göstergeleri ve tekliflerle ilgili IoT hizmetlerinin ürünün satılma ihtimalini

arttırdığı gözlemlendi. Bazı IoT hizmetlerinin, rekabet ortamının yüksek olduğu perakende market pazarında önemli bir rol oynayabileceği belirtildi [12].

Adame ve diğerleri (2018) Katalanca dilinde “bakım” anlamına gelen CUIDATS projesinin ana çıktılarını özetlediler. CUIDATS projesinde öncelikle akıllı sağlık çözümlerinin iki ana dezavantajı belirlendi. Bu dezavantajlar, IoT teknolojileri arasındaki entegrasyon eksikliği ve gerçek senaryolardaki uygulama eksikliği olarak belirtildi. Bu eksiklikleri gidermek için Radyo Frekansı ile Tanımlama (Radio Frequency Identification - RFID) ve Kablosuz Sensör Ağı (Wireless Sensor Network - WSN) teknolojilerinin birleştirilmesiyle IoT hibrit izleme sistemi CUIDATS oluşturuldu. CUIDATS, sağlık ortamındaki hastaların ve varlıkların yerleri ile hastaların yaşamsal belirtilerini (sıcaklık ve nabız gibi) 7/24 izlemeyi sağlar. Hastaların gerçek zamanlı izlenmesini sağlamak için 3 boyutlu baskı teknolojisi kullanılarak bir bilekliğin tasarlandığı projenin gerçek bir hastanede başarılı bir şekilde uygulandığı ifade edildi [13].

Rodrigues ve diğerleri (2018) gerçekleştirdikleri çalışmada sağlık sektöründe IoT kullanımına dayanan en son yayınlardan yola çıkarak bu alandaki mevcut teknikleri ele aldılar. Yazarlar mevcut gelişmeleri inceleyerek, üstesinden gelinmesi gereken zorlukları belirlediler. Yapılan çalışma ilgililer için gelecek eğilimlere yönelik bir yaklaşım sundu [14].

Thapliyal ve diğerleri (2017) stresi tespit etmek ve yönetmek için tüketicilere sunulan IoT tabanlı bazı giyilebilir cihazları incelediler. Giyilebilir cihazların; veri kümeleri, bulut tabanlı hizmetler ve akıllı telefon uygulamaları aracılığı ile stres tespitini sağlayabileceği, aynı zamanda nefes alma ve meditasyon egzersizleri ile stres yönetimini gerçekleştirebileceği anlaşılmaktadır [15].

Hamim ve diğerleri (2019) hastalar ve yaşlılar için IoT tabanlı uzaktan sağlık izleme sistemi önerdiler. Elektrodermal aktivite (ElectroDermal Activity - EDA) sensörü, kalp hızı sensörü, sıcaklık sensörü ve Arduino Uno kullanılarak verilerin toplanması sağlandı. Elde edilen verilerin her biri, fiziksel aktivite değişikliklerine göre analiz edildi. Bu veriler Raspberry Pi bağlantısı ile buluta aktarıldı. Verileri grafiksel olarak göstermek için Android uygulaması geliştirildi. Giyilebilir teknolojilerin sağlık sektöründe kullanılması ile hastalara ve sağlık çalışanlarına çeşitli kolaylıklar sağlayacağı ifade edildi [16].

Xu ve McArdle (2018) IoT cihazlarının sayısındaki aşırı büyümenin enerji, çevre ve sağlık gibi çeşitli alanlarda doğurabileceği istenmeyen sonuçları tanımlamak için “IoT sel” kavramını sundular. Yazarlar akıllı taşımacılık sistemini inceleyerek “IoT sel” sorununu ve potansiyel çözümleri gösterdiler [17].

Alaa ve diğerleri (2017) IoT tabanlı akıllı ev uygulamalarını incelediler. 2010 yılından 2016 yılına kadar gerçekleştirilen konu ile ilgili 229 çalışma ele alınarak 4 sınıfa ayrıldı. Akıllı ev uygulamalarının faydaları, akıllı ev uygulamalarının kullanımında karşılaşılan zorluklar ve bu zorlukların üstesinden gelmek için öneriler tartışıldı [18].

2.2. Yol Güvenliğine Yönelik Çalışmalar

Jain ve diğerleri (2018) gerçek zamanlı olarak trafik yoğunluğunu izleyebilen ve görüntüleyebilen bir trafik yönetimi uygulaması önerdiler. Mevcut trafik yönetim tekniklerinin incelendiği çalışmada; trafik yoğunluğunun psikolojik strese, çarpışmalara, hava kirliliğine, kaynak israfına yol açtığı yazarlar tarafından ifade edildi [19].

Sharma ve Kaushik (2019) IoT’nin taşımacılık uygulamalarını güvenlik, konfor ve bilgi-eğlence, trafik verimliliği ve yönetimi ile sağlık alanları olmak üzere 4 kategoriye ayrılarak kapsamlı bir araştırma yaptılar. IoT’nin taşımacılıkta büyük miktarda veriyi içerdiği belirtilerek güvenlik gereklilikleri, güvenlik zorlukları ve güvenlik saldırıları incelendi. Mevcut çözümlerin dezavantajları açıklanarak, daha iyi ve düşük maliyetli bir kimlik doğrulama protokolü önerildi [20].

Chang ve diğerleri (2018) yol güvenliğini arttırmak için akıllı gözlük, sürücüye destek sağlayacak telematik servis ve bulut tabanlı yönetim platformundan oluşan uyku ve yorgunluk tespit sistemini önerdiler. Önerilen sistemde akıllı gözlükte bilinen kızılötesi sensörler yerine daha verimli sonuçlar için bant geçiren kızılötesi sensörler geliştirildi. Bant geçiren kızılötesi sensörler ile sürücünün göz kapaklarındaki gerilim sinyalleri okunarak sürücünün uyku ve yorgunluk durumu gerçek zamanlı izlenir. Sürücüde uyku ve yorgunluk yönünde bir eğilim olduğunda hoparlörler tarafından sürücüye uyarı sesi iletilir. Ayrıca uyku ve yorgunluk durumunda takip eden taşıtları uyarmak için arka lambaların yanıp sönmeye sağlanır. Elde edilen bilgiler bulut tabanlı yönetim platformuna aktarılır [21].

Zhang ve diğerleri (2017) sürüş anormalliklerinin tespiti için etiketli veri gerektirmeyen ve çevrim içi bir yaklaşım olan SafeDrive'ı önerdi. SafeDrive öncelikle farklı araçların geçmiş verilerinden bir durum grafiği oluşturur. Çevrim içi sürüş verileri bölümlere ayrılarak oluşturulan bu durum grafiği ile karşılaştırılır. Durum grafiği ile önemli ölçüde ayrılan bölümler anormal olarak tanımlanır. SafeDrive, 60 ilden 29 000'den fazla taşıtın bağlandığı taşıtların interneti (Internet of Vehicles - IoV) bulutunda değerlendirildiğinde sürüş anormalliklerini etkili bir şekilde tespit ettiği görüldü [22].

Gruyer ve diğerleri (2017) sürüş otomasyonu sistemlerinin güvenilirliği üzerine genel bir bakış sundular. Oldukça yüksek otomasyona sahip bu sistemlerin sınırlılıkları ve gelecek potansiyel araştırma yolları hakkında görüşler açıklandı. Ayrıca yardımcı pilot uygulamasının tasarlanmasında yer alan aşamalar hakkında bilgiler verilerek, yapay zekâ ve IoT gibi son teknolojilerin kullanımına dayanan yardımcı pilot uygulamaları tartışıldı [23].

X. Wang ve diğerleri (2019) üç şeritli bir yolda sürücünün değişen eğilimlerinin taşıt kümelenmesindeki değişime etkisini incelediler. Taşıt kümelenmesi, trafikteki taşıtların dinamik olarak düzenlenmesini ifade eder. Sürücünün eğilim durumu, sürücünün fizyolojik verilerinden (solunum gibi) ve davranışsal verilerden (hızlanma, şerit değiştirme gibi) elde edilerek; buna bağlı taşıt kümelenmesi durumu hesaplandı [24].

Lozoya-Santos ve diğerleri (2019) bilişsel otomobil sistemleri için biyometrik sistemler üzerine yaptıkları araştırmalarında kullanılan yöntemleri ve son uygulamaları açıkladılar. Dört seviyeli bir biyometrik sistem önerilen çalışmada, biyometrik sistemlerin; insan-taşıtlar ilişkisini geliştirebileceği, yol güvenliğini arttırılabileceği ve sürücülere daha güzel bir sürüş deneyimi yaşatabileceği anlaşıldı [25].

Kaplan ve diğerleri (2015) sürücü uyuşukluğunu ve dikkatsizliğini tespit ederek yol güvenliğini sağlamak için geliştirilen teknikleri, kapsamlı bir şekilde araştırmış ve sınıflandırmıştır. Sürücü dikkatsizliğinin tespitine odaklanan çok sayıda çalışma bulunduğunu ama dikkatsiz bir sürücüyü uyarmak için yapılan çalışmaların sayısının yetersiz olduğunu belirttiler. Buna ek olarak güvenli sürüş için taşıttan taşıta iletişime dayanan sürücü davranışını yayma kavramını önerdiler [26].

Khan ve diğerleri (2018) sürücü yorgunluğunun tespiti için yüz ifadelerinin analizine

odaklanan bir sistem önerdiler. Aydınlatma gibi çevresel parametrelerin yüz ifadelerinin analizini etkilediği belirtilen çalışmada yüz bölgelerinin seçimi için entropi analizine dayalı model geliştirilmiştir. Farklı çözünürlükteki görüntülerde çalışabilen ve gürültüden etkilenmeyen sistem, test sonuçlarına göre benzer tekniklerden daha iyi bir başarımla göstermektedir [27].

X. Meng ve diğerleri (2018) tarafından Kapton ve Alüminyum folyo malzemelerden oluşan, kendi gücünü sağlayabilen, triboelektrik nanojeneratör (TriboElectric NanoGenerator - TENG) tabanlı sensör; sürüş simülatörü ile sürücü davranışını izlemek için ilk kez kullanıldı. Düşük maliyetle üretilebilen sensörler basınca duyarlıdır. Gerçek zamanlı elde edilen verilerin ilk değerlendirmesi, bu sensörlerin, sürücülerin davranışlarını izlemek ve trafik güvenliğini artırmak için kullanılabileceğini gösterir [28].

Koesdwiady ve diğerleri (2016) sürücü durumu izleme sistemlerindeki son gelişmeleri incelediler. Gelişmiş yardımcı sürüş sistemleri hakkında genel bir bakış sunulan çalışmada, dikkatsizlik nedenleri araştırılarak kapsamlı bir sınıflandırmanın yapılması sağlandı. Ayrıca araç içi sensörler ve sürücü davranışlarının yanında dış çevre ile etkileşime geçilebilmesini sağlayan IoV kavramı açıklandı. Sürücü durumu izleme sistemlerinin gelecekteki araştırma yönleri, umut verici gelişmeler ve karşılaşılan ana zorluklar tartışıldı [29].

Dobbins ve Fairclough (2018) sürücülerde stres tespitine yönelik fizyolojik sinyallere ve sürüş verilerine dayanan bir grup algoritmayı açıkladılar. Fizyolojik sinyaller, elektrokardiyogram (EKG) ve fotopletizmogram (PhotoPlethysmoGram - PPG) sinyallerinden; sürüş verileri ise taşıt hızı ile taşıt sayısı, hava durumu gibi çevresel özellikleri içeren fotoğraflardan oluşur. Gerçek dünya ortamında 21 katılımcıdan elde edilen veriler, veri ön işleme aşamasından geçtikten sonra stres tespiti için tasarlanmış çeşitli sınıflandırma algoritmaları ile değerlendirildi. Sonuçta en yüksek %86,9 doğruluk elde edilerek yöntemin geçerliliği ispatlandı [30].

Rigas ve diğerleri (2011) sürücü stres tahmini için fizyolojik sinyallerin ve sürüş bilgilerinin kullanıldığı bir metodoloji sundular. Gerçek sürüş koşullarında elde edilen EDA, EKG ve solunum sinyallerinden oluşan fizyolojik veriler işlenerek stres tespiti için Bayes Ağları sınıflandırıcısında test edildi. Sadece fizyolojik sinyallere dayalı stres tespitinin doğruluğu %82 olurken, denetleyici alanı ağ veri yolu (Controller Area Network bus - CAN bus) ve

küresel konumlama sistemi (Global Positioning System - GPS) üzerinden elde edilen sürüş bilgilerinin dâhil edilmesi doğruluğu %96'ya yükseltti. Bununla birlikte yalnızca fizyolojik sinyallere dayalı sistemlerin yeterli olabileceği belirtildi [31].

Lanata ve diğerleri (2014) artan stres koşullarında sürücünden alınan fizyolojik sinyallerin değişimi ile taşıttan alınan sürüş verilerinin değişimini inceledi. 15 katılımcı ile eğitim, dinlenme, normal sürüş, birinci seviye stresli sürüş ve ikinci seviye stresli sürüş aşamalarından oluşan 5 aşamalı bir deney, simülasyon ortamında gerçekleştirildi. Normal sürüş sırasında sürücüye dışardan stres olayları ile müdahale edilmedi. Birinci seviye stresli sürüş ve ikinci seviyeli sürüş sırasında sürücüye artırımlı stres uygulandı. Deney aşamalarında sürücünden alınan EDA, kalp hızı ve solunum ile direksiyon açısı ve hız gibi sürüş verileri kaydedildi. Deney sonuçları normal sürüş ile stresli sürüş aşamalarında fizyolojik sinyallerde ve sürüş verilerinde anlamlı farklılıklar olduğunu kanıtladı [32].

Ghaderi ve diğerleri (2015) stres tespitinde fizyolojik sinyalleri kullanan makine öğrenmesi algoritmalarına dayalı bir yaklaşım sundular. Sürüş esnasında farklı stres ortamlarında 17 sürüşten elde edilen EDA, elektromiyogram (ElectroMyoGram - EMG) ve solunum gibi fizyolojik sinyallerden, 7 sürüş için elde edilen veriler kullanıldı. Farklı stres seviyeleri için veri bölütleme ve öznitelik çıkarma işlemleri yapıldı. Sınıflandırma gerçekleştirilirken; k-En Yakın Komşu ve Destek Vektör Makineleri sınıflandırıcıları kullanıldı. Düşük stres, orta stres ve yüksek stres olmak üzere üç seviyeli durum için sınıflandırma gerçekleştirildi. Sonuçta yüksek bir doğruluk elde edilirken, solunum verilerinin stres tespitinde en önemli fizyolojik sinyaller olduğu anlaşıldı [33].

Lee ve diğerleri (2016) stres tespiti için fizyolojik sinyallere ve sürüş davranışına dayalı, düşük maliyetli giyilebilir bir eldiven sistemi geliştirdiler. Fizyolojik sinyaller, parmak ucundan alınan PPG sinyalinden; sürüş davranışı verileri direksiyon hareketine bağlı değişimlerden elde edildi. Simülasyon ortamında 28 katılımcı ile üç farklı stres ortamında gerçekleştirilen çalışma sonucunda %95'in üstünde elde edilen doğruluk, yöntemin geçerliliğini gösterir [34].

Keshan ve diğerleri (2015) sürüş koşullarından kaynaklanan stresin tespiti için yalnızca EKG sinyallerine dayalı bir çalışma yaptılar. Bu çalışmada, bir bireyin stres analizi üç stres düzeyinde yapıldı: düşük, orta ve yüksek. Makine öğrenmesi algoritmaları kullanılarak

düşük, orta ve yüksek stres sınıfları %88,24 doğrulukla; düşük ve yüksek stres sınıfları %100 doğrulukla tespit edildi. EKG sinyallerinin stres tespitindeki başarısı bu sinyallerin stres kaynaklı trafik kazalarının önlenmesi amacıyla kullanılabileceğini gösterir ve stresle karşılaşılan başka alanlarda da kullanılmasına imkân tanıyabileceği düşünülür [35].

Choi ve diğerleri (2017) stres, yorgunluk ve uyuşukluk gibi olumsuz durumları izlemek için giyilebilir bir cihaz geliştirdiler. Simülasyon ortamındaki sürüş deneylerinde, 28 katılımcıya ait fizyolojik sinyal ve sürüş davranışı verileri, bileğe takılan ve rahatsızlık vermeyen cihaz yardımıyla alındı. Veriler üzerinde gürültü kaynaklı hataların önüne geçmek için ön işleme işleminden sonra öz nitelik çıkarma işlemi gerçekleştirildi. Sürücü durumu tespiti Destek Vektör Makineleri sınıflandırıcısı ile yapıldı. Sonuçlar önerilen sistemin sürücülerin olumsuz durumlarını normal durumlardan ayırt edebileceğini ve bu sayede sürüş güvenliğini arttırabileceğini gösterir [36].

Mühlbacher-Karrer ve diğerleri (2017) sürücünün stres seviyesini izlemek için hücresel yapay sinir ağına (cellular neural network) dayalı bir sistem sundular. Yazarlar fizyolojik sinyaller için kullanılan sensörlerin yanında kapasitif el algılama sensörünü önerdiler. 22 katılımcı ile simülasyon ortamında gerçekleştirilen deneylerde yalnızca fizyolojik sensörlerin kullanılması durumunda doğruluk %82 iken kapasitif el algılama sensörünün fizyolojik sensörlere eklenmesi durumunda doğruluğun %92'ye yükseldiği bulundu. Neticede önerilen yöntemin iyi bir başarıyı gösterdiği ve kapasitif el algılama sensörünün doğruluğu önemli derecede iyileştirdiği anlaşıldı [37].

Gutmann ve diğerleri (2015) sürüş simülatörünün fizyolojik sinyal değerlerindeki değişimler üzerinden duygu ve stres tespitinde kullanımını incelediler [38].

Munla ve diğerleri (2015) EKG sinyalinden türetilen kalp hızı değişkenliğini kullanarak sürüş stresinin tespitini amaçladılar. “MIT drivenb” veri kümesindeki 16 farklı katılımcıdan elde edilen verilerin kullanıldığı çalışmada sürücüler, stresli ve normal olarak iki kategoride sınıflandırıldı. Sınıflandırma için k-En Yakın Komşu, Radyal Bazlı Fonksiyon (Radial Basis Function - RBF) ve Destek Vektör Makineleri algoritmaları seçilerek karşılaştırıldı. Destek Vektör Makineleri, lineer ve RBF çekirdekli Destek Vektör Makineleri olmak üzere iki şekilde uygulandı. Stres tespiti için en yüksek doğruluk %83 ile RBF çekirdekli Destek Vektör Makineleri algoritması ile elde edildi [39].

Singh ve diğerleri (2011) stres tespitinde fizyolojik sinyallere dayalı bir yaklaşım sundular [40].

Lopez-Martinez ve diğerleri (2019) gerçek dünya ortamında sürüş deneylerinde elde edilen üç ayrı veri kümesini kullanarak duygusal durumun tespiti için bir makine öğrenmesi yöntemi önerdiler. Fizyolojik sinyallerden EDA ve kalp hızı sinyallerine dayalı gerçekleştirilen çalışma sonucunda yüksek sınıflandırma doğruluğu elde edildi [41].

Saeed ve diğerleri (2017) stres ve uyuşukluğun tespiti için derin öğrenme algoritmalarını kullandılar. 11 profesyonel kamyon sürücüsünden giyilebilir cihaz yardımı ile toplanan EDA, kalp hızı gibi fizyolojik sinyaller üzerinde eğitilen evrişimsel sinir ağının (convolutional neural network) temel bir sinir ağından daha iyi başarımlar gösterdiği görüldü [42].

Napoletano ve Rossi (2018) sürücü stresinin otomatik olarak tespit edilmesi için kalp hızı ve solunum sinyallerinin kullanımını araştırdılar. Deneyler simülasyon ortamında katılımcılardan alınan fizyolojik sinyal verilerinin bulunduğu veri kümesi kullanılarak yapıldı. RBF destekli Destek Vektör Makineleri ile stresli ve stressiz iki kategoride sınıflandırma gerçekleştirildi. Sonuçlar bu sinyallerin stres tespiti için kullanılabileceğini gösterirken, en yüksek doğruluk %69 ile sinyallerin birlikte kullanıldığı durumda elde edildi [43].

Qiu ve diğerleri (2019) sürücünün fizyolojik sinyalleri ile sürüş manevraları arasındaki ilişkiyi araştırdılar. Gerçek dünya ortamında oluşturulan sürüş veri kümesi kullanılarak gerçekleştirilen çalışmada; sağa dönüş, sola dönüş, U dönüşü, kavşak geçişi, sol şerit değiştirme ve sağ şerit değiştirme olmak üzere altı sürüş manevrası dikkate alındı. EDA, kalp hızı ve solunum sinyallerinin normale göre daha düşük ya da daha yüksek olduğu durumların sürüş manevraları ile bağlantılı olduğu anlaşıldı [44].

Athanasiou ve diğerleri (2014) elektrikli taşıt üzerinde stres odaklı sürücü destek sistemi önerildiler. Sürücünden alınan EDA, EKG ve solunum sinyallerinden oluşan fizyolojik veriler Bayes Ağları modeli tarafından gerçek zamanlı stres tespiti için kullanıldı. Önerilen sistem güvenli ve konforlu bir sürüş için trafik koşullarına göre taşıt hızının yönetilmesini amaçlar [45].

Nita ve diğerleri (2019) EKG sinyali kullanarak düşük, orta ve yüksek üç seviyeli sürücü stresinin tespiti için bir yaklaşım sundular. Stres tespiti için geleneksel Karar Ağaçları Ormanı yöntemi ile benzetimli tavlama (simulated annealing) yöntemini birleştirerek gelişmiş bir Karar Ağaçları Ormanı kullandılar. Sonuçta düşük, orta ve yüksek 3 stres seviyesini tespit etmede %97; düşük ve yüksek 2 stres seviyesini tespit etmede %100'e yakın doğruluğa ulaşıldı. Uygulanan yöntem, Karar Ağaçları Ormanı ve Destek Vektör Makineleri gibi diğer sınıflandırma yöntemlerine kıyasla daha iyi bir başarımla gösterdi [46].

Li ve diğerleri (2016) gerçek dünya sürüşü sırasında üç sürücünden alınan fizyolojik sinyalleri “Normal”, “Olay” ve “Gürültü” kümeleri olarak sınıflandırmak için kümeleme algoritması kullandılar. Sürücü davranışı olaylarını, sürücünün psikolojik durumuna göre “zor manevralar”, “sürücü şaşkınlıkları” ve “sürücünün duygusal uyarılmaları” isimli üç gruba ayırdılar. Sürücünün psikolojik durumundaki değişikliklerin, sürücüye ait fizyolojik sinyaller değerlerinde sapmalara neden olabileceği ve sürücü davranışı olaylarını etkileyebileceği belirtildi. Sonuçta “Olay” kümesinin sürücü davranışı olayları ile yakından ilişkili olduğu bulundu [47].

Kavitha ve Perumalraja (2014) sürüş sırasında sürücülerde meydana gelebilecek kalp krizi gibi olumsuz sağlık durumlarını yönetmek için sağlık izleme sistemi önerdiler. Önerilen sistem ile sürücülerden alınan kalp hızı, solunum gibi fizyolojik sinyallerde oluşabilecek anormallikler sağlık ve ulaşım merkezlerine bildirildi [48].

Cassani ve diğerleri (2019) tarafından direksiyon simidinde yerleştirilen elektrotlar aracılığı ile EKG sinyalleri alındı. Sonuçta alınan bu sinyallerin anlık ve ortalama kalp hızı ölçümü ile solunum hızı ölçümüne olanak tanıdığı görüldü [49].

Schmidt ve diğerleri (2016) bilişsel ve duygusal durumların ortaya çıkarılması için farklı sürüş koşullarında taşıt kullanımını araştırdılar. Sürüş simülatörü üzerinde çeşitli trafik senaryoları kullanılarak oluşturulan sürüş koşullarında 46 katılımcıya ait fizyolojik veriler ve taşıt verileri sensörler yardımıyla toplandı. Katılımcılar her bir sürüş koşulunun sonunda bilişsel ve duygusal durumlarını ölçmeye yönelik anketler doldurdu. Sürücü durumunun tespitinde fizyolojik verilerin kullanımının geçerliliği ile sürücü durumu hakkında bilgi içeren sinyallerin sürücüye bağlı değişebildiği görüldü [50].

F. Liu ve diğerleri (2019) sürücü yorgunluğunun tespiti için yapılan çalışmaları ve son eğilimleri incelediler. Yorgunluk tespiti ile ilgili yaklaşımlar; sürücünden alınan fizyolojik sinyallere, sürücülerin davranış özelliklerine, taşıt sürüş özelliklerine ve hibrit tekniklere dayalı olarak gruplandırılarak karşılaştırıldı. Son eğilimlerden olan derin öğrenme teknolojilerinin yorgunluk tespitinde önemli fırsatlar oluşturarak sağlamlığı arttırabileceği belirtildi [51].

