



SÜRÜŞ KARAKTERİSTİĞİ ÇIKARMA

Furkan ÇAKMAK

**2021
YÜKSEK LİSANS TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ**

**Tez Danışmanı
Dr. Öğr. Üyesi Nesrin AYDIN ATASOY**

SÜRÜŞ KARAKTERİSTİĞİ ÇIKARMA

Furkan ÇAKMAK

T.C.

Karabük Üniversitesi

Lisansüstü Eğitim Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalında

Yüksek Lisans Tezi

Olarak Hazırlanmıştır

Tez Danışmanı

Dr. Öğr. Üyesi Nesrin AYDIN ATASOY

KARABÜK

Eylül 2021

Furkan ÇAKMAK tarafından hazırlanan “SÜRÜŞ KARAKTERİSTİĞİ ÇIKARMA” başlıklı bu tezin Yüksek Lisans Tezi olarak uygun olduğunu onaylarım.

Dr. Öğr. Üyesi Nesrin AYDIN ATASOY
Tez Danışmanı, Bilgisayar Mühendisliği Anabilim Dalı

Bu çalışma, jürimiz tarafından oy birliği ile Bilgisayar Mühendisliği Anabilim Dalında Yüksek Lisans tezi olarak kabul edilmiştir. 28/09/2021

<u>Ünvanı, Adı SOYADI (Kurumu)</u>	<u>İmzası</u>
Başkan : Dr. Öğr. Üyesi Emel SOYLU (SAMÜ)
Üye : Dr. Öğr. Üyesi Ferhat ATASOY (KBÜ)
Üye : Dr. Öğr. Üyesi Nesrin AYDIN ATASOY (KBÜ)

KBÜ Lisansüstü Eğitim Enstitüsü Yönetim Kurulu, bu tez ile, Yüksek Lisans derecesini onamıştır.

Prof. Dr. Hasan SOLMAZ
Lisansüstü Eğitim Enstitüsü Müdürü

“Bu tezdeki tüm bilgilerin akademik kurallara ve etik ilkelere uygun olarak elde edildiğini ve sunulduğunu; ayrıca bu kuralların ve ilkelerin gerektirdiği şekilde, bu çalışmadan kaynaklanmayan bütün atıfları yaptığımı beyan ederim.”

Furkan ÇAKMAK

ÖZET

Yüksek Lisans Tezi

SÜRÜŞ KARAKTERİSTİĞİ ÇIKARMA

Furkan ÇAKMAK

Karabük Üniversitesi

Lisansüstü Eğitim Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

Tez Danışmanı:

Dr. Öğr. Üyesi Nesrin AYDIN ATASOY

Eylül 2021, 58 sayfa

Trafik kazaları toplumların en temel sorunlarından biridir. Dünya Sağlık Örgütü verilerine göre dünyada her yıl yaklaşık 1,35 milyon kişi trafik kazaları nedeniyle hayatını kaybetmektedir. Yılda yaklaşık 20 ila 50 milyon kişi ise trafik kazaları nedeniyle sakat kalmaktadır. Ölümle ya da yaralanmayla sonuçlanan trafik kazaları toplumlara hem psikolojik hem de ekonomik yük oluşturmaktadır. Trafik kazalarına neden olan unsurlar incelendiğinde ise ilk sırada insan faktörü yer almaktadır. Nüfusu çok olan büyük şehirler düşünüldüğünde sürücü ve taşıt sayılarının fazla olması trafikte kaza riskini arttırmaktadır. Sürücülerin denetlenmesi kazaların azaltılmasında önemli bir faktördür. Günümüzde sürücü belgesi alımı sırasında denetlenen sürücüler dışında sürücü davranışları bir uzman tarafından denetlenmemektedir. Bu nedenle trafik kazalarının önlenmesinde sürücülerin sürüş esnasındaki davranışlarını tespit etmek önemli bir konu haline gelmiştir. Literatürde bu alanda ilk çalışma bir anket çalışmasıdır ancak anket yardımıyla sürüş karakteristiğinin çıkarılması sürücülerin kendilerini olumsuz değerlendirmemek amacı taşıyabilir bu yüzden tutarlı değildir.

Günümüzde gelişen teknolojiyle sürüş karakteristiklerini çıkarmak amacıyla akıllı telefon, ivme ölçer, jiroskop, kontrol alan ağı, ışın algılama mesafe ölçümü, inersiyal ölçme ünitesi ve kamera gibi cihaz veya sensör yardımıyla sürüş verileri toplanabilir. Bu tez çalışmasında gerçek trafik ortamlarında kaydedilmiş sürüş verilerinin bulunduğu Honda Sürüş Verisi (HDD) ve mobil sürüş veri setleri kullanılmıştır. Veri setlerinde yer alan değişkenler özellik çıkarma yöntemiyle zenginleştirilmiştir. Her iki veri seti üzerinde Ulusal Karayolu Trafik Güvenliği İdaresi (NHTSA) yönergelerine göre sert hızlanma, yavaşlama, ani manevra ve dönüş olayları tespit edilmiştir. Geliştirilen web tabanlı yazılımda sürüş özellikleri grafiksel ve istatistiksel olarak sunulmuştur. Ayrıca, yolculukla ilgili hız, rota, durma ve duraklama gibi olaylar harita üzerinde kullanıcı dostu ara yüz ile sürüş karakteristiğinin çıkarılması için görselleştirilmiştir. Gerçekleşen her sürüş sonunda sürücünün puan grafiği ve sürüş raporu sonuçları oluşturulmuştur. Böylece sürüş kolayca değerlendirilebilmektedir.

Anahtar Sözcükler : Sürüş karakteristikleri tespiti, sürüş olayları görselleştirme, web tabanlı sürüş analizi

Bilim Kodu : 92408

ABSTRACT

M. Sc. Thesis

EXTRACTING DRIVING CHARACTERISTIC

Furkan ÇAKMAK

Karabuk University

Institute of Graduate Programs

Department of Computer Engineering

Thesis Advisor:

Assist. Prof. Dr. Nesrin AYDIN ATASOY

September 2021, 58 pages

Traffic accidents are one of the most basic problems of societies. According to the data of the World Health Organization, approximately 1,35 million people die every year in the world due to traffic accidents. Approximate 20 to 50 million people a year become disabled due to traffic accidents. Traffic accidents resulting in death or injury create both a psychological and economic burden on societies. When the factors that cause traffic accidents are examined, the human factor takes the first place. Considering the large cities with a large population, the high number of drivers and vehicles increases the risk of accidents in traffic. Nowadays, driver behaviour isn't supervised by an expert, except for the drivers who are supervised during the acquisition of the driver's license, but the supervision of the driving is an important factor in reducing the accidents. Therefore, it has become an important issue to determine the behaviour of drivers in the prevention of traffic accidents. The first study in the literature is a survey study. Determining the driving characteristics with the help of a survey may target not to negatively evaluate the drivers themselves.

Therefore it is not consistent. Nowadays, driving data can be collected with the help of devices or sensors such as smart phone, accelerometer, gyroscope, control area network, beam detection distance measurement, inertial measuring unit and camera in order to extract the driving characteristics with the developing technology. In this thesis, Honda Driving Dataset (HDD) and mobile driving data sets with recorded driving data in real traffic environments were used. The variables in the data sets were enriched by the feature extraction method. Hard acceleration, deceleration, sudden maneuvering and turning events were detected on both data sets according to National Highway Traffic Safety Administration (NHTSA) guidelines. Driving characteristics are presented graphically and statistically in the developed web-based software. In addition, events such as speed, route, pause and stop related to the journey are visualized on the map with a user-friendly interface to extract the driving characteristics. At the end of each ride, the driver's score graph and driving report results were created. Thus, driving can be evaluated easily.

Key Words : Driving characteristics detection, driving events visualization, web based driving analysis

Science Code : 92408

TEŐEKKÜR

Bu tez alıŐmasının oluŐumunda, planlanmasında, araŐtırılmasında, yürütölmesinde desteęini ve ilgisini esirgemeyen, bilgi ve tecrübeleriyle yönlendirerek alıŐmamı bilimsel temeller ışığında Őekillendiren sayın hocam Dr. Öğr. Üyesi Nesrin AYDIN ATASOY'a, fikirleri ve tecrübeleriyle desteęini hiç esirgemeyen deęerli hocam Dr. Öğr. Üyesi Ferhat ATASOY'a sonsuz teşekkürlerimi sunarım.

Öęrenim hayatım boyunca maddi, manevi desteklerini hiç eksik etmeyen aileme ve tez alıŐmamda manevi desteęiyle hep yanımda olan deęerli arkadaşım İsa YURDAGÜL'e tüm kalbimle teşekkür ederim.

İÇİNDEKİLER

	<u>Sayfa</u>
KABUL.....	ii
ÖZET.....	iv
ABSTRACT.....	vi
TEŞEKKÜR.....	viii
İÇİNDEKİLER	ix
ŞEKİLLER DİZİNİ.....	xii
ÇİZELGELER DİZİNİ	xiii
SİMGELER VE KISALTMALAR DİZİNİ	xiv
BÖLÜM 1	1
GİRİŞ	1
1.1. TEZİN AMACI VE KAPSAMI.....	2
1.2. HİPOTEZ	2
1.3. TEZİN BÖLÜMLERİ	4
BÖLÜM 2	5
ÖNCEKİ ÇALIŞMALAR.....	5
BÖLÜM 3	13
SÜRÜŞ KARAKTERİZASYONU.....	13
3.1. SÜRÜŞ KARAKTERİZASYONU TANIMLAMASI	13
3.2. SÜRÜŞ KARAKTERİZASYONUNDA KULLANILAN ALGILAYICI SENSÖRLER VE TEKNOLOJİLER	15
3.3. SÜRÜŞ KARAKTERİZASYONUNDA KULLANILAN GİRİŞ PARAMETRELERİ.....	18
3.4. SÜRÜŞ KARAKTERİZASYONU SINIFLANDIRMA KATEGORİLERİ .	20
3.5. SÜRÜŞ KARAKTERİZASYONUNDA KULLANILAN VERİ SETLERİ. 22	
3.5.1. Honda Sürüş Veri Seti	23

	<u>Sayfa</u>
3.5.2. OBD-Veri Seti	23
3.5.3. DBNET Veri Seti	24
3.5.4. Taşıt Veri Seti.....	24
3.5.6. UDrive Veri Seti.....	24
3.5.7. AEGIS Sürücü Veri Seti.....	25
3.5.8. Brain4Cars Veri Seti.....	25
3.5.9. Comma.ai Veri Seti	25
3.5.10 UAH-Veri Seti.....	26
3.5.11. Sürücü Güvenliği Veri Seti	26
3.5.12. HciLab Veri Seti.....	26
3.5.13. UTDrive Veri Seti	27
BÖLÜM 4	28
MATERYAL VE YÖNTEM	28
4.1. VERİ TOPLAMA	28
4.1.1. Veri Setleri.....	28
4.1.1.1. Honda Sürüş Veri Seti	29
4.1.1.2. Akıllı Telefonla Kaydedilen Veri Seti	30
4.2. VERİ ÖNİŞLEME	31
4.2.1. Veri Temizleme	31
4.2.2. Veri Birleştirme	32
4.2.3 Veri Dönüştürme	32
4.3. ÖZELLİK ÇIKARMA	32
4.4. VERİ GÖRSELLEŞTİRME.....	33
4.5. KURAL TABANLI ALGORİTMA.....	33
BÖLÜM 5	34
UYGULAMA VE DENEYSEL SONUÇLAR.....	34
5.1. UYGULAMA.....	35
5.2. DENEYSEL SONUÇLAR.....	40

	<u>Sayfa</u>
BÖLÜM 6	46
TARTIŞMA VE SONUÇ	46
BÖLÜM 7	47
SINIRLILIKLAR VE GELECEK ÇALIŞMALARA KATKI	47
KAYNAKLAR	48
ÖZGEÇMİŞ	58

ŞEKİLLER DİZİNİ

Sayfa

Şekil 3.1. Sürüş karakterizasyonunu etkileyen insani ve çevresel faktörler.....	14
Şekil 4.1. Veri önışleme adımları	31
Şekil 5.1. Uygulama yapısı.....	36
Şekil 5.2. Mobil uygulama veri kayıt başlatma ekranı	37
Şekil 5.3. Mobil uygulama veri kayıt gösterme ekranı	38
Şekil 5.4. Web uygulama sürüş yükleme seçenekleri ekran görüntüleri.....	40
Şekil 5.5. İvme ölçer grafiđi	40
Şekil 5.6. Hız, hızlanma ve yavaşlama grafiđi	41
Şekil 5.7. X, Y, Z eksenli jiroskop grafiđi	41
Şekil 5.8. Aracın enlem, boylam, rakım grafiđi	42
Şekil 5.9. Alınan mesafe ve yolun eğim grafiđi	42
Şekil 5.10. Kümülatif sürücü puanları grafiđi	43
Şekil 5.11. Harita açılır bilgi pencereleri ve konum işaretçileri.....	43
Şekil 5.12 Sürücülerin sürüş raporu sonuçları.....	45

ÇİZELGELER DİZİNİ

Sayfa

Çizelge 3.1. Sürüş karakterizasyonunda yaygın kullanılan algılayıcı sensörler, teknolojiler, avantajları ve dezavantajları.....	15
Çizelge 3.2. Sürüş karakterizasyonu sınıflandırmasında yaygın kullanılan giriş parametreleri.....	19
Çizelge 3.3. Sürüş karakterizasyonu sınıflandırmada yaygın kullanılan sınıf sayısı ve etiketler.....	21
Çizelge 3.4. Kamuya açık ücretsiz yayınlanan veri setleri ve özellikleri.....	22
Çizelge 4.1. HDD’de kullanılan sensörler ve veri seti özellikleri.....	29
Çizelge 4.2. Akıllı telefonla toplanan veri seti ve özellikleri.....	30
Çizelge 5.1. Uygulamada kullanılan yazılım dilleri ve kütüphaneler.....	34
Çizelge 5.2. NHTSA sürüş karakterizasyonu kuralları.....	44

SİMGELER VE KISALTMALAR DİZİNİ

SİMGELER

x_i : örnek

n : örnek sayısı

μ : ortalama

X_{var} : varyans

σ : standart sapma

X_{std} : standardize edilmiş örnek

KISALTMALAR

ABD	: Amerika Birleşik Devletleri
ADAS	: Advanced Driving Analysis System (Gelişmiş Sürücü Destek Sistemi)
AEGIS	: Advanced Big Data Value Chain for Public Safety and Personal Security (Kamu Güvenliği ve Kişisel Güvenlik için Gelişmiş Büyük Veri Değer Zinciri)
AESOM	: Autoencoder and Self-Organized Maps (Kendi Kendini Düzenleyen Özellik Haritaları)
CAN	: Controller Area Network (Kontrol Alan Ağı)
CSS	: Cascading Style Sheets (Basamaklı Stil Şablonları)
CSV	: Comma Separated Values (Virgülle Ayrılmış Değerler)
DRIMS	: Dynamic Response Intelligent Monitoring System (Dinamik Tepki Akıllı İzleme Sistemi)
DSÖ	: Dünya Sağlık Örgütü
DTW	: Dynamic Time Warping (Dinamik Zaman Bükme)
EGM	: Emniyet Genel Müdürlüğü
EKG	: Electrocardiography (Elektrokardiyografi)
GIS	: Geographical Information Systems (Coğrafi Bilgi Sistemi)
GPS	: Global Positioning System (Küresel Konumlama Sistemi)
HDD	: Honda Driving Dataset (Honda Sürüş Veri Seti)
HTML	: Hypertext Markup Language (Hipermetin İşaratleme Dili)
IMU	: Inertial Measurement Unit (İnersiyal Ölçme Ünitesi)
KNN	: K Nearest Neighbors (K En Yakın Komşu)
LIDAR	: Light Detection and Ranging (Işın Algılama ve Mesafe Ölçümü)
MDSI	: Multidimensional Driving Style Inventory (Çok Boyutlu Sürüş Stili Envanteri)
MIROAD	: A Mobile- Sensor-Platform for Intelligent Recognition Of Aggressive Driving (Agresif Sürüşün Akıllıca Tanımlanması için Mobil Sensör Platformu)
MLP	: Multilayer Perceptron (Çok Katmanlı Algılayıcı)
MLR	: Multilayer Logistic Regression (Çok Terimli Lojistik Regresyon)