Y. Liu ve Du (2018) EDA sinyallerini kullanarak üç stres seviyesinin tespiti için bir yöntem sundular. Gerçek sürüş verilerinin bulunduğu “MIT drivedb” veri kümesindeki 11 sürücüye ait ve ayağa bağlı sensörlerle ölçülen sinyaller kullanıldı. Sonuçta düşük, orta ve yüksek üç stres seviyesinin tespitinde doğrusal diskriminant analizi (Linear Discriminant Analysis - LDA) kullanılarak %81.82 ile kabul edilebilir bir doğruluğa ulaşıldı [52].

J. S. Wang ve diğerleri (2013) stres tespiti için k-En Yakın Komşu algoritması kullanarak kalp hızı değişkenliği analizine dayanan çalışma yaptılar. Çalışmada kullanılan veriler “MIT drivedb” veri kümesinden indirildi. Kalp hızı değişkenliği öznitelik tabanlı dönüşüm algoritması; öznitelik oluşturma, öznitelik seçme ve öznitelik boyutu azaltma işlemlerinden oluşur. Kalp hızı değişkenliği analizi ile önemli öznitelikleri oluşturmak için “trend tabanlı” ve “parametre tabanlı” iki farklı yaklaşım sundular. Öznitelik seçme ve sonrasında temel bileşenler analizi (Principal Component Analysis - PCA) ve LDA ile öznitelik boyutu azaltma işlemleri gerçekleştirildi. Stres tespitinde "trend tabanlı" yaklaşımda en yüksek %97.78 ve “parametre tabanlı” yaklaşımda en yüksek %81.06 tanıma oranları ile yöntemin doğruluğu anlaşılmıştır [53].

Healey ve Picard (2005) sürüş görevleri sırasında stres tespitine yönelik olarak fizyolojik sinyalleri toplamak ve analiz etmek için çeşitli yöntemler sundular. Dinlenme, otoyol ve şehir içi sürüş koşullarındaki sürüş stresini belirlemek için Boston bölgesinde belirli bir rotada gerçekleştirilen sürüşlerde 9 katılımcıdan elde edilen 24 sürüş verisi ile “MIT drivedb” veri kümesi oluşturuldu. 5 dakikalık veri aralıkları kullanılarak gerçekleştirilen sınıflandırma sonucunda üç farklı stres seviyesi için doğruluk %97,4 olarak bulundu. Ayrıca EDA ve kalp hızı sinyallerinin çoğu sürücü için sürücü stres düzeyi ile yakından ilişkili olduğu anlaşıldı. Araştırmacıların oluşturdukları veri kümesinde 17 sürüş verisi herkese açık olarak paylaşılmakta ve veri kümesi literatürde sürücü stres tespitinde sıklıkla kullanılmaktadır [54].



3. AKILLI ŞEHİRLER İÇİN NESNELERİN İNTERNETİ (IoT) UYGULAMA ALANLARI

3.1. Nesnelerin İnterneti (IoT) Kavramı

Nesnelerin interneti (Internet of Things - IoT), verilerin toplanması ve değiştirilmesini kolaylaştırmak için fiziksel cihazların birbirleriyle dinamik bir şekilde bağlantılı olduğu bir ağ sistemidir [55, 56]. IoT, fiziksel cihazların, insan müdahalesi olmaksızın, bilgi paylaşmak ve karar vermek için görmesini, duymasını, düşünmesini sağlayarak konuşmasına olanak tanır [57, 58]. IoT'nin amacı enerjiden, zamandan ve paradan tasarruf sağlayarak insan hayatını kolaylaştırmak ve akıllı bir çevre oluşturmaktır [59]. IoT kavramı, 1999 yılında tedarik zincirlerinde RFID kullanımını konu alan bir sunumda Kevin Ashton tarafından ilk defa kullanılmış; sensörler, aktüatörler, GPS cihazları ve mobil cihazlar gibi diğer teknolojiler daha sonra IoT ile ilişkilendirilmiştir [60, 61]. IoT; bilgisayarlar, gömülü sistemler, iletişim teknolojileri, algılayıcı ağlar, internet protokolleri gibi temel teknolojiler ile geleneksel varlıkları “akıllı” hale getirerek yeni nesil interneti tanımlar [57, 58].

Temel teknolojilerdeki hızlı gelişmelere bağlı olarak, IoT, her alanda yaşam kalitesini arttırmayı vaat eden çok sayıda yeni uygulama için muazzam fırsatlar sunmaktadır [5, 62]. IoT şu anda küçük bir bölümünün mevcut olduğu farklı alanlarda çok sayıda uygulama geliştirmeyi mümkün kılmaktadır. Çok yakın gelecekte; evde, yolculukta, hastanede, iş yerinde, okulda, spor salonunda, alışverişte birçok yeni uygulama ile yaşam kalitesinin artması sağlanabilecektir [63]. Örneğin, bir uygulama şehir trafiğini izlemeye ve kontrol etmeye yardımcı olabilir, bir başkası finansal ve yatırım işlemlerini gerçekleştirebilir, diğeri otomatik olarak ihtiyaca yönelik alışveriş siparişi verebilir, bir diğeri sağlık sorununu hafifletmek, tedavi etmek ve hatta önlemek için tıbbi bir problemin erken teşhisini sağlayabilir [5]. Ayrıca IoT sınırlı kaynakların verimli ve etkin bir şekilde kullanılmasına yardımcı olacaktır [64]. IoT'nin bazı gelişmiş toplum problemlerini çözeceği ya da bu problemlerin çözümüne çok büyük katkı sağlayacağı beklenmektedir [65].

İnternet üzerinden bağlanan nesnelerin sofistike bir ağı olan IoT, bilimsel ve endüstriyel toplulukların odaklandığı nispeten yeni bir paradigmadır [66, 67]. Endüstride son yıllarda verimliliği arttırmak adına IoT teknolojilerinin benimsenmesi, Endüstri 4.0'ın temelini

oluşturmaktadır [67, 68]. Son zamanlarda imalat, perakende, sağlık, taşımacılık, enerji gibi çok sayıda alanda IoT uygulamaları geliştirilmekte ve uygulanmaktadır [61, 64].

IoT, iletişim ve hesaplama işlevlerine sahip akıllı nesnelerden oluşur [69]. Akıllı nesneler, IoT'nin çevre ile etkileşim kurabilen temel parçasıdır. Elde ettiği bilgiler ile otonom karar verebilir. Akıllı nesnelere örnek olarak bilgisayarlar, akıllı telefonlar, akıllı buzdolapları, tabletler, bazı arabalar, akıllı televizyonlar gibi karmaşık cihazların yanında çeşitli sensörler içeren elbise, kâğıt, mobilya, sanat eseri, gıda ürünleri gibi nesnelerde gösterilebilir [70, 71]. IoT nesnelerinin sayısının zaman içerisinde hızla artacağı ve bu akıllı nesnelerin, imalat, akıllı ölçüm, sağlık, çeşitli ev otomasyonları ve henüz tanımlanmamış birçok yeni alanda kullanılması öngörülmektedir [56, 72].

IoT, akıllı nesnelerin yeteneklerini temsil eden üç sacayağı üzerine kurulu bir yapıdır. Bu yetenekler, nesnelerin tanımlanabilir olmasını (herhangi bir nesne kendini tanımlayabilir), iletişim kurmasını (herhangi bir nesne iletişim kurar) ve karşılıklı etkileşimde (herhangi bir nesne etkileşir) bulunabilmesini gerektirir [73].

IoT'nin üç teknolojik bileşeni; donanım, ara katman yazılımları ve sunum olarak tanımlanır. Donanım; IoT'nin fiziksel yapısı için sensörler, aktüatörler ve gömülü iletişim cihazlarından meydana gelir. Ara katman yazılımları; veri depolama ve veri analizi için gerekli hesaplama araçlarından oluşur. IoT sistemlerini akıllı hale getirir. Sunum, farklı platformlardan erişilebilen, farklı uygulamalar için tasarlanmış görselleştirme ve yorumlama araçlarını ifade eder [74]. IoT'de, veriler fiziksel cihazlar ile toplanarak, kablosuz ağlar üzerinden iletilir. Bu veriler hesaplama araçları tarafından analiz edilir. Analiz edilen veriler ihtiyaca yönelik uygulamanın gerektirdiği şekilde kullanılır.

McKinsey Küresel Enstitü raporu, IoT'nin 2025 yılında yıllık 3,9 trilyon dolar ile 11,1 trilyon dolara arasında potansiyel bir ekonomik etkiye sahip olduğunu öngörmektedir. Üst sınır değeri olan 11,1 trilyon dolar, 2025 yılında beklenen dünya ekonomik değerinin yaklaşık %11'ine eşittir [75].

Tez çalışmasının bu bölümünde geliştirilen bazı IoT uygulamaları incelenmiş ve akıllı şehirler başlığı altında sınıflandırılmıştır.


3.2. Akıllı Şehirler

Dünya nüfusunun %70'inin 2050 yılına kadar şehirlerde ve çevresindeki bölgelerde yaşayacağı öngörülmektedir. Şehirlerdeki nüfus artışından kaynaklanan sorunların aşılarda ekonomik, sosyal ve çevresel refahı sağlamak için şehirler akıllı olmalıdır. Akıllı şehirler, şehir hizmetlerini sunmak için bilgi ve iletişim teknolojilerini kullanan daha etkileşimli ve etkili izlenen şehirlerdir [76, 77]. Akıllı şehirlerin esas hedefi kamu kaynaklarının daha iyi kullanılması ve vatandaşlara sunulan hizmetlerin kalitesinin artırılmasıdır [78].

Akıllı şehirlerde, şehir hakkında bilgi toplamak için şehrin çeşitli noktalarına yerleştirilmiş, gelişmiş algılama ve hesaplama yeteneklerine sahip farklı türlerde sensörler bulunmaktadır [70, 76]. Bu sensörlerden elde edilen büyük miktardaki veriler kullanılarak birçok akıllı şehir uygulamasının geliştirilmesi sağlanır [79]. Akıllı şehirler, yaygın iletişim ağları ve akıllı sistemleri kullanarak şehir yönetimini kolaylaştırır, fiziksel şehir altyapılarının optimize edilmesini sağlar, sunulan yeni hizmetlerle vatandaşların günlük hayatını ve şehrin yaşam koşullarını iyileştirir [70, 73, 76]. Akıllı şehirlerde enerji kullanımı, atık yönetiminin sağlanması, aydınlatma, hava ve gürültü kirliliğinin takibi, yolların, taşıtların, otoparkların, metroların, havaalanlarının ve limanların izlenmesi, çeşitli kamu hizmetlerinin yönetilmesi gibi çok sayıda uygulama alanı mevcuttur.

Akıllı şehirlerin temel sorunlardan birisi sunulan uygulama ve hizmetlerdeki karar verme yetkisinin farklı kişi ve kurumlarca yönetilmesidir [78]. Akıllı şehirlerde, enerji kullanımı, ulaşım, sağlık, çevre, eğitim ve çeşitli hizmetlerin iyileştirilmesi gibi ihtiyaçların yönetimini tek merkezde birleştiren bir stratejinin tasarlanması gerekir [80].

Akıllı şehirler, gerçek zamanlı bilgileri, gereken zamanda, doğru bir şekilde sunmak için şehirdeki insanları akıllı teknolojilere bağlayarak teknolojileri çok daha geniş bir alana yayar [68]. Şekil 3.1, akıllı şehirler için IoT uygulama alanlarını göstermektedir. Akıllı şehir uygulama alanları bu çalışmada imalat, perakende, sağlık, taşımacılık ve diğer olmak üzere 5'e ayrılmıştır. IoT uygulamaları çok fazla olduğu için bu başlıkları çoğaltmak da mümkündür.



Şekil 3.1. Akıllı şehirler için IoT uygulama alanları

Şehirlerin akıllı hale dönüştürülerek daha verimli, emniyetli, çekici, konforlu ve rekabetçi olması için pek çok değişiklik yapılmalıdır. Bu değişim, şehirlerin görünümüne iş dünyasının, vatandaşların ve akademik çevrelerin birlikte şekillendireceği yeni bir doku kazandıracaktır. Vatandaşlar, kullanıcı olmanın yanında önemli bir paydaş ve teknoloji, statik bir varlık yerine dinamik bir süreç destekleyicisi olarak görülmelidir [81].

3.2.1. İmalat

Sanayi devriminden itibaren imalatta verimliliğin artması değişmez bir amaç olmuştur [82]. Verimliliğin artması için üretim ve lojistik maliyetleri düşürmek, ürün ve hizmet kalitesini arttırmak, üretim süreçlerini hızlandırmak gerekir [83]. Verimlilik, çevre standartları, tüketici talepleri ve rekabet gücünü koruma gerekliliği gibi etkenler imalatın gelişmesi için üreticilere baskı oluşturur [83, 84]. İmalat teknolojilerinin gelişimi bilgi teknolojileri ile doğrudan ilgilidir. İmalatın her büyük değişimi, bilgi teknolojilerinin ilerlemesi ile desteklenmiştir [85]. İmalatta her türlü yeni bilgi teknolojisini destekleyen IoT kullanımı bu değişimlerden birisidir [86]. İmalatta IoT, çeşitli sensörlerden ve nesnelerden sürekli bilgi almak, izlemek ve sensör okumalarını veri merkezine güvenli bir şekilde iletmek için uygulanan bilgi teknolojileri altyapısıdır. IoT, işletmelere daha iyi bir sistem performansı sunarak, işletmelerin ilerlemesine katkı sağlar [6, 85].

İmalat alanında IoT'nin ortaya çıkarak büyük veri ve bulut hizmetleri ile birlikte kullanılması akıllı imalat ya da yaygın kullanımıyla Endüstri 4.0 olarak adlandırılır. Endüstri 4.0, esnek hatlarda, farklı ürün türleri ve değişen koşullarda üretim süreçlerini otomatik olarak gerçekleştiren bir sistemdir. Endüstri 4.0 sayesinde kaliteli ve özelleştirilmiş ürünlerin elde edilmesi ile kaynak tüketiminin iyileştirilmesi, üretkenliğin ve esnekliğin artması sağlanabilir [9]. Bununla birlikte, pratik olarak uygulanmasında çeşitli zorluklar bulunur. Farklı nitelikteki verilerin algılanması ve bu algılamının gerçek zamanlı olarak uygulanması için çok sayıda cihaz kullanılmalıdır. İhtiyaç duyulan cihazların türleri ve miktarları belirlenmeli, fayda-maliyet analizi yaparak imalatta IoT'nin makul bir yatırım olup olmadığına önceden karar verilmelidir [84].

Sanayide üretim işlemlerini ve verimliliği sistem üzerinden kontrol etmek ve izlemek için IoT kullanılır [58]. Örneğin, fabrikadan gerçek zamanlı olarak imalat durumu bilgileri, işleyiş ve çevre ile ilgili çeşitli sensör verileri toplanır. Bu veriler, insan müdahalesi gerekmeksizin tasarım ve imalat sistemlerini sürdürmek ve optimize etmek için işleyişi otomatikleştirmekte kullanılabilir. Farklı kaynaklardan gelen büyük veri için akıllı algoritmalar otomatik olarak en doğru kararları verebilir [84, 87]. Bu süreç yetkili kişiler tarafından takip edilerek istenildiğinde müdahale edilebilir, akıllı algoritmaların oluşturacağı alternatif kararlar değerlendirilebilir.

Çeşitli yeteneklere sahip imalat cihazlarının kusursuz uyumunu gerçekleştirebilen IoT, günümüzde imalat endüstrisini büyük ölçüde değiştirebilen yeni bir kavram olarak kabul edilmektedir. Bu şekilde gerçekleştirilen imalatın yeni iş ve pazar fırsatları oluşturularak küresel ekonomi üzerinde büyük etki oluşturması beklenmektedir [84].

3.2.2. Perakende

İşletmelerin, sektördeki diğer işletmelere rekabet etme amacı, verimlilik ihtiyacı ve büyüme arzusu, doğru atılmış ticari adımların yanında yenilik yapmayı da gerektirir [88]. İnternetin giderek artan kullanımı perakende işletmelerin iş süreçlerini yenilemelerini sağlamıştır. İşletmelere çeşitli avantajlar sağlayan internet tabanlı bilgi mimarisi olarak IoT giderek önem kazanmaktadır. Perakende sektöründe IoT'nin uygulanması, işletmelerin müşterileriyle etkileşime girebilmesi için yeni imkânlar sunar [89]. IoT teknolojisi için uygulama alanları çok sayıdadır, ancak en önemli uygulama alanlarından birisi perakende sektörüdür [67].

IoT, perakende sektöründe kendinden önceki teknolojilerin yerini hızlı bir şekilde alan teknolojidir. İşletmeler, müşteri memnuniyetini arttırmak, tedarik zinciri işlemlerini optimize etmek, yeni fırsatlarla gelir elde etmek ve yeni hizmetler geliştirmek için IoT'yi kullanabilirler. IoT ile işletmeler; veri toplama, izleme, kontrol, optimizasyon gibi yeni yetenekler kazanabilir [67, 89]. İşletmeler, müşteri hareketlerini takip eden sensörler ile ürün yerleştirme kararlarını verebilir. Örneğin, bazı giyim mağazalarında birinci sınıf ürünlerin yerleştirilmesine yardımcı olması için ısı sensörleri kullanılabilir [90].

IoT'nin perakende sektöründe kullanılması ile müşteriler almayı düşündükleri ürünler hakkında bilgi edinebilir, bu ürünlere ait fiyatları ve indirimleri anlık olarak görüntüleyebilir. IoT aracılığı ile perakende sektörünün pek çok alt alanında o alana özgü müşteri beklentileri karşılanabilir. Bir gıda ürününde, üretimin başlangıç aşamasından satışa sunulacağı aşamaya kadar gerçekleşen dönüşüm tüketiciler tarafından bilinebilir. Bu sayede tüketicilerin sağlık, hijyen ve ürün kalitesi gibi beklentileri karşılanırken, üreticilerin kârlılıklarını arttırabileceği yeni rekabet olanakları elde edilir.

IoT teknolojilerinin sahip olduğu ürün tanımlayabilme, kolay ve hızlı iletişim ve gerçek zamanlı bilgi paylaşımı yetenekleri, pazar payını arttırmak isteyen işletmelerin IoT'ye

yönelmelerini sağlamıştır [89]. Örneğin, bir kuyumcu perakende şirketi, ürünleriyle ilgili ek bilgi sağlamak için sensörler ve interaktif ekranlar kullanabilir. İşletmeler, IoT teknolojileri yardımıyla müşterileri ile gerçek zamanlı ve çift yönlü iletişime imkân tanıyan bir akıllı sistem oluşturabilirler. Bu sistemler müşterilere karar verme sürecinde ve alışverişlerinde yardımcı olur. Ayrıca müşteri ihtiyaçlarını öngörebilirler ve ihtiyaçlara yönelik kapsamlı ve spesifik bilgiler sağlayabilirler [67].

Otomatik ödeme sistemleri, kişiselleştirilmiş ürün tavsiyeleri gibi müşteri ile etkileşimi arttıran, satın alma kararlarını kolaylaştıran ve zaman tasarrufu sağlayarak alışveriş deneyimini iyileştiren sistemlere perakende sektöründe artan bir ihtiyaç vardır [91]. İşletmeler IoT sistemleri kullanarak, alışveriş yapmak isteyen müşterilerin akıllı cihazları ile bağlantı kurabilir, müşteriler mağazaya geldiklerinde doğrudan satın almak istedikleri ürüne yönelmelerine imkân tanınır. Bu akıllı sistemler, müşterilerin aldıkları ürünler için ödeme yaparken kuyruklarda beklemek zorunda olmayacakları çözümler de üretir. Zaman alıcı ve maliyetli süreçlerin kısılması işletmeler ve müşteriler için faydalı olur. Akıllı sistemlerin perakende sektöründe kullanımı yeni ve verimli iş süreçleri oluşturur, üretkenliğin ve satışların artmasını, maliyetlerin azalmasını sağlar [89]. Amazon; derin öğrenme, bilgisayarla görme ve çeşitli sensör teknolojilerini kullanarak alışveriş yapılmasını sağlayan kasiyersiz mağazalar kurdu. Akıllı telefon uygulaması ile mağazaya giriş yapan müşteriler almak istedikleri ürünü alır ve mağazadan ayrılır. Alınan ürünler telefon uygulamasındaki sanal bir alışveriş sepetine eklenir ve bu uygulama aracılığı ile ödeme gerçekleştirilir [92].

İşletmeler, tüketicilerin satın alma davranışlarını anlamak ve ilerdeki satın alma davranışlarını tahmin etmek için akıllı sistemlere ihtiyaç duyarlar. Bu sistemlerden toplanan tüketici davranışı ile ilgili veriler, işletmeler tarafından çok tercih edilen ürünleri izlemek, daha az tercih edilen ürünleri çok tercih edilen ürünlerle değiştirmek, daha hızlı ve çok satış yapmak için kullanılabilir [91]. Perakende pazarındaki rekabetçi ortamdan dolayı, her geçen gün daha fazla sayıda işletme, yeni pazarlar elde etmek ve gelecek stratejilerin belirlemek adına akıllı sistemleri tercih etmektedir [89].

Perakende uygulamalarında akıllı teknolojiler, gerçek zamanlı olarak ürün durumunu izlemek ve stok yönetimini sağlamak için de kullanılabilir. Ayrıca satış sonrası destekte sağlanabilir, böylece müşteriler satın aldıkları ürünler hakkındaki verilere kolaylıkla erişebilirler. RFID ve sensör teknolojileri kullanılarak, ürünün kontrol süreçlerine, ürün

kalitesine ve olası raf ömrüne karar verilebilir. Örneğin; biyolojik sensörler, satışa hazır olan ürünün kalitesini kontrol etmek için sıcaklık, ışık ve bakteri gibi parametrelerini izleyebilirken, RFID teknolojisi ürünü tanımlamak ve takip etmek için kullanılabilir [73]. Bütün bunların verimliliği, ürün kalitesini, müşteri memnuniyetini ve satış miktarını arttırması beklenir.

3.2.3. Sağlık

Tıbbi teknoloji ve sağlık hizmetleri, toplumsal refah ve ekonomik durum ile yakından ilgilidir [65]. Toplumlarda teknolojik ve sosyal gelişmenin ana gayesi, insan sağlığını korumak, mutluluğunu arttırmak ve dünyanın herhangi bir yerinde, her zaman, herkese daha iyi bir sağlık hizmeti sunmaktır [56, 93]. IoT kavramının ortaya çıkarak yeni nesil akıllı cihazların ve sensörlerin geliştirilmesi her zaman ve her yerde çalışabilen uzman sistemlerin oluşturulmasını sağlar. Uzman sistemler çok etkili sağlık hizmetlerini hayatımızın her alanında kullanılabilir ve uygulanabilir hale getirirler [56, 94]. Sağlık sektöründe IoT, çeşitli sağlık aktivitelerini gerçekleştirmek ve yönetmek için tüm mevcut kaynakların birbirine bağlandığı, hastanelere ve sağlık çalışanlarına büyük kolaylıklar sağlayan ağ yapısıdır [65, 95]. Sağlık hizmetlerinde IoT kullanımı ile uzaktan sağlık izleme, kimlik doğrulama, fitness programları, kronik hasta ve yaşlı bakımı için çeşitli tıbbi sistemler güvenilir, etkili ve akıllı bir şekilde geliştirilebilir [63, 64].

Örneğin, uzaktan sağlık izleme amacıyla oluşturulan bir sistem, doktor hastanın yakınında olmaması durumunda hastaya yardımcı olacak tavsiyede bulunabilir. Hastaya ait kalp hızı, solunum gibi çeşitli veriler toplanarak uzaktan izlenebilir ve ani değişikliklerde uyarı verebilir [96]. Oluşturulan sistemler ile 2019 yılında Çin’de hayvanlar üzerinde yapılan ilk uzaktan ameliyatın 50 km mesafeden başarılı bir şekilde gerçekleştiği görülmüştür [97].

IoT cihazları ile hastanın kullanmakta olduğu ilaçlar takip edilebilir ve hastanın ihtiyacı olan yeni ilaçların alerjik reaksiyonlar ve çeşitli etkileşimler açısından riski değerlendirilebilir [98]. Giyilebilir cihazların kullanımı, günlük yaşam aktivitelerinin (adım, egzersiz, kalori, uyku gibi) izlenmesini ve yaşam standartlarının geliştirilmesini sağlar. Farklı sensörler içeren cihazlar, sağlık parametrelerinin kapsamlı olarak takibini sağlayabilir. IoT cihazları ile hasta sağlığında bozulmaya neden olabilecek durumların saptanması üzerine sağlık personeli harekete geçirebilir, böylece önleyici bakım gerçekleştirilebilir [73]. Önemli

hastalıklar, hastalığın daha başlangıç aşamasında fark edilerek daha kolay tedavi edilebilir.

Bu sistemler, kullanılabilirliği, kaliteyi arttırarak ve maliyetleri azaltarak sağlık sistemlerini önemli ölçüde iyileştirir [56]. Örneğin, IBM sağlık çalışanlarının her hasta kontrolünden sonra ellerini yıkamalarını izlemek için bir RFID teknolojisi geliştirmiştir. Bu ve benzeri sistemler ile her yıl yaklaşık 90 bin ölüme ve 30 milyar dolarlık maddi zarara neden olan enfeksiyonlardan korunma sağlanabilir [58]. Günümüzde gerçekleştirilen çeşitli tıbbi sistemlere rağmen büyük veri yönetimine dayanan akıllı bir IoT tabanlı sağlık sisteminin nasıl uygulanacağı ve bu sistemlerin hızlı ve sistematik olarak nasıl kurulacağı halen belirsizdir [95].

Hastalar, sağlık merkezleri ve sağlık çalışanları arasında kesintisiz ve güvenli bağlantı oluşturarak uygun maliyetli iletişimin sağlanması önemlidir. IoT tabanlı sağlık uygulamaları ile kronik hastalıklar, erken teşhis, uzaktan sağlık izleme gibi alanlarda daha etkin çözümlerin sunulması beklenir [64].

Sağlık endüstrisinde bir eğilim olan kronik hastaların kendi kendisini idare edebilmesi, önemli fayda oluşturma potansiyeline sahiptir. Başta kronik hastalıklar olmak üzere çeşitli hastalıklarda hastaneye gidip gelmenin zorlukları, şu anda hastane merkezli olarak gerçekleştirilen sağlık hizmetlerinin, yakın gelecekte ev merkezli olmasına zemin hazırlamaktadır. Bu nedenle sağlık sektöründe, sağlıkla ilgili uygulamaların geliştirmesi ve onların ev ortamında kullanılması gerekmektedir [99]. IoT uygulamalarının 2025 yılında oluşturması öngörülen ekonomik etkisine değinen bazı çalışmalar, IoT teknolojilerindeki gelirlerinin en büyük yüzdesinin sağlık uygulamalarına gideceğini belirtmektedir [56].

3.2.4. Taşımacılık

Dünya genelinde mevcut taşıtların sayısının 1 milyardan fazla olduğu bilinmekte ve 2050 yılında 2,5 milyar sınırını geçeceği tahmin edilmektedir [100]. Taşımacılık her yönüyle sürekli iyileştirmeye ihtiyaç duyulan ve teknolojik gelişmelerle sürekli yenilenen çok geniş bir alandır. Kişisel seyahat, toplu taşıma sistemleri, trafik yönetimi, yol tıkanıklığı analiz sistemleri, lojistik, araç ve nesne takip sistemleri, araç içi sistemler, akıllı park etme, sürücüsüz taşıtlar ve diğer pek çok yönü bulunur [17, 101]. IoT'nin en önemli uygulama alanlarından birisi olan taşımacılık sistemlerinde, ulaşım ağını izlemek, kontrol etmek ve bu

alandaki başka gereksinimleri karşılamak için geliştirilen çok sayıda sabit ve hareketli sensörden yararlanılır [58, 101, 102].


Taşıtlar, her yıl daha fazla sayıda ve daha fazla özellikte sensörler ile iletişim cihazları kullanılarak yenilenir. Sürücü ve yolcuların güvenlik ihtiyacını, konforunu ve zevkini arttırmak için motoru devre dışı bırakma, uzaktan güvenlik gibi çeşitli yenilikçi sistemler kullanıma sunulur. Trafik kontrolünü optimize etmek için IoT ile akıllı sistemler geliştirilir [103].

Lojistik sistemlerde müşteri memnuniyetini ve teslimat kalitesini arttırmak, hızlı ve verimli tedarik zinciri oluşturarak gerçekleştirilir. Bu nedenle, lojistik sistemlerde akıllı sistemlerin kullanılması, lojistik sisteminin geliştirilmesi için bir zorunluluk haline gelmiştir [104]. IoT tabanlı lojistik sistemler; bir ürünün hammaddesinin elde edilmesi, üretimi, nakliyesi, depolanması, satışı, satış sonrası hizmetlerinin gerçekleştirilmesi ve gerekirse iadesine varıncaya kadar tüm bu ürün bilgilerinin gerçek zamanlı olarak ilgililere iletilmesini sağlar. Et ve süt ürünleri gibi bozulabilecek gıdaların nakliye aşamalarında, gerekli koşullarda saklanarak zarar görmemesi için takibine olanak tanır [63].

Akıllı taşımacılıkta trafik yönetimi sağlanırken; yol, taşıt ve sürücü verilerini izlemek, gerektiğinde uyarmak ve kontrol etmek için yollara ve taşıtlara sensör, aktüatör gibi gerekli cihazlar yerleştirilir. Elde edilen veriler iletişim ağları ile diğer taşıtlara ve trafik yönetim merkezine gönderilir. Bu şekilde sürücüler ve yolcular, yol ve trafik bilgisini gerçek zamanlı edinerek, gidecekleri yere daha güvenli ve daha hızlı ulaşabilir. Yetkililer, trafik ve şehir planlamalarını gerçekleştirirken bu bilgilerden istifade eder [63, 105]. Bu bilgiler kullanarak gerekli durumlarda, gerekli yerlere, yeni yollar inşa edilebilir. Trafik yoğunluğunun yüksek olduğu yerlerde oluşacak muhtemel kirlilik analiz edilerek buna ilişkin önlemler alınabilir [106].

Çok şeritli yolun altına sensörler yerleştirilerek elektronik levhalar ve bunları birbirine bağlayan bir yönetim sistemi ile oluşturulan bir dinamik şerit tahsisi yaklaşımının görüntüsü Şekil 3.2’de gösterilmiştir. Burada trafik durumlarını ve yetkili şoförlerden (otobüsler, acil durum taşıtları vb.) gelen talepleri toplayan sensörler, gözlemlenen durumları yönetim sistemine iletir. Bu sistem, yönetim politikasına uygun komutları ve sistem durumunu (örneğin, otobüs beklenmediği zaman otobüs için ayrılmış şeritlerin diğer sürücüler

tarafından kullanılması gibi) tüm kullanıcılara haber verir [107].



Şekil 3.2. Dinamik şerit tahsisi yaklaşımı [107]

Son yıllarda taşıt sayısının artması ile birlikte işe gidiş ve işten dönüş gibi günün en yoğun saatlerinde, neredeyse büyük şehirlerin tamamında trafik yoğunluğu yaşanmaktadır. Trafikte gerçekleşebilecek talihsiz bir kaza ya da basit bir yol bakım çalışması, büyük bir trafik yoğunluğuna ve yeni kazalara neden olabilmektedir. Ayrıca uykulu olmak, yorgunluk, stres gibi bazı anormal sürücü durumları da yaralanma ve ölümle sonuçlanan trafik kazalarına neden olur. Sürücü durumu; fiziksel özellikler, zihinsel durum, duygusal durum, yetenekler ve karakteristiklerden oluşur [108, 109]. Çeşitli araç içi sistemleri ile sürücülerdeki olumsuz durumlarının tespit edilerek sürücünün uyarılması, olası bir trafik kazasının önlenmesi bakımından önemlidir.

Taşımacılıkta yol güvenliğinin sağlanması, taşımacılık hizmetlerinin emniyetli, verimli ve kullanılabilir olması bu alandaki en önemli amaçlardır [58]. Yol güvenliğini sağlamak için kullanılan yaklaşımlar, temelde pasif güvenlik ve aktif güvenlik olarak iki kategoride sınıflandırılır. Pasif güvenlik, kaza sonrası sürücüler aleyhine olan zararları hafifletmeye çalışır (örneğin; emniyet kemerleri, hava yastıkları) ama çoğu durumda olası kazaları engelleyemez. Aktif güvenlik, kaza risklerini öngörerek, sürücü ve yolcuları bu riskler konusunda uyarır. Gelişmiş sensör teknolojisi ve doğru zamanda gerçekleşen bilgi alışverişi

ile geliştirilen aktif güvenlik sistemleri yol güvenliğinin sağlanmasında hayati önem taşır [110]. Bu sistemler, taşıtların, diğer taşıtlarla ve altyapılarla haberleşmesini sağlar. Bu sayede sürücüler gerçek zamanlı olarak yol durumu, güvenlik, verimlilik, eğlence ve konfor gibi ilgili bilgileri kolaylıkla paylaşabilirler [104, 108].

Bu sektördeki nihai amaçlardan birisi, sürücüsüz taşıtların ve bu taşıtlara uygun altyapının oluşmasını sağlamaktır. Sürücüsüz taşıtlar insan müdahalesini gerektirmeyen ya da çok nadir gerektiren taşıtlardır. Etrafındaki nesneleri algılayarak hareket eden bu taşıtlar içerdiği sensörler ile yol güvenliğini sağlamak için muhtemel tehlikelerde (örneğin, başka taşıtlarla arasındaki mesafe çok azaldığında veya hız limitlerinin aşıldığı durumlarda) önlem alırlar. Sürücüsüz taşıtlar ile yol güvenliğinin artması ve kazaların önlenmesi beklenmektedir. Ayrıca park yeri bulmayı kolaylaştırabilir ve araç durumu hakkında faydalı bilgiler de sağlar [104]. Bununla birlikte yüzbinlerce taşıtın kontrolünün, karmaşık ve zor olduğu unutulmamalıdır. Trafik düzenini aksatacak ani bir felakette taşıtların koordinesi gereken şekilde yapılabilmelidir [111].

Taşımacılıktaki IoT uygulamalarından birisi de akıllı otoparklardır. Akıllı otoparklar bir bölgedeki taşıt sayısını ve hareketlerini izleyerek tasarlanabilir. İhtiyaç duyulan yerlere yeni otopark planları yapılabilir. Taşıtları, bulundukları bölgeye en yakın otoparka yönlendirerek trafik yoğunluğunun, yakıt tüketiminin ve yakıtlardan kaynaklı hava kirliliğinin azalmasına yardımcı olur [106].

3.2.5. Diğer

Akıllı şehirlerde IoT üzerine gerçekleştirilebilecek uygulama alanları çok fazladır. Önceki bölümlerde önemli olduğu düşünülen ve kendi içerisinde de çok sayıda farklı uygulama bulunduran sektörlere yer verildi. Bu bölümde akıllı şehirler için gerçekleştirilmekte olan diğer IoT uygulama alanlarından 4 tanesi akıllı enerji, akıllı ev, sosyal uygulamalar ve çevre izleme başlıkları altında ele alındı. Bu sayının artırılması mümkündür. Örneğin; tarım ve hayvancılık, atık yönetimi, aydınlatma bu çalışmada yer verilmeyen uygulama alanlarından bazılarıdır.


Akıllı enerji

Akıllı enerji, akıllı şehirlerin önemli bir araştırma alanıdır. Akıllı enerji ile amaçlanan yüksek kaliteli ve çevre dostu enerjiyi uygun maliyetle elde etmektir. Akıllı enerji, sızıntı izleme sistemleri ile enerji tüketimini kontrol altında tutar [59, 68]. Ayrıca insan gücüne duyulan ihtiyacı azaltabilir [98]. Akıllı enerji ile enerji şirketleri evlere ve sanayi bölgelerine gönderilen elektrik, gaz ve su tüketimini etkin bir şekilde yöneterek enerji tasarrufu sağlar.

Akıllı enerjinin uygulama alanı olan akıllı şebekeler, geleneksel elektrik şebekesinin yerini almak için geliştirilmiştir. Akıllı şebekeler, potansiyel arızaların azaltılmasını ve tüketicilerin beklentileri doğrultusunda enerji sağlayıcıların hizmetlerini geliştirmelerini sağlar. Bu sayede tüketicilere güvenilir ve verimli enerji hizmeti sunulur [58, 105]. Akıllı şebekeler, nüfus değişimleri ve tüketici ihtiyaçları doğrultusunda güç sağlamak için enerji kaynaklarının kontrol edilmesine ve yönetilmesine destek olur. Örneğin; akıllı şebekeler, milyonlarca sayacı, enerji şirketlerinin ağına bağlamak için IoT sistemlerini kullanırlar. Bu sayaçlar; enerji tüketimini belirlemek, analiz etmek, denetlemek, takip etmek ve yönetmek için kullanılır [58].

Akıllı ev

Akıllı evler, akıllı şehirlerde önemli bir rol oynayan temel yapı taşlarıdır [68, 112]. Akıllı evler, günlük hayatımızı kolaylaştırmak için uzaktan kumandalar veya akıllı telefonlar aracılığıyla ya da otomatik olarak kontrol edilen bir sistem sunar [70]. Akıllı evler; klima, ısıtma, enerji, havalandırma, aydınlatma, güvenlik, eğlence ve konfor sistemleri gibi algılama ve kontrol cihazlarına sahip binalardır [18]. Bu cihazlarda kaynak tüketimini izlemek ve kullanıcıların ihtiyaçlarını önceden belirlemek için kullanılan sensörler önemli rol oynarlar [73]. Mesela, akıllı bir ev, hava durumu verilerine göre pencereleri ve perdeleri otomatik olarak açıp kapatabilir. Akıllı evlerin iç ve dış ortamlarıyla sürekli etkileşim içinde olması gerekir [58]. Şekil 3.3'te akıllı ev alanına örnek bir senaryo gösterilmiştir [112].



Şekil 3.3. Akıllı ev alanına örnek bir senaryo [112]

Senaryoya göre kullanıcı evine akıllı bir buzdolabı satın alır. Buzdolabı (1) numaralı adımda gösterildiği gibi kablosuz interneti tespit eder. (2) numaralı adımda buzdolabı sahip olduğu sensörler hakkında bilgi verir ve (3)’te kullanıcı ile iletişim kurar. Kullanıcı, hangi sensörler bilgilerinin yayınlanacağını, hangi tür tekliflere izin verileceğini ve ne tür bir dönüş (ücret veya başka herhangi bir teklif) beklendiğini tanımlar. (4) numaralı adımda kullanıcı, dondurma üreticisi olan şirketten bir e-posta alır. Dondurma üreticisi çeşitli indirim teklifleri ile buzdolabına erişmek istemektedir. (5) numaralı adımda kullanıcı teklifi kabul ederek indirim kazanır ya da bu teklifi reddeder. Eğer kullanıcı teklifi kabul ederse (6) numaralı adım veri akışını göstermektedir [112].

Sosyal uygulamalar

IoT cihazlarının nesne ve insanlarla ilişkisi düşünüldüğünde IoT’nin sosyal uygulamalar yönünden de incelenmesi gerekir. IoT cihazları çeşitli sosyal medya uygulamaları ile etkileşimde bulunabilir. Sosyal medya uygulamaları, kişilerin birbirleri hakkında bilgi edinmesine imkân tanır. Kişiler, bulundukları konumlar üzerinden arkadaşlarına ya da çevrelerinde ilgi duydukları etkinliklere yakın olduklarında bilgilendirilebilir [98]. Tarihi ve turistik yerler, lokantalar, alışveriş merkezleri hakkında bilgi edinmek amacı ile bu uygulamalardan faydalanılabilir. Sosyal medya uygulamalarından yapılan beğeniler, paylaşılan fotoğraflar, arkadaşlıklar, takipler gibi gerçekleştirilen birçok etkileşim büyük miktarda veri oluşturur. Bu büyük veri kullanılarak yapay zekâ uygulamalarının yardımı ile alışveriş, sağlık, sigortacılık gibi pek çok alanda kişisel öneriler ve teklifler oluşturulabilir. Bununla birlikte, elde edilen verilerin kişisel veri güvenliğine tehdit oluşturabileceği üzerinde düşünülmesi gereken bir konudur.

Çevre izleme

Akıllı şehirlerde sensörler ile elde edilebilecek nehirler, göller, barajlar ve diğer rezervuara ait bilgiler ile sıcaklık, yağmur, rüzgâr hızı, sis, basınç, hava kirliliği, gürültü gibi bilgiler ilgili kurumlara iletilir. Kurumlarca takip edilecek bu bilgiler ile şehrin verimliliğinin artması sağlanır [73, 106, 113]. İlgili kurumlar gerçek zamanlı izlenen bu bilgileri kullanarak çeşitli hastalıkları, yaralanma ve ölümleri engellemeyi amaçlar [106]. Ayrıca günlük hayatı olumsuz etkileyebilecek çeşitli doğa olaylarını ve şehrsel aksaklıkları önceden öngörerek uyarı oluşturacak sistemler, yetkililerin gerekli tedbirleri almasını sağlayabilir.





4. ÖNERİLEN YÖNTEM

Bu bölümde sürücü durumu tespitinde önerilen çevrim dışı ve çevrim içi yöntem detaylı olarak anlatılmaktadır. Öncelikle önerilen yöntemin uygulanabilmesi için kullanılan araçlar hakkında bilgiler verilmiş ve ardından çevrim dışı sürücü durumu tespitinin adımları açıklanarak sınıflandırma sonuçları sunulmuştur. Son olarak ise çevrim içi sürücü durumu tespiti için oluşturulan IoT tabanlı sistem tanıtılmıştır.

4.1. Kullanılan Araçlar

Burada mikrodnetleyici kartları, kablosuz internet bağlantısı modülü, sensörler gibi tez çalışması sırasında kullanılan başlıca araçlardan kısaca bahsedilmektedir.

4.1.1. Mikrodnetleyici kartları

Arduino Uno Rev3 (Resim 4.1), ATmega328P tabanlı bir mikrodnetleyici kartıdır. Arduino Uno Rev3 mikrodnetleyici kartında; 6 tanesi darbe genişlik modülasyonu (Pulse Width Modulation - PWM) çıkışı olarak kullanılabilen 14 sayısal giriş/çıkış pini, 6 analog girişi, 16 MHz kuvars kristali, USB bağlantısı, güç girişi, devre üzerinde seri programlama (In Circuit Serial Programming - ICSP) bağlantısı ve sıfırlama butonu bulunur. Bu mikrodnetleyici kartı, USB bağlantısı veya harici bir güç kaynağı ile çalıştırılabilir. Yazılım yüklemek için ayrı bir donanım parçası bulunmaz. USB kablosu ile bilgisayara bağlanarak sadeleştirilmiş bir C++ sürümü olan Arduino yazılımı ile programlanır [114, 115].



Resim 4.1. Arduino Uno Rev3 [114]

Arduino Uno Rev3 mikrodnetleyici kartı 6 volt ile 20 volt arasındaki güç kaynağı ile çalıştırılabilir ancak önerilen değerler 7 volt ile 12 volt arasındadır. Önerilen değerlerin altında kart kararsız hale gelebilir; üstünde ise gerilim regülatörü fazla ısınarak kartın zarar görmesine neden olabilir. Arduino Uno Rev3 mikrodnetleyici kartı, aktüatörleri ve sensörleri kontrol etmek için çeşitli uygulamalarda kullanılır. Açık kaynaklı bir donanım olan bu mikrodnetleyici kartının teknik özellikleri için Çizelge 4.1 incelenebilir.

Çizelge 4.1. Arduino Uno Rev3 mikrodnetleyici kartının teknik özellikleri [114]

Mikrodnetleyici	ATmega328P
Çalışma Gerilimi	5 V
Giriş Gerilimi (önerilen)	7-12 V
Giriş Gerilimi (limit)	6-20 V
Dijital Giriş/Çıkış Pinleri	14
Analog Giriş Pinleri	6
Giriş/Çıkış Pin Başına DC Akımı	20 mA
3.3 Volt Pin için DC Akımı	50 mA
Flash Bellek	32 KB
SRAM	2 KB
EEPROM	1 KB
Çalışma Hızı	16 MHz
Dâhili Led	13. Pin
Uzunluk	68,6 mm
Genişlik	53,4 mm
Ağırlık	25 g

Arduino Nano (Resim 4.2), ATmega328 tabanlı küçük bir mikrodnetleyici kartıdır. Arduino Uno Rev3 mikrodnetleyici kartına benzer özelliklere sahiptir. USB Mini-B kablosuyla çalışır [116]. Arduino Nano kartının teknik özellikleri için Çizelge 4.2 incelenebilir.



Resim 4.2. Arduino Nano [116]

Çizelge 4.2. Arduino Nano mikrodenetleyici kartının teknik özellikleri [116]

Mikrodenetleyici	ATmega328
Çalışma Gerilimi	5 V
Giriş/Çıkış Pin Başına DC Akımı	40 mA
Giriş Gerilimi	7-12 V
Flash Bellek	32 KB
SRAM	2 KB
EEPROM	1 KB
Çalışma Hızı	16 MHz
Dâhili Led	13. Pin
Uzunluk	45 mm
Genişlik	18 mm
Ağırlık	7 g

4.1.2. Kablosuz internet bağlantısı modülü

Bu çalışma da kablosuz internet bağlantısı için ESP8266 (ESP-01) kullanılmıştır. ESP8266 (Resim 4.3) düşük maliyetli, yüksek işlevli ve TCP/IP protokolünü destekleyen kablosuz internet bağlantısı modülüdür.



Resim 4.3. ESP8266 (ESP-01) [117]


ESP8266 kablosuz internet bağlantısı modülünü ilgi çekici yapan temel özellikler şunlardır [118]:

- 802.11 b/g/n kablosuz internet bağlantısı standartları desteği,
- Cihazların birbirine kolayca bağlanmasını sağlayan eşler arası (Peer to Peer - P2P) iletişim desteği,
- Dâhili TCP/IP protokol yığını,
- Kablosuz haberleşme için güvenlik protokolleri,
- Gerilim regülatörü ve güç yönetim bileşenleri,
- Dâhili sıcaklık sensörü,
- Dâhili düşük güçlü 32 bit merkezi işlem birimi,

- Senkron seri haberleşme,
- Asenkron seri haberleşme,
- Uyanma ve veri paketi aktarım süresi $< 2\text{ms}$,
- Bekleme sırasında güç tüketimi $< 1\text{mW}$.

4.1.3. Elektrodermal aktivite sensörü

Elektrodermal aktivite (ElectroDermal Activity - EDA) insan derisindeki elektrik iletkenliğinin ölçüsüdür. Fizyolojik sinyal çeşidi olan EDA, literatürde fizyolojik durumların tespiti için kullanılan temel önlemlerden birisidir. Stres, çeşitli duygusal değişikliklerin algılanması gibi bazı fizyolojik durumlar sempatik sinir sisteminde uyarılmalara neden olur. Bu durum sempatik sinir sistemi tarafından kontrol edilen ter bezlerini etkileyerek derideki elektrik iletkenliğinde değişikliklere neden olur. EDA sensörü (Resim 4.4), iki parmağa bağlanan iki elektrot ile insan derisinin elektrik iletkenliğini ölçerek fizyolojik durumların tespitini sağlar. EDA sensörü ile elde edilen veriler yüksek tanıma doğruluğu göstermekte ve doğrudan bireyin durumu hakkında fikir vermektedir [109, 119-121]. Galvanik deri tepkisi (Galvanic Skin Response - GSR) olarak da adlandırılan EDA; el ya da ayağa bağlanan sensörler ile deri üzerinde nem seviyesindeki değişikliklere bağlı, ölçülmesi kolay bir tekniktir. Düşük maliyetli EDA ölçümünün dezavantajı, bireyin hareketlerini kısmen kısıtlayan ekipman gerektirmesidir.



Resim 4.4. EDA sensörü [119]

4.1.4. Kulak klipsli kalp hızı sensörü

Bir fotoplethysmogram (PhotoPlethysmoGram - PPG) tabanlı sensör ile kulaklar, parmak uçları ya da bileklerden kalp hızı (nabız) kolaylıkla ölçülebilir. PPG tabanlı sensör, cildi ışıık yayan diyot ile aydınlatır ve yansıyan ya da iletilen ışıığın yoğunluğundaki değışiklikleri foto diyot aracılığıyla algılar. Bu değışikliklerden kalp hızı, solunum gibi bilgiler elde edilebilir [122, 123].


Bu tez çalışmasında kalp hızının ölçümü için yüksek hassasiyete ve düşük güç tüketimine sahip kulak klipsli kalp hızı sensörü (Resim 4.5) kullanılmıştır [124].



Resim 4.5. Kulak klipsli kalp hızı sensörü [124]

4.1.5. Hafıza kartı modülü

Çalışmada kullanılan hafıza kartı modülü (Resim 4.6) mikro SD kartlara okuma ve yazma yapabilmeyi sağlar. Üzerinde gerilim regülatörü bulunduran modül, başta Arduino mikrodenetleyici kartları olmak üzere çok sayıda mikrodenetleyici ile birlikte kullanılabilir.