NHTSA	: National Highway Traffic Safety Administration (Ulusal Karayolu Trafik Güvenliđi İdaresi)
OBD	: On Board Diagnostics (Bütünleşik Tanı Sistemi)
PCA	: Principal Component Analysis (Temel Bileşenler Analizi)
PHP	: Hypertext Preprocessor (Hiper metin Ön İşlemcisi)
RF	: Random Forest (Rastgele Orman)
SDA	: Sürücü Davranışları Anketi
SOM	: Self Organizing Maps (Öz Düzenleyici Haritalar)
SVM	: Support Vector Machine (Destekleyici Vektör Makinesi)
TÜİK	: Türkiye İstatistik Kurumu

BÖLÜM 1

GİRİŞ

Trafik kazaları, ülkelerin ve toplumların başlıca sorunlarından biridir. Dünya Sağlık Örgütü'ne (DSÖ) göre dünya çapında her yıl yaklaşık 1,35 milyon kişinin ölüm nedeni trafik kazalarıdır. Yılda yaklaşık 20 ila 50 milyon arasında birey trafik kazası sonucu sakat kalmaktadır. Trafik kazaları manevi acının yanı sıra, yaralıların tedavi masrafları aynı zamanda ölen veya yaralananların üretkenliklerini kaybetmeleri nedeniyle toplumlar üzerinde hem psikolojik hem de ekonomik yük oluşturmaktadır. Kazaların ülke ekonomisine de ciddi etkileri vardır. Her yıl ülkelerin gayri safi yurtiçi hasılanın yaklaşık %3'lük kaybına trafik kazaları sebep olmaktadır [1]. Trafik kazalarının meydana gelmesinde yol yapısı, hava koşulları, araç ve insan faktörü gibi birçok etken vardır. Trafik kazalarının başlıca nedenlerine bakıldığında ise ilk sırada sürücü hataları gelmektedir. Türkiye Emniyet Genel Müdürlüğü (EGM) verilerine göre 2020 yılında meydana gelen ölümlü ve yaralanmalı trafik kazalarına %88,3 ile en çok sürücü hataları neden olmuştur [2].

Türkiye İstatistik Kurumu (TÜİK) Aralık 2020 verilerine göre ülkemizde trafiğe kayıtlı 24 milyon 64 bin 532 taşıt bulunmaktadır [3]. EGM verilerine göre ülkemizde 30 milyon 541 bin 611 kişi sürücü belgesine sahiptir [4]. Özellikle kalabalık nüfusa sahip şehirlerde sürücü ve taşıtların sayılarına bakıldığında trafikte kaza riski oranı hayli yüksektir. Sürücülerin bireysel araç kullanım davranışları takip edilerek güvenlik, verimlilik, risk oranları belirlenebilir. Gelecekte araç kullanımı sırasında maddi ve manevi hasarlar azaltılabilir ya da sürücü davranışları kontrol edilebilir. Ayrıca kamusal veya kurumsal filo yönetiminde, sürücülerin, araçların verimlilik, güvenlik vb. süreçlerin planlanması, maliyetlerin azaltılması önemli bir gerekliliktir. Bu sebeplerle dünyada araç üreticileri, sigorta şirketleri, araştırma konuları trafik kazalarını azaltarak araç ve trafik güvenliğini artırmayı amaç edinmişlerdir.

1.1. TEZİN AMACI VE KAPSAMI

Akıllı sistemlerin hayatın her alanına girdiği günümüzde, motorlu kara taşıtlarının bakım ve işletme maliyetlerinin en aza indirilmesi ve trafik güvenliğinin artırılması için sürücülerin araç kullanım davranışlarının karakterize edilmesini sağlamak çalışmanın konusu oluşturmaktadır.

Tezin amacı, bireysel sürücülerin veya kurumlara ait araçlarla, sigorta şirketlerinin müşterilerine ait araçların kimler tarafından nasıl bir sürüş karakteristiği ile kullanıldığının tespit edilmesini sağlamaktır. Böylece sigortalama işlemlerinde risk değerlendirmesi için yaş, şehir vb. yerine daha ölçülebilir bir model geliştirilmiş olacaktır. Ayrıca kurum ve işletmelere ait araçları kullanan sürücülerin sürüş karakteristiklerinin ortaya çıkarılması ile sürücü denetiminin yapılması sağlanarak, araçların bakım ve işletme maliyetlerinin en aza indirilmesi trafikte kaza risklerinin azaltılarak daha güvenli hale getirilmesi hedeflenmektedir.

1.2. HİPOTEZ

Sürücülerin davranışları daha önceki çalışmalarda farklı modeller ve yöntemler kullanılarak sınıflandırılmaktadır. Sürüş karakteristikleri genellikle bağımsız bir kaynaktan alınan veriler veya hali hazırda farklı algılayıcı cihazlarla toplanan veriler hızlanma, frenleme, manevra, anlık hız, yakıt tüketimi gibi parametrelerle analiz edilmektedir. Daha önceki çalışmalarda önerildiği üzere veri setinin çok parametreliliğinin sürüş karakterizasyonunun analiz edilmesinde daha başarılı sonuçlar ortaya koyacağı düşünülmektedir. Çalışmanın özgün tarafı hem araçtan hem de haricen toplanan sensör bilgilerinin birlikte kullanılmasıyla çok parametreliliğinin, daha doğru sürüş karakterizasyonunun yapılmasının sağlanmasıdır.

Literatürde sürücü davranışlarının analiz edilmesinde kullanılan modeller ve sınıflandırmalar, sürüş detaylarını içeren görsel bir ara yüz sunmamaktadır. Bu çalışmada gerçek sürüş sırasında kaydedilen konum, gaz ve fren pedalı konumları, direksiyon açısı ve hızı, jiroskop ve ivme ölçer verileri kullanılarak tespit edilen

hızlanma, yavaşlama, dönme vb. olayların istatistik, grafik ve harita üzerinde gösteriminin sağlanmasıdır.

Çalışmanın temel yapısı, gerçek trafik koşullarında küresel konumlama sistemi (GPS), inersiyal ölçme ünitesi (IMU), kontrol alan ağı (CAN) sensörleriyle kaydedilmiş verilerden oluşan kamuya açık veri seti ve mobil uygulama geliştirilerek oluşturulan veri setine, veri madenciliği yapılarak sürücünün sürüş karakteristiğini temsil eden hızlanma, yavaşlama, sağa ve sola dönüş, rampa iniş ve çıkış, durma ve duraklama gibi ortak özellikler keşfedilmesidir. Uygulama sayesinde sürücünün aşağıda belirtilen sürüş karakterizasyonu için zenginleştirilmiş bilgilerin elde edilmesini sağlamaktır.

- Anlık hızı
- Ortalama ve en yüksek hızı
- Anlık hızlanması ve yavaşlaması
- Sert hızlanma ve yavaşlama sıklığı
- Birim zamanda aldığı yol uzunluğu
- Toplamda aldığı yol uzunluğu
- Yolun anlık eğimi
- Aracının yalpalanma ve sarsılma şiddeti
- Hareket başlangıç ve bitiş konumları
- Duraklama konumu ve süresi
- Ortalama sürücü puanı

Ayrıca geliştirilen yazılım sayesinde Amerika Birleşik Devletleri (ABD) Ulusal Karayolu Trafik Güvenliği İdaresi (NHTSA) tarafından tanımlanmış kurallara göre sürüş hakkında istatistiksel bilgiler vermesi ve bu istatistiklere göre sınıflandırma yapmasıdır. Tüm bunlarla birlikte sürüş karakteristiğinin yol ve zamana bağlı analizini kolaylaştıracak, kullanıcı dostu web tabanlı bir ara yüz geliştirilmesidir.

1.3. TEZİN BÖLÜMLERİ

Bölüm 1’de tez konusu, amaç, kapsam ve hipotez hakkında bilgilerin içerdiği bölümlerin ardından Bölüm 2’de sürüş karakterizasyonu için kullanılan anket, ölçek, vb. tekniklerin ve yapay zekâ modeli önerilerinin bulunduğu kapsamlı bir literatür taraması bulunmaktadır. Bölüm 3’te, sürüş karakterizasyonu tanımı, kullanılan algılayıcı sensörler, giriş parametreleri, sınıflandırma kategorileri ve veri setleri yer almaktadır. Bölüm 4’te tez çalışmasında kullanılan veri setleri detaylı olarak tanıtılmış, kullanılan veri madenciliği ve yapay zekâ modelleri kavramları hakkında bilgilere yer verilmiştir. Bölüm 5’te, çalışmada geliştirilen uygulama süreci ve uygulama deneysel sonuçları aktarılmıştır. Bölüm 6’da tez çalışmasında çıkarılan sonuçlar tartışılmaktadır. Son bölüm olan Bölüm 7’de, tez araştırmasındaki sınırlılıklar ve gelecekte yapılacak çalışmalara öneriler sunulmaktadır.

BÖLÜM 2

ÖNCEKİ ÇALIŞMALAR

Literatürde sürüş karakterizasyonunu farklı yaklaşımlarla değerlendiren çeşitli çalışmalar bulunmaktadır. Bilinen ilk sürüş karakterizasyonu tanımlama çalışması Reason vd. tarafından 520 sürücünün katılımıyla yapılan sürücü davranışları anketi (SDA) adlı çalışmadır. Çalışmada sürücü davranışları dikkatsizlik sonucu yapılan hatalar, kasıtlı hatalar ve tehlikeli hatalar olarak üç farklı kategoride sınıflandırılmaktadır [5].

Lawton vd. Reason ve arkadaşlarının geliştirdikleri SDA'ya yeni maddeler ekleyerek, 830 sürücünün katılımıyla yeni bir anket çalışması yapılmıştır. Çalışmanın sonucunda ihlallerin iki boyutta değerlendirilmesi gerektiği öne sürülerek ihlaller, saldırgan ihlal ve sıradan ihlal olarak iki boyutta sınıflandırılmıştır [6].

Taubman vd. tarafından günümüzde halen kullanılan Çok Boyutlu Sürüş Stili değerlendirme anketi geliştirilmiştir. Çalışmada, daha önce geliştirilen anket sorularına yazarların yaklaşımları eklenerek 44 anket sorusu hazırlanmıştır. Yazarlar anket yanıtlarıyla sürücünün endişeli, kızgın, sabırlı ve dikkatsiz sürüş karakterinden birine sınıflandırılabileceğini iddia etmişler ve günümüzde halen kullanılmakta olan dört sürüş karakterinin temelini oluşturmuşlardır. Yazarlar aynı zamanda demografik altyapı, eğitim, bilinçli veya bilinçsiz karar verme, sürüş deneyimi, çevre ve araca aşinalık gibi parametrelerin sürüş karakterlerinin çıkarılmasındaki etkisine dikkat çekmiştir [7].

Daha sonraki yıllarda Newnam vd. tarafından oluşturulan Kurumsal Sürücü Davranışları Ölçeği [8], Harris vd. tarafından oluşturulan Pro-sosyal ve Agresif Sürüş

Envanteri [9] literatürdeki diğer popüler anket çalışmalarıdır. Yapılan tüm anket çalışmaları sürüş karakterizasyonu kriterlerine ve bu kriter seçimlerinin neden yapıldığına genel bir bakış sağlamaktadır. Tüm anket çalışmalarının ortak özelliği sürüş karakteri tanımlanması için çeşitli agresiflik, dikkatsizlik, yorgunluk vb. kriterlerin değerlendirilmesidir. SDA'dan ilham alınarak geliştirilen diğer anket çalışmaları sürücülerin farklı koşullar altında farklı sürüş karakteri örnekleri sergilediklerine işaret etmektedir. SDA ile benzer kriterlere sahip olan anketlerde dahi sürüş karakterinin, trafikte güvenlikle ilgili konuların daha derinlemesine değerlendirilmesi gerektiği ve sürüş karakteri tanımlamasının birçok etkene dayandığı vurgulanmaktadır [7–9].

Sürücülerin sadece bir anket ile değerlendirilmesi, sürücünün kendini olumsuz değerlendirmemek amacıyla anket cevaplarını bilinçli olarak değiştirmek isteyebilir. Bu sebeple sürüş verileriyle desteklenmeyen anket veya ölçek gibi yaklaşımlar tek başına sürüş karakterizasyonu tanımlamasında tutarlı olmamaktadır.

Sürüş karakterizasyonu tanımlamasında literatürdeki diğer yaklaşımlar genellikle hız, şerit değiştirme, manevra, ivmesel hareket, takip mesafesi ve yakıt tüketimi gibi rakamlarla ifade edilen parametrelerle tespit etmeye odaklanır. Günümüzde teknolojinin de gelişmesiyle birlikte sürüş karakterizasyonu analizinde çeşitli ticari ve araştırma amaçlı sistemler önerilmiştir. Geliştirilen sistemlerde ivme ölçer, jiroskop, IMU, CAN, GPS, kamera, ses, video, akıllı telefon ve araç simülatörü gibi çeşitli sensör ve veri kaydedici teknolojiler kullanılmaktadır.

Qingwen vd. yaptıkları çalışmada arkadan çarpma kaza risklerine dikkat çekmişlerdir. Köprülere yerleştirilmiş kameralardan alınan görüntülere, görüntü işleme ve makine öğrenmesi sınıflandırma yöntemleri uygulayarak sürücü davranışlarını tanımlamanın ve sürücü destek sistemlerini tasarlamının mümkün olabileceğini önermişlerdir. Önerilen çalışmaya göre video kayıtlarındaki araçların ilk önce güzergahları tespit edilir. Daha sonra aracın önünde veya arkasında bulunan araç ile mesafesine bağlı olarak çarpışma riski seviyesi, destekleyici vektör makinesi (SVM), rastgele orman (RF), k-en yakın komşu (KNN), çok katmanlı algılayıcı (MLP) yöntemleriyle ayrı ayrı hesaplanır ve karşılaştırılır. Ancak yapılan çalışmanın sonucunda sürüş karakterinin

yol koşulları ve trafik akışından da etkilenebileceği dolayısıyla daha doğru tespit edilebilmesi için daha fazla özellik eklenmesi gerektiği bildirilmiştir [10].

Quek ve Eldwin, MetroMile sigorta şirketinden sağlanan veri seti kullanılarak 6 farklı sürücü ve 18 farklı araca ait hız, rota ve gaz pedalı konumu girişleriyle hızlanma, yavaşlama, dönüş hızı ve dönüş yarı çapı özellikleri çıkarılmıştır. Çıkarılan özelliklerle SVM ve çok terimli lojistik regresyon (MLR) yöntemleri uygulanarak sürücüler güvenli sürücü, agresif sürücü ve ekonomik sürücü olarak sınıflandırılmıştır. Önerilen çalışma sonucunda yazarlar tarafından sürüş karakterinin araca, yol koşullarına, hava koşullarına, sürücünün ruh haline bağlı olabileceği değerlendirilmiştir [11].

Sürücüye uyum sağlayacak akıllı sistemleri geliştirmek için sürüş karakteristiği modellerini araştırmak aynı zamanda farklı trafik durumları ve ortamlar dikkate alınarak destek sistemlerini bütüncül yaklaşımla geliştirmek çok önemlidir. Bu çalışmalar farklı trafik sıklığı seviyelerine sahip senaryoları değerlendirmek için aşırı basit olabilir. Bu nedenle tüm sürüş senaryolarını temsil edemez. Ayrıca şehir güzergahları, otoyollarda çoklu fren olayları, dönüş manevraları, hız profilleri nedeniyle sürüş karakteri çok karmaşık hale gelebilmektedir.

Fugiglando vd. araç ve sürücü etkileşiminin sürüş karakterizasyonunda daha başarılı olacağını önermişlerdir. Direksiyon simidi ve pedallardan alınan verilerin “doğrudan” sürücü hareketlerini ve eylemlerini yansıtırken, hız, motor devri ve ivmesel hareketliliğin “hissedilen” sürücü hareketlerini temsil ettiğini düşünmüşlerdir. Bu fikri desteklemek için 64 sürücüye ait araç içi CAN veri yoluyla kaydedilen sekiz sinyali (hız, dakikada devir sayısı, gaz pedalı konumu, fren pedalı basıncı, direksiyon simidi açısı, direksiyon simidi momentumu, boylamsal hızlanma, yanal hızlanma) kullanarak temel bileşen analizi (PCA) boyut azaltma yöntemiyle keşfedilmiş yedi farklı özellikle sürüş karakterizasyonunun sınıflandırılması önerilmiştir. Ayrıca, boyut azaltma stratejisinin doğru seçilmesiyle, sınıflandırma performansını bozmadan toplam veri setinin boyutunu %99'a kadar azaltmanın mümkün olduğu bildirilmiştir. Araştırmacılar ümit verici sonuçlar elde etse de çevresel bilgilerin eksikliğinde, insan davranışının doğallığı ve öngörülemezliği (belirsizliği) arasındaki ilişkiye dikkat

çekerek sürüş karakterizasyonu tanımlamanın güçlüğünden bahsetmişlerdir. Bu nedenle sürüş karakterizasyonunu sınıflandırılması için veri setinin daha fazla özellikle zenginleştirilmesi tavsiye edilmiştir [12].

Weishan vd. önerdikleri çalışmada GPS verilerine derin öğrenme yöntemleri uygulayarak sürücü davranışlarını sınıflandırılmaktadır. Yapılan çalışmada sürücülerin araç kullanma becerileri ve konuma bağlı dönme hareketleriyle karmaşık sürüş modelleri ortaya çıkarılmıştır. Çalışmada kullanılan veri seti Kaggle platformunda paylaşılan ve motor devri, yakıt tüketimi vb. araç kinematiği verilerden yoksun olarak yalnızca GPS verileri üzerinden gerçekleştirildiği için yetersizdir. Yazarlar öneriler kısmında sürüş karakterini temsil edecek veri seti özellikleri sayısını vurgulayarak giriş parametre sayısının artırılmasıyla daha başarılı modeller geliştirilebileceği ifade edilmiştir [13].

Christian vd. tarafından yapılan çalışmada akıllı sürüş teşhis sistemi adı altında sürücü davranışlarını sınıflandıran model önerilmektedir. GPS verilerinden elde edilen sinyallerden konum, hız, ivme model için kullanılacak giriş bilgileri artırılmaktadır. Giriş sinyalleri özellik çıkarma tekniğiyle zenginleştirerek aracın hızlanma, yavaşlama, direksiyon hareketleri ve şerit değiştirme değerleri yapay sinir ağı modeline girdi olarak verilmektedir. Geliştirilen model sayesinde sürücülerin direksiyon profilleri, pedal kullanımları, hızlanma ya da yavaşlama eylemleri, şeritten veya yoldan çıkma davranışları istatistiksel olarak hesaplanmanın mümkün olabileceğini açıklamaktadır. Model sonucunda sürücü davranışlarını agresif ve sakin sürücü olarak sınıflandırılan sistemde simülasyon üzerinde performansı test edilmiştir. Simülasyon ortamında performans sonuçları gerçek trafik ortamında gerçekleşen sürüşleri tam manasıyla yansıtamayacak olsa da farklı davranış sergileyen sürücülerin sınıflandırabileceğini göstermektedir [14].

Literatürde birçok yazar tarafından sürüş karakterizasyonunu temsil eden daha çok sensör verisi kullanmanın sürüş karakteristiği sınıflandırma başarısının artırılmasında faydalı olacağı önerilmektedir [12–17].

Minh Van Ly vd. tarafından tehlikeli araç manevralarını azaltmak amacıyla akıllı telefonlarda bulunan ivme sensörüyle yakalanan sinyallerin bazı sürücü hareketlerini temsil ettiği iddia edilmiştir. İvme sensörü sinyalleri kullanılarak aracın hızlanma, frenleme ve dönme olayları tespit edilmiştir. Önerilen çalışmada SVM ve k-ortalama kümeleme modelleri uygulanarak farklı sürücüler arasında sınıflandırma yapabilmenin mümkün olduğu ayrıca frenleme ve dönme eylemlerinin sürüş karakterizasyonu sınıflandırmasında daha baskın özellikler olduğu tespit edilmiştir [15].

Mohammad Siami tarafından yapılan çalışma sigorta şirketinde poliçe sahibi kişilerin kaza risklerini tahmin edilmesi amacıyla geliştirilmiştir. Çalışmada, sigorta müşterileri için mobil verilerle bir risk modelinin derin öğrenme yöntemleriyle tahmin edilmesinin kavramsal bir yapısı önerilmektedir. Tahmin modelinde giriş verileri olarak, sigorta şirketi tarafından yayınlanan 2011 ve 2015 yılları arasında akıllı telefonla kaydedilmiş 2.500 sürücüye ait 50.000 seyahat içeren veri seti kullanılmıştır. Önerdiği modelde mobil verilerin aralarındaki korelasyona göre boyut azaltmak amacıyla ilk önce öz düzenleyici haritalar (SOM) yöntemini daha sonra dokuz katmanlı derin otomatik kodlayıcı modeline giriş olarak verilerek özellik çıkarma yöntemi uygulanmıştır. Son olarak etiketsiz olan verilerin 5 kümeleme yöntemini karşılaştırarak birbirine yakın özelliklerin aynı küme içerisinde yer aldığı tespit edilmiştir. Elde edilen sonuçlara göre en başarılı yöntemin SOM ve k-ortalama kümeleme yönteminin bir arada kullanıldığı model olarak belirlenmiştir. Geliştirilen model ile 29 sürücü davranışı kategorisi elde edilmiştir. Yazar çalışma sonucunda bu kategorilerin gerçek hayatta tam karşılığının bulunamaması nedeniyle modelin gelecek çalışmalarda etiketlenmiş verilerin etiketlenmesinde genel bir çerçeve olarak kullanabileceğini iddia etmektedir [16].

Guo vd. tarafından sürücü davranışlarını sınıflandırmak ve trafik kazası risklerini incelemek amacıyla hibrit derin öğrenme modeli önerilmiştir. Önerilen çalışmada Çin'in Shenzhen şehrinde GPS sensörü verilerinden oluşan 4032 kayıtlı veri seti kullanılmıştır. Kısa ve düzenli zaman aralığında (1 Hz) kaydedilen enlem ve boylam değişkenleri daha fazla özellikle zenginleştirilmiştir. Çalışmada ham verilerden yeni özellikler türeterek hız, hızlanma, yavaşlama, dönme hareketleri tespit edilmektedir. Özellik çıkarma ve sınıflandırma modeli olarak hibrit denetimsiz derin öğrenme

yöntemi olan otomatik kodlayıcı ve öz düzenleyici haritalar (AESOM) yöntemleri birleştirilerek kullanılmıştır. AESOM ağları sayesinde kaydedilmiş ham GPS verilerinden sürücü davranışı kategorileri için daha fazla yorumlanabilir bilgi sağladığı keşfedilmiştir [17].

Zhang vd. farklı zaman serisine sahip 51 değişkenli araç içi CAN verilerine evrişimli sinir ağları ve tekrarlayan sinir ağları yöntemlerini beraber kullanıldığı bir derin öğrenme modeli önermişlerdir. Önerdikleri yöntemde yüksek boyutlardaki sensör verilerinin özellik seçimi ve önışleme olmaksızın belirgin yapı özelliklerini yakalamakta ayrıca sürüş karakteristiğinde zengin özellik gösterimleri için çoklu sensör verileri arasındaki korelasyonları keşfetmekte işe yaradığı tezini savunmuşlardır. Sürüş karakteristiğini tanımlamak için sırasıyla DeepConvGRU ve DeepConvLSTM iki derin evrişimli ve tekrarlayan sinir ağlarını kullanarak denetimli öğrenme yöntemleriyle özellik seçiminin mümkün olduğunu açıklanmaktadır. İlk adımda her sürücü için araç içi CAN sensör verilerini toplayarak veri seti elde etmişlerdir. İkinci adımda zaman serisi altında CAN verileri normalleştirme ve kayan pencere yardımıyla parçalara ayrılmıştır. Daha sonra normalleştirilen veriler sürücü davranışını belirlemek için derin öğrenme modeline aktarılmıştır. Önerdikleri modelde yüksek boyutlu sensör verilerinin yüksek korelasyonlu özelliklerin hesaplanarak çok boyutlu özellik gösterimleri için kullanılabilceği gösterilmiştir. Deneysel sonuçlarına göre geliştirilen derin öğrenme modelinin herhangi önışleme ve özellik seçimi uygulanmadan ham 51 değişkenli veri setinden modelin, öznelikleri öğrenebildiği ve sırasıyla 0,984 ve 0,970 doğrulukla öğrenilen öznelikleri birleştirebildiği sonucu çıkarılmıştır [18].

Cheng vd. araçların CAN ve akıllı telefon ile kaydedilen ivmeölçer, jiroskop, manyometre, GPS, sıcaklık ve ışık sensörü verileriyle sürücü davranışı tanımlama sistemi geliştirmişlerdir. Yazarlar tarafından kaydedilen sürüş verileri 3 farklı araç ile önceden planlanan rotada sokak yolları, otoyol, rampa, farklı trafik işaretleri içeren 11,6 km uzunluğunda yolda gerçekleşmektedir. Tasarlanan model sırasında sürücülerini sınıflandırmak için kullanılan giriş parametrelerinin bilgi kazanımı (info gain) sonucunda öne çıkan jiroskop, GPS ve ivme sensörü verilerinin, sürüş karakteristiği tanımlamada daha etkin özellikler olabileceğini öne sürmüşlerdir. Ayrıca yazarlar veri

toplayıcı olarak kullanılan akıllı telefonun araç ile aynı ekseninde konumlandırılarak akıllı telefon ve araç doğrultuları arasında eksen farklılıkları olmaması gerektiğine dikkat çekmişlerdir [19].

Johnson ve Trivedi yaptıkları çalışmada daha az maliyetli sürüş karakteristiği çıkarmak amacıyla akıllı telefonlarda bulunan sensörleri kullanarak agresif sürüşün akıllıca tanımlanması için mobil sensör platformu (MIROAD) olarak adlandırdıkları mobil uygulama geliştirmişlerdir. Sürücülerini agresif ve agresif olmayan olarak iki kategoride sınıflandırmışlardır. Farklı bir donanımsal alet kullanmadan, sadece akıllı telefonlarda bulunan ivmeölçer, jiroskop, manyetometre, GPS, kamera algılayıcılarını kullanarak dinamik zaman bükme (DTW) algoritmasıyla, sürücülerini anlık olarak takip eden ve agresif durum sergilediklerinde onları akıllı telefonları sayesinde sesli geri bildirimle uyararak sistem geliştirmişlerdir. Gerçek zamanlı olarak çalışan uyarı sistemi sürücülerin agresif olay sergiledikleri zaman video, konum, hız ve son sürüş manevralarını kaydederek, olayın gerçekleştiği bölgelerde agresif sürücülerin sayısını belirleyerek o bölgede trafik kazalarının meydana gelme olasılığı hakkında bilgi vermesini amaç edinmiştir. Sonuçlara bakıldığında ivmeölçer veya jiroskop verilerinin DTW algoritmasının tek başına kullanıldığında, sola dönüşü bir U dönüşünden ayırmakta güçlük çektiği gözlenmiştir. Geliştirilen MIROAD uygulaması U-dönüşünü ivmeölçer sensörü ile %23'ünü, jiroskop sensörü ile %46'sını doğru olarak tanımlamıştır. Ayrıca uygulama sonucunda tüm sensör verilerinden alınan verilerle, agresif olayların %97'sini doğru olarak tanımladığı sonucu çıkarılmıştır [20].

Serttaş vd. önceden belirlenen bir rota üzerinde 13 farklı sürücünün davranışlarını analiz etmişlerdir. Araca sabitlenen bir akıllı telefonun ivme sensörü ve GPS sensör sinyalleriyle veri seti hazırlanmıştır. Yazarlar tarafından yol, sensör ve araç sayısı sabit kalarak yalnızca sürücülerin değiştirilmesi yaklaşımı uygulanmıştır. Yazarlar bu yaklaşımın sürüş karakterizasyonunun güçlü olması sebebiyle yapıldığını iddia etmişlerdir. Çalışmada akıllı telefonla kaydedilen veriler bilgisayar ortamında işlenerek sürücülerin hızlanma, yavaşlama ve dönme hareketleri tespit edilmektedir. Önerilen sınıflandırma modelinde k-ortalama yöntemine sürücüler agresif sürücü, normal sürücü veya sakin sürücü olarak %93,3 başarıyla sınıflandırılmıştır [21].

Serttaş vd. yaptıkları bir başka çalışmada araç içerisine yerleştirdikleri akıllı telefonun 3 eksenli jiroskop, ivme ölçer, yakınlık sensörü ve ortam ışığı sensörlerinden algılanan sinyallerin dinamik tepki akıllı izleme sistemi (DRIMS) uygulaması kullanarak sinyalleri bilgisayar ortamına aktarma işlemi gerçekleştirmişlerdir. Akıllı telefon sinyalleriyle hız, ivme ve konum verileri alınarak, test grubundaki sürücüler için hızlanma, şerit değiştirme, ani yavaşlama eğilimi gibi temel sürücü davranışı modeli geliştirilmiştir. Yapılan çalışma iki farklı senaryo ile sürücü davranışı tanımlama yaklaşımı sunmaktadır. İlk senaryoda iki farklı sürücü, aynı yol şartlarında, aynı güzergâh ve saatte, aynı araçla önceden belirlenmiş parkuru tamamlamıştır. İkinci senaryoda ise aynı güzergâh, aynı araç ve aynı sürücü ile farklı saatlerde gerçekleştirilen sürüşte trafik koşullarının sürücü davranışını nasıl etkilediği tespit edilmektedir. Her iki senaryoda kaydedilen sensör verileriyle gerçek zamanlı standart sapma, varyans ve ortalama en düşük ve en yüksek hareket değerleri gibi istatistiksel bilgilerle sürücü davranışlarını tanımlamaya çalışılmıştır [22].