Resim 4.6. Hafıza kartı modülü

4.2. Çevrim Dışı Sürücü Durumu Tespiti

Çevrim dışı sürücü durumu tespiti ile sürüş sırasındaki stres durumunun, fizyolojik sinyaller üzerinden tespiti için bir yöntem önerilmektedir. Önerilen yöntemde kullanılmak üzere deney ortamlarında alınan fizyolojik sinyaller ile sürücü durumu veri kümesi oluşturulmuştur. Deney ortamları, düşük stres durumunu temsil eden dinlenme ortamı ile sürüş sırasındaki stres durumunu temsil eden simülasyon ortamıdır. Alınan fizyolojik sinyaller, EDA ve kalp hızı sinyalleridir. Sınıflandırma gerçekleştirilirken veri kümesi çok sürücülü veri kümesi ve tek sürücülü veri kümesi olarak iki farklı şekilde ele alınmıştır. Çok sürücülü ve tek sürücülü veri kümelerinin sınıflandırılması sağlanarak kullanılan makine öğrenmesi algoritmalarının başarımları karşılaştırılmıştır. Ayrıca veri kümesi oluşturulurken deneyin bazı adımlarında katılımcılara çeşitli testler uygulanmıştır.

4.2.1. Veri kümesi oluşturma süreci

Veri kümesi 12 katılımcının dinlenme ve simülasyon ortamlarında elde edilen fizyolojik verileri ile oluşturulmuştur. Katılımcılardan [32]'de gerçekleştirilen deneysel çalışmaya benzer şekilde deneyin çeşitli aşamalarında Zuckerman–Kuhlman Kişilik Testi (Zuckerman-Kuhlman Personality Questionnaire - ZKPQ) ile Durumluk-Sürekli Kaygı Envanterinin (State-Trait Anxiety Inventory - STAI), Durumluk Kaygı Ölçeği olarak ifade edilen bölümünü doldurmaları istenmiştir. Veri kümesi oluşturma sürecinde izlenen adımların blok diyagramı Şekil 4.1'de gösterilmektedir.



Şekil 4.1. Veri kümesi oluşturma sürecine ait blok diyagram

Başlangıçta katılımcılara ZKPQ ölçeği uygulanmıştır. Bu test ile katılımcıların kişilik özelliklerinin anlaşılması amaçlanmıştır. Ardından düşük stresli ve durgun durumları temsil eden dinlenme ortamında katılımcıların EDA ve kalp hızı sinyalleri kaydedilmiştir.

Dinlenme ortamında gerçekleştirilen kayıt sonrasında katılımcılardan Durumluk Kaygı Ölçeğini doldurmaları istenmiştir. Daha sonra simülasyon ortamındaki fizyolojik sinyalleri ölçmek için katılımcılardan tekrar EDA ve kalp hızı sinyalleri alınarak, simülasyon ortamında alınan kayıt sonrası katılımcılara yeniden Durumluk Kaygı Ölçeği uygulanmıştır. Anlık kaygı durumunu yansıtan Durumluk Kaygı Ölçeği, simülasyon ortamındaki deney öncesinde ve sonrasında iki kez uygulanarak katılımcıların kaygı seviyelerindeki değişikliğin öznel olarak değerlendirilebilmesi amaçlanmıştır. Veri kümesi oluşturulma süreci ile ilgili ayrıntılı bilgiler ilerde ilgili bölümlerde anlatılmaktadır.

4.2.2. Katılımcılar

Bu çalışmada kullanılan veri kümesi 9 erkek, 3 kadın toplam 12 katılımcının iki farklı ortamda alınan fizyolojik verileri ile oluşturulmuştur. Katılımcılara ait bilgiler Çizelge 4.3'te gösterilmektedir.

Çizelge 4.3. Deneylere gönüllü olan katılımcılara ait bilgiler

Katılımcılar	Yaş	Cinsiyet	Sürücü Belgesi Tarihi (Yıl)
Katılımcı 1	29	Erkek	2009
Katılımcı 2	27	Erkek	2012
Katılımcı 3	55	Erkek	1984
Katılımcı 4	57	Erkek	1991
Katılımcı 5	59	Erkek	1989
Katılımcı 6	49	Kadın	2012
Katılımcı 7	32	Kadın	2016
Katılımcı 8	36	Kadın	2019
Katılımcı 9	40	Erkek	1998
Katılımcı 10	30	Erkek	2011
Katılımcı 11	21	Erkek	2018
Katılımcı 12	23	Erkek	2015

Yaşları 21’den 59’a kadar olan 9 erkek (ortalama=37,89) ile yaşları 32’den 49’a kadar olan 3 kadın (ortalama=39) toplam 12 katılımcı (ortalama=38,17) deneylere gönüllü olarak katılmışlardır. Katılımcılar sürücü belgesini aldıkları yıllara göre 1 yıl ile 36 yıl arasında (ortalama=13,83) tecrübeye sahiptir. Kadınlarda tecrübe 1 yıl ile 8 yıl arasında (ortalama=4,33), erkeklerde tecrübe 2 yıl ile 36 yıl arasında (ortalama=17) değişmektedir.

Deneylerden önce deneyin adımları, amacı ve ne oldukları hakkında katılımcılar bilgilendirilmiş ve simülasyon ortamındaki sürüş görevi için katılımcılara eğitim verilmiştir. Ayrıca katılımcıların tüm gizlilik gerektiren kişisel verilerinin korunacağı ve bu deneysel prosedürlerle ilgili kanunlara saygı gösterildiği belirtilmiştir.

4.2.3. Zuckerman–Kuhlman Kişilik Testi

Zuckerman–Kuhlman Kişilik Testi (Zuckerman-Kuhlman Personality Questionnaire - ZKPQ), kişilik veya mizacın temel faktörlerini tanımlama girişiminin bir sonucu olarak Zuckerman, Kuhlman, Joireman, Teta ve Kraft tarafından geliştirilmiştir. ZKPQ ölçeği Evet/Hayır şeklinde cevap verilen ve genellikle 15 - 20 dakikalık sürede tamamlanan 99 maddeden oluşur. 99 maddenin 89 tanesi kişiliğin beş faktörünü ölçen özelliklerle ilgiliyken, kalan 10 madde şüpheli cevap veren katılımcıların testlerini elemek için oluşturulmuştur. ZKPQ ölçeğinin beş faktörü; Dürtüsel Heyecan Arayışı, Sosyallik, Nörotisizm-Anksiyete, Saldırganlık-Düşmanlık ve Aktivite’dir [125-127].

Dürtüsel Heyecan Arayışı alt ölçeği (örneğin, “Biraz korkutucu olsalar bile, yeni ve heyecan verici deneyimleri ve hisleri yaşamaktan hoşlanırım.” gibi) 19 maddeden oluşmaktadır. Plan yapma eksikliği, düşünmeden hızlı hareket etme eğilimi, heyecan arayışı ve öngörülemez durumlar için risk alma isteğini sorgular. Sosyallik alt ölçeğinde (örneğin, “Çok sosyal bir insanım.” gibi) 17 madde bulunmaktadır. Eğlenceli toplantılara katılma isteği, insanlarla etkileşime girme, yalnız kalma isteği gibi durumlar değerlendirilir. Nörotisizm-Anksiyete alt ölçeği (örneğin, “Belli bir nedeni olmadan vücudumu çoğu kez fazla gergin hissederim.” gibi) 19 maddeden meydana gelmektedir. Kaygı, öz güven eksikliği, gerginlik, saplantı haline gelmiş kararsızlık, üzüntü ve eleştiriye duyarlı olma durumları tanımlanır. Saldırganlık-Düşmanlık alt ölçeğinde (örneğin, “Sıklıkla başkalarıyla münakaşa ederim.” gibi) 17 madde vardır. Sözlü saldırganlık, kaba ve düşüncesiz davranışlar, intikam duygusu, kindarlık, tahammül gösterememe ve çabuk sinirlenme durumları irdelenir. Aktivite alt

ölçeği (örneğin, “Çok çaba ve konsantrasyon (yoğunlaşma) gerektiren karmaşık işleri severim.” gibi) 17 maddeden oluşur. Genel aktivite ihtiyacı, sabırsızlık, tez canlılık, sıkı çalışma ve yaşam enerjisi; aktivite alt ölçeğinin konuları arasındadır. ZKPQ ölçeğinde Seyreklik olarak belirtilen ve abartılı bir şekilde sosyal olarak arzu edilen içeriğe sahip kayıtları elemek için kullanılan (örneğin, “Oyunlarda hep kazanırım.” gibi) 10 madde bulunur [125]. ZKPQ ölçeğinde “Evet” cevabı verilen maddeler 1, “Hayır” cevabı verilen maddeler 0 değerini alır. Bazı maddeler için bu değerler tersine döner yani “Hayır” cevabı 1; “Evet” cevabı 0 değerini alır. Alt ölçeklerin toplam puanı, her bir alt ölçek için bu değerlerin toplanması ile bulunur [126].

Dinlenme ve simülasyon ortamlarında yapılan deneysel oturumlar öncesi katılımcılardan ZKPQ ölçeğini doldurmaları istendi. Burada amaç, katılımcıların kişilik özelliklerinin anlaşılması ile deneyler için uygun olup olmadığına karar vermektir. Burada [32]’de olduğu gibi iki alt ölçeğin puanlarına odaklanıldı. Bunlar, yüksek olması halinde sürücü stres durumunun tespitinde yanıltıcı sonuçlara neden olabileceği ifade edilen Dürtüsel Heyecan Arayışı ve Nörotisizm-Anksiyete alt ölçekleridir. Katılımcıların hiç birisi bu ölçeklerde önemli derecede yüksek puana sahip olmadıkları için tüm katılımcılar deneylere dâhil edildiler. Aynı zamanda katılımcıların her birisi geçerli bir sürücü belgesine de sahiptirler.

4.2.4. Dinlenme ortamı

Önceki bazı çalışmalarda, katılımcıların sürüş stres seviyelerini kıyas etmek için sakinlik veren dinlenme ortamları oluşturulmuştur. Örneğin, [54]’te sürücülerden taşıt boşken gözleri kapalı bir şekilde beklemeleri istenerek dinlenme ortamı oluşturulmuştur. Ancak sessiz bir şekilde bekleme durumu ile dinlendirici su videosu izlemenin kalp hızı üzerinde etkisini karşılaştıran araştırmacılar [128] dinlendirici su videosu izlemenin kalp hızı değerlerinin düşmesinde daha etkili olduğunu göstermişler. Bu nedenle, bu çalışmada katılımcılardan 10 dakika boyunca dinlendirici bir su videosu izlemeleri istenerek, onların düşük stresli, sakin ve rahat bir duruma geçmesi amaçlanmıştır. Bu tez çalışmasında kullanılan video çeşitli deniz canlılarının görüntülerinden oluşan ve hafif müziğin bu görüntülere eşlik ettiği bir videodur. Katılımcılardan izlemeleri istenen videoya [129] ait bazı görüntüler Resim 4.7’de gösterilmektedir. Su videosu izlenen dinlenme ortamında katılımcılara bağlanan sensörler yardımı ile fizyolojik sinyallerin kaydı yapılmıştır. EDA ve kalp hızı sensörlerinin, hafıza kartı modülünün ve mikrodenetleyici kartının (Arduino Uno Rev3) gerekli bağlantılarının

yapılması ile fizyolojik sinyalleri toplamak için kullanılan donanım (Resim 4.8) oluşturulmuştur.



(a)




(b)



(c)

Resim 4.7. Su videosundan görüntüler [129]



Resim 4.8. Veri kümesi oluşturulurken fizyolojik sinyalleri toplamak için kullanılan donanım

4.2.5. Durumluk- Sürekli Kaygı Envanteri

Kaygı literatürde durumluk kaygı ve sürekli kaygı olmak üzere iki kategoride ifade edilir. Durumluk kaygı, kişinin içinde bulunduğu stresli durumdan dolayı hissettiği kısa süreli bir duyguyu ifade eder. Stresin yoğun olduğu zamanlarda durumluk kaygı yükselirken, stresin az olduğu zamanlarda durumluk kaygı düşer. Sürekli kaygı ise kişinin yaşantısını genellikle stresli olarak algılamasıdır. Sürekli kaygısı yüksek olan kişilerde durumluk kaygının olağan hâle geldiği söylenebilir. Speilberger ve arkadaşları durumluk kaygı ve sürekli kaygıyı ölçmek için Durumluk-Sürekli Kaygı Envanterini (State-Trait Anxiety Inventory - STAI) geliştirmişler. STAI formu, Öner ve Le Comte tarafından Türkçeye uyarlanarak geçerlilik ve güvenilirlik çalışmaları yapılmıştır [130, 131].

STAI formu, 20 maddelik anlık durumu yansıtan (örneğin, “Kendimi dinlenmiş hissediyorum.” gibi) Durumluk Kaygı Ölçeği ile 20 maddelik genel durumu yansıtan

(örneğin, “Hayal kırıklıklarını öyle ciddiye alırım ki hiç unutamam.” gibi) Sürekli Kaygı Ölçeğinden oluşur. Durumluk Kaygı Ölçeği cevaplanırken “(1) Hiç”, “(2) Biraz”, “(3) Çok”, “(4) Tamamıyla” seçeneklerinden birisi; Sürekli Kaygı Ölçeğinde “(1) Hemen hiçbir zaman”, “(2) Bazen”, “(3) Çoğu zaman” ve “(4) Hemen her zaman” seçeneklerinden birisinin seçilmesi istenilir [131, 132].

Ölçeklerde bazı maddeler (Durumluk Kaygı Ölçeği için 1, 2, 5, 8, 10, 11, 15, 16, 19 ve 20 numaralı maddeler; Sürekli Kaygı Ölçeği için 21, 26, 27, 30, 33, 36 ve 39 numaralı maddeler) tersine çevrilmiş ifadelerdir. Bu maddelerin değerlendirilmesinde kaygı durumu da ters bir şekilde ele alınır. Örneğin, “Pişmanlık duygusu içindeyim.” ifadesi düz bir ifadedir, 4 numaralı seçenek burada yüksek kaygıyı ifade eder. Ancak “Şu anda huzur içindeyim.” ifadesi tersine çevrilmiş bir ifade olduğu için 1 numaralı seçenek burada yüksek kaygıyı ifade etmektedir. Düz ifadelerde seçeneklerin yanındaki numaralar kaygı durumunun puanını ifade eder. Tersine çevrilmiş ifadelerde ise puanlama da tersine çevrilir. Yani tersine çevrilmiş ifade de 1 numaralı seçenek 4 puan olarak hesaplanır. Durumluk Kaygı Ölçeği puanı hesaplanırken düz ifadeler için verilen cevapların toplam puanından, tersine çevrilmiş ifadeler için verilen cevapların toplam puanı çıkarılır ve bulunan değer 50 sabiti ile toplanır. Sürekli Kaygı Ölçeği puanı hesaplanırken de aynı işlem yapılır, ancak burada bulunan değer 35 sabiti ile toplanır. Her iki ölçekten elde edilen puanın 20 ile 80 arasında olması beklenir. Puanın büyük olması yüksek kaygıyı, küçük olması düşük kaygıyı ifade eder. Uygulamalarda belirlenen ortalama puanın 36 ile 41 arasında değiştiği ifade edilir [133-136].

Simülasyon ortamında gerçekleştirilen sürüş görevinin öncesinde ve sonrasında katılımcılara, Durumluk Kaygı Ölçeği (STAI formunun durumluk kaygıyı ölçmek için kullanılan ilk 20 maddesi) yöneltildi. Bu ölçeğin uygulanması ile amaçlanan sürüş görevinin katılımcılar üzerinde stres, kaygı ya da herhangi bir psikolojik değişikliğe neden olup olmadığını sorgulamaktır. 12 katılımcıya 20 sürüş görevinden önce ve sonra yöneltilerek elde edilen Durumluk Kaygı Ölçeğine ait ortalama puanlar Çizelge 4.4’te gösterilmektedir.

Çizelge 4.4. Katılımcıların Durumluk Kaygı Ölçeğine ait ortalama puanlar

	Ortalama	Standart Sapma
Simülasyondan Önce	43,8	3,81
Simülasyondan Sonra	42	5,66

Sürüş görevi öncesinde elde edilen Durumluk Kaygı Ölçeği ortalama puanları, sürüş görevi sonrasında elde edilen Durumluk Kaygı Ölçeği ortalama puanlarından daha yüksektir. Bu sonuçlar sürüş görevinin katılımcılar üzerinde stres, heyecan ve endişe gibi duygular uyandırdığını düşündürür.

4.2.6. Simülasyon ortamı

Simülasyon ortamı, sürücülerde sürüş görevi sırasında strese bağlı fizyolojik sinyal değerlerinin belirlenmesi için oluşturulmuştur. Gerçek hayatta sürüş sırasında sürücünün fizyolojik sinyallerini ölçmek tehlikeli olabilirdi. Bu nedenle, deneyi gerçekleştirmek için sürüş görevinin yer aldığı bir simülasyon ortamı oluşturulmuştur. Sürüş görevinde kullanılmak üzere gerçek şehir modeli üzerinde sürüş uygulamaları için tasarlanan City Car Driving [137] isimli sürüş simülatörü seçilmiştir. Sürüş simülatörüne ait çeşitli görüntüler Resim 4.9’da gösterilmiştir.

Kullanılan sürüş simülatörü gün içindeki zaman dilimini, çeşitli hava koşullarını ve trafik yoğunluğunu ayarlayabilmeyi mümkün kılmaktadır. Bu çalışmada 10 dakika uzunluğundaki sürüş görevi sırasında katılımcılara bağlanan donanım (Bkz. Resim 4.8) yardımı ile katılımcıların EDA ve kalp hızı sinyalleri toplanmıştır. Katılımcılardan; şehir trafiğinde sürüş yapma, belirli bir rotayı takip etme, görüş mesafesinin düşük olduğu yağmurlu havada gece sürüşü yapma gibi çeşitli sürüş görevlerini yerine getirmeleri istenmiştir. Bazı sürüş oturumlarında katılımcılara sürüş görevi sırasındaki trafik kuralı ihlalleri için ceza puanı uygulanmıştır.



(a)



(b)



(c)



(d)


Resim 4.9. Sürüş simülatöründen görüntüler [137]

4.2.7. Veri kümesi


Sürücü durumu veri kümesi 12 katılımcının dinlenme ortamında ve simülasyon ortamında alınan EDA ve kalp hızı sinyalleri ile oluşturulmuştur. Toplam 20 oturumda gerçekleştirilen deneylerde 9 katılımcıdan 1'er kez veri alınmıştır. Kalan 11 oturum verisi ise farklı günlerde, katılımcı 1'den 5; katılımcı 4 ile katılımcı 11'den 3 farklı oturumda alınan verilerle sağlanmıştır. Toplamda 20 oturumun her birisinde dinlenme ve simülasyon ortamları için ayrı ayrı kayıtlar yapılarak veri dosyaları hazırlanmıştır. Her bir oturum için veri dosyaları kullanılarak hazırlanan EDA sinyallerine ait grafikler EK-1'de, kalp hızı sinyallerine ait grafikler EK-2'de verilmiştir.

Katılımcılardan alınan EDA sinyallerine ait grafikler incelendiğinde bu grafiklerin neredeyse tamamında dinlenme ortamında yapılan kayıtlar ile simülasyon ortamında yapılan

kayıtlar arasında açık bir fark göze çarpmaktadır. Simülasyon ortamında yapılan kayıtlarda EDA sinyal değerlerinin dinlenme ortamında yapılan kayıtlara göre daha düşük olduğu gözlemlenmektedir. Şekil 4.2’de Katılımcı 1 Oturum 2’ye ait EDA sinyal değerlerinin zamana göre değişimini gösteren grafik ve Şekil 4.3’te Katılımcı 3 Oturum 1’e ait EDA sinyal değerlerinin zamana göre değişimini gösteren grafik gösterilmektedir.




Şekil 4.2. Katılımcı 1’den 2. oturumda alınan EDA sinyal değerlerinin zamana göre değişimi



Şekil 4.3. Katılımcı 3’ten 1. oturumda alınan EDA sinyal değerlerinin zamana göre değişimi

Şekil 4.2 ve Şekil 4.3 incelendiğinde EDA sinyal değerlerinin simülasyon ortamında sürüş görevi sırasında zamanla azaldığı açık bir şekilde görülmektedir. Ayrıca Şekil 4.3’te


dinlenme ortamında EDA sinyal değerlerinin zamanla artması da önemlidir. Şekil 4.4'te Katılımcı 1 Oturum 4 için EDA sinyal değerlerinin zamana göre değişimini gösteren grafik gösterilmektedir.



Şekil 4.4. Katılımcı 1'den 4. oturumda alınan EDA sinyal değerlerinin zamana göre değişimi


Şekil 4.4'te verilen grafik incelendiğinde diğer oturumlardan farklı olarak burada EDA sinyal değerlerinin dinlenme ve simülasyon ortamlarına ait ortalamaları neredeyse aynıdır.

Katılımcılardan alınan kalp hızı sinyal değerlerine ait grafikler incelendiğinde bu grafiklerin çoğunda dinlenme ortamında yapılan kayıtlar ile simülasyon ortamında yapılan kayıtlar arasında anlamlı bir fark olmadığı anlaşılmaktadır. Katılımcı 11 Oturum 1 için kalp hızı sinyal değerlerinin zamana göre değişimini gösteren grafik Şekil 4.5'te gösterilmektedir.



Şekil 4.5. Katılımcı 11’den 1. oturumda alınan kalp hızı sinyal değerlerinin zamana göre değişimi

Şekil 4.5’te verilen grafik incelendiğinde kalp hızı sinyal değerlerinin dinlenme ve simülasyon ortamlarına ait ortalamalarının aynı olduğu anlaşılmıştır. Şekil 4.6’da Katılımcı 5 Oturum 1’e ait kalp hızı sinyal değerlerinin zamana göre değişimini gösteren grafik gösterilmektedir.



Şekil 4.6. Katılımcı 5’ten 1. oturumda alınan kalp hızı sinyal değerlerinin zamana göre değişimi

Şekil 4.6’da simülasyon ortamında alınan kalp hızı sinyal değerlerinin dinlenme ortamında alınan sinyal değerlerinden yüksek olduğu görülmektedir. Bu durum simülasyon

ortamındaki sürüş görevi sırasında beklenen durumdur.

Her bir oturum için dinlenme ve simülasyon ortamlarında alınan EDA sinyal değerlerinin ortalaması ve bu değerlere ait standart sapmalar Çizelge 4.5’te gösterilmiştir.

Çizelge 4.5. Dinlenme ve simülasyon ortamlarında alınan EDA sinyal bilgileri

Katılımcı ve Oturum Bilgileri	Dinlenme Ortamında EDA Sinyal Değerlerinin Ortalaması	Dinlenme Ortamında EDA Sinyal Değerlerine Ait Standart Sapma	Simülasyon Ortamında EDA Sinyal Değerlerinin Ortalaması	Simülasyon Ortamında EDA Sinyal Değerlerine Ait Standart Sapma
Katılımcı 1 Oturum 1	391	33,7	282	12,6
Katılımcı 1 Oturum 2	328	21,5	215	31,9
Katılımcı 1 Oturum 3	515	43,7	357	31,1
Katılımcı 1 Oturum 4	362	46,8	365	39,4
Katılımcı 1 Oturum 5	418	27,3	317	33,4
Katılımcı 2 Oturum 1	474	5,6	405	16,5
Katılımcı 3 Oturum 1	495	32,5	308	64,3
Katılımcı 4 Oturum 1	340	14,9	320	6,5
Katılımcı 4 Oturum 2	525	12,6	466	11,4
Katılımcı 4 Oturum 3	574	4,4	488	17,6
Katılımcı 5 Oturum 1	602	3,7	416	48,5
Katılımcı 6 Oturum 1	489	44,9	445	35,2
Katılımcı 7 Oturum 1	544	23,8	445	39,4
Katılımcı 8 Oturum 1	589	8,9	504	22,3
Katılımcı 9 Oturum 1	493	19,7	447	16,6
Katılımcı 10 Oturum 1	554	14	538	11,8
Katılımcı 11 Oturum 1	540	36,8	299	54
Katılımcı 11 Oturum 2	367	68	221	27
Katılımcı 11 Oturum 3	550	6,9	312	23
Katılımcı 12 Oturum 1	557	15	545	35,9

EDA sinyal değerlerinin ortalamasının dinlenme ortamında yüksek, simülasyon ortamında düşük olması sürüş görevi sırasında beklenen durumdur. Çizelge 4.5 incelendiğinde, EDA sinyal değerlerinin ortalamasının 20 oturumun yalnızca 1 tanesi hariç kalan 19 oturumda simülasyon ortamında düşük olduğu görülmektedir.