BÖLÜM 3

SÜRÜŞ KARAKTERİZASYONU

Sürüş karakterizasyonu sürücü hareketlerinin veya sürüş eylemlerinin tespit edilerek tanımlanmasıdır. Bu bölüm sürücü veya sürüş hareketlerinin neler olduğuna ve nelerden etkilendiğine kısacası sürüş karakterizasyonu tanımlamasına bir bakış açısı kazandırmaktadır. Ayrıca bu bölümde sürüş karakterizasyonu çıkarmada kullanılabilecek giriş parametreleri, sürüş karakterizasyonu kategorileri ve sürüş karakterizasyonu analizinde kullanılabilecek kamuya açık ücretsiz yayınlanan veri setleri detaylı olarak anlatılmaktadır.

3.1. SÜRÜŞ KARAKTERİZASYONU TANIMLAMASI

Sürücülükte insan faktörü, sürüş karakterizasyonu ve sürücü becerileri (performansı) olarak iki ana başlık altında açıklanmaktadır. Bir sürücünün sürüş esnasında sergilediği tipik hareketler sürüş karakterizasyonu olarak tanımlanır. Örneğin; bir sürücünün aracını nasıl kullandığıyla alakalı tercihleri, hız, manevra ve sollama yapması, trafik ihlali yapıp yapmadığı sürücü davranışlarını karakterize etmek anlamına gelmektedir. Sürücü becerileri, güvenlikle ve algısal motor kapasitesi ile ilgilidir. Sürücünün bir durum karşısında ortaya koyabileceği en iyi performans sürücü becerisi olarak tanımlanmaktadır [23,24]. Sürüş karakterizasyonu tanımlanması, sürücü ve trafik durumlarının çeşitli özelliklerine bağlı olmasından dolayı karmaşık bir konu olarak kabul edilir [25]. Sürüş karakterizasyonunu tanımlamak ve değerlendirmek için sürücü psikolojisi, çevresel faktörler, yol durumu, araç kinematığı gibi farklı biyolojik ve fizyolojik faktörlerin dikkate alınması gereklidir [26]. Sürüş olayının doğallığı nedeniyle tüm bu faktörlere dayalı doğru ve eksiksiz bir model oluşturmak oldukça zordur.

Literatürdeki bazı çalışmalar sürüş karakterizasyonunda bilinçli karar verme, demografik yapı, karakter, cinsiyet, yaş, eğitim, sürüş deneyimi, araç ve çevreye aşinalık gibi parametrelerin özgüven, sabır, umursamazlık, öfke ve dışa dönüklüğe etkisini ortaya koymuştur [7]. Benzer şekilde sürücü durumlarının uyuşturuculardan, yorgunluktan, dikkat dağınıklığı vb. nedenlerden etkilendiği saptanmıştır [27]. Tüm bu faktörler sürücünün iç dünyasıyla alakalıdır. Ayrıca sürüş karakterizasyonunun dış koşullardan güçlü bir şekilde etkilendiği kabul edilmektedir. Sürücünün sürüş karakteri gün, saat, hava durumu, yol tıkanıklığı ve yolun fiziksel durumu gibi farklı koşullar altında farklı davranış kalıpları gösterebilir [28]. Örneğin her gün işe giderken normal hızda giden bir sürücü kar ya da yağmur yağdığı günlerde daha yavaş veya daha hızlı araç sürebilir. Şekil 3.1’de sürüş karakterizasyonunu etkileyen insani ve çevresel faktörler gösterilmektedir.



Şekil 3.1. Sürüş karakterizasyonunu etkileyen insani ve çevresel faktörler.

Son yıllarda teknolojisinin gelişmesiyle sürüş karakterizasyonunu analiz etmek ve sürücü performansını değerlendirmek için çeşitli ticari ve araştırma sistemleri önerilmiştir [29]. Sürücüye uyum sağlayacak akıllı sistemleri geliştirmek için sürüş karakteristiği modellerini araştırmak ve aynı zamanda farklı trafik durumlarını, ortamlarını dikkate alarak destek sistemlerini bütüncül yaklaşımla geliştirmek çok önemlidir. Günümüzde gelişmiş sürücü destek sistemleri (ADAS) araçların verimliliği, yakıt tüketimi, güvenlik potansiyelinin geliştirilmesinde umut verici bir alandır. ADAS gibi sistemler sürücü performansının kişiselleştirilerek sürüş karakterizasyonu tanımlamayı hedeflemektedir [30].

3.2. SÜRÜŞ KARAKTERİZASYONUNDA KULLANILAN ALGILAYICI SENSÖRLER VE TEKNOLOJİLER

Sürüş karakterizasyonu tanımlama sistemlerinde ana modül, sürüş manevraları ve sürüş olaylarının çeşitli sensör algılayıcılarıyla yakalanması daha sonra akıllı sistemler kullanılarak sürüş karakterlerinin sınıflandırılmasıdır [20]. Genellikle araç hızı, durma, hızlanma, yavaşlama, dönme ve sarsıntı gibi sürüş olaylarının algılanabilmesi için tek başına veya çoklu sensör kullanımıyla sürüş verileri kaydedilmektedir. Sürüş manevraları ve olaylarını tespit edebilmek için ivme ölçer, jiroskop, IMU, GPS, LIDAR, CAN, araç içi veya araç dışı kameralar, akıllı telefonlar, sürüş simülasyonları, trafik videoları gibi farklı çeşit sensör algılayıcılar ve teknolojiler kullanılmaktadır. Çizelge 3.1’de sürüş karakterizasyonu tanımlaması için veri toplamak amacıyla yaygın olarak kullanılan sensörlerin, teknolojilerin avantajları ve dezavantajları yer almaktadır.

Çizelge 3.1. Sürüş karakterizasyonunda yaygın kullanılan algılayıcı sensörler, teknolojiler, avantajları ve dezavantajları.

Algılayıcı Sensörler ve Teknolojiler	Avantajlar	Dezavantajlar
Akıllı Telefon [20,21,31–38]	- Farklı algılayıcı sensörler bir arada bulunmaktadır.	- Gürültülü veri sayısı fazladır.

Akıllı Telefon [20,21,31–38]	- Düşük maliyetli, kolay ulaşılabilir. ulaşılabilir.	- Eksen doğrultuları ve verilerin doğruluğu önemlidir.
IMU [15,28,39–41]	- Gerçek zamanlı sürüş verileri sağlamaktadır. - Her araca harici olarak yerleştirilebilir.	- Yüksek maliyetlidir. - Kalibrasyon doğruluğu kritiktir.
CAN [12,18,19,42–45]	- Gerçek zamanlı araç telematiği verileri sağlamaktadır. - Genellikle her araçta bulunmaktadır.	- Araç kontrol verilerine erişim OBD gibi harici cihazlarla sağlanmaktadır.
GIS [46]	-Yol tipi, kavşak, tünel, köprü vb. veri bilgileri sağlamaktadır.	- Sürekli değişen veriler içermektedir. -Veri güncelliği önemlidir.
GPS [13,17,46–48]	- Gerçek zamanlı sürüş verileri sağlamaktadır. - Sürücü ve araç lokalizasyonu sağlamaktadır.	- Veri hassasiyeti ve zamanlama serileri kritiktir.
İvme Ölçer [49–51]	- Düşük maliyetlidir. - Genellikle CAN veri yolundan sayesinde bilgi sağlanmaktadır. - Her araca harici olarak eklenmektedir.	- Tek başına kullanıldığında sadece hız, hızlanma, yavaşlama verileri elde edilmektedir. -Yön bilgileri için harici sensörler kullanılmaktadır.
Kamera [52–55]	- Gerçek zamanlı sürücü, trafik ve yol durumları hakkında yüksek doğrulukla veriler sağlanmaktadır.	- Sürücünün kişisel verilerine erişim sağlamaktadır. - Veri işleme maliyeti fazladır.
LIDAR [40,56–58]	- Hız kontrolü ve şerit takibi senaryoları için kullanılmaktadır.	-Yüksek maliyetlidir.
Sürüş Simülatörleri [59–63]	- Kontrollü ve önceden tasarlanmış sürüş senaryoları için kullanılmaktadır.	- Gözlemlenen sürücü davranışları her zaman gerçek sürüşlerle aynı olmamaktadır.
Trafik Videoları [64–70]	- Gerçek trafik durumları, trafik akışı, sıklığı ve araç etkileşimleri gözlemlenebilir.	- Video işleme maliyeti yüksektir. - Videoda bulunan trafik bölgeleriyle sınırlıdır.

Günümüzde artan popüleritesi, kolay ulaşılabilir ve düşük maliyetli olması sebebiyle sürüş karakterizasyonu tanımlamasında akıllı telefon teknolojisi kullanımı oldukça yaygınlaşmaktadır. Akıllı telefonlar içerisinde ivme ölçer, jiroskop, GPS, manyetik alan sensörleri ve kameralar yer almaktadır. Birçok algılayıcıyı tek bir sistem içerisinde barındırması veri kaydetme işlemini oldukça kolaylaştırmaktadır. Aynı

zamanda internete erişim, telefonun donanımsal performansının yeterli olmasıyla birlikte sürücü profilinin çıkarılması veya sürüş değerlendirmelerini gerçek zamanlı tespit etmektedir.

IMU, sürüş karakterizasyonu analizinde yaygın olarak kullanılan bir bilgi kaynağıdır. İçerisinde barındırdığı jiroskop ve ivme ölçer sensörleri sayesinde açılma hız ve doğrusal ivme verileri algılanarak aracın hızlanma ve dönme olayları tespit etmektedir.

Sürüş karakterizasyonu tanımlamasında birçok araştırma araç telematiğiyle alakalı verileri kaydetmek için CAN veri algılayıcısını kullanmaktadır. CAN algılayıcısı gaz pedalı veya fren pedalı durumları, tork bilgisi, yakıt düzeyi, direksiyon açısı, tekerlek hızı, motor devri, motor sıcaklığı, araç hızı, ivme gibi araç bilgisine dayalı birçok veri sağlanmaktadır. CAN aracılığıyla erişilemeyen veya elde edilemeyen verileri kaydetmek için harici sensör algılayıcılarıyla beraber kullanılmaktadır.

Coğrafi bilgi sistemi (GIS) daha gelişmiş araçlarda, belirli manevralar altında döner kavşaklar gibi birçok yol durumlarının konumlandırılması için kullanılmaktadır.

GPS aracılığıyla araç lokalizasyonu, araç hızı verilerine ulaşılmaktadır.

İvme ölçer algılayıcı sensörler sayesinde aracın hız, hızlanma ve yavaşlama verilerine ulaşılabilmektedir. Ucuz ve kolay elde edilebilir. Cep bilgisayarı (Raspberry Pi, Beaglebone Black vb.), akıllı telefon ve diğer teknolojiler ile birlikte yaygın olarak kullanılmaktadır.

Araç içi kameralar, sürücü hareketlerinin görüntülenmesi, araç dışı kameralar ise araç takibi, trafik durumu, bina, geçit, sinyalizasyon sistemleri, şerit veya yol görüntülerinin tespit edilmesi amacıyla kullanılmaktadır.

Otonom sürüş çalışmalarında radar teknolojisi olarak yaygın kullanılan LIDAR, araba ve şerit takibi parametrelerinin kullanımı, uyarlanabilir hız sabitleme özellikleri için kullanılmaktadır.

Sürüş simülasyonları, bilgisayar platformlarında önceden tasarlanan sürüş koşullarını bir araya getirerek sürücülerin eğitilmesini veya sürücü davranışlarını izlenmesini sağlamaktadır. Simülasyon sistemi gerçek sürüş koşullarını ne kadar bilgisayar ortamına taşımayı hedeflense de gerçek hayattaki psiko-sosyal ortamının tam anlamıyla sağlaması oldukça zordur.

Trafik videoları ise genellikle kavşak ve otoyol üzerinde bulunan kameralar ile sağlanan görüntülerle araçların yol üzerinde diğer araçlarla etkileşimleriyle alakalı görüntülerle şerit değiştirme, araç takibi vb. çıkarımlar yapmak için kullanılmaktadır. Tek başına araç ve yol görüntüleriyle, sürücülerin içsel yapısının anlaşılması, doğal ve gerçekçi sürücü profili çıkarılması zordur.

3.3. SÜRÜŞ KARAKTERİZASYONUNDA KULLANILAN GİRİŞ PARAMETRELERİ

Sürüş karakteristiği çıkarmada parametre seçimi 1978 yılında M. Kuhler ve D. Karstens tarafından erken bir tarihte başlamıştır. Araştırmacılar ortalama hız, duraklamasız ortalama hız, ortalama hızlanma, ortalama yavaşlama, ortalama sürüş süresi, periyodik olan hızlanma ve yavaşlama sayısı, hızlanma süresi oranı, yavaşlama süresi oranı, sabit hızdaki zaman oranı gibi 10 sürüş modeli parametresi tanıtmıştır [71]. Ericsson bir sürüş olayı döngüsünde emisyon ve yakıt tüketimi bakış açısıyla sürüş karakterizasyonunu tanımlamak için 62 tane parametre kullanarak bunları 16 bağımsız grup altında sınıflandırmıştır. Yazarlar bu sınıflandırmalardan şehir içi yoğun yolların, eğimli yolların, hızlanma ve yavaşlama sıklığının fazla olduğu durumların yakıt emisyonunu ve yakıt ekonomisini önemli ölçüde etkilediğini öne sürmektedir [72]. Langari ve Won bu parametrelerin 40 tanesine, kendi yaklaşımlarıyla sürüş döngüsü tanımlamak için 7 parametre daha ekler. Ancak çok fazla parametre, daha yüksek donanım maliyetine aynı zamanda daha uzun hesaplama süresine neden olur bu nedenle modeli gerçek zamanlı olarak araçlara uygulayamaz [73]. Günümüzde bu tip araştırmalar gerçek zamanlı sürüş karakteristik döngüsünü temsil etmek için giriş parametrelerini azaltmaya çalışmaktadır. Huang vd. 11 parametre kullanarak bu parametrelerin sürüş karakterizasyonu tanımlama üzerindeki etkisini incelemektedir. Seçtikleri parametrelerden 4 tanesini (ortalama hız, durma

zamanı/toplam zaman, maksimum hızlanma ve minimum yavaşlama) kullanarak sürücü davranışlarını tahmin sonuçlarının yeterince iyi olduğunu ileri sürmektedir [74].

Sürüş karakterizasyonu sınıflandırması yapabilmek için ilk adım, izlenmesi gereken parametre ve sinyallerin belirlenmesidir. Doğru bir sınıflandırma yapabilmek için doğru sinyallerin seçilmesi çok önemlidir çünkü daha sonra yapılacak işlemler ve sonuçlar buna bağlıdır. Literatürde kullanılacak parametreler için genel bir fikir birliği maalesef yoktur. Bu anlaşmazlık birçok sürüş karakterizasyonu uygulamasında yakıt tüketimi verimliliği, güvenliği artırma, sürücü davranışı izlenimi vb. farklı görüş bildirilmesinden dolayıdır. Sürüş karakterizasyonu tanımlaması yapılırken az parametre kullanımı belirli sürüş döngülerini temsil etmeyebilir diğer taraftan çok fazla parametre kullanımı ise hesaplama yükü maliyetlerini artırır gerçek zamanlı kontroller için çok fazla süre gerektirebilir.

Seçilen giriş parametreleri araç dinamikleri ve sürücü davranışlarıyla yakından ilişkilidir. Bu ilişki sürüş karakterizasyonu hakkında bilgiler vermektedir [20]. Tanımlanan temel sürüş hareketleri frenleme, hızlanma, ani durma ya da kalkma, araç takip mesafesi, kavşaklarda dönüş, geçit veya trafik ışıklarında geçiş, şerit değiştirme, viraj alma, yol tutuşu, direksiyon hareketleri ve trafik durumlarını içermektedir. Sürüş hareketleriyle alakalı sistematik veriler sinyal yakalama sensörleri ve teknolojiler sayesinde çıkarılmaktadır. Çizelge 3.2’de sürüş karakterizasyonu sınıflandırılmasında yaygın olarak kullanılan giriş parametreleri yer almaktadır.

Çizelge 3.2. Sürüş karakterizasyonu sınıflandırmasında yaygın kullanılan giriş parametreleri.

Giriş Parametreleri	Referanslar
Yakıt ihtiyacı ve tüketimi, Güç, Kinetik enerji	[31,75–78]
Sarsıntı, Ani hareket	[28]
Trafik sıkışıklığı	[72,79]
Hızlanma, Yavaşlama	[20,41,78]

Sağa ve sola dönüş, U dönüşü	[20,32,33,46]
Açısal hız, Enlem ve boylam ivmesi	[15,41,80]
Hız, Gaz pedalı konumu, Yakıt tüketimi	[81]
Fren basıncı, Gaz pedalı konumu	[82]
Hız, Gaz pedalı konumu, Fren basıncı, Mesafe koruma	[39,83]
Sürücü karakteri özellikleri	[7]
Aşırı hız, Agresif hızlanma ve yavaşlama, Şerit değiştirme, Sağa ve sola dönüş	[20]
Viraj, Yol tutuşu, Trafik durumu	[84]
Kavşak ve geçitlerde hız, Dönüş	[46]

Literatürdeki bazı çalışmalar parametre seçiminde önemli bir azalma gerçekleştirmiş olsada araç içi gerçek zamanlı uygulanan sürüş karakterizasyonu tanımlama algoritmalarında daha az maliyet ve çalışma süresi için daha fazla basitleştirme gerektirmektedir. Daha basit yaklaşım önerileri, agresif sürücülerin yüksek hızlanma, hız profilleri yakıt ve güç tüketimi arasındaki ilişkiden yararlanır. Hızlanma ve yavaşlama ivmesi genellikle hız ve frenleme istatistikleri ile tanımlanır. Aynı zamanda sarsıntı, fren basıncı ve gaz pedalının kullanımı gibi özellikler birçok araştırmada daha iyi göstergeler olarak kullanılmıştır [28,39,83].

3.4. SÜRÜŞ KARAKTERİZASYONU SINIFLANDIRMA KATEGORİLERİ

Sürüş karakterizasyonu sınıflandırma kriterleri, seçilen parametre ve yapay zekâ algoritmalarıyla güçlü şekilde ilişkilidir. Çok sayıda parametre çeşitliliği ve farklı sürüş karakterizasyonu uygulamaları nedeniyle farklı etiketleme stratejine sahip sınıflandırma yaklaşımları bulunmaktadır. Çok faktörlü bir sürüş karakterizasyonu tanımlamasında etkili olan tüm parametrelerin sınıflandırma algoritması tasarımından önce hesaba katılması gerekmektedir. Etiketleme inceliği ve sınıflandırma karmaşıklığı arasındaki denge, algoritmanın sağlamlığını test etmek için ayrıca son kullanıcı tarafından sonuçların anlaşılabilir olması çok önemlidir [80]. Sınıf etiketleri

yakıt ekonomisi ve güvenlik yaklaşımlarıyla değerlendirilmektedir. Güvenlikle ilgili sürüş karakterizasyonu sınıflandırması agresiflik seviyesine işaret ederken, yakıt tüketimi odaklı sınıflandırma genellikle verimlilik veya sportiflikle ilgili tanımlamaları kullanmaktadır. Literatür incelendiğinde iki veya üç sınıf etiketi kullanarak basit sınıflandırma kategorilerinin yaygın olduğu görülmektedir. Basit sınıflandırma stratejisi algoritma ayarlamalarını kolaylaştırırken son kullanıcı tarafından kolayca anlaşılabilir sonuçlar sağlamaktadır. Çizelge 3.3’de yaygın kullanılan sınıf sayısı ve sınıflandırma etiketleri verilmektedir.

Çizelge 3.3. Sürüş karakterizasyonu sınıflandırmada yaygın kullanılan sınıf sayısı ve etiketler.

Sınıf Sayısı/ Aralık	Sınıflandırma Etiketleri	Referanslar
2	Agresif, Sakin	[20,32,49,80,85–87]
3	Agresif, Normal, Sakin	[28,40,57,72,88,89]
4	Çok kötü, Kötü, İyi, Çok iyi	[33,90]
4	Dikkatsiz, Endişeli, Öfkeli, Sabırlı	[7]
5	Sakin, Normal, Sabit, Dinamik, Agresif	[47]
Aralık (0-100)	Yakıt tüketimi, Güç tüketimi	[31,41,78,79]
Aralık (0-100)	Agresif, Sakin	[91]

Çizelgeye bakıldığında agresifliğin sürüş karakterizasyonunda yaygın olarak kullanıldığı görülmektedir. Agresif sürücüler genellikle ani ve öngörülemez sürüş olayları gerçekleştirirler. Aşırı hız, uygunsuz araç takibi, hatalı dönüş manevraları ve düzensiz şerit değiştirme dahil olmak üzere araçları güvenli olmayan bir şekilde kullanma eğilimindedir. Bu yüzden agresif sürücüler daha yüksek yakıt tüketimine ve tehlikeli durumlara neden olmaktadır. Model analizinde bu bilgiler yüksek hız, daha yüksek hızlanma veya yavaşlama tepe noktaları, kısa yol manevraları, araçlara olan mesafe, gaz ve fren pedalının yoğun bir şekilde değiştirilmesi ile karakterize edilmektedir [92]. Agresif sürücülerde bu değerler daha büyük genliklere sahipken, sakin sürücülerde ise küçük genlikler göstermektedir.

3.5. SÜRÜŞ KARAKTERİZASYONUNDA KULLANILAN VERİ SETLERİ

Günümüzde sürüş karakterizasyonu ve gelişmiş sürücü destek sistemleri alanlarında yapılan birçok çalışma bulunmaktadır. Bu çalışmaların genel amacı analiz sonuçlarının hata oranını azaltmak ve doğruluğunu geliştirmektir. Bu konuda birçok araştırmacı ve ticari kuruluş kaydedilen sürücü, araç, çevre ve yol özelliklerini barındıran verileri gelecekte geliştirilecek çalışmalara daha fazla katkı sağlamak amacıyla kamuya açık platformlarda yayınlamaktadır. Bu sayede paylaşılan veriler, yapılan çalışmanın geliştirilmesi veya başka bir bakış açılarıyla değerlendirilmesine olanak sağlamaktadır. Çizelge 3.4’de literatürde kamuya açık ücretsiz olarak yayınlanan veri setleri ve kullanım alanları özetlenmektedir. Sürücü hareketlerini yakalamak ve sürücü davranışlarını tespit etmek için tanımlanmış net bir açıklama veya yaklaşım yoktur. Bu yüzden bu veri kümeleri birbirinden oldukça farklıdır.

Çizelge 3.4. Kamuya açık ücretsiz yayınlanan veri setleri ve özellikleri.

Veri Seti	Yayın Tarihi	Konum	Yol Tipi		Sensör					Kullanım Alanı
			Şehir içi	Otoyol	Video Kamera	GPS	CAN	LIDAR	IMU	
HDD [93]	2018	San Fransisco	✓	✓	✓	✓	✓	✓	✓	Sürücü Davranışları ve Otonom Sürüş
OBD [94]	2018	Portekiz	✓	✓			✓			Sürücü Davranışları
DBNet [56]	2018	Çin	✓	✓	✓	✓	✓	✓		Otonom Sürüş
Taşıt [95]	2018	Brazilya	✓	✓		✓	✓			Sürücü Tanımlama
Udrive [96]	2017	Avrupa Ülkeleri	✓	✓	✓	✓	✓			Sürücü Davranışları
AEGIS [97]	2017	Graz	✓	✓		✓	✓			Sürücü Davranışları
Brain4Car [98]	2016	ABD	✓	✓	✓	✓				Sürüş Manevraları

Comma.ai [99]	2016	San Fransisco		✓	✓	✓		✓	Sürücü Davranışları ve Otonom Sürüş
UAH [100]	2016	Madrid	✓	✓	✓	✓			Sürücü Davranışları
Sürücü Güvenliği [45]	2015	Güney Kore	✓	✓			✓		Sürücü Davranışları
HciLab [101]	2013	Stuttgart	✓	✓		✓	✓		Sürücü Davranışları
UTDrive [102]	2008	Uluslararası	✓	✓	✓	✓	✓		Sürücü Davranışları

3.5.1. Honda Sürüş Veri Seti

Honda Araştırma Enstitüsü tarafından yayınlanan Honda Sürüş Veri Seti (HDD) gerçek trafik ortamlarında sürücü davranışlarını analiz etmeye yönelik kamuya açık sunulmaktadır. Veriler San Francisco şehrinde banliyö, otoyol ve şehir yolları dahil olmak üzere farklı rotalarda gerçek sürücüler tarafından kaydedilen 104 saat sürüş verilerine sahiptir. Veri seti içerisinde araca yerleştirilen kamera sayesinde sürüş anı kayıt altına alınırken LIDAR, CAN, GPS sensörlerle algılanan veriler yer almaktadır.

3.5.2. OBD-Veri Seti

Barreto vd. tarafından yayınlanan veri setinde sürücü davranışı analizi için OBD arabirimi kullanılarak veriler kaydedilmiştir. Ancak yayınlanan veri setinde ‘NaN’ değerine sahip kayıp veri miktarı oldukça fazladır. Eksik veri miktarının çok olması analiz sonuçlarına olumsuz etki edebilir. Bunun sebebi sürüş karakterizasyonu analizinde, sürüş hareketlerini temsil edemeyen önemli verilerin eksik olabileceğidir. Bu durum analiz sonuçlarının doğru değerlendirilmesinde olumsuz etkiye sahip olmaktadır. Yazarlar, yayınladıkları veri setinde eksik verilerin tamamlanma sürecinde nasıl bir teknik uyguladıklarını açıklamamaktadır. Bu nedenlerle kamuya açık yayınlanan veri setinin kullanılması analiz sonuçlarının başarısı tartışmalıdır.

3.5.3. DBNET Veri Seti

Chen vd. otonom sürüş çalışmaları için büyük ölçekli bir veri seti kaydederek kamuya açık olarak yayınlamışlardır. Veri kaydetme işlemleri kavşak, üst geçit, rampa yollar ve keskin virajlarla birlikte hafif, normal ve yoğun olan trafik koşullarında gerçekleştirilmiştir. Toplam 1000 km yolda video, GPS ve CAN verileri ve LIDAR görüntüleri içeren veri seti otonom sürüş çalışmaları için yayınlanmıştır.

3.5.4. Taşıt Veri Seti

Rettore vd. tarafından kamuya açık yayınladıkları veri setinde, 8 erkek 6 kadın olmak üzere 14 farklı sürücü tarafından kullanılan 2 farklı araçla GPS ve CAN sensörleriyle veri kaydetme işlemi gerçekleştirilmiştir. Araştırmacılar veri kaydetme yaklaşımlarında ikinci aracı kullanan 4 sürücünün 2 farklı yol türünden geçmesini isterken, birinci araçtaki 10 sürücünün günlük rutin rotalarında araçlarını kullanmasını istemektedir. Bu sayede veri setinin doğallığını gözlemlemeyi amaç edinmişlerdir. Fakat sürücülerin kişisel bilgilerinin gizliliği nedeniyle veri setinde sürüşlerin başlangıç ve bitiş verileri silinmiştir. Bu yüzden veri kayıtlarındaki başlangıç ve bitiş verilerinin eksikliği düşük hız veya farklı trafik durumları için değerlendirildiğinde sürüş karakterizasyonunda kullanımı uygun değildir.

3.5.6. UDrive Veri Seti

UDrive veri seti, Büyük Britanya, Polonya, Fransa, Hollanda ve Almanya'da 120 araçla bir yılda kat edilen yaklaşık 1,8 milyon kilometre yolda veri paylaşma rızası alınmış sürücülerin verilerini içermektedir. Araçlarda veri toplama sistemi adı altında ön sol, ön sağ, ön merkez, kabin, kokpit, sürücü yüzü ve araç pedallarında olmak üzere 7 kamera, araç hızı, ivme, direksiyon açısı, gaz ve fren pedalları hareketlerini algılamak için CAN ve GPS verileri kaydedilmiştir. CAN verileri 10Hz, GPS verileri ise 1Hz örnekleme frekansına sahiptir. Ayrıca veri seti GPS verileri kullanılarak harita eşleştirmesi yoluyla yol eğriliği, belirtilen hız sınırları, kavşak ve yol türü (otoyol, kırsal, şehir içi) hakkında bilgiler ile zenginleştirilmiştir. Veri seti ayrıca araç

kinematığının yanı sıra cinsiyet, yaş, sürücü deneyimi ve ülkeyle ilgili sorular içeren anketler aracılığıyla sürücülerin demografik bilgilerini de içermektedir.

3.5.7. AEGIS Sürücü Veri Seti

Avrupa Birliği Horizon 2020 araştırma ve yenilik programı destekleriyle kamu güvenliği ve kişisel güvenlik için gelişmiş büyük veri değer zinciri (AEGIS) projesi kapsamında otomotiv alanında yenilikler için kamuya açık veri seti yayınlanmıştır. Veri seti Avusturya'nın Graz bölgesinde bir araç ve bir sürücü ile kaydedilen toplam 35 farklı sürüş verisi içermektedir. BeagleBone adlı küçük kart üzerine yerleştirilen GPS, jiroskop, ivme ölçer sensörlerine ek olarak aracın CAN verileri kaydedilmiştir.

3.5.8. Brain4Cars Veri Seti

Jain vd. sürüş manevralarını önceden tahmin etmek amacıyla kamuya açık veri seti yayınlamışlardır. ABD'de 2 farklı eyalette otoban ve şehir içi olmak üzere yaklaşık 1899 kilometre yolda 10 farklı sürücünün sürüş manevraları kaydedilmiştir. Arabanın içine yerleştirilen kamerayla sürücünün gövde üstü hareketleri, araç dışına yerleştirilen kamerayla aracın önündeki yolun görüntüleri ayrıca GPS ile aracın hız bilgisi, şerit bilgisi ve sokak haritası bilgileri yer almaktadır. Veri setinde zaman serileriyle birlikte toplam 234 düz gitme, 124 sola şerit değiştirme, 58 sağa şerit değiştirme, 123 sola dönme, 55 sağa dönme manevra sürüş verisi bulunmaktadır.