Her bir oturum için dinlenme ve simülasyon ortamlarında alınan kalp hızı sinyal değerlerinin ortalaması ve bu değerlere ait standart sapmalar Çizelge 4.6’da gösterilmiştir.

Çizelge 4.6. Dinlenme ve simülasyon ortamlarında alınan kalp hızı sinyal bilgileri

Katılımcı ve Oturum Bilgileri	Dinlenme Ortamında Kalp Hızı Sinyal Değerlerinin Ortalaması	Dinlenme Ortamında Kalp Hızı Sinyal Değerlerine Ait Standart Sapma	Simülasyon Ortamında Kalp Hızı Sinyal Değerlerinin Ortalaması	Simülasyon Ortamında Kalp Hızı Sinyal Değerlerine Ait Standart Sapma
Katılımcı 1 Oturum 1	77	5,6	73	6,4
Katılımcı 1 Oturum 2	84	7	78	7,7
Katılımcı 1 Oturum 3	65	7,8	69	9,6
Katılımcı 1 Oturum 4	74	5,6	76	6,8
Katılımcı 1 Oturum 5	76	5,7	73	5,5
Katılımcı 2 Oturum 1	77	5,9	73	7,1
Katılımcı 3 Oturum 1	74	2,5	76	3,6
Katılımcı 4 Oturum 1	79	6,6	74	2,8
Katılımcı 4 Oturum 2	82	5,3	79	3,6
Katılımcı 4 Oturum 3	79	3,7	78	3,4
Katılımcı 5 Oturum 1	60	4,3	65	6,3
Katılımcı 6 Oturum 1	80	8	80	5,9
Katılımcı 7 Oturum 1	83	5,7	84	4,1
Katılımcı 8 Oturum 1	81	4,8	78	4,5
Katılımcı 9 Oturum 1	72	5,5	68	3,4
Katılımcı 10 Oturum 1	79	5,8	82	7,2
Katılımcı 11 Oturum 1	81	9,4	81	7
Katılımcı 11 Oturum 2	87	3,6	89	10,6
Katılımcı 11 Oturum 3	88	6,9	75	4,8
Katılımcı 12 Oturum 1	89	6,2	93	8,3

Kalp hızı sinyal değerlerinin ortalamasının dinlenme ortamında düşük, simülasyon ortamında yüksek olması sürüş görevi sırasında beklenen durumdur. Ancak Çizelge 4.6 incelendiğinde kalp hızı sinyal değerlerinin ortalamasının bazı simülasyon oturumlarında düşük bazı simülasyon oturumlarında yüksek olduğu görülmektedir.

Bu çalışmada veri kümesinin oluşturulmasında, veri ön işlemede ve verilerin sınıflandırmasında WEKA [138] kullanıldı. WEKA, araştırmacıların makine öğrenmesi ile ilgili son tekniklere erişimini sağlamak amacıyla bir ihtiyacın sonucu olarak, Yeni Zelanda'da bulunan Waikato Üniversitesi tarafından geliştirildi. Açık kaynak kodlu bir yazılı olan WEKA, ismini İngilizce “The Waikato Environment for Knowledge Analysis” kelimelerinin kısaltmasından alır. Regresyon, sınıflandırma, kümeleme, ilişkililik kuralı ve öznitelik seçme işlemleri için algoritmalar içerir. Verilerle ilgili çeşitli ön işleme işlemleri sağlar. WEKA farklı kaynaklardan veri yüklemeye olanak tanır ve ARFF, CSV gibi çeşitli

dosya formatlarını destekler [139]. ARFF, WEKA tarafından geliştirilen ve klasik bir metin editörü ile düzenleme yapılabilen dosya formatıdır. Bu tezde sürücü durumu veri kümesi ARFF formatında (Resim 4.10) oluşturulmuştur.

```
%
% SÜRÜCÜ DURUMU VERİ KÜMESİ
%
% Gazi Üniversitesi Bilişim Enstitüsü
% Bilişim Sistemleri Ana Bilim Dalı
%
% Yazarlar: Ahmet SUSAR, Nursel AKÇAM
%
% Veri Kümesi İçeriği:
%     Zaman (milisaniye)
%     Kalp Hızı Sinyali
%     Elektrodermal Aktivite (EDA) Sinyali
%     Sınıf İsmi

@relation surucudurumu

@attribute milisaniye integer
@attribute nabiz integer
@attribute eda integer
@attribute class {simulasyon,dinlenme}

@data
8114,76,472,dinlenme
9733,71,473,dinlenme
11318,73,471,dinlenme
12932,74,474,dinlenme
14505,76,478,dinlenme
16030,76,478,dinlenme
17627,74,476,dinlenme
19226,73,464,dinlenme
20779,76,454,dinlenme
22339,75,447,dinlenme
23794,80,445,dinlenme
```

Resim 4.10. ARFF formatında örnek veri kümesi dosyası

Sürücü durumunun tespiti, dinlenme ve simülasyon ortamlarının her birinden alınan 5'er dakikalık veri segmentleri kullanılarak gerçekleştirilmiştir. Veri segmentleri 10'ar dakikalık dinlenme ve simülasyon ortamlarının ortasında bulunan 5'er dakikalık fizyolojik sinyaller alınarak oluşturulmuştur.

4.2.8. Veri ön işleme

Veri ön işleme, veri kümesindeki verileri ihtiyaca göre daha kullanılır hale getirmeyi amaçlamaktadır. Örneğin, veri kümesinde varsa eksik verilerin giderilmesi, kullanılamayacak verilerin silinmesi ya da düzeltilmesi bazı veri ön işleme çeşitleridir. Bu çalışmada öncelikle az sayıdaki tutarsız veriler silinmiştir. Ardından veri kümesindeki verilerin anlaşılabilirliğini arttırmak amacı ile veri kümesindeki değerleri (0,1) aralığına normalleştiren “normalize” filtresi uygulanmıştır.

4.2.9. Verilerin sınıflandırılması

Veri kümeleri üzerinde veri madenciliği yapabilmek için çok sayıda makine öğrenmesi algoritması geliştirilmiştir. Bu algoritmalar farklı yaklaşımlar sergileyerek veri kümelerinin yapılarına göre farklı başarımlar elde etmektedir. Bu çalışmada verilerin sınıflandırılması için popüler 7 makine öğrenmesi algoritması kullanılmıştır. Bu algoritmalar aşağıda kısaca açıklanmıştır.

Bayes Ağları (Bayesian Networks), yönlü ve çevrimsiz grafiklere dayalı olasılıksal modellerdir. Bu modeller, değişkenler arasındaki nedensel ilişkileri doğrudan temsil eder. Grafikteki her düğüm rastgele bir değişkeni gösterirken, düğümler arasındaki kenarlar ise olasılığa dayalı bağımlılıkları gösterir. Grafikteki bu koşullu bağımlılıklar, genellikle bilinen istatistiksel ve hesaplama yöntemleri kullanılarak tahmin edilir. Bayes Ağları, nedensel biçimde gelen ve ön bilgi ile gözlemlenen verileri birleştirmek için idealdir. Nedensel ilişkileri öğrenmek, çeşitli problem alanlarını anlamak ve gelecekteki olayları tahmin etmek için kullanılabilir [140]. Bu çalışmada oluşturulan veri kümesi üzerinde Bayes Ağları test edilirken WEKA’da bulunan “BayesNet” algoritması kullanılmıştır.

Naif Bayes (Naive Bayesian) ile sınıflandırma koşullu olasılıklara bağlı olarak gerçekleştirilir. Bayes teoremine dayanan bu sınıflandırma tekniğinde öznitelikler, birbirinden bağımsız olarak olasılığa katkıda bulunduğu için Naif olarak adlandırılır. Birkaç nedenden dolayı önemli bir yöntemdir. Büyük veri kümelerinde kolayca uygulanabilir. Yorumlanması kolaydır, bu sayede kullanıcılar yapılan sınıflandırmanın mantığını kavrayabilirler. Herhangi bir problemde mümkün olan en iyi sınıflandırıcı olmasa da genellikle şaşırtıcı derecede iyi sonuçlar verir. Metin sınıflandırma ve spam filtreleme gibi

alanlarda yaygın olarak kullanılır [141-143]. Bu çalışmada oluşturulan veri kümesi üzerinde Naif Bayes test edilirken WEKA’da bulunan “NaiveBayes” algoritması kullanılmıştır.

Lojistik Regresyon (Logistic Regression) sigmoid adı verilen ve doğrusal olmayan bir fonksiyona en uygun parametreleri bulur. Lojistik Regresyon sınıflandırıcı için öznitelikler alınarak her biri bir ağırlıkla çarpılır ve sonra çıkan değerler toplanır. Bu sonuç sigmoid fonksiyonuna yerleştirildiğinde 0 ile 1 arasında bir çıktı alınır. 0.5'in üzerindeki her şey 1 olarak sınıflandırılır ve 0.5'in altındaki her şey 0 olarak sınıflandırılır. Lojistik Regresyon bir olasılık tahmini olarak da düşünülebilir. Uygulanması ve yorumlanması kolaydır, ama doğruluğu düşük olabilir [144]. Bu çalışmada oluşturulan veri kümesi üzerinde Lojistik Regresyon test edilirken WEKA’da bulunan “Logistic” algoritması kullanılmıştır.

Yapay Sinir Ağları (Artificial Neural Network) biyolojik sinir sisteminin yapısını ve işleyişini soyut bir şekilde taklit eden, basit, birbiriyle bağlantılı yapay nöronlardan oluşurlar. Yapay Sinir Ağları fikri biyolojik sistemlerin işleyişini birebir kopyalamak değil, karmaşık problemleri çözmek için biyolojik sistemlerin işlevselliğinden yararlanmaktır. Yapay Sinir Ağları sınıflandırıcısının ilgi çekici olması doğrusal olmamak, gürültüye duyarsızlık, öğrenme ve işleme yetenekleri, genelleme gibi bazı özelliklerden ötürüdür. Doğrusal olmamak, verilere daha iyi uyum sağlamasına; gürültüye duyarsızlık, belirsiz veriler ve ölçüm hataları olduğunda doğru tahmini gerçekleştirmeye; öğrenme ve işleme yetenekleri, sistemin değişen ortam şartlarında yapısını güncellemesine; genelleme ise modelin öğrenilmemiş verilere uygulanmasına olanak tanır. Yapay Sinir Ağları tabanlı hesaplamanın temel amacı, insan beynindeki bilgi edinmeyi ve bilgi işlemeyi taklit ederek öğrenmesini sağlayacak matematiksel algoritmalar geliştirmektir [145, 146]. Bu çalışmada oluşturulan veri kümesi üzerinde Yapay Sinir Ağları test edilirken WEKA’da bulunan “MultilayerPerceptron” algoritması kullanılmıştır.

Destek Vektör Makineleri (Support Vector Machines) popüler algoritmalar arasında en doğru yöntemlerden birisini sunar. Sağlam bir teorik temeli vardır. İki sınıflı bir öğrenme görevinde Destek Vektör Makineleri sınıflandırıcısının amacı iki sınıfa ait verileri birbirinden ayırmak için en iyi işlevi bulmaktır. Doğrusal olarak ayrılabilir bir veri kümesi için doğrusal bir sınıflandırma işlevi, iki sınıfı ayırarak ortasından geçen bir ayırıcı hiperdüzleme karşılık gelir. Veri kümesini ayırmak için belki de sonsuz sayıda hiperdüzlem olsa da iki sınıf arasındaki en büyük mesafeyi sağlayan hiperdüzlemin sınıflandırma

başarımını artıracak kabul edilir. Çok sınıflı problemlerde ise ikili sınıflandırmalar yapılabileceği gibi her sınıfı birbirinden ayıran hiperdüzlemler kullanılabilir [35, 141, 147]. Bu çalışmada oluşturulan veri kümesi üzerinde Destek Vektör Makineleri test edilirken WEKA’da bulunan “SMO” algoritması kullanılmıştır.

k-En Yakın Komşu (k-Nearest Neighbor) sınıflandırıcısında etiketlenmemiş olan örnekler, daha önceden etiketlenmiş olan örneklerden en yakın olanlarına göre sınıflandırılır. Basit bir yöntemdir ve yöntemin başarımı için iyi bir k değeri seçilmesi önemlidir. k-En Yakın Komşu sınıflandırıcısının uygulanması kolaydır, ancak büyük ölçekli ve yüksek boyutlu veri kümeleri için verimsizdir [148, 149]. Bu çalışmada oluşturulan veri kümesi üzerinde k-En Yakın Komşu test edilirken WEKA’da bulunan “IBk” algoritması kullanılmıştır.

Karar Ağaçları Ormanı (Random Forest) adından da anlaşıldığı gibi karar ağaçları topluluğudur. Yeni bir örneğin sınıflandırılmasında birden fazla karar ağacını dikkate alır. Karar Ağaçları Ormanı, daha fazla sayıda ağacın doğru kararı vereceği düşüncesinden hareketle sınıflandırma için oylama sistemi kullanır. Büyük veri kümeleriyle iyi çalışır. Hızlıdır ancak ağaç sayısı arttıkça gerçek zamanlı tahmin için yavaşlar. Gürültüye karşı dayanıklıdır. Karar Ağaçları Ormanı sınıflandırıcısının yorumlanması ve görselleştirilmesi kolaydır [143, 149]. Bu çalışmada oluşturulan veri kümesi üzerinde Karar Ağaçları Ormanı test edilirken WEKA’da bulunan “RandomForest” algoritması kullanılmıştır.

4.2.10. Sınıflandırma başarımları

Bu tez çalışmasında, veri ön işleme ile normalize edilen verilerin sınıflandırılması için önceki kısımda bahsedilen 7 popüler makine öğrenmesi algoritması WEKA ile test edilmiştir. Sınıflandırma işlemi ile amaçlanan düşük stresli durumu ifade eden dinlenme ortamındaki verilerden, sürüş esnasındaki stresi ifade eden simülasyon ortamındaki verileri ayırarak sürücü durumunun tespitini sağlamaktır. Veri kümesinde eğitim ve test kümeleri 10 katlı çapraz geçerlilik sınaması (k-fold cross validation, k=10) yöntemi kullanılarak belirlenmiştir. Bu çalışma sırasında oluşturulan sürücü durumu veri kümesi sınıflandırma için iki farklı şekilde kullanılmıştır. İlk olarak oluşturulan kullanım şekli 12 katılımcıdan 20 oturumda elde edilen tüm verilerin yer aldığı çok sürücülü veri kümesidir. Çok sürücülü veri kümesi ile farklı sürücülerin fizyolojik verilerinin sınıflandırma başarımına etkisi gözlemlenir. İkinci olarak oluşturulan kullanım şekli ise 1 katılımcıdan 5 farklı oturumda

alınan verilerin yer aldığı tek sürücülü veri kümesidir. Tek sürücülü veri kümesi ile sadece bir sürücüye ait fizyolojik verilerin, sınıflandırma başarımına etkisi gözlemlenir. Tek sürücülü veri kümesi ile sınıflandırma fizyolojik verilerin takibinde kişiselleştirilebilir sistemler geliştirmek açısından önemlidir. Sınıflandırma için kullanılan makine öğrenmesi algoritmalarının başarımları değerlendirme ölçütleri kullanılarak karşılaştırılmıştır. Değerlendirme ölçütü olarak Precision, Recall, F-Measure, ROC Area ve Doğruluk (Accuracy) kullanılmıştır.

Çok sürücülü veri kümesi ile sınıflandırma başarımları

12 katılımcıdan 20 oturumda alınan tüm verilerin bulunduğu çok sürücülü veri kümesinde EDA ve kalp hızı sinyalleri için Çizelge 4.7 Bayes Ağları ile elde edilen sınıflandırmaya ait hata matrisini, Çizelge 4.8 değerlendirme ölçütlerine göre Bayes Ağları ile elde edilen sınıflandırmaya ait başarımları göstermektedir.

Çizelge 4.7. Çok sürücülü veri kümesinde Bayes Ağları ile elde edilen sınıflandırmaya ait hata matrisi

Simülasyon	Dinlenme	
3212	664	Simülasyon
1273	2715	Dinlenme

Çizelge 4.8. Çok sürücülü veri kümesinde değerlendirme ölçütlerine göre Bayes Ağları ile elde edilen sınıflandırmaya ait başarımlar

Sınıf	Precision	Recall	F-Measure	ROC Area
Simülasyon	0,716	0,829	0,768	0,841
Dinlenme	0,803	0,681	0,737	0,841
Ortalama	0,760	0,754	0,752	0,841

12 katılımcıdan 20 oturumda alınan tüm verilerin bulunduğu çok sürücülü veri kümesinde EDA ve kalp hızı sinyalleri için Çizelge 4.9 Naif Bayes ile elde edilen sınıflandırmaya ait hata matrisini, Çizelge 4.10 değerlendirme ölçütlerine göre Naif Bayes ile elde edilen sınıflandırmaya ait başarımları göstermektedir.

Çizelge 4.9. Çok sürücülü veri kümesinde Naif Bayes ile elde edilen sınıflandırmaya ait hata matrisi

Simülasyon	Dinlenme	
2332	1544	Simülasyon
1038	2950	Dinlenme

Çizelge 4.10. Çok sürücülü veri kümesinde değerlendirme ölçütlerine göre Naif Bayes ile elde edilen sınıflandırmaya ait başarımlar

Sınıf	Precision	Recall	F-Measure	ROC Area
Simülasyon	0,692	0,602	0,644	0,760
Dinlenme	0,656	0,740	0,696	0,760
Ortalama	0,674	0,672	0,670	0,760

12 katılımcıdan 20 oturumda alınan tüm verilerin bulunduğu çok sürücülü veri kümesinde EDA ve kalp hızı sinyalleri için Çizelge 4.11 Lojistik Regresyon ile elde edilen sınıflandırmaya ait hata matrisini, Çizelge 4.12 değerlendirme ölçütlerine göre Lojistik Regresyon ile elde edilen sınıflandırmaya ait başarımları göstermektedir.

Çizelge 4.11. Çok sürücülü veri kümesinde Lojistik Regresyon ile elde edilen sınıflandırmaya ait hata matrisi

Simülasyon	Dinlenme	
2460	1416	Simülasyon
1131	2857	Dinlenme

Çizelge 4.12. Çok sürücülü veri kümesinde değerlendirme ölçütlerine göre Lojistik Regresyon ile elde edilen sınıflandırmaya ait başarımlar

Sınıf	Precision	Recall	F-Measure	ROC Area
Simülasyon	0,685	0,635	0,659	0,768
Dinlenme	0,669	0,716	0,692	0,768
Ortalama	0,677	0,676	0,676	0,768

12 katılımcıdan 20 oturumda alınan tüm verilerin bulunduğu çok sürücülü veri kümesinde EDA ve kalp hızı sinyalleri için Çizelge 4.13 Yapay Sinir Ağları ile elde edilen sınıflandırmaya ait hata matrisini, Çizelge 4.14 değerlendirme ölçütlerine göre Yapay Sinir

Ağları ile elde edilen sınıflandırmaya ait başarımları göstermektedir.

Çizelge 4.13. Çok sürücülü veri kümesinde Yapay Sinir Ağları ile elde edilen sınıflandırmaya ait hata matrisi

Simülasyon	Dinlenme	
3103	773	Simülasyon
1023	2965	Dinlenme

Çizelge 4.14. Çok sürücülü veri kümesinde değerlendirme ölçütlerine göre Yapay Sinir Ağları ile elde edilen sınıflandırmaya ait başarımlar

Sınıf	Precision	Recall	F-Measure	ROC Area
Simülasyon	0,752	0,801	0,776	0,847
Dinlenme	0,793	0,743	0,768	0,847
Ortalama	0,773	0,772	0,771	0,847

12 katılımcıdan 20 oturumda alınan tüm verilerin bulunduğu çok sürücülü veri kümesinde EDA ve kalp hızı sinyalleri için Çizelge 4.15 Destek Vektör Makineleri ile elde edilen sınıflandırmaya ait hata matrisini, Çizelge 4.16 değerlendirme ölçütlerine göre Destek Vektör Makineleri ile elde edilen sınıflandırmaya ait başarımları göstermektedir.

Çizelge 4.15. Çok sürücülü veri kümesinde Destek Vektör Makineleri ile elde edilen sınıflandırmaya ait hata matrisi

Simülasyon	Dinlenme	
3086	790	Simülasyon
1163	2825	Dinlenme

Çizelge 4.16. Çok sürücülü veri kümesinde değerlendirme ölçütlerine göre Destek Vektör Makineleri ile elde edilen sınıflandırmaya ait başarımlar

Sınıf	Precision	Recall	F-Measure	ROC Area
Simülasyon	0,726	0,796	0,760	0,752
Dinlenme	0,781	0,708	0,743	0,752
Ortalama	0,754	0,752	0,751	0,752

12 katılımcıdan 20 oturumda alınan tüm verilerin bulunduğu çok sürücülü veri kümesinde

EDA ve kalp hızı sinyalleri için Çizelge 4.17 k-En Yakın Komşu ile elde edilen sınıflandırmaya ait hata matrisini, Çizelge 4.18 değerlendirme ölçütlerine göre k-En Yakın Komşu ile elde edilen sınıflandırmaya ait başarımları göstermektedir.

Çizelge 4.17. Çok sürücülü veri kümesinde k-En Yakın Komşu ile elde edilen sınıflandırmaya ait hata matrisi

Simülasyon	Dinlenme	
3137	739	Simülasyon
826	3162	Dinlenme

Çizelge 4.18. Çok sürücülü veri kümesinde değerlendirme ölçütlerine göre k-En Yakın Komşu ile elde edilen sınıflandırmaya ait başarımlar

Sınıf	Precision	Recall	F-Measure	ROC Area
Simülasyon	0,792	0,809	0,800	0,879
Dinlenme	0,811	0,793	0,802	0,879
Ortalama	0,801	0,801	0,801	0,879

12 katılımcıdan 20 oturumda alınan tüm verilerin bulunduğu çok sürücülü veri kümesinde EDA ve kalp hızı sinyalleri için Çizelge 4.19 Karar Ağaçları Ormanı ile elde edilen sınıflandırmaya ait hata matrisini, Çizelge 4.20 değerlendirme ölçütlerine göre Karar Ağaçları Ormanı ile elde edilen sınıflandırmaya ait başarımları göstermektedir.

Çizelge 4.19. Çok sürücülü veri kümesinde Karar Ağaçları Ormanı ile elde edilen sınıflandırmaya ait hata matrisi

Simülasyon	Dinlenme	
2940	936	Simülasyon
921	3067	Dinlenme

Çizelge 4.20. Çok sürücülü veri kümesinde değerlendirme ölçütlerine göre Karar Ağaçları Ormanı ile elde edilen sınıflandırmaya ait başarımlar

Sınıf	Precision	Recall	F-Measure	ROC Area
Simülasyon	0,761	0,759	0,760	0,855
Dinlenme	0,766	0,769	0,768	0,855
Ortalama	0,764	0,764	0,764	0,855

Çok sürücülü veri kümesinde değerlendirme ölçütlerine göre makine öğrenmesi algoritmaları ile gerçekleştirilen sınıflandırmalara ait başarımlar incelendiğinde en yüksek başarımlara sahip sınıflandırma algoritmasının k-En Yakın Komşu olduğu anlaşılmaktadır.

Tek sürücülü veri kümesi ile sınıflandırma başarımları

1 katılımcıdan 5 oturumda alınan tek sürücülü veri kümesinde EDA ve kalp hızı sinyalleri için Çizelge 4.21 Bayes Ağları ile elde edilen sınıflandırmaya ait hata matrisini, Çizelge 4.22 değerlendirme ölçütlerine göre Bayes Ağları ile elde edilen sınıflandırmaya ait başarımları göstermektedir.

Çizelge 4.21. Tek sürücülü veri kümesinde Bayes Ağları ile elde edilen sınıflandırmaya ait hata matrisi

Simülasyon	Dinlenme	
841	65	Simülasyon
155	805	Dinlenme

Çizelge 4.22. Tek sürücülü veri kümesinde değerlendirme ölçütlerine göre Bayes Ağları ile elde edilen sınıflandırmaya ait başarımlar

Sınıf	Precision	Recall	F-Measure	ROC Area
Simülasyon	0,844	0,928	0,884	0,946
Dinlenme	0,925	0,839	0,880	0,946
Ortalama	0,886	0,882	0,882	0,946

1 katılımcıdan 5 oturumda alınan tek sürücülü veri kümesinde EDA ve kalp hızı sinyalleri için Çizelge 4.23 Naif Bayes ile elde edilen sınıflandırmaya ait hata matrisini, Çizelge 4.24 değerlendirme ölçütlerine göre Naif Bayes ile elde edilen sınıflandırmaya ait başarımları göstermektedir.

Çizelge 4.23. Tek sürücülü veri kümesinde Naif Bayes ile elde edilen sınıflandırmaya ait hata matrisi

Simülasyon	Dinlenme	
709	197	Simülasyon
132	828	Dinlenme

Çizelge 4.24. Tek sürücülü veri kümesinde değerlendirme ölçütlerine göre Naif Bayes ile elde edilen sınıflandırmaya ait başarımlar

Sınıf	Precision	Recall	F-Measure	ROC Area
Simülasyon	0,843	0,783	0,812	0,924
Dinlenme	0,808	0,863	0,834	0,924
Ortalama	0,825	0,824	0,823	0,924

1 katılımcıdan 5 oturumda alınan tek sürücülü veri kümesinde EDA ve kalp hızı sinyalleri için Çizelge 4.25 Lojistik Regresyon ile elde edilen sınıflandırmaya ait hata matrisini, Çizelge 4.26 değerlendirme ölçütlerine göre Lojistik Regresyon ile elde edilen sınıflandırmaya ait başarımları göstermektedir.

Çizelge 4.25. Tek sürücülü veri kümesinde Lojistik Regresyon ile elde edilen sınıflandırmaya ait hata matrisi

Simülasyon	Dinlenme	
748	158	Simülasyon
109	851	Dinlenme

Çizelge 4.26. Tek sürücülü veri kümesinde değerlendirme ölçütlerine göre Lojistik Regresyon ile elde edilen sınıflandırmaya ait başarımlar

Sınıf	Precision	Recall	F-Measure	ROC Area
Simülasyon	0,873	0,826	0,849	0,934
Dinlenme	0,843	0,886	0,864	0,934
Ortalama	0,858	0,857	0,857	0,934

1 katılımcıdan 5 oturumda alınan tek sürücülü veri kümesinde EDA ve kalp hızı sinyalleri için Çizelge 4.27 Yapay Sinir Ağları ile elde edilen sınıflandırmaya ait hata matrisini, Çizelge 4.28 değerlendirme ölçütlerine göre Yapay Sinir Ağları ile elde edilen sınıflandırmaya ait başarımları göstermektedir.

Çizelge 4.27. Tek sürücülü veri kümesinde Yapay Sinir Ağları ile elde edilen sınıflandırmaya ait hata matrisi

Simülasyon	Dinlenme	
822	84	Simülasyon
102	858	Dinlenme

Çizelge 4.28. Tek sürücülü veri kümesinde değerlendirme ölçütlerine göre Yapay Sinir Ağları ile elde edilen sınıflandırmaya ait başarımlar

Sınıf	Precision	Recall	F-Measure	ROC Area
Simülasyon	0,890	0,907	0,898	0,961
Dinlenme	0,911	0,894	0,902	0,961
Ortalama	0,901	0,900	0,900	0,961

1 katılımcıdan 5 oturumda alınan tek sürücülü veri kümesinde EDA ve kalp hızı sinyalleri için Çizelge 4.29 Destek Vektör Makineleri ile elde edilen sınıflandırmaya ait hata matrisini, Çizelge 4.30 değerlendirme ölçütlerine göre Destek Vektör Makineleri ile elde edilen sınıflandırmaya ait başarımları göstermektedir.

Çizelge 4.29. Tek sürücülü veri kümesinde Destek Vektör Makineleri ile elde edilen sınıflandırmaya ait hata matrisi

Simülasyon	Dinlenme	
763	143	Simülasyon
103	857	Dinlenme

Çizelge 4.30. Tek sürücülü veri kümesinde değerlendirme ölçütlerine göre Destek Vektör Makineleri ile elde edilen sınıflandırmaya ait başarımlar

Sınıf	Precision	Recall	F-Measure	ROC Area
Simülasyon	0,881	0,842	0,861	0,867
Dinlenme	0,857	0,893	0,874	0,867
Ortalama	0,869	0,868	0,868	0,867

1 katılımcıdan 5 oturumda alınan tek sürücülü veri kümesinde EDA ve kalp hızı sinyalleri için Çizelge 4.31 k-En Yakın Komşu ile elde edilen sınıflandırmaya ait hata matrisini, Çizelge 4.32 değerlendirme ölçütlerine göre k-En Yakın Komşu ile elde edilen

sınıflandırmaya ait başarımları göstermektedir.

Çizelge 4.31. Tek sürücülü veri kümesinde k-En Yakın Komşu ile elde edilen sınıflandırmaya ait hata matrisi

Simülasyon	Dinlenme	
821	85	Simülasyon
115	845	Dinlenme

Çizelge 4.32. Tek sürücülü veri kümesinde değerlendirme ölçütlerine göre k-En Yakın Komşu ile elde edilen sınıflandırmaya ait başarımlar

Sınıf	Precision	Recall	F-Measure	ROC Area
Simülasyon	0,877	0,906	0,891	0,955
Dinlenme	0,909	0,880	0,894	0,955
Ortalama	0,893	0,893	0,893	0,955

1 katılımcıdan 5 oturumda alınan tek sürücülü veri kümesinde EDA ve kalp hızı sinyalleri için Çizelge 4.33 Karar Ağaçları Ormanı ile elde edilen sınıflandırmaya ait hata matrisini, Çizelge 4.34 değerlendirme ölçütlerine göre Karar Ağaçları Ormanı ile elde edilen sınıflandırmaya ait başarımları göstermektedir.

Çizelge 4.33. Tek sürücülü veri kümesinde Karar Ağaçları Ormanı ile elde edilen sınıflandırmaya ait hata matrisi

Simülasyon	Dinlenme	
784	122	Simülasyon
126	834	Dinlenme

Çizelge 4.34. Tek sürücülü veri kümesinde değerlendirme ölçütlerine göre Karar Ağaçları Ormanı ile elde edilen sınıflandırmaya ait başarımlar

Sınıf	Precision	Recall	F-Measure	ROC Area
Simülasyon	0,862	0,865	0,863	0,945
Dinlenme	0,872	0,869	0,871	0,945
Ortalama	0,867	0,867	0,867	0,945

Tek sürücülü veri kümesinde değerlendirme ölçütlerine göre makine öğrenmesi

algoritmaları ile gerçekleştirilen sınıflandırmalara ait başarımlar incelendiğinde en yüksek başarımlara sahip sınıflandırma algoritmasının Yapay Sinir Ağları olduğu anlaşılmaktadır.

Sınıflandırma doğruluklarının karşılaştırılması

Sınıflandırma problemlerinde en çok kullanılan değerlendirme ölçütü doğruluktur. Çok sürücülü ve tek sürücülü veri kümelerinde 7 makine öğrenmesi algoritması kullanılarak gerçekleştirilen sınıflandırmalara ait doğruluklar Çizelge 4.35'te verilerek karşılaştırılmaktadır.


Çizelge 4.35. Çok sürücülü ve tek sürücülü veri kümelerinde makine öğrenmesi algoritmalarına göre doğruluklar

Makine Öğrenmesi Algoritması	Çok sürücülü veri kümesinde doğruluk	Tek sürücülü veri kümesinde doğruluk
Bayes Ağları	%75,4	%88,2
Naif Bayes	%67,2	%82,4
Lojistik Regresyon	%67,7	%85,7
Yapay Sinir Ağları	%77,2	%90
Destek Vektör Makineleri	%75,2	%86,8
k-En Yakın Komşu	%80,1	%89,3
Karar Ağaçları Ormanı	%76,4	%86,7

Çok sürücülü veri kümesinde sınıflandırma işleminde en yüksek doğruluk %80,1 ile k-En Yakın Komşu ile elde edilirken, tek sürücülü veri kümesinde sınıflandırma işleminde en yüksek doğruluk %90 ile Yapay Sinir Ağları ile elde edilmiştir. Sınıflandırma doğruluklarına birlikte bakıldığında 7 makine öğrenmesi algoritmasının tamamı da tek sürücülü veri kümesinde çok sürücülü veri kümesine nazaran daha yüksek doğruluğa ulaşmıştır. Bu durum kişileştirilebilir sistemlerin önemini göstermektedir.

4.3. Çevrim İçi Sürücü Durumu Tespiti

Çevrim içi sürücü durumu tespiti ile sürüş esnasındaki stres durumunun, fizyolojik veriler üzerinden, IoT teknolojilerini kullanarak, gerçek zamanlı tespiti için kural tabanlı bir yöntem önerilmektedir. Önerilen yöntem, sürüş esnasında sürücülere ait EDA ve kalp hızı sinyallerinden oluşan fizyolojik verilerin uzaktan takibine imkân tanımaktadır. Fizyolojik verilerinden elde edilecek olası anormal sürücü stres durumlarının belirlenmesi ve bu stres durumlarında gerçek zamanlı olarak çeşitli uyarılarda bulunulması bu sistemin başlıca faydaları arasındadır. Bu sayede trafik kazalarının önüne geçilmesi ve yol güvenliğinin sağlanması amaçlanmaktadır. Önerilen sistemin mimarisi Şekil 4.7’de gösterilmektedir.




Şekil 4.7. Önerilen çevrim içi sürücü durumu tespiti için sistem mimarisi

Önerilen çevrim içi sistemde sensörler yardımı ile toplanan fizyolojik sinyaller IoT platformuna gönderilerek IoT platformunda depolama işlemi ve uzaktan takibi yapılmaktadır. IoT platformunun acil durumlarda mobil uygulamalarla etkileşime geçmesi sağlanarak bu uygulamalar aracılığı ile sürücü ve üçüncü kişiler için bildirimler oluşturulmaktadır.

4.3.1. Sistem prototipi

Önerilen çevrim içi sistemde sensörlerin, kablosuz internet bağlantısı modülünün ve mikrodenetleyici kartının (Arduino Nano) birbirlerine gerekli bağlantılarının yapılması ile fizyolojik sinyalleri toplamak ve IoT platformuna iletmek için kullanılan donanım (Resim 4.11) hazırlanmıştır. Gerçek trafik ortamlarına benzer şekilde oluşturulan iç mekân sürüş ortamında (Resim 4.12), hazırlanan donanımın katılımcıya bağlanması ile City Car Driving [137] isimli sürüş simülâtörü kullanılarak, sistem test edilmiştir. Sistem ile EDA ve kalp hızı sinyallerinin sürüş stresi için düşük, normal ve yüksek olarak sınıflandırıldığı üç seviyeli çevrim içi sürücü durumu tespiti gerçekleştirilmektedir.



Resim 4.11. Çevrim içi sürücü durumu tespitinde fizyolojik sinyalleri toplamak ve IoT platformuna iletmek için kullanılan donanım




Resim 4.12. Çevrim içi sürücü durumu tespiti için hazırlanan iç mekân sürüş ortamı


4.3.2. IoT platformu ile fizyolojik verilerin uzaktan takibi ve depolanması

Önerilen sistemde sürücüye ait fizyolojik verilerin uzaktan takibi IoT analiz platformu olan ThingSpeak üzerinden yapılır. ThingSpeak akıllı cihazlar, sensörler gibi veri sağlayıcılardan gelen verilerin özel veya genel kanalda saklandığı buluta gönderilmesine olanak tanır. ThingSpeak kanalındaki veriler analiz edilebilir, görselleştirilebilir. Bu veriler ile sosyal medya, web hizmetleri ve diğer cihazlar üzerinden etkileşimlerde bulunulabilir. Verilerdeki ilişkiler ve eğilimler keşfedilebilir, yeni veriler hesaplanabilir, gelen verilere göre bir reaksiyon tetiklenebilir ve bir eylem kontrol edilebilir [150].

Çevrim içi sürücü durumunun tespiti için sensörler aracılığı ile kaydedilen EDA ve kalp hızı sinyalleri ThingSpeak platformu ile uzaktan takip edilmekte ve depolanmaktadır. 30 dakikadan daha uzun bir süre iç mekân sürüş ortamında test edilen EDA ve kalp hızı sinyallerine ait grafikler Şekil 4.8’de gösterilmektedir.



(a) EDA sinyali



(b) Kalp hızı sinyali

Şekil 4.8. Çevrim içi sürücü durumu tespiti için iç mekân sürüş ortamında test edilen fizyolojik sinyallere ait grafikler

Test amacı ile kaydı yapılan EDA verilerinin ortalaması 291 ve kalp hızı verilerinin ortalaması 84 olarak ölçülmüştür. Bunun yanında ölçümü yapılan fizyolojik veriler, sürüş stres seviyesi için düşük ve yüksek olduğu durumlarda gerçek zamanlı olarak çeşitli uyarılar oluşturmak için kullanılmaktadır.

4.3.3. Trafikte anormal durumlar için uyarı sistemi

Trafikte sürücülerin anormal fizyolojik durumları trafik kazalarına davetiye çıkarır. Bu yüzden olumsuz sürücü durumlarını tespit etmek ve bu durumlar hakkında uyarılar oluşturmak hayati derecede önemlidir. Sürüş sırasında sürücülerden elde edilen fizyolojik sinyal değerlerinde anormallikler olduğu durumlarda, sürücülerin sürüş görevi için gereken konsantrasyonu sağlayamayacağı düşünülür. Bu düşüncesinden hareketle bir uyarı sistemi geliştirilmiştir.

Sistem, fizyolojik sinyalleri kullanarak sürüş sırasında olması gereken stres seviyesinin daha düşük ya da daha yüksek olduğu durumların tespiti için tasarlanmıştır. Düşük ya da yüksek stres durumunun tespitinde, birisi sürücüye yapılan uygulama bildirimi, diğeri daha önce belirlenen üçüncü kişiye gönderilen SMS bildirimi olmak üzere iki farklı şekilde uyarılar oluşturulmaktadır. Uyarı sisteminin çalışması için sürücüye ait EDA ve kalp hızı sinyallerinin herhangi birisinin belirlenen aralıkların dışına çıkması gerekmektedir. Normal sürüş stresi için belirlenen aralıklar şunlardır:


- EDA sinyal değeri 200'den küçük ya da 400'den büyük olduğunda,
- Kalp hızı sinyal değeri 60'tan küçük ya da 115'ten büyük olduğunda,

uygulama bildirimi ve SMS bildirimi oluşmaktadır. Bu değerlerin belirlenmesinde çevrim dışı sürücü durumu tespiti için yapılan sınıflandırmalardan faydalanılmıştır.

Sürüş esnasında alınan ve ThingSpeak platformunda kaydedilen EDA ve kalp hızı sinyal değerleri, sürüş için belirlenen değerlerin dışına çıktığında ThingSpeak platformu tepki oluşturur. Bu tepki IFTTT [151] aracılığı ile uygulama ve SMS bildirimlerinin oluşturulmasını sağlamaktadır. IFTTT, ürün ve servislerin birlikte çalışmasına yardımcı olur. Uygulama bildirimi oluşturmak için IFTTT yapısı içerisinde tetikleyici olarak Webhooks ile bildirim için Pushover [152] uygulaması kullanılmıştır. SMS bildirimi oluşturmak için ise IFTTT yapısı içerisinde tetikleyici olarak yine Webhooks ile bildirim için Android SMS uygulaması kullanılmıştır.


Sürücü stres durumu düşük ya da yüksek olarak tespit edildiğinde sürücünün akıllı cihazına Pushover uygulaması aracılığı ile gerçek zamanlı sesli ve görüntülü uyarı için uygulama bildirimi gönderilmektedir. Bu sayede trafikte olası bir olumsuzlukta uyarı bildirimi alan sürücü dinlenmek için mola verebilecek ya da daha acil ve ciddi durumlarda sağlık

kuruluşlarına gidebilecektir. Resim 4.13'te anormal sürücü durumları tespitinde gerçek zamanlı olarak sürücüye iletilen uygulama bildirimleri gösterilmektedir.



Resim 4.13. Anormal sürücü durumları tespitinde sürücüye iletilen uygulama bildirimleri

Anormal sürücü durumu tespit edildiğinde sürücünün telefonundan, sürücü tarafından belirlenen üçüncü kişinin telefonuna otomatik olarak SMS bildirimi gönderilmektedir. Bu bildirim trafikte gerçekleşebilecek olumsuzluklarda önlem almayı sağlayabilecek ve direksiyon başında sıkça meydana gelen kalp krizi gibi durumlarda erken müdahaleyi kolaylaştırabilecektir. Resim 4.14'te anormal sürücü durumları tespit edildiğinde gerçek zamanlı olarak üçüncü kişinin telefonuna gönderilen SMS bildirimleri gösterilmektedir.



Resim 4.14. Anormal sürücü durumları tespitinde önceden belirlenen üçüncü kişiye iletilen SMS bildirimleri

Oluşturulan uyarı sisteminde, uygulama ve SMS bildirimlerinin iletilme süreleri de hesaplanmıştır. Anormal ölçümden ortalama 4-5 saniye sonra sürücüye gönderilen uygulama bildirimi iletilirken, ortalama 6-7 saniye sonra üçüncü kişiye gönderilen SMS bildirimi iletilmektedir.



5. TARTIŞMA

Bu tez çalışma ile fizyolojik sinyallere bağlı olarak sürücü durumu tespiti için bir yaklaşım önerilmiştir. Önerilen yaklaşımın yapılan benzer çalışmalarla kıyaslanması Çizelge 5.1’de gösterilmektedir.

Çizelge 5.1. Önerilen yaklaşımın yapılan benzer çalışmalarla kıyaslanması

Çalışma	Yıl	Amaç	Veri Türü	Açıklamalar
Chang ve diğerleri [21]	2018	Sürücü uykululuk ve yorgunluk tespiti	Göz kapaklarındaki gerilim sinyalleri	- Bulut tabanlı yönetim platformu kullanımı - Gerçek zamanlı uyarı sistemi
Khan ve diğerleri [27]	2018	Sürücü yorgunluğu tespiti	Yüz ifadeleri	- Gürültü ve farklı görüntü çözünürlüklerindeki değişikliklere karşı duyarsız - Farklı aydınlatma koşullarında test edilmeli
X. Meng ve diğerleri [28]	2018	Sürücü davranışını izlemek	Gaz pedalına, fren pedalına ve sürücü gözlüğüne bağlı sensörlerden alınan gerilim sinyalleri	- Sürücü davranışını izlemek için ilk kez kullanılan TENG tabanlı sensörler - Düşük maliyetli - Gerçek zamanlı takip sistemi
Dobbins ve Fairclough [30]	2018	Sürücü stres tespiti	EKG, PPG ve Sürüş verileri	- Gerçek dünya ortamı - 21 katılımcı - En yüksek %86,9 doğruluk
Lanata ve diğerleri [32]	2014	Sürücü stres tespiti	EDA, Kalp hızı, Solunum ve Sürüş verileri	- Simülasyon ortamı - 15 katılımcı - %90 üstü doğruluk
Ghaderi ve diğerleri [33]	2015	Sürücü stres tespiti	EDA, EMG, Kalp hızı ve Solunum	- Gerçek dünya ortamında oluşturulan “MIT drivenb” veri kümesine ait 7 sürüş verisinin kullanımı - Destek Vektör Makineleri ve k-En Yakın Komşu sınıflandırıcılarının kullanımı - En yüksek %99 doğruluk - Solunum sensörünün stres tespiti için en önemli sensör olduğunun anlaşılması
Lee ve diğerleri [34]	2016	Sürücü stres tespiti	PPG ve Sürüş verileri	- Simülasyon ortamı - 28 katılımcı - En yüksek %95 doğruluk - Düşük maliyetli
Keshan ve diğerleri [35]	2015	Sürücü stres tespiti	EKG	- Gerçek dünya ortamında oluşturulan “MIT drivenb” veri kümesine ait 10 sürüş verisinin kullanımı - 10 sınıflandırıcı algoritmanın kullanımı - En yüksek %88,24 doğruluk (Üç stres sınıfı için)

Çizelge 5.1. (devam) Önerilen yaklaşımın yapılan benzer çalışmalarla kıyaslanması

Choi ve diğerleri [36]	2017	Sürücü stres, yorgunluk ve uyukluk tespiti	EDA, PPG, Sıcaklık ve Sürüş verileri	- Simülasyon ortamı - 28 katılımcı - Destek Vektör Makineleri tabanlı sınıflandırıcı kullanımı - Rahatsız edici olmayan giyilebilir bir cihaz geliştirilmesi
Munla ve diğerleri [39]	2015	Sürücü stres tespiti	EKG	- Gerçek dünya ortamında oluşturulan “MIT drivedb” veri kümesine ait 16 sürüş verisinin kullanımı - Destek Vektör Makineleri ve k-En Yakın Komşu ve RBF sınıflandırıcılarının kullanımı - En yüksek %83 doğruluk
Napoletano ve Rossi [43]	2018	Sürücü stres tespiti	Kalp hızı ve Solunum	- Simülasyon ortamında oluşturulan veri kümesine ait 52 katılımcı verisinin kullanımı - En yüksek %69 doğruluk
Qiu ve diğerleri [44]	2019	Sürücünün fizyolojik sinyalleri ile sürüş manevraları arasındaki ilişkinin analizi	EDA, Kalp hızı ve Solunum	- Gerçek dünya ortamında oluşturulan veri kümesi kullanımı - Destek Vektör Makineleri ve Karar Ağaçları Ormanı sınıflandırıcılarının kullanımı
Nita ve diğerleri [46]	2019	Sürücü stres tespiti	EKG	- Gerçek dünya ortamında oluşturulan “MIT drivedb” veri kümesine ait 10 sürüş verisinin kullanımı - Gelişmiş Karar Ağaçları Ormanı sınıflandırıcısı kullanımı - En yüksek %97 doğruluk (Üç stres sınıfı için)
Y. Liu ve Du [52]	2018	Sürücü stres tespiti	EDA	- Gerçek dünya ortamında oluşturulan “MIT drivedb” veri kümesine ait 11 sürüş verisinin kullanımı
Healey ve Picard [54]	2005	Sürücü stres tespiti	EDA, EKG, EMG ve Solunum	- Dinlenme ortamı, otoyolda sürüş ve şehir içi sürüş koşulları için üç farklı stres ortamı - Gerçek dünya ortamında 9 katılımcıdan 24 sürüş verisinin yer aldığı “MIT drivedb” veri kümesinin oluşturulması
Önerilen yöntem	2021	Sürücü stres tespiti	EDA ve Kalp hızı	- Simülasyon ortamında 12 katılımcıdan 20 oturumda alınan fizyolojik sinyallerin yer aldığı sürücü durumu veri kümesinin oluşturulması - 7 sınıflandırıcı algoritmanın kullanımı - En yüksek %90 doğruluk - IoT tabanlı gerçek zamanlı takip ve uyarı sistemi

Literatürde yer alan ilgili çalışmaların birçoğu sürücülerini olumsuz etkileyen durumları incelerken çevrim dışı bir yöntem önermektedir. Araştırmacılar sürücüye ait ya da taşıta ait verilere göre uyukluluk, yorgunluk, stres gibi olumsuz durumları anlamaya çalışmaktadır. Kimi araştırmacılar bu olumsuz durumların yalnızca bir tanesine odaklanırken kimi

araştırmacılar olumsuz durumların birkaç tanesini birlikte ele aldılar. Bu tez ile literatürdeki çalışmalara benzer şekilde fizyolojik sinyaller kullanılarak sürücü durumunun tespiti için çevrim dışı bir yaklaşımda bulunulmuştur. Fizyolojik sinyallerden sürüş esnasında sürücülerden alınabilmesi kolay olan EDA ve kalp hızı sinyalleri seçilmiştir. İki seviyeli sınıflandırmada kullanılmak üzere deney ortamları, düşük stres durumu için dinlenme ortamından ve sürüş sırasındaki normal stres durumu için simülasyon ortamından oluşturulmuştur. Hazırlanan deney ortamlarında, katılımcılardan alınan EDA ve kalp hızı sinyalleri ile veri kümesi oluşturularak, makine öğrenmesi algoritmaları ile test edilmiştir. Sınıflandırma sonucunda, 12 sürücünden 20 oturumda alınan veriler ile oluşturulan çok sürücülü veri kümesinden en yüksek %80,1 doğruluk elde edilmiştir. 1 sürücünden 5 oturumda alınan veriler ile oluşturulan tek sürücülü veri kümesinde ise en yüksek %90 doğruluk elde edilmiştir. Sonuçlar stres durumu tespitinde yöntemin uygulanabilirliğini göstermekte ve sürücüye özgü farklılıkların hesaba katıldığı kişiselleştirilebilir sistemler geliştirmenin önemini ortaya koymaktadır. Bunun yanında kullanılan veri türü de sürücü durumu tespiti için önemlidir. Örneğin, sürüş esnasında toplanırken oldukça rahatsız edici EKG, EMG gibi sinyallerinin yerine daha az rahatsız edici olan EDA ve kalp hızı sinyallerine bağlı olarak bir çalışma gerçekleştirilmiştir. EDA ve kalp hızı sinyallerinin sürücünün rahatsız olmayacağı hatta farkında bile olmayacağı sadece direksiyona monte edilecek sensörler yardımı ile de ölçülebilmesi de mümkündür.