3.5.9. Comma.ai Veri Seti

ABD San Francisco şehrinde bir sürücü tarafından kullanılan araca yerleştirilen, kamera ve çeşitli sensörlerle veriler kaydedilmiştir. Veri seti içerisinde aracın ön camına yerleştirilen kamera sayesinde yolun görüntüleri, IMU, jiroskop, GPS sensörleriyle toplanan araç hızı, direksiyon açısı gibi araç dinamikleriyle alakalı veriler içermektedir. Veri seti analiz kolaylığı için sensör verilerinin ölçüldüğü zaman serileri ve kamera karelerinin yakalandığı zaman damgalarıyla birlikte HDF5 dosya formatında kamuya açık yayınlanmıştır.

3.5.10 UAH-Veri Seti

Romera ve arkadaşları tarafından yayınlanan veri seti akıllı telefon sensörleri kullanılarak Madrid'in farklı bölgelerinde toplam 82 km rotada 500 dakika kaydedilmiştir. Veri kaydetme işlemine başlamadan önce farklı yaş gruplarında 5 erkek ve 1 kadın olmak üzere 6 farklı sürücünden yol boyunca araçlarını agresif, uykulu ve normal davranışlarla sürmeleri ayrıca uykulu sınıflandırma için sürücülerden yol boyunca ara sıra hafif uykuluymuş gibi davranılması istenmektedir. Araca sabitlenmiş akıllı telefonda bulunan ivme ölçer, jiroskop, GPS sensörleriyle ivme, açısız hız ve konum verileri kaydedilmiştir. Araştırmacıların paylaştıkları veri setindeki sürüş verileri 50 km/s hız ve üzerindeki hızlar içindir. Bu hız altındaki başlangıç ve bitiş gibi önemli sürüş olaylarını temsil eden veriler yer almamaktadır. Bu sebeple gerçek trafik ortamlarında bu değerlerin eksikliği tutarlı tespit yapılmasına engel olmaktadır. Şehir içi hız limitleri, duraklama veya durma olayları dikkate alındığında veri setinin kullanılabilirliği de tartışmalıdır.

3.5.11. Sürücü Güvenliği Veri Seti

Kwak vd. tarafından kamuya açık yayınlanan veri seti, Güney Kore'nin Seul şehrinde 10 farklı sürücü tarafından kullanılan bir araç ile kaydedilmiştir. Her sürücü otoyol, şehir yolu, park alanı olmak üzere 3 farklı yol tipinde sürüş gerçekleştirilmektedir. Veri seti toplamda 46 kilometre uzunluğuna ve 23 saatlik sürüş kaydına sahiptir. Veri seti sınıflandırma başarısını arttırmak amacıyla hafta içi aynı saatlerde gidiş ve dönüş şeklinde kaydedilmiştir. Veri seti sürücülerin kullandığı araçlardan toplanan CAN sensörü verileriyle 51 farklı araç dinamiği bilgisi içermektedir.

3.5.12. HciLab Veri Seti

Schneegass vd. tarafından yayınlanan kamuya açık veri seti 7 erkek 3 kadın sürücü tarafından otoyol, tünel ve şehir içi yollarının bulunduğu 23 km'lik aynı rota üzerinde kaydedilmiştir. Sürüş sırasında akıllı telefonla GPS, ivme ölçer sensörleri, aynı zamanda sürücülerin sol ellerine cilt iletkenliği ve sıcaklık sensörleri, göğüs bölgesine elektrokardiyografi (EKG) sensörü yapıştırılarak sürücünün fizyolojik verileri

kaydedilmiştir. Ayrıca araca yerleştirilen kamera sayesinde sürüş görüntüleri kaydedilmiştir. Ancak sürücü bilgilerinin gizliliği nedeniyle video kayıtları kamuya açık paylaşılmamaktadır. Veri kaydetme işlemi için farklı cihaz kullanımı nedeniyle veri toplama frekansları birbirinden farklıdır. Bu nedenle tüm verileri senkronize etmek için zaman damgaları kullanılmalıdır.

3.5.13. UTDrive Veri Seti

UTDrive veri seti, sürücü özellikleri ve sürücü davranışları alanında araştırma yapmak amacıyla ABD, Türkiye, Japonya, İtalya, Singapur ülkelerindeki araç toplulukları ve üniversiteler iş birliğiyle UTDrive projesi adı altında yayınlanmıştır. Veri seti, 20 farklı sürücüyle çok sayıda yol tipinin bulunduğu farklı şehir ve yollarda kaydedilmiştir. Araç içine yerleştirilen kamerayla sürücü hareketleri, araç dışına yerleştirilen kamerayla yol ve trafik görüntüleri kaydedilmiştir. Yayıncılara göre kameralardan gelen veriler sürücü davranışlarının ve sürüş manevralarının belirlenmesi için temel oluşturması nedeniyle kullanılmıştır. Hem sürücü hem de yanındaki kişilerin seslerini kaydetmek amacıyla araç içerisinde mikrofon kullanılmıştır. Ayrıca veri setinde, sürücünün gaz ve fren pedallarına bastığı anda ki gerçek basıncı yakalamak için gaz ve fren pedalı basınç sensörü, GPS verileri, öndeki araçla arasındaki mesafeyi ölçen mesafe sensörü ve CAN sensörü verileri yer almaktadır.

BÖLÜM 4

MATERYAL VE YÖNTEM

Bu bölümde sürüş karakterizasyonu çıkarmada kullanılan materyaller ve geliştirilen veri madenciliği yöntemleri tanıtılmaktadır.

4.1. VERİ TOPLAMA

Veri toplama süreci çözüm aranan probleme en uygun çözümün bulunması amacıyla istatistiksel alanda görüşme, ölçek, anket, deney ve gözlem yöntemleriyle, mühendislik alanında elektronik algılayıcılar aracılığıyla gerekli verilerin toplama sürecidir [103]. Bu süreçte toplanan verilerin bilgisayarların işleyebileceği uygun formatlara dönüştürülmesi, kaydedilmesi ve basit ya da karmaşık analizlerde kullanılması hedeflenmektedir.

4.1.1. Veri Setleri

Tez çalışmasında gerçek trafik ortamında toplanan HDD ve Android işletim sistemine sahip akıllı telefonla kaydedilmiş veri setleri kullanılmaktadır. HDD kamuya açık veri seti Honda Araştırma Enstitüsü tarafından sözleşme karşılığında araştırmacılara sağlanmaktadır. Veriler sensör gruplarına göre virgülle ayrılmış değerler (CSV) formatında indirilebilmektedir. Akıllı telefon içerisindeki sensörlerle toplanan sürüş veri seti Karabük ili sınırları içerisinde farklı yol tipleri ve gerçek trafik koşullarında kaydedilmiştir.

4.1.1.1. Honda Sürüş Veri Seti

HDD kamera, LIDAR, GPS, IMU, CAN sensörleriyle donatılmış araçla, gerçek trafik ortamında, farklı hava koşulları ve yol tiplerinde 1 sürücü tarafından toplanmıştır. ABD'nin San Francisco bölgesinde, 27 Şubat 2017 - 6 Ekim 2017 tarihleri arasında şehir içi, şehir dışı, hemzemin geçitleri ve otoyollarda farklı zamanlarda 136 farklı sürüş içeren ve toplamda 104 saat veri bulunmaktadır. Çizelge 4.1'de HDD'de kullanılan sensörler ve veri seti özellikleri verilmiştir. Veri seti sürüş zamanı, araba hızı, gaz pedalı açısı, fren pedalı basıncı, enlem, boylam, direksiyon simidi açısı, direksiyon simidi dönüş hızı ve arabanın yalpalama oranı özellikleri içermektedir.

Çizelge 4.1. HDD'de kullanılan sensörler ve veri seti özellikleri.

Özellikler	HDD
CAN	✓
Farklı Sürüş Kaydı	136
GPS	✓
IMU	✓
Kamera	✓
LIDAR	✓
Sürücü Sayısı	1
Sürüş Süresi	104 saat
Tarafsız Sürüş Puanlaması	X
Yol Tipi	Şehir içi, Şehir dışı Otoyol, Hemzemin geçit

Toplanan ham veriler bilgisayarda işlenebilecek CSV formatına çevrilerek yayınlanmıştır. Aynı zamanda veri seti, sürüş verilerinin doğruluğunu ve güvenilirliğini kontrol edilebilmesini sağlayan araç içi kamerayla kaydedilmiş sürüş videolarına sahiptir. Ayrıca veri seti, sürüş karakterizasyonu sınıflandırmasında, otonom sürüş araştırmaları, sürücü hareketinin tahmin edilmesini ve sürücü destek sistemlerinin geliştirilmesini hedefleyen araştırmacılar için ölçeklenebilir yaklaşımla

hazırlanmıştır. Tez çalışmasında bu nedenle kamuya açık çok sayıda veri seti olmasına rağmen en güncel ve gerçek trafik koşullarında kaydedilen HDD kullanılması tercih edilmiştir [93].

4.1.1.2. Akıllı Telefonla Kaydedilen Veri Seti

Tez çalışması için mobil uygulama geliştirilerek toplanan veri seti Karabük ili sınırları içerisinde gerçek trafik ortamında şehir içi, şehir dışı ve otoyol üzerinde, farklı hava koşullarında ve saat dilimlerinde 1 sürücü tarafından kaydedilmiştir. 2020 Model 1.5 TSI motor ve DSG şanzımanlı Škoda Superb araca yerleştirilen Android 10 Q işletim sistemli Xiaomi Redmi Note 9 4GB RAM ve 128GB hafızaya sahip akıllı telefon ile veri toplanmıştır. Akıllı telefonda bulunan GPS, ivme ölçer ve jiroskop sensörleriyle toplam 6 saat ve 20 farklı sürüş verisi kaydedilmiştir. Çizelge 4.2’de kayıt sırasında kullanılan sensörler ve veri seti özellikleri verilmiştir.


Çizelge 4.2. Akıllı telefonla toplanan veri seti ve özellikleri.

Özellikler	Akıllı Telefonla Kaydedilen Veri Seti
CAN	X
Farklı Sürüş Kaydı	20
GPS	✓
İvme ölçer	✓
Jiroskop	✓
Kamera	X
LIDAR	X
Sürücü Sayısı	1
Sürüş Süresi	6 saat
Tarafsız Sürüş Puanlaması	✓
Yol Tipi	Şehir içi, Şehir dışı, Otoyol

Veri seti içerisinde 3 eksenli ivme, 3 eksenli jiroskop, enlem, boylam, rakım, hız ve sürücü puanı özellikleri bulunmaktadır. Farklı sürüş verilerine sahip olmak için bilinçli olarak farklı zamanlarda, yol tiplerinde ve trafik koşullarında sürüşler gerçekleştirilmiştir. Mobil uygulama geliştirilerek kaydedilen sürüş kayıtları daha sonra veri tabanı tarayıcısı (DB browser) uygulamasıyla bilgisayarın işleyebileceği CSV formatlı dosyalara dönüştürülmüştür.

4.2. VERİ ÖNİŞLEME

Veri önileme süreci, veri analizindeki kritik süreçlerden biridir. Kullanılacak verilerin analiz edilmeden önce kaliteli, tutarlı, eksiksiz, güvenilir ve yorumlanabilir olması gerekmektedir. Toplanan ham verilerin işlenmeden önce eksik ve gürültülü verilerden temizlenmesi, farklı kaynaklardan alınan verilerin birleştirilmesi, dönüştürülmesi analiz sonuçlarının başarısını arttırmada kritik süreçlerden biridir [103–105]. Tez çalışmasında veriler analiz edilmeden önce Şekil 4.1’de gösterilen veri önileme adımları takip edilmiştir.



Şekil 4.1. Veri önileme adımları.

4.2.1. Veri Temizleme

Kaydedilen veriler her zaman anlamlı olmayabilir. Veriler ölçüm hatası, alet, bilgisayar ya da insan hatasından kaynaklanan nedenlerle bazen tutarsız, gürültülü, hatalı ve eksik olarak kaydedilebilir. Veri temizleme sürecinde bu veriler veri kümesinden atılabilir, eksik değerlerin yerine sabit, ortalama, tahmini değerler eklenebilir ya da anlamlı verilerle düzeltilebilir. Bu verilerin analiz edilmeden önce veri kümesinden çıkarılması ya da düzeltilmesi sonuçların doğruluğu ve güvenilirliği açısından oldukça önemlidir [106].

4.2.2. Veri Birleřtirme

Veri birleřtirme, farklı kaynaklardan toplanan verilerin birlikte deęerlendirilebilmesi için uygun formatta birleřtirilerek bir bütn haline getirilmesi sürecidir [105]. Birden fazla veri kümesi kullanıldıęında aynı nitelikte fakat farklı isimlerle temsil edilen özellikler olabilir. Birbiriyle yüksek derecede korelasyonu olan iki nitelięin aynı anda kullanılması gereksiz veriye sebep olmaktadır. Veri birleřtirme süreci, birden fazla veri kümesinden gelen verilerin birleřtirilerek, tutarsızlıkları ve gereksiz verileri önlemeye, madencilik hızını ve kalitesini iyileřtirmeye katkı saęlamaktadır.

4.2.3 Veri Dnřtrme

Veri kümelerinde iřlenecek özelliklerin deęer aralıkları farklı olabilmektedir. Özelliklerin, ortalama ve varyansları farklı olduęu durumlarda büyük ortalama veya varyansa sahip özelliklerin sonuç üzerindeki etkisi daha fazla olmakta ve dięer özelliklerin sonuç üzerindeki etkisini önemli ölçde azalmaktadır. Bu durum özellikle nmerik veya istatistiksel yöntemlerle korelasyonu, doęrudan tespit edilmemiř veri setlerinde çok daha önemli bir gereklilik haline gelmektedir. Yapay zekâ uygulamalarında veri kümesinde yer alan özellięin etkisinin ne olacaęı geliřtirilen öęrenme modeli uygulandıęında ortaya çıktıęı için veri iřlemeden önce özelliklerin etkilerinin benzer olmasını saęlamak gerekmektedir. Farklı deęer aralıklarına sahip deęiřkenlerin birlikte deęerlendirilmesi için normalizasyon, standardizasyon, ondalık ölçekleme gibi yöntemler uygulanmaktadır [107]

4.3. ÖZELLİK ÇIKARMA

Özellik çıkarma, veri madencilięi tanımında ham verilerden türetilmiř yeni deęerler oluřturulması iřlemidir [108]. Birden fazla ham verilerden türetilen yeni bir özellik tek başına ham verileri temsil edebiliyorsa, ham veriler yerine türetilen özellik kullanılarak boyut indirilmesi yapılır eęer temsil edemiyorsa veri zenginleřtirme iřlemi gerçekleřtirilmiř olmaktadır.

4.4. VERİ GÖRSELLEŐTİRME

Görselleőtirme, sayısal veya karmaőık bilgilerin görsel olarak temsil edilmesini ve anlaşılabilirliğini arttıran yöntemdir [109]. Veri görselleőtirme ise veriyi hedeflenen kitleye őekiller, animasyonlar, grafikler vb. görsel materyaller kullanarak anlatma biçimidir [110]. Ayrıca veri görselleőtirme birden fazla verinin birlikte deęerlendirilmesini aynı zamanda korelasyon gibi iliőkilerin görsel olarak sunulmasını kolaylaőtirmektedir.