Literatürde çevrim içi sürücü durumu takibi yaparak bir tespit sistemi için yapılan çalışmalar oldukça yetersizdir. Önceki araştırmalar çeşitli veri kümelerini kullanarak sürücü durumu tespitinde farklı tekniklerle farklı yaklaşımlar sunmaktadırlar. Bununla beraber sürücülerini gerçek zamanlı takip ederek gerekli durumlarda uyarılar oluşturacak sistemler az sayıda araştırmacının konusu olabilmektedir. Bu çalışma ile EDA ve kalp hızı sinyallerinin uzaktan takibine ve anormal stres durumlarında uyarı oluşturmaya olanak sağlayan çevrim içi IoT tabanlı bir sistem de sunulmuştur. Bu fizyolojik sinyal değerlerinin alt ve üst sınır değerlerini aşması durumunda, verilecek uyarılar sayesinde sürücüler mola verebilir ya da daha ciddi durumlarda sağlık kuruluşlarına başvurabilirler. Gerçekleştirilen prototip çalışmanın pratikte yaygınlaştırılarak yol güvenliğine ve yaşam kalitesine ciddi katkıda bulunabileceği düşünülmektedir. Birkaç örnek vermek gerekirse, ölçülen fizyolojik değerlerin üst ve alt sınıra yaklaşması durumlarında bu değerleri normalleştirecek araç içi sistemler geliştirilebilir. Sürücü verilerinin yanında yolcuların verilerinin de takip edilmesi ve sisteme başka sinyalleri takip eden sensörlerin eklenmesi ile daha kapsamlı bir takip ve uyarı sistemi

oluřturulabilir. Yetkili kurumlarca geliřtirilecek trafik bulutu ile trafikteki verilerinin uzaktan takibi ve yönetimi tek bir merkezden saęlanabilir.



6. SONUÇ VE ÖNERİLER

Sürücü hataları, trafik kazalarındaki ölüm ve yaralanmaların ana sebebidir. Sürüş esnasında dikkatsizlik, alkollü olmak, uykulu olmak, yorgunluk, stres gibi bazı durumlar sürüş görevini olumsuz etkileyen ve sürücü hatalarına neden olan faktörlerdendir. Bu faktörlerin belirlenmesi yol güvenliğini sağlamak için ciddi bir önem teşkil eder. Bu çalışma sürücülerde hatalara sebep olan ve sürüş görevini olumsuz etkileyen stres durumlarının tespiti için fizyolojik sinyallere dayalı yöntem önermektedir. Fizyolojik sinyaller, sürücü durumu hakkında bilgi sağlamak için yararlı bir ölçümdür.

Bu tez ile çevrim dışı sürücü durumu tespiti için EDA ve kalp hızı sinyallerini kullanan bir sistem sunulmuştur. 12 katılımcının 20 oturumda dinlenme ve simülasyon olmak üzere iki farklı stres ortamında EDA ve kalp hızı sinyalleri ölçülerek veri kümesi oluşturulmuştur. Oluşturulan veri kümesi, çok sürücülü veri kümesi ve tek sürücülü veri kümesi olmak üzere iki farklı şekilde, 7 makine öğrenmesi algoritması ile değerlendirilmiştir. Değerlendirme ölçütü olarak Precision, Recall, F-Measure, ROC Area ve Doğruluk (Accuracy) kullanılarak, makine öğrenmesi algoritmalarının başarımları karşılaştırılmıştır. Neticede çok sürücülü sınıflandırmada elde edilen en yüksek %80,1 doğruluk ve tek sürücülü sınıflandırmada elde edilen en yüksek %90 doğruluk yöntemin geçerliliğini kanıtlamaktadır. Bulunan Precision, Recall, F-Measure, ROC Area ve Doğruluk (Accuracy) değerlerine bakıldığında; tek sürücülü veri kümesi ile elde edilen başarımların, çok sürücülü veri kümesi ile elde edilen başarımlara göre daha yüksek olduğu anlaşılmıştır. Bu durum stres tespitinde kişiye özel olarak oluşturulacak yöntemlerle daha etkili ve doğru çıkarımlar elde edilebileceğini açıkça göstermektedir.

Günlük hayatı kolaylaştıran ve verimliliği arttıran IoT ile hayatın her alanını etkileyen köklü bir yenilenme yaşanmaktadır. Gerek bilimsel gerekse ticari olarak çok sayıda IoT uygulaması geliştirilmekte, dinamik bir şekilde yeni uygulamalar ortaya çıkmaktadır. Bu çalışma ile son yıllarda popüler hale gelen IoT kavramı ele alınarak, IoT'nin yaygın kullanıldığı uygulama alanlarından bahsedilmiştir. Öte yandan sürücü stresinin tespitinde de IoT teknolojilerinin kullanılması ile çevrim içi sürücü durumu tespiti için bir yaklaşım önerilmiştir. Önerilen yaklaşım EDA ve kalp hızı sinyallerinin gerçek zamanlı olarak uzaktan takibine olanak tanımakta ve sürücü stresinin sürüş görevi için düşük ya da yüksek

olduđu anormal fizyolojik sinyal deđerlerinde uyarılar sağlamaktadır. Bu sayede olası trafik kazalarının önüne geçilebileceđi düşünölmektedir.

Gelecekte sürücü durumu tespiti ile ilgili olarak yapılacak çalışmaların, simölasyon ortamı yerine gerekli tedbirlerin alındıđı gerçek dünya ortamında yapılması önerilir. Çünkü simölasyon ortamı ile gerçek dünya ortamında birtakım farklılıklar olması muhtemeldir. Çevrim dışı sürücü durumu tespitinde katılımcılardan öznel olarak doldurmaları istenen kişilik testleri ile katılımcıların fizyolojik sinyallerinin ilişkisini inceleyen bir çalışma da ilginç olabilir. Ayrıca çevrim içi sürücü durumu tespitine makine öğrenmesi algoritmalarının dâhil edilerek gerçek zamanlı sınıflandırmaların yapılması gelecek için önemli bir araştırma konusudur.

KAYNAKLAR

1. World Health Organization. (2018). *Global status report on road safety 2018: Summary* (No. WHO/NMH/NVI/18.20). World Health Organization.
2. İnternet: Türkiye İstatistik Kurumu. (2020). Trafik kaza istatistikleri. *TÜİK*. Web: <https://data.tuik.gov.tr/Kategori/GetKategori?p=ulastirma-ve-haberlesme-112&dil=1>, Son Erişim Tarihi: 30.11.2020.
3. İnternet: UN General Assembly. (2015). Resolution adopted by the General Assembly on 25 September 2015. *New York: United Nations*. Web: https://www.un.org/en/development/desa/population/migration/generalassembly/docs/globalcompact/A_RES_70_1_E.pdf, Son Erişim Tarihi: 30.11.2020.
4. İnternet: World Health Organization. (2020). Global gathering of ministers determines road safety agenda to 2030. *WHO*. Web: https://www.who.int/violence_injury_prevention/road_traffic/ministerial-conference-2020/en/, Son Erişim Tarihi: 30.11.2020.
5. Stankovic, J. A. (2014). Research directions for the Internet of Things. *IEEE Internet of Things Journal*, 1(1), 3-9.
6. Wan, J., Tang, S., Shu, Z., Li, D., Wang, S., Imran, M., and Vasilakos, A. V. (2016). Software-defined industrial Internet of Things in the context of industry 4.0. *IEEE Sensors Journal*, 16(20), 7373-7380.
7. ur Rehman, M. H., Yaqoob, I., Salah, K., Imran, M., Jayaraman, P. P., and Perera, C. (2019). The role of big data analytics in industrial Internet of Things. *Future Generation Computer Systems*, 99, 247-259.
8. Meng, Z., Wu, Z., and Gray, J. (2018). RFID-based object-centric data management framework for smart manufacturing applications. *IEEE Internet of Things Journal*, 6(2), 2706-2716.
9. Frank, A. G., Dalenogare, L. S., and Ayala, N. F. (2019). Industry 4.0 technologies: Implementation patterns in manufacturing companies. *International Journal of Production Economics*, 210, 15-26.
10. Liu, L., Zhou, B., Zou, Z., Yeh, S. C., and Zheng, L. (2018, September). A smart unstaffed retail shop based on artificial intelligence and IoT. In *2018 IEEE 23rd International Workshop on Computer Aided Modeling and Design of Communication Links and Networks (CAMAD)* (pp. 1-4). IEEE.
11. Kamble, S. S., Gunasekaran, A., Parekh, H., and Joshi, S. (2019). Modeling the Internet of Things adoption barriers in food retail supply chains. *Journal of Retailing and Consumer Services*, 48, 154-168.
12. Fagerstrøm, A., Eriksson, N., and Sigurdsson, V. (2020). Investigating the impact of Internet of Things services from a smartphone app on grocery shopping. *Journal of Retailing and Consumer Services*, 52, 101927.

13. Adame, T., Bel, A., Carreras, A., Melia-Segui, J., Oliver, M., and Pous, R. (2018). CUIDATS: An RFID–WSN hybrid monitoring system for smart health care environments. *Future Generation Computer Systems*, 78, 602-615.
14. Rodrigues, J. J. P. C., Segundo, D. B. D. R., Junqueira, H. A., Sabino, M. H., Prince, R. M., Al-Muhtadi, J., and De Albuquerque, V. H. C. (2018). Enabling technologies for the Internet of Health Things. *IEEE Access*, 6, 13129-13141.
15. Thapliyal, H., Khalus, V., and Labrado, C. (2017). Stress detection and management: A survey of wearable smart health devices. *IEEE Consumer Electronics Magazine*, 6(4), 64-69.
16. Hamim, M., Paul, S., Hoque, S. I., Rahman, M. N., and Baqee, I. A. (2019, January). IoT based remote health monitoring system for patients and elderly people. In *2019 International Conference on Robotics, Electrical and Signal Processing Techniques (ICREST)* (pp. 533-538). IEEE.
17. Xu, L., and Mcardle, G. (2018). Internet of too many things in smart transport: The problem, the side effects and the solution. *IEEE Access*, 6, 62840-62848.
18. Alaa, M., Zaidan, A. A., Zaidan, B. B., Talal, M., and Kiah, M. L. M. (2017). A review of smart home applications based on Internet of Things. *Journal of Network and Computer Applications*, 97, 48-65.
19. Jain, B., Brar, G., Malhotra, J., Rani, S., and Ahmed, S. H. (2018). A cross layer protocol for traffic management in Social Internet of Vehicles. *Future Generation Computer Systems*, 82, 707-714.
20. Sharma, S., and Kaushik, B. (2019). A survey on Internet of Vehicles: Applications, security issues & solutions. *Vehicular Communications*, 20, 100182.
21. Chang, W. J., Chen, L. B., and Chiou, Y. Z. (2018). Design and implementation of a drowsiness-fatigue-detection system based on wearable smart glasses to increase road safety. *IEEE Transactions on Consumer Electronics*, 64(4), 461-469.
22. Zhang, M., Chen, C., Wo, T., Xie, T., Bhuiyan, M. Z. A., and Lin, X. (2017). SafeDrive: online driving anomaly detection from large-scale vehicle data. *IEEE Transactions on Industrial Informatics*, 13(4), 2087-2096.
23. Gruyer, D., Magnier, V., Hamdi, K., Claussmann, L., Orfila, O., and Rakotonirainy, A. (2017). Perception, information processing and modeling: Critical stages for autonomous driving applications. *Annual Reviews in Control*, 44, 323-341.
24. Wang, X., Liu, Y., Guo, Y., Xia, Y., and Wu, C. (2019). Transformation mechanism of vehicle cluster situations under dynamic evolution of driver's propensity. *Transportation Research Part F: Traffic Psychology and Behaviour*, 65, 665-684.

25. Lozoya-Santos, J. D. J., Sepúlveda-Arróniz, V., Tudon-Martinez, J. C., and Ramirez-Mendoza, R. A. (2019). Survey on biometry for cognitive automotive systems. *Cognitive Systems Research*, 55, 175-191.
26. Kaplan, S., Guvensan, M. A., Yavuz, A. G., and Karalurt, Y. (2015). Driver behavior analysis for safe driving: A survey. *IEEE Transactions on Intelligent Transportation Systems*, 16(6), 3017-3032.
27. Khan, S. A., Hussain, S., Xiaoming, S., and Yang, S. (2018). An effective framework for driver fatigue recognition based on intelligent facial expressions analysis. *IEEE Access*, 6, 67459-67468.
28. Meng, X., Cheng, Q., Jiang, X., Fang, Z., Chen, X., Li, S., Li, C., Sun, C., Wang, W., and Wang, Z. L. (2018). Triboelectric nanogenerator as a highly sensitive self-powered sensor for driver behavior monitoring. *Nano Energy*, 51, 721-727.
29. Koesdwiady, A., Soua, R., Karray, F., and Kamel, M. S. (2016). Recent trends in driver safety monitoring systems: State of the art and challenges. *IEEE Transactions on Vehicular Technology*, 66(6), 4550-4563.
30. Dobbins, C., and Fairclough, S. (2018). Signal processing of multimodal mobile lifelogging data towards detecting stress in real-world driving. *IEEE Transactions on Mobile Computing*, 18(3), 632-644.
31. Rigas, G., Goletsis, Y., and Fotiadis, D. I. (2011). Real-time driver's stress event detection. *IEEE Transactions on Intelligent Transportation Systems*, 13(1), 221-234.
32. Lanatà, A., Valenza, G., Greco, A., Gentili, C., Bartolozzi, R., Bucchi, F., Frendo, F., and Scilingo, E. P. (2014). How the autonomic nervous system and driving style change with incremental stressing conditions during simulated driving. *IEEE Transactions on Intelligent Transportation Systems*, 16(3), 1505-1517.
33. Ghaderi, A., Frounchi, J., and Farnam, A. (2015, November). Machine learning-based signal processing using physiological signals for stress detection. In *2015 22nd Iranian Conference on Biomedical Engineering (ICBME)* (pp. 93-98). IEEE.
34. Lee, D. S., Chong, T. W., and Lee, B. G. (2016). Stress events detection of driver by wearable glove system. *IEEE Sensors Journal*, 17(1), 194-204.
35. Keshan, N., Parimi, P. V., and Bichindaritz, I. (2015, October). Machine learning for stress detection from ECG signals in automobile drivers. In *2015 IEEE International Conference on Big Data (Big Data)* (pp. 2661-2669). IEEE.
36. Choi, M., Koo, G., Seo, M., and Kim, S. W. (2017). Wearable device-based system to monitor a driver's stress, fatigue, and drowsiness. *IEEE Transactions on Instrumentation and Measurement*, 67(3), 634-645.
37. Mühlbacher-Karrer, S., Mosa, A. H., Faller, L. M., Ali, M., Hamid, R., Zangl, H., and Kyamakya, K. (2017). A driver state detection system—Combining a capacitive hand detection sensor with physiological sensors. *IEEE Transactions on Instrumentation and Measurement*, 66(4), 624-636.

38. Gutmann, M., Grausberg, P., and Kyamakya, K. (2015, October). Detecting human driver's physiological stress and emotions using sophisticated one-person cockpit vehicle simulator. In *2015 Information Technologies in Innovation Business Conference (ITIB)* (pp. 15-18). IEEE.
39. Munla, N., Khalil, M., Shahin, A., and Mourad, A. (2015, September). Driver stress level detection using HRV analysis. In *2015 international conference on advances in biomedical engineering (ICABME)* (pp. 61-64). IEEE.
40. Singh, R. R., Conjeti, S., and Banerjee, R. (2011, October). An approach for real-time stress-trend detection using physiological signals in wearable computing systems for automotive drivers. In *2011 14th International IEEE Conference on Intelligent Transportation Systems (ITSC)* (pp. 1477-1482). IEEE.
41. Lopez-Martinez, D., El-Haouij, N., and Picard, R. (2019, September). Detection of real-world driving-induced affective state using physiological signals and multi-view multi-task machine learning. In *2019 8th International Conference on Affective Computing and Intelligent Interaction Workshops and Demos (ACIIW)* (pp. 356-361). IEEE.
42. Saeed, A., Trajanovski, S., van Keulen, M., and van Erp, J. (2017, November). Deep physiological arousal detection in a driving simulator using wearable sensors. In *2017 IEEE International Conference on Data Mining Workshops (ICDMW)* (pp. 486-493). IEEE.
43. Napoletano, P., and Rossi, S. (2018, September). Combining heart and breathing rate for car driver stress recognition. In *2018 IEEE 8th International Conference on Consumer Electronics-Berlin (ICCE-Berlin)* (pp. 1-5). IEEE.
44. Qiu, Y., Misu, T., and Busso, C. (2019, October). Analysis of the relationship between physiological signals and vehicle maneuvers during a naturalistic driving study. In *2019 IEEE Intelligent Transportation Systems Conference (ITSC)* (pp. 3230-3235). IEEE.
45. Athanasiou, G., Tsotoulidis, S., Mitronikas, E., and Lymberopoulos, D. (2014, August). Stress-oriented driver assistance system for electric vehicles. In *2014 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society* (pp. 5936-5939). IEEE.
46. Nita, S., Bitam S., and Mellouk A. (2019, October). A body area network for ubiquitous driver stress monitoring based on ECG signal. In *2019 International Conference on Wireless and Mobile Computing, Networking and Communications (WiMob)* (pp. 1-6). IEEE.
47. Li, N., Misu, T., and Miranda, A. (2016, November). Driver behavior event detection for manual annotation by clustering of the driver physiological signals. In *2016 IEEE 19th International Conference on Intelligent Transportation Systems (ITSC)* (pp. 2583-2588). IEEE.
48. Kavitha, K. C., and Perumalraja, R. (2014, April). Smart wireless healthcare monitoring for drivers community. In *2014 International Conference on Communication and Signal Processing* (pp. 1105-1108). IEEE.

49. Cassani, R., Falk, T. H., Horai, A., and Gheorghe, L. A. (2019, October). Evaluating the measurement of driver heart and breathing rates from a sensor-equipped steering wheel using spectrotemporal signal processing. In *2019 IEEE Intelligent Transportation Systems Conference (ITSC)* (pp. 2843-2847). IEEE.
50. Schmidt, E., Decke, R., and Rasshofer, R. (2016, June). Correlation between subjective driver state measures and psychophysiological and vehicular data in simulated driving. In *2016 IEEE Intelligent Vehicles Symposium (IV)* (pp. 1380-1385). IEEE.
51. Liu, F., Li, X., Lv, T., and Xu, F. (2019, January). A review of driver fatigue detection: progress and prospect. In *2019 IEEE International Conference on Consumer Electronics (ICCE)* (pp. 1-6). IEEE.
52. Liu, Y., and Du, S. (2018). Psychological stress level detection based on electrodermal activity. *Behavioural Brain Research*, 341, 50-53.
53. Wang, J. S., Lin, C. W., and Yang, Y. T. C. (2013). A k-nearest-neighbor classifier with heart rate variability feature-based transformation algorithm for driving stress recognition. *Neurocomputing*, 116, 136-143.
54. Healey, J. A., and Picard, R. W. (2005). Detecting stress during real-world driving tasks using physiological sensors. *IEEE Transactions on intelligent transportation systems*, 6(2), 156-166.
55. Junaid, M., Shah, M. A., and Satti, I. A. (2017, September). A survey of Internet of Things, enabling technologies and protocols. In *2017 23rd International Conference on Automation and Computing (ICAC)* (pp. 1-5). IEEE.
56. Maksimović, M., Vujović, V., and Perišić, B. (2015, June). A custom Internet of Things healthcare system. In *2015 10th Iberian Conference on Information Systems and Technologies (CISTI)* (pp. 1-6). IEEE.
57. Li, S., Da Xu, L., and Zhao, S. (2015). The Internet of Things: A survey. *Information Systems Frontiers*, 17(2), 243-259.
58. Al-Fuqaha, A., Guizani, M., Mohammadi, M., Aledhari, M., and Ayyash, M. (2015). Internet of Things: A survey on enabling technologies, protocols, and applications. *IEEE Communications Surveys & Tutorials*, 17(4), 2347-2376.
59. Mahdavinejad, M. S., Rezvan, M., Barekatin, M., Adibi, P., Barnaghi, P., and Sheth, A. P. (2018). Machine learning for Internet of Things data analysis: A survey. *Digital Communications and Networks*, 4(3), 161-175.
60. Ashton, K. (2009). That 'Internet of Things' thing. *RFID journal*, 22(7), 97-114.
61. Da Xu, L., He, W., and Li, S. (2014). Internet of Things in industries: A survey. *IEEE Transactions on Industrial Informatics*, 10(4), 2233-2243.
62. Xia, F., Yang, L. T., Wang, L., and Vinel, A. (2012). Internet of Things. *International Journal of Communication Systems*, 25(9), 1101.

63. Atzori, L., Iera, A., and Morabito, G. (2010). The Internet of Things: A survey. *Computer Networks*, 54(15), 2787-2805.
64. Islam, S. R., Kwak, D., Kabir, M. H., Hossain, M., and Kwak, K. S. (2015). The Internet of Things for health care: A comprehensive survey. *IEEE Access*, 3, 678-708.
65. Luo, S., and Ren, B. (2016). The monitoring and managing application of cloud computing based on Internet of Things. *Computer Methods and Programs in Biomedicine*, 130, 154-161.
66. Hellaoui, H., Koudil, M., and Bouabdallah, A. (2017). Energy-efficient mechanisms in security of the Internet of Things: A survey. *Computer Networks*, 127, 173-189.
67. Balaji, M. S., and Roy, S. K. (2017). Value co-creation with Internet of Things technology in the retail industry. *Journal of Marketing Management*, 33(1-2), 7-31.
68. Hui, T. K., Sherratt, R. S., and Sánchez, D. D. (2017). Major requirements for building Smart Homes in Smart Cities based on Internet of Things technologies. *Future Generation Computer Systems*, 76, 358-369.
69. Patil, K. (2016, December). Retail adoption of Internet of Things: Applying TAM model. In *2016 International Conference on Computing, Analytics and Security Trends (CAST)* (pp. 404-409). IEEE.
70. García, C. G., Meana-Llorián, D., G-Bustelo, B. C. P., Lovelle, J. M. C., and Garcia-Fernandez, N. (2017). Midgar: Detection of people through computer vision in the Internet of Things scenarios to improve the security in Smart Cities, Smart Towns, and Smart Homes. *Future Generation Computer Systems*, 76, 301-313.
71. Botta, A., De Donato, W., Persico, V., and Pescapé, A. (2016). Integration of cloud computing and Internet of Things: A survey. *Future Generation Computer Systems*, 56, 684-700.
72. İnternet: Microsoft Dynamics 365. (2019). 2019 manufacturing trends report. *Microsoft*. Web: <https://info.microsoft.com/rs/157-GQE-382/images/EN-US-CNTNT-Report-2019-Manufacturing-Trends.pdf>, Son Erişim Tarihi: 02.12.2020.
73. Miorandi, D., Sicari, S., De Pellegrini, F., and Chlamtac, I. (2012). Internet of Things: Vision, applications and research challenges. *Ad Hoc Networks*, 10(7), 1497-1516.
74. Gubbi, J., Buyya, R., Marusic, S., and Palaniswami, M. (2013). Internet of Things (IoT): A vision, architectural elements, and future directions. *Future Generation Computer Systems*, 29(7), 1645-1660.
75. İnternet: James, M., Chui, M., Bisson, P., Woetzel, J., Dobbs, R., Bughin, J., and Aharon, D. (2015). The Internet of Things: Mapping the value beyond the hype. *McKinsey Global Institute*. Web: https://www.mckinsey.com/~media/McKinsey/Industries/Technology%20Media%20and%20Telecommunications/High%20Tech/Our%20Insights/The%20Internet%20of%20Things%20The%20value%20of%20digitizing%20the%20physical%20world/Unlocking_the_potential_of_the_Internet_of_Things_Executive_summary.pdf, Son Erişim Tarihi: 02.12.2020.