4.5. KURAL TABANLI ALGORİTMA

Kurallar, yani eęer o zaman ifadeleri (if-then) olarak çıkarımları belirlemek veya bazı tanımlı koőullar altında ki verilerle eylemleri iliőkilendirmek için kullanılmaktadır. Bu nedenle, kurallar uzman veya karar destek sistemlerinin aynı zamanda bilgi tabanlı kontrollerin en popöler yapı taőı olarak bilinmektedir. Kural tabanlı algoritma insan düşüncelerinin (koőullarının) bilgisayarda ifade edilebilmesi için gerekli olan soyutlama ve formal netlięi karşılaőtırmanın en iyi yollarından birini saęlamaktadır. Kural tabanlı sistemler genellikle bilgi tabanı, çıkarım motoru ve uygulama ara yüzünden oluşmaktadır. Bilgi tabanı, uygulama alanı hakkında bilgileri temsil eden kuralları içermektedir. Algoritmada kurallar tek tek çalıştırılır. En baştaki kuraldan başlayarak koőulların gerçekleşmesi veya gerçekleşmemesi durumlarına göre aőağıdaki koőullara doęru işler. Çıkarım motoru, hangi kuralların uygulanabileceğini kontrol eder ve çıkarımlarda bulunur. Dinamik ortam kurallamalarında yani deęişen farklı koőullar altında őartlar deęiőtğinde yeni kurallara ihtiyaç duyulabilir. Ayrıca eski (çöp) kuralların deęiőtikliğe uğraması ya da çıkarılması gerekebilir. Bu sebeplerle tasarlanan kural tabanlı sistemlerin ölçeklenebilir geliőtirmeye uygun olması gerekmektedir. Uygulama ara yüzü ise kullanıcının sistemle iletiőim kurabilmesini yani tüm koőullar işlendikten sonra gerçekleşen sonucun kullanıcıya bildirilmesini saęlamaktadır.

BÖLÜM 5

UYGULAMA VE DENEYSEL SONUÇLAR

Sürüş karakterizasyonu çıkarma sistemi, sürüş hareketlerini NHTSA kurallarına göre sınıflandıran, sunduğu görsellerle sürüş olaylarının kolay analiz edilebilir olmasını sağlayan bir ara yüz uygulamasıdır. Uygulama farklı yazılım dilleri ve kütüphaneler kullanılarak geliştirilmiştir. Çizelge 5.1’te kullanılan yazılımlar, kütüphaneler ve tercih edilen versiyonları verilmektedir. Uygulama geliştirmede kullanılan teknolojiler ve kütüphaneler açık kaynak kodlu ve ücretsizdir.

Çizelge 5.1. Uygulamada kullanılan yazılım dilleri ve kütüphaneler.

Yazılım ve Kütüphaneler	Versiyonlar
Android	10.0.0 (Q)
Bootstrap	3.3.7
Cascading Style Sheets (CSS)	3.0.0
Chart	2.8.0
Hypertext Markup Language (HTML)	5.2.0
Hypertext Preprocessor (PHP)	7.2.0
Java Script (JS)	ECMA Script 2020
Jquery	3.3.1
Leaflet	1.7.1
Papaparse	5.0.0
PostgreSQL	12.6.0

5.1. UYGULAMA

Tez çalışmasında veri toplama adımında akıllı telefonda bulunan ivme ölçer, jiroskop ve GPS sensör verileri Android uygulama geliştirilerek toplanmıştır. Geliştirilen uygulama sayesinde sürücünün hız, hızlanma, yavaşlama, durma ve dönüş verileri kaydedilmiştir.

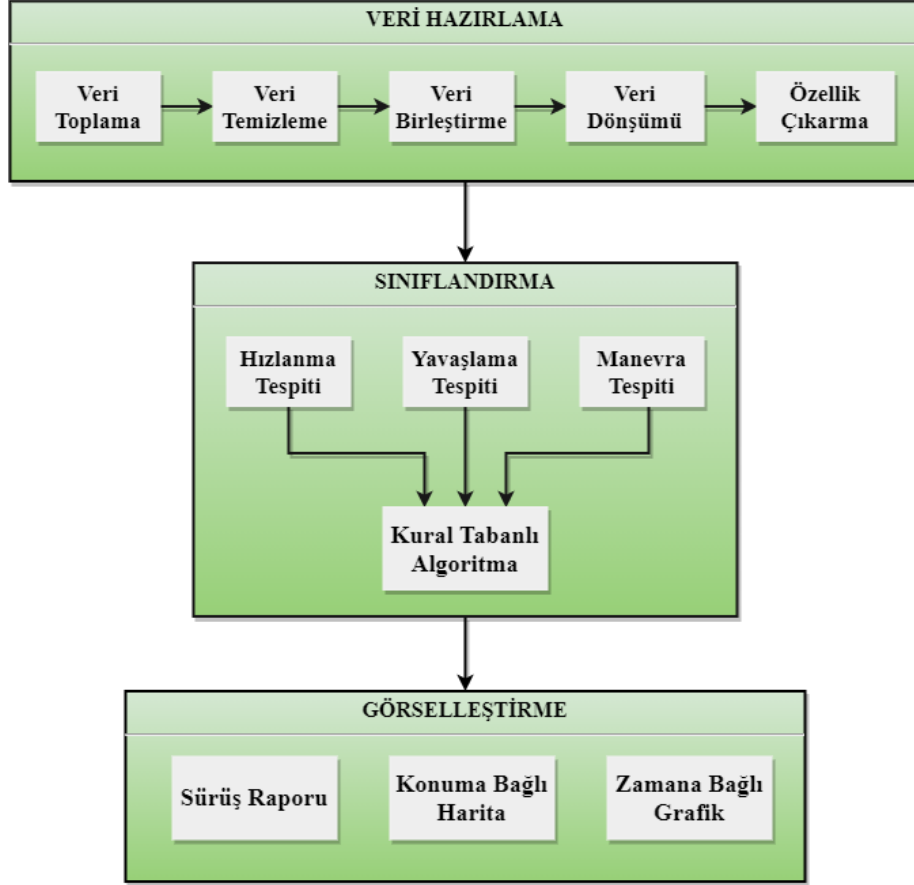
Çalışmada basamaklı stil şablonları (CSS) ve Bootstrap web sayfası tasarımını düzenlemek amacıyla kullanılmıştır.

JavaScript (JS), web ön yüzünde bulunan buton, animasyon, efekt vb. işlevlerin web tarayıcılarında dinamik olarak çalıştırılmasını sağlamaktadır. JS chart, jquery, leaflet, papaparse gibi kütüphaneleri içerisinde barındırmaktadır. Chart web uygulamalarında grafik görseller sağlayan ücretsiz JS kütüphanesidir. Sürüş verilerinin grafikler üzerinde görselleştirilmesi için chart kütüphanesi kullanılmıştır. Web sayfasında yer alan buton olayları, animasyon, açılır pencere, kayan görsel gibi görsel efektlerin oluşturulması ve dinamik olarak kullanılması için jquery kütüphanesi kullanılmıştır. Leaflet web uygulamalarında ücretsiz harita entegrasyonu sağlayan JS kütüphanesidir. Konum değişkenlerinin haritada üzerinde gösterilmesi için leaflet kütüphanesi kullanılmıştır. Papaparse, bilgisayar dosya sisteminde CSV formatındaki dosyaları web sayfalarında okumak ve ayrıştırmak için kullanılmıştır.

PostgreSQL yazılımı veri tabanı sisteminde veri kayıt, düzenleme ve sorgulama işlemleri için kullanılmıştır. Sunucu taraflı çalışan PHP programlama diliyle, sunucu taraflı çalışan veri tabanı bağlantısı ve çalıştırılan veri tabanı sorgusu sonuçlarının web sayfasında gösterilmesi sağlanmıştır.

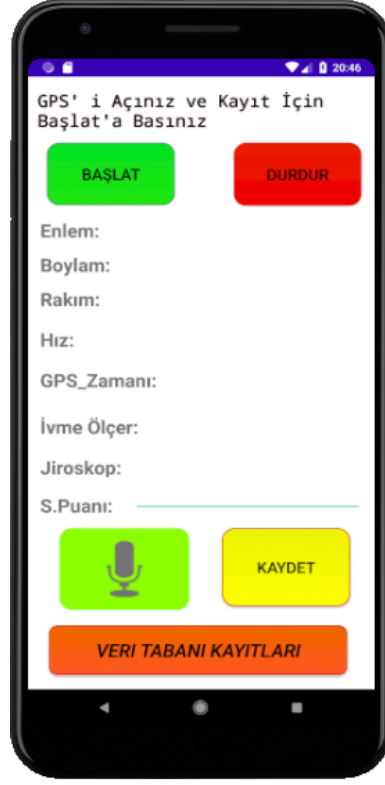
Uygulama genel yapısı 3 kısımdan oluşmaktadır. İlk kısımda veriler ön işleme adımlarından geçer ve özellik çıkarımı yapılır. Daha sonra veri ön işleme ve görselleştirme süreçlerinden geçirilmiş sürüş verileri için NHTSA tarafından belirlenmiş kriterlere göre sürüşlere puan verilerek sınıflandırma yapılmaktadır. Son kısımda ise GPS koordinatlarına göre aracın izlediği rota görselleştirilerek hız ve konum bilgisine göre gerçek sürüş simülasyonu gerçekleştirilmektedir. Aynı zamanda

uygulamanın sürüş esnasında gerçekleşen olaylara ait veriler ve çıkarılan özellikler ile harita görseli oluşturulmaktadır. Uygulamanın genel yapısı Şekil 5.1’de verilmiştir.



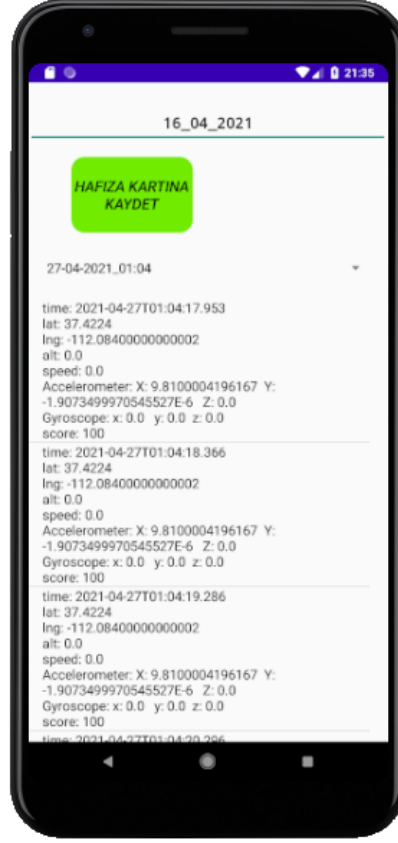
Şekil 5.1. Uygulama yapısı.

Tez çalışmasında veri toplama sürecinde HDD veri seti içerisinde yer alan hız, GPS, IMU verileri alınmış ve hız, hızlanma, yavaşlama, enlem, boylam, aracın boylamsal, yanal, dikey (roll, pitch, yaw) eksenlerindeki hareket değişkenleri seçilmiştir. Tez çalışmasında kullanılan diğer veri setinin oluşturulması için Android işletim sisteminde çalışan mobil bir uygulama geliştirilmiştir. Şekil 5.2’de veri toplama için geliştirilen mobil uygulamanın ekran görüntüsü yer almaktadır.



Şekil 5.2. Mobil uygulama veri kayıt başlatma ekranı.

Android işletim sistemine sahip akıllı telefon araç içerisine sabitlenerek 3 eksenli ivmeölçer ve 3 eksenli jiroskop ve GPS sensörleriyle zaman, hız, açısız hız, enlem, boylam, rakım verileri 1 Hz. frekans aralıklarıyla veri tabanına kaydedilmiştir. Ayrıca sürücü puanı veri girişi sürücü tarafından mikrofon veya dokunmatik klavye sayesinde yapılabilmektedir. Farklı zaman dilimlerinde gerçekleştirilen her sürüş tarih ve saat verisiyle birbirinden ayrılarak veri tabanına kaydedilmiştir. Şekil 5.3'te kaydedilen sürüş verilerin mobil uygulama ekran görüntüsü verilmektedir.



Şekil 5.3. Mobil uygulama veri kayıt gösterme ekranı.

Telefon hafızasında tablolar halinde bulunan veri tabanı kayıtları CSV formatına dönüştürülmüştür. Sürüş sırasında tekrar eden gürültülü veriler ayrıca gelen çağrı vb. nedenlerle kayıt işleminin durması sonucu oluşan hatalı veriler tespit edilmiştir. Tekrar eden veriler veri setinden çıkartılmış, hatalı veriler ise uygun değerlerle örneğin; SeksanDart – 84 olarak düzeltilmiştir. Bu sayede ham veriden güvenilir ve doğru sonuç almayı zorlaştıracı veriler temizlenmiştir. Daha sonra paparse JS kütüphanesi kullanılarak dosyaların web uygulama sistemine yüklenmesi sağlanmıştır. Sürücü bilgileri ve zaman değerine göre farklı zaman dilimlerinde toplanan ayrık veriler jquery JS kütüphanesi kullanılarak sıralı verilere dönüştürülmüş ve günlük sürüşler birleştirilmiştir. Birleştirilen sürüş kayıtları veri dönüşümü adımı için hazır hale getirilmiştir.

Değer aralıkları önemli ölçüde farklı olan hız, ivme, jiroskop, eğim, mesafe ve yalpalanma oranı varyans değerlerinin fazla uzak olması nedeniyle Eşitlik 5.1 ile ortalama, Eşitlik 5.2 ile varyans, Eşitlik 5.3 ile standart sapma ve Eşitlik 5.4 ile

standardizasyon hesaplamaları yapılarak birbiriyle değer aralıkları uzak olan özellikler dönüştürülmüştür.

$$\mu = \frac{1}{n} \sum_{i=1}^n x_i \quad (5.1)$$

$$X_{var} = \frac{\sum_{i=1}^n (x_i - \mu)^2}{n} \quad (5.2)$$

$$\sigma = \sqrt{\frac{\sum_{i=1}^n (x_i - \mu)^2}{n}} \quad (5.3)$$

$$X_{std} = \frac{x - \mu}{\sigma} \quad (5.4)$$

x; örnek, n; örnek sayısı, μ ; ortalama, X_{var} ; varyans, σ ; standart sapma, X_{std} ; standardize edilmiş örneği temsil etmektedir.

Veri dönüşümünün ardından özellik çıkarma adımı uygulanmıştır. Bu adımda eldeki değişkenlerden yeni özellikler türetilmiştir. Örneğin enlem ve boylam verilerinden, leaflet JS kütüphanesi kullanılarak rakım bilgisi çıkarılmış bu sayede yol koşulları daha çok detay içerecek şekilde zenginleştirilmiştir. Bu zenginleştirme işlemi hem HDD hem de kendi oluşturduğumuz veri seti için gerçekleştirilmiştir. Veri setinde bulunan enlem, boylam değişkenlerinden mesafe bilgisi, türetilen rakım bilgisinden eğim bilgisi elde edilmiştir. Hız değişkenlerine uygulanan özellik çıkarma sayesinde hızlanma ve yavaşlama bilgileri çıkarılmış, ivmeölçer ve jiroskop değişkenlerinden yalpalanma (yaw, pitch, row) bilgileri türetilmiştir. Özellik çıkarma sayesinde veri seti zenginleştirilerek harita ve grafik görsellerinde son kullanıcı için sunulan sürüşe ait bilgiler daha fazla detaylandırılacak şekilde görselleştirilmiş, aynı zamanda NHTSA yönergelerinde belirtilen hızlanma, yavaşlama ve dönme olaylarının tespiti için daha fazla girdi parametresi elde edilmiştir.

Şekil 5.4'te verilen ekran görüntüsünde, yükleme seçenekleri bölümünden seçilen sürüş bilgileriyle PostgreSQL veri tabanı sorgusu yapılarak seçilen tarihe ait sürüş


verileri çağırılmaktadır. Sorgu sonucu ulaşılan sürüşe ait zaman bilgileri enlem, boylam, rakım özellikleri leaflet kütüphanesi kullanılarak harita üzerinde görselleştirilmiştir. Aynı zamanda hız, hızlanma, yavaşlama, mesafe, ivme, jiroskop enlem, boylam, rakım, eğim ve sürücü puanı özellikleri grafikler kullanılarak son kullanıcıya sunulmuştur.

- a) Veri seti ve tarih seçimi ekran görüntüsü. b) Seçilen tarihe göre sürüş seçimi ekran görüntüsü.

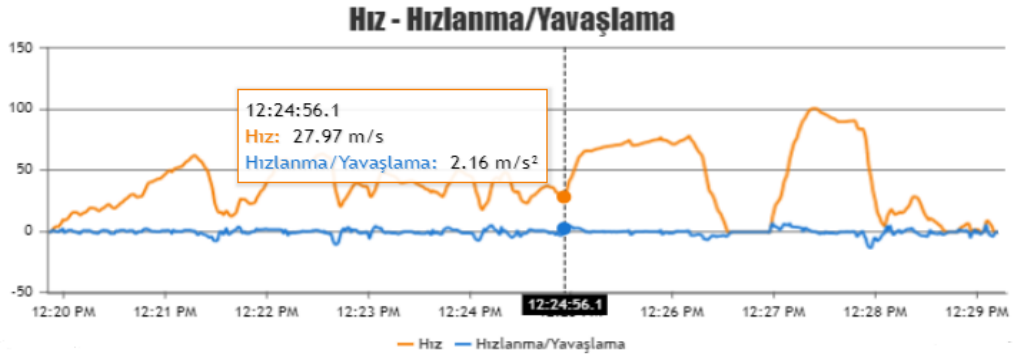
Şekil 5.4. Web uygulama sürüş yükleme seçenekleri ekran görüntüleri.

5.2. DENEYSEL SONUÇLAR

İvmenin, Y eksenindeki değişimi, aracın şerit değiştirmesini ve manevra yapmasını temsil etmektedir. X eksenindeki ivme değişiminden hızlanma ve yavaşlama olayları tespit edilmektedir. Z eksenindeki ivme değişimi, yokuş (rakım) inişi veya çıkışında gerçekleşen hıza bağlı yer değişimini temsil etmektedir. Tüm bu sürüş verileri web uygulama içerisinde grafikler yardımıyla görselleştirilmektedir. Uygulamada, araca ait ivme değerleri Şekil 5.5'te gösterilmektedir. Birim zamandaki hız ve bu bilgiden türetilen hızlanma ve yavaşlama değerleri Şekil 5.6'da gösterilmektedir.



Şekil 5.5. İvme ölçer grafiği.



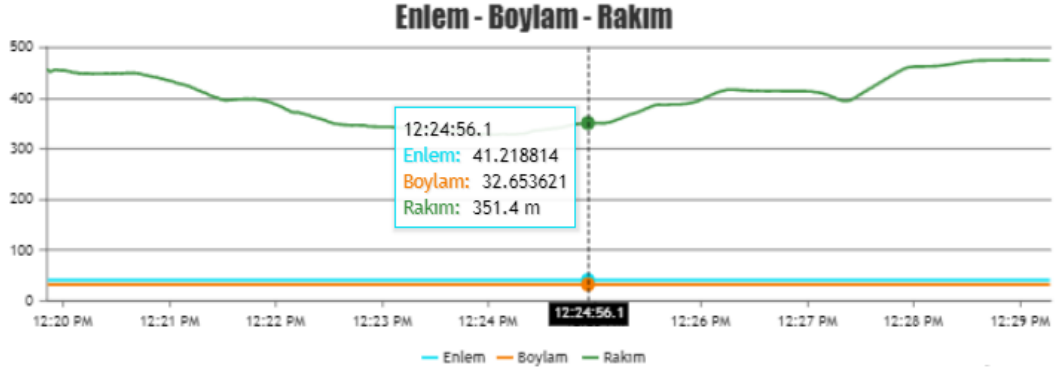
Şekil 5.6. Hız, hızlanma ve yavaşlama grafiği.

X, Y, Z eksenli jiroskop sensörüyle toplanan veriler Şekil 5.7’de gösterilmektedir. Jiroskop verileri, aracın yalpalanma yani sert kalkış veya duruş aynı zamanda sarsılma yani sağa veya sola dönüş, tümsekten veya çukurdan geçiş hareketlerini tespit etmek için kullanılmıştır. X ya da boylamsal olarak adlandırılan eksen değerleriyle ani şerit değiştirme ya da tümsek ve çukur geçişlerinde sarsılma olayları tespit edilmektedir. Y ya da yatay olarak adlandırılan eksen değerleriyle ani hızlanma ya da yavaşlama olayları tespit edilmektedir. Z ya da dikey olarak adlandırılan eksen değerleriyle ani manevra veya dönüş olayları tespit edilmektedir.



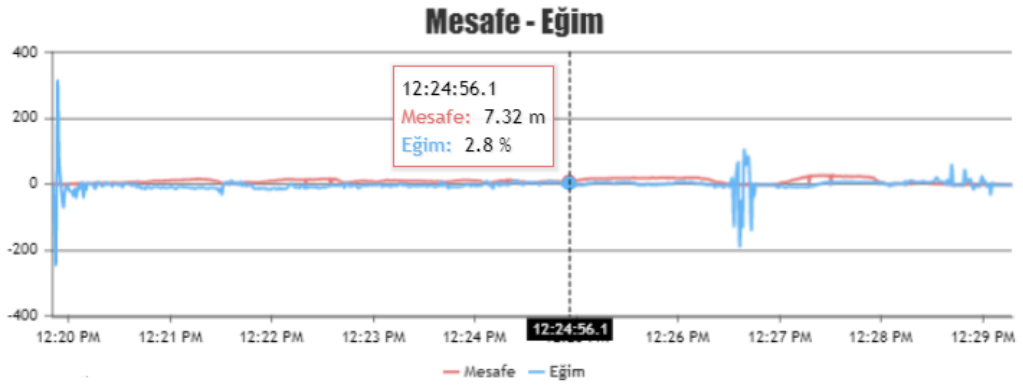
Şekil 5.7. X, Y, Z eksenli jiroskop grafiği.

Aracın enlem, boylam ve rakım değerleri Şekil 5.8’de gösterilmektedir. Görselleştirmede kullanılan enlem ve boylam değerleriyle şerit değiştirme, dönme, yön bilgileri tespit edilmiştir. Rakım değeriyle tümsek ya da çukur geçişleri aynı zamanda yokuş iniş ya da çıkış hareketleri tespit edilmiştir.




Şekil 5.8. Aracın enlem, boylam ve rakım grafiği.

Eğim değerleri, hızlanma, yavaşlama değerleriyle birlikte değerlendirildiğinde; rampa yollarda sürücünün iniş veya çıkış sırasındaki davranışlarının tespiti için zenginleştirilmiş eğim ve mesafe gibi ek bilgiler sağlamaktadır. Enlem ve boylam özellikleri kullanılarak sürüşün gerçekleştiği toplam yol uzunluğu ve birim zamandaki mesafe bilgisi elde edilmiştir. Şekil 5.9’da grafikte mesafe ve eğim değerleri verilmektedir.



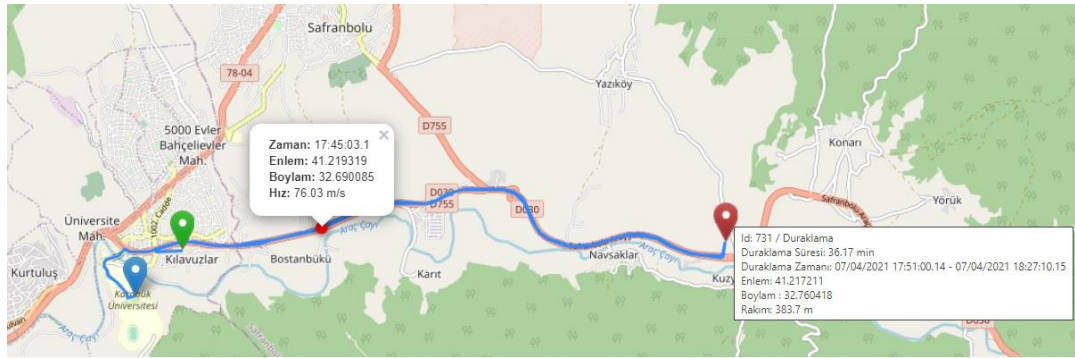
Şekil 5.9. Alınan mesafe ve yolun eğim grafiği.

Araç ve sürücü etkileşimi sonucunda verilen kümülatif sürüş puanları sürücünün aracı ne kadar çevreci kullandığını göstermektedir. Şekil 5.10’da sürücülerin elde ettiği zamana bağlı kümülatif sürüş puanları verilmektedir.



Şekil 5.10. Kümülatif sürücü puanları grafiği.

Şekil 5.11'de sürüşün başlangıç, duraklama, bitiş ve zamana bağlı rotaları harita üzerinde görselleştirilmektedir. Rota üzerindeki araç işaretçisine tıklandığında anlık olarak araç konumu, hızı, sürüş zamanı bilgileri açılır pencerede gösterilmektedir. Zamana ve konuma bağlı hız bilgisi sayesinde sürücünün o anda ki araç hızı ve konum bilgisine erişilmektedir. Harita üzerindeki mavi başlangıç ve yeşil bitiş işaretçilerinin üzerine tıklandığında bu noktaların konum bilgileri, hareket başlangıç ve bitiş zamanı bilgileri sunulmaktadır. Kırmızı duraklama işaretçisinin üzerine tıklandığında sürücünün hangi konumda ne kadar süre duraklama gerçekleştirdiği ve ne zaman hareket ettiği bilgisi verilmektedir.



Şekil 5.11. Harita açılır bilgi pencereleri ve konum işaretçileri.

NHTSA yönergelerine göre, trafikte güvensiz sürücülerin $2,7448 \text{ m/s}^2$ 'den daha fazla hızlanma yaptıkları $3,0398 \text{ m/s}^2$ 'den daha fazla yavaşlama yaptıkları, $6,7056 \text{ m/s}^2$ 'den yüksek dönüş yaptıkları değerlendirilmektedir. Agresif veya sakin sürücülerin bu olayları sıklıkla tekrar etmesi durumları istatistiksel yöntemlerle belirlenmiştir[112]. Bu tez çalışmasında NHTSA yönergelerinde belirlenen kurallara

göre sürüş karakterizasyonu sınıflandırılmaktadır. Çizelge 5.2’de NHTSA istatistiksel yöntemlerle elde edilmiş sürüş kuralları yer almaktadır.

Çizelge 5.2. NHTSA sürüş karakterizasyonu kuralları.

Sürüş Karakteri	Hızlanma	Yavaşlama	Dönüş
Sert	$2,7448 \text{ m/s}^2 < x$	$3,0398 \text{ m/s}^2 < x$	$6,7056 \text{ m/s}^2 < x$
Normal	$x = 2,7448 \text{ m/s}^2$	$x = 3,0398 \text{ m/s}^2$	$x = 6,7056 \text{ m/s}^2$
Sakin	$x < 2,7448 \text{ m/s}^2$	$x < 3,0398 \text{ m/s}^2$	$x < 6,7056 \text{ m/s}^2$

Bu belirlenen kurallara göre sınıflandırmada sürüşlerin zaman, hız, hızlanma, yavaşlama, eğim, rakım, mesafe, ivme ve jiroskop parametreleri birlikte değerlendirilerek sürüş boyunca sürücülerin sürüş karakteristiğini belirleyici ortalama hız, en yüksek hız, sert hızlanma, sert yavaşlama, toplam sürüş süresi, toplam alınan yol istatistikleri elde edilmiştir.

Şekil 5.12’de sürücülerin sınıflandırma sonucunda elde edilen verilerle hesaplanan sürüş raporu uygulama ekran görüntüleri gösterilmektedir. Ayrıca uygulamada sürüş karakteristiğini tespit etmek amacıyla oluşturulan harita, grafik ve sürüş raporu sonuçları birlikte değerlendirilerek sürüş karakteristiğini açıklayıcı bilgiler son kullanıcıya sunulmaktadır.



a) Mobil uygulamayla kaydedilen sürücü sonuçları.



b) HDD sürücü sonuçları.

Şekil 5.12. Sürücülerin sürüş raporu sonuçları.

BÖLÜM 6

TARTIŞMA VE SONUÇ

Bu tez çalışmasında, gerçek trafik koşullarında CAN, IMU, GPS, ivme ölçer ve jiroskop sensörleriyle kaydedilmiş kamuya açık verilerden ve mobil uygulama geliştirilerek oluşturulan veri seti ile NHTSA yönergelerine uygun olarak belirlenen kurallara göre sürüş karakteristiğini temsil eden hızlanma, yavaşlama, sağa ya da sola dönüş, rampa iniş ya da çıkış, durma ya da duraklama gibi ortak özellikler tespit edilmektedir. Elde edilen verilerden yeni özellikler türetilerek giriş verileri zenginleştirilerek ve sürüş karakteristiği sınıflandırılmaktadır. Uygulama sayesinde sürücünün; anlık hızı, ortalama ve en yüksek hızı, anlık hızlanma ve yavaşlama, sert hızlanma ve yavaşlama sıklığı, birim zamanda alınan yol uzunluğu, toplamda alınan yol uzunluğu, yolun anlık eğimi, aracın yalpalanma ve sarsılma şiddeti, hareket başlangıç bitiş noktalarının konumu, duraklama konumu ve süresi, ortalama sürücü puanı bilgileri elde edilmiştir. Geliştirilen web ara yüzü uygulamasında, haritalar ve grafiklerle bu bilgiler görselleştirilmiştir.

Daha önceki çalışmalarda sürüş karakterizasyonu sınıflandırılması için zengin özellikli veri seti kullanmanın sınıflandırma başarısı açısından yararlı olacağı önerilmiştir [12-17,111,112]. Veri setinde var olan değişkenlerle türettiğimiz yeni bilgiler sayesinde sürüş karakterizasyonu sınıflandırma başarısının artırılması için ek bilgiler çıkarılmıştır. Örneğin hız verisi kullanılarak hızlanma ve yavaşlama bilgileri, jiroskop ve ivme ölçer verileriyle yalpalanma ve sarsılma bilgileri elde edilmiştir. Daha önceki çalışmalardan farklı olarak veri setinde var olan enlem ve boylam verilerinden duraklama, anlık mesafe ve rakım bilgileri çıkarılarak veri seti özellikleri zenginleştirilmiştir. Ayrıca türetilen rakım özelliği kullanılarak yolun eğimi bilgileri elde edilmiş grafik ve harita görselleriyle tümsek, çukur, yokuş tespiti yapmak mümkün hale gelmiştir.

BÖLÜM 7

SINIRLILIKLAR VE GELECEK ÇALIŞMALARA KATKI

Tez çalışmasında, düşük maliyetle ve yüksek