76. Jin, J., Gubbi, J., Marusic, S., and Palaniswami, M. (2014). An information framework for creating a smart city through Internet of Things. *IEEE Internet of Things Journal*, 1(2), 112-121.
77. Silva, B. N., Khan, M., and Han, K. (2018). Towards sustainable smart cities: A review of trends, architectures, components, and open challenges in smart cities. *Sustainable Cities and Society*, 38, 697-713.
78. Zanella, A., Bui, N., Castellani, A., Vangelista, L., and Zorzi, M. (2014). Internet of Things for smart cities. *IEEE Internet of Things Journal*, 1(1), 22-32.
79. Ahmed, S. H., and Rani, S. (2018). A hybrid approach, smart street use case and future aspects for Internet of Things in smart cities. *Future Generation Computer Systems*, 79, 941-951.
80. Letaifa, S. B. (2015). How to strategize smart cities: Revealing the SMART model. *Journal of Business Research*, 68(7), 1414-1419.
81. Lom, M., Pribyl, O., and Svitek, M. (2016, May). Industry 4.0 as a part of smart cities. In *2016 Smart Cities Symposium Prague (SCSP)* (pp. 1-6). IEEE.
82. Lade, P., Ghosh, R., and Srinivasan, S. (2017). Manufacturing analytics and industrial Internet of Things. *IEEE Intelligent Systems*, 32(3), 74-79.
83. Papakostas, N., O'Connor, J., and Byrne, G. (2016, October). Internet of Things technologies in manufacturing: Application areas, challenges and outlook. In *2016 International Conference on Information Society (i-Society)* (pp. 126-131). IEEE.
84. Yang, C., Shen, W., and Wang, X. (2016, May). Applications of Internet of Things in manufacturing. In *2016 IEEE 20th International Conference on Computer Supported Cooperative Work in Design (CSCWD)* (pp. 670-675). IEEE.
85. Bi, Z., Da Xu, L., and Wang, C. (2014). Internet of Things for enterprise systems of modern manufacturing. *IEEE Transactions on Industrial Informatics*, 10(2), 1537-1546.
86. Qiang, M., Yu-feng, D., Ting, X., and Shun-li, W. (2015, November). Research of visualization monitoring technology based on Internet of Things in discrete manufacturing process. In *2015 2nd International Symposium on Dependable Computing and Internet of Things (DCIT)* (pp. 128-133). IEEE.
87. Gao, Q., Li, F., and Chen, C. (2015, June). Research of Internet of Things applied to manufacturing execution system. In *2015 IEEE International Conference on Cyber Technology in Automation, Control, and Intelligent Systems (CYBER)* (pp. 661-665). IEEE.
88. Caro, F., and Sadr, R. (2019). The Internet of Things (IoT) in retail: Bridging supply and demand. *Business Horizons*, 62(1), 47-54.

89. Dlamini, N. N., and Johnston, K. (2016, November). The use, benefits and challenges of using the Internet of Things (IoT) in retail businesses: A literature review. In *2016 International Conference on Advances in Computing and Communication Engineering (ICACCE)* (pp. 430-436). IEEE.
90. İnternet: Thomasson, E. (2013). Big Retailer is watching you: stores seek to match online savvy. *Reuters*. Web: <https://www.reuters.com/article/retail-tracking/big-retailer-is-watching-you-stores-seek-to-match-online-savvy-idUSL5N0IY3JL20131115>, Son Erişim Tarihi: 02.12.2020.
91. Sfar, A. R., Natalizio, E., Challal, Y., and Chtourou, Z. (2017, May). A Markov game privacy preserving model in retail applications. In *2017 International Conference on Selected Topics in Mobile and Wireless Networking (MoWNeT)* (pp. 1-8). IEEE.
92. İnternet: Amazon Go. (2018). Watch to learn more about just walk out shopping. *Amazon*. Web: <https://www.amazon.com/b?node=16008589011>, Son Erişim Tarihi: 02.12.2020.
93. Vippalapalli, V., and Ananthula, S. (2016, October). Internet of Things (IoT) based smart health care system. In *2016 International Conference on Signal Processing, Communication, Power and Embedded System (SCOPES)* (pp. 1229-1233). IEEE.
94. Bhatia, M., and Sood, S. K. (2017). A comprehensive health assessment framework to facilitate IoT-assisted smart workouts: A predictive healthcare perspective. *Computers in Industry*, 92, 50-66.
95. Yuehong, Y. I. N., Zeng, Y., Chen, X., and Fan, Y. (2016). The Internet of Things in healthcare: An overview. *Journal of Industrial Information Integration*, 1, 3-13.
96. Saha, H. N., Auddy, S., Pal, S., Kumar, S., Pandey, S., Singh, R., Singh, A. K., Sharan, P., Ghosh, D., and Saha, S. (2017, August). Health monitoring using Internet of Things (IoT). In *2017 8th Annual Industrial Automation and Electromechanical Engineering Conference (IEMECON)* (pp. 69-73). IEEE.
97. İnternet: Huawei. (2019). World's first remote operation using 5G surgery. *Huawei*. Web: <https://www.huawei.com/en/industry-insights/outlook/mobile-broadband/wireless-for-sustainability/cases/worlds-first-remote-operation-using-5g-surgery>, Son Erişim Tarihi: 02.12.2020.
98. Whitmore, A., Agarwal, A., and Da Xu, L. (2015). The Internet of Things—A survey of topics and trends. *Information Systems Frontiers*, 17(2), 261-274.
99. Dimitrioglou, N., Kardaras, D., and Barbounaki, S. (2017, July). Multicriteria evaluation of the Internet of Things potential in health care: The case of dementia care. In *2017 IEEE 19th Conference on Business Informatics (CBI)* (Vol. 1, pp. 454-462). IEEE.
100. İnternet: Voelcker, J., (2011). It's official: We now have one billion vehicles on the planet. *Green Car Reports*. Web: https://www.greencarreports.com/news/1065070_its-official-we-now-have-one-billion-vehicles-on-the-planet, Son Erişim Tarihi: 02.12.2020.

101. Ganzha, M., Paprzycki, M., Pawłowski, W., Szmeja, P., and Wasielewska, K. (2017). Semantic interoperability in the Internet of Things: An overview from the INTER-IoT perspective. *Journal of Network and Computer Applications*, 81, 111-124.
102. Chunli, L. (2012, April). Intelligent transportation based on the Internet of Things. In *2012 2nd International Conference on Consumer Electronics, Communications and Networks (CECNet)* (pp. 360-362). IEEE.
103. Ashokkumar, K., Sam, B., and Arshadprabhu, R. (2015). Cloud based intelligent transport system. *Procedia Computer Science*, 50, 58-63.
104. Xu, D., Zhang, X., and Deng, Q. (2015, August). Study on intelligent logistics system: Based on Internet of Vehicles. In *2015 IEEE 12th Intl Conf on Ubiquitous Intelligence and Computing and 2015 IEEE 12th Intl Conf on Autonomic and Trusted Computing and 2015 IEEE 15th Intl Conf on Scalable Computing and Communications and Its Associated Workshops (UIC-ATC-ScalCom)* (pp. 681-685). IEEE.
105. Lin, J., Yu, W., Zhang, N., Yang, X., Zhang, H., and Zhao, W. (2017). A survey on Internet of Things: Architecture, enabling technologies, security and privacy, and applications. *IEEE Internet of Things Journal*, 4(5), 1125-1142.
106. Rathore, M. M., Ahmad, A., Paul, A., and Rho, S. (2016). Urban planning and building smart cities based on the Internet of Things using big data analytics. *Computer Networks*, 101, 63-80.
107. Wang, C., David, B., Chalon, R., and Yin, C. (2016). Dynamic road lane management study: A smart city application. *Transportation Research Part E: Logistics and Transportation Review*, 89, 272-287.
108. Alam, K. M., Saini, M., and El Saddik, A. (2015). Toward social Internet of Vehicles: Concept, architecture, and applications. *IEEE Access*, 3, 343-357.
109. Chen, L. L., Zhao, Y., Ye, P. F., Zhang, J., and Zou, J. Z. (2017). Detecting driving stress in physiological signals based on multimodal feature analysis and kernel classifiers. *Expert Systems with Applications*, 85, 279-291.
110. Chen, C., Xiang, H., Qiu, T., Wang, C., Zhou, Y., and Chang, V. (2018). A rear-end collision prediction scheme based on deep learning in the Internet of Vehicles. *Journal of Parallel and Distributed Computing*, 117, 192-204.
111. Gerla, M., Lee, E. K., Pau, G., and Lee, U. (2014, March). Internet of Vehicles: From intelligent grid to autonomous cars and vehicular clouds. In *2014 IEEE World Forum on Internet of Things (WF-IoT)* (pp. 241-246). IEEE.
112. Perera, C., Zaslavsky, A., Christen, P., and Georgakopoulos, D. (2014). Sensing as a service model for smart cities supported by Internet of Things. *Transactions on Emerging Telecommunications Technologies*, 25(1), 81-93.
113. Arasteh, H., Hosseinneshad, V., Loia, V., Tommasetti, A., Troisi, O., Shafie-khah, M., and Siano, P. (2016, June). IoT-based smart cities: A survey. In *2016 IEEE 16th International Conference on Environment and Electrical Engineering (EEEIC)* (pp. 1-6). IEEE.

114. İnternet: Arduino. Arduino Uno Rev3. *Arduino*. Web: <https://store.arduino.cc/usa/arduino-uno-rev3>, Son Erişim Tarihi: 02.12.2020.
115. Badamasi, Y. A. (2014, September). The working principle of an Arduino. In *2014 11th International Conference on Electronics, Computer and Computation (ICECCO)* (pp. 1-4). IEEE.
116. İnternet: Arduino. Arduino Nano. *Arduino*. Web: <https://store.arduino.cc/usa/arduino-nano>, Son Erişim Tarihi: 02.12.2020.
117. Schwartz, M. (2016). *Internet of Things with ESP8266*. Birmingham, UK: Packt Publishing, 2.
118. Mesquita, J., Guimarães, D., Pereira, C., Santos, F., and Almeida, L. (2018, September). Assessing the ESP8266 WiFi module for the Internet of Things. In *2018 IEEE 23rd International Conference on Emerging Technologies and Factory Automation (ETFA)* (Vol. 1, pp. 784-791). IEEE.
119. İnternet: Seeed. Grove - GSR sensor. *Seeed*. Web: https://wiki.seeedstudio.com/Grove-GSR_Sensor/, Son Erişim Tarihi: 02.12.2020.
120. Shi, Y., Ruiz, N., Taib, R., Choi, E., and Chen, F. (2007, April). Galvanic skin response (GSR) as an index of cognitive load. In *CHI'07 Extended Abstracts on Human Factors in Computing Systems* (pp. 2651-2656).
121. Jatti, A., Kannan, M., Alisha, R. M., Vijayalakshmi, P., and Sinha, S. (2016, May). Design and development of an IoT based wearable device for the safety and security of women and girl children. In *2016 IEEE International Conference on Recent Trends in Electronics, Information & Communication Technology (RTEICT)* (pp. 1108-1112). IEEE.
122. Temko, A. (2017). Accurate heart rate monitoring during physical exercises using PPG. *IEEE Transactions on Biomedical Engineering*, 64(9), 2016-2024.
123. Kong, Y., and Chon, K. (2019, July). Heart Rate Estimation using PPG signal during Treadmill Exercise. In *2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)* (pp. 3253-3256). IEEE.
124. İnternet: Seeed. Grove - Ear-clip heart rate sensor. *Seeed*. Web: http://wiki.seeedstudio.com/Grove-Ear-clip_Heart_Rate_Sensor/, Son Erişim Tarihi: 02.12.2020.
125. Zuckerman M. (2002). Zuckerman–Kuhlman Personality Questionnaire (ZKPQ): An alternative five factorial model. In De Raad B, Perugini M. (Eds), *Big five assessment*. Seattle, WA: Hogrefe & Huber Publishers, 377–396.
126. Turan, R. (2010). *Madde kullanım nedeniyle denetimli serbestlik ve tedavi tedbirine hükmolan kişilerin tedaviyi başarıyla tamamlamalarını öngören etkenlerin irdelenmesi*, Yayınlanmamış Doktora Tezi, İstanbul Üniversitesi Adli Tıp Enstitüsü, İstanbul.
127. Terziköy, E. (2014). *Sanat dissosiasyon ve kişilik*, Yayınlanmamış Yüksek Lisans Tezi, İstanbul Arel Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul.


128. Piferi, R. L., Kline, K. A., Younger, J., and Lawler, K. A. (2000). An alternative approach for achieving cardiovascular baseline: viewing an aquatic video. *International Journal of Psychophysiology*, 37(2), 207-217.
129. İnternet: Dinlendirici su videosu. Web: <https://www.youtube.com/watch?v=OVct34NUk3U>, Son Erişim Tarihi: 03.12.2020.
130. Büyüköztürk, Ş. (1997). Araştırmaya yönelik kaygı ölçeğinin geliştirilmesi. *Kuram ve Uygulamada Eğitim Yönetimi Dergisi*, 3(4), 453-464.
131. Türkçapar, Ü. (2012). Güreşçilerin farklı değişkenler açısından sürekli kaygı düzeylerinin incelenmesi. *Gazi Üniversitesi Gazi Eğitim Fakültesi Dergisi*, 32(1), 129-140.
132. Kara, H., ve Acet, M. (2012). Spor yöneticilerinde durumluk kaygısının otomatik düşünceler üzerindeki etkisinin incelenmesi. *Social Sciences*, 7(4), 244-258.
133. Güler, Ö. (2013). *Selim ve malign tiroid hastalarında tiroidektomi öncesi anksiyetenin değerlendirilmesi: STAI-State, APAIS ve Smiley-VAS skorlarının karşılaştırılması*, Yayınlanmamış Uzmanlık Tezi, İstanbul Üniversitesi Tıp Fakültesi, İstanbul.
134. Civan, A. (2001). *Bireysel ve takım sporlarında yer alan sporcuların müsabaka öncesi ve sonrası durumluk ve sürekli kaygılarının karşılaştırılması*, Yayınlanmamış Yüksek Lisans Tezi, Selçuk Üniversitesi Sağlık Bilimleri Enstitüsü, Konya.
135. Aykent, R., Kocamanoğlu, İ. S., Üstün, E., Tür, A., ve Şahinoğlu, H. (2007). Preoperatif anksiyete nedenleri ve değerlendirilmesi: APAIS ve STAI skorlarının karşılaştırılması. *Türkiye Klinikleri Journal of Anesthesiology Reanimation*, 5(1), 7-13.
136. Taşdemir, A. (2012). *STAI testi ile preoperatif ve postoperatif anksiyete düzeylerinin değerlendirilmesi*, Yayınlanmamış Uzmanlık Tezi, Ege Üniversitesi Tıp Fakültesi, İzmir.
137. İnternet: Sürüş simülatörü. Web: <https://citycardriving.com/>, Son Erişim Tarihi: 03.12.2020.
138. İnternet: WEKA. Web: <https://www.cs.waikato.ac.nz/ml/weka/>, Son Erişim Tarihi: 03.12.2020.
139. Hall, M., Frank, E., Holmes, G., Pfahringer, B., Reutemann, P., and Witten, I. H. (2009). The WEKA data mining software: an update. *ACM SIGKDD Explorations Newsletter*, 11(1), 10-18.
140. Ben-Gal, I. (2008). Bayesian networks. *Encyclopedia of Statistics in Quality and Reliability*, 1.
141. Wu, X., Kumar, V., Quinlan, J. R., Ghosh, J., Yang, Q., Motoda, H., McLachlan, G. J., Ng, A., Liu, B., Yu, P. S., Zhou, Z. H., Steinbach, M., Hand, D. J., and Steinberg D. (2008). Top 10 algorithms in data mining. *Knowledge and Information Systems*, 14(1), 1-37.

142. Dey, A. (2016). Machine learning algorithms: A review. *International Journal of Computer Science and Information Technologies*, 7(3), 1174-1179.
143. Ramalingam, V. V., Dandapath, A., and Raja, M. K. (2018). Heart disease prediction using machine learning techniques: A survey. *International Journal of Engineering & Technology*, 7(2.8), 684-687.
144. Harrington, P. (2012). *Machine learning in action*. New York: Manning Publications, 83-100.
145. Basheer, I. A., and Hajmeer, M. (2000). Artificial neural networks: Fundamentals, computing, design, and application. *Journal of Microbiological Methods*, 43(1), 3-31.
146. Subasi, A., and Ercelebi, E. (2005). Classification of EEG signals using neural network and logistic regression. *Computer Methods and Programs in Biomedicine*, 78(2), 87-99.
147. Durgesh, K. S., and Lekha, B. (2010). Data classification using support vector machine. *Journal of Theoretical and Applied Information Technology*, 12(1), 1-7.
148. Kataria, A., and Singh, M. D. (2013). A review of data classification using k-nearest neighbour algorithm. *International Journal of Emerging Technology and Advanced Engineering*, 3(6), 354-360.
149. Singh, A., Thakur, N., and Sharma, A. (2016, March). A review of supervised machine learning algorithms. In *2016 3rd International Conference on Computing for Sustainable Global Development (INDIACom)* (pp. 1310-1315). IEEE.
150. İnternet: ThingSpeak. Web: https://thingspeak.com/pages/how_to, Son Erişim Tarihi: 04.12.2020.
151. İnternet: IFTTT. Web: <https://ifttt.com/about>, Son Erişim Tarihi: 04.12.2020.
152. İnternet: Pushover. Web: <https://pushover.net/>, Son Erişim Tarihi: 04.12.2020




EKLER

EK-1. Katılımcılardan alınan EDA sinyallerine ait grafikler




Şekil 1.1. Katılımcı 1’den 1. oturumda alınan EDA sinyal değerlerinin zamana göre değişimi




Şekil 1.2. Katılımcı 1’den 2. oturumda alınan EDA sinyal değerlerinin zamana göre değişimi

EK-1. (devam) Katılımcılardan alınan EDA sinyallerine ait grafikler




Şekil 1.3. Katılımcı 1’den 3. oturumda alınan EDA sinyal değerlerinin zamana göre değişimi




Şekil 1.4. Katılımcı 1’den 4. oturumda alınan EDA sinyal değerlerinin zamana göre değişimi

EK-1. (devam) Katılımcılardan alınan EDA sinyallerine ait grafikler




Şekil 1.5. Katılımcı 1’den 5. oturumda alınan EDA sinyal değerlerinin zamana göre değişimi




Şekil 1.6. Katılımcı 2’den 1. oturumda alınan EDA sinyal değerlerinin zamana göre değişimi

EK-1. (devam) Katılımcılardan alınan EDA sinyallerine ait grafikler




Şekil 1.7. Katılımcı 3'ten 1. oturumda alınan EDA sinyal değerlerinin zamana göre değişimi




Şekil 1.8. Katılımcı 4'ten 1. oturumda alınan EDA sinyal değerlerinin zamana göre değişimi

EK-1. (devam) Katılımcılardan alınan EDA sinyallerine ait grafikler




Şekil 1.9. Katılımcı 4'ten 2. oturumda alınan EDA sinyal değerlerinin zamana göre değişimi




Şekil 1.10. Katılımcı 4'ten 3. oturumda alınan EDA sinyal değerlerinin zamana göre değişimi

EK-1. (devam) Katılımcılardan alınan EDA sinyallerine ait grafikler




Şekil 1.11. Katılımcı 5'ten 1. oturumda alınan EDA sinyal değerlerinin zamana göre değişimi




Şekil 1.12. Katılımcı 6'dan 1. oturumda alınan EDA sinyal değerlerinin zamana göre değişimi

EK-1. (devam) Katılımcılardan alınan EDA sinyallerine ait grafikler




Şekil 1.13. Katılımcı 7’den 1. oturumda alınan EDA sinyal değerlerinin zamana göre değişimi




Şekil 1.14. Katılımcı 8’den 1. oturumda alınan EDA sinyal değerlerinin zamana göre değişimi

EK-1. (devam) Katılımcılardan alınan EDA sinyallerine ait grafikler




Şekil 1.15. Katılımcı 9'dan 1. oturumda alınan EDA sinyal değerlerinin zamana göre değişimi




Şekil 1.16. Katılımcı 10'dan 1. oturumda alınan EDA sinyal değerlerinin zamana göre değişimi

EK-1. (devam) Katılımcılardan alınan EDA sinyallerine ait grafikler




Şekil 1.17. Katılımcı 11'den 1. oturumda alınan EDA sinyal değerlerinin zamana göre değişimi




Şekil 1.18. Katılımcı 11'den 2. oturumda alınan EDA sinyal değerlerinin zamana göre değişimi

EK-1. (devam) Katılımcılardan alınan EDA sinyallerine ait grafikler




Şekil 1.19. Katılımcı 11'den 3. oturumda alınan EDA sinyal değerlerinin zamana göre değişimi




Şekil 1.20. Katılımcı 12'den 1. oturumda alınan EDA sinyal değerlerinin zamana göre değişimi

EK-2. Katılımcılardan alınan kalp hızı sinyallerine ait grafikler




Şekil 2.1. Katılımcı 1'den 1. oturumda alınan kalp hızı sinyal değerlerinin zamana göre değişimi




Şekil 2.2. Katılımcı 1'den 2. oturumda alınan kalp hızı sinyal değerlerinin zamana göre değişimi

EK-2. (devam) Katılımcılardan alınan kalp hızı sinyallerine ait grafikler




Şekil 2.3. Katılımcı 1'den 3. oturumda alınan kalp hızı sinyal değerlerinin zamana göre değişimi




Şekil 2.4. Katılımcı 1'den 4. oturumda alınan kalp hızı sinyal değerlerinin zamana göre değişimi

EK-2. (devam) Katılımcılardan alınan kalp hızı sinyallerine ait grafikler




Şekil 2.5. Katılımcı 1'den 5. oturumda alınan kalp hızı sinyal değerlerinin zamana göre değişimi




Şekil 2.6. Katılımcı 2'den 1. oturumda alınan kalp hızı sinyal değerlerinin zamana göre değişimi

EK-2. (devam) Katılımcılardan alınan kalp hızı sinyallerine ait grafikler




Şekil 2.7. Katılımcı 3'ten 1. oturumda alınan kalp hızı sinyal değerlerinin zamana göre değişimi




Şekil 2.8. Katılımcı 4'ten 1. oturumda alınan kalp hızı sinyal değerlerinin zamana göre değişimi

EK-2. (devam) Katılımcılardan alınan kalp hızı sinyallerine ait grafikler




Şekil 2.9. Katılımcı 4'ten 2. oturumda alınan kalp hızı sinyal değerlerinin zamana göre değişimi




Şekil 2.10. Katılımcı 4'ten 3. oturumda alınan kalp hızı sinyal değerlerinin zamana göre değişimi

EK-2. (devam) Katılımcılardan alınan kalp hızı sinyallerine ait grafikler




Şekil 2.11. Katılımcı 5'ten 1. oturumda alınan kalp hızı sinyal değerlerinin zamana göre değişimi




Şekil 2.12. Katılımcı 6'dan 1. oturumda alınan kalp hızı sinyal değerlerinin zamana göre değişimi

EK-2. (devam) Katılımcılardan alınan kalp hızı sinyallerine ait grafikler




Şekil 2.13. Katılımcı 7’den 1. oturumda alınan kalp hızı sinyal değerlerinin zamana göre değişimi




Şekil 2.14. Katılımcı 8’den 1. oturumda alınan kalp hızı sinyal değerlerinin zamana göre değişimi

EK-2. (devam) Katılımcılardan alınan kalp hızı sinyallerine ait grafikler




Şekil 2.15. Katılımcı 9'dan 1. oturumda alınan kalp hızı sinyal değerlerinin zamana göre değişimi




Şekil 2.16. Katılımcı 10'dan 1. oturumda alınan kalp hızı sinyal değerlerinin zamana göre değişimi

EK-2. (devam) Katılımcılardan alınan kalp hızı sinyallerine ait grafikler




Şekil 2.17. Katılımcı 11'den 1. oturumda alınan kalp hızı sinyal değerlerinin zamana göre değişimi




Şekil 2.18. Katılımcı 11'den 2. oturumda alınan kalp hızı sinyal değerlerinin zamana göre değişimi

EK-2. (devam) Katılımcılardan alınan kalp hızı sinyallerine ait grafikler



Şekil 2.19. Katılımcı 11’den 3. oturumda alınan kalp hızı sinyal değerlerinin zamana göre değişimi



Şekil 2.20. Katılımcı 12’den 1. oturumda alınan kalp hızı sinyal değerlerinin zamana göre değişimi

ÖZGEÇMİŞ**Kişisel Bilgiler**

Soyadı, adı : SUSAR, Ahmet
Uyruğu : T.C.
Doğum tarihi ve yeri :
Medeni hali :
Telefon :
e-mail :

Eğitim

Derece	Eğitim Birimi	Mezuniyet Tarihi
Yüksek lisans	Gazi Üniversitesi / Bilişim Sistemleri Ana Bilim Dalı	Devam ediyor
Lisans	Kırıkkale Üniversitesi / Elektrik-Elektronik Mühendisliği	2015
Lise	Kırıkkale Fen Lisesi	2008



GAZİLİ OLMAK AYRICALIKTIR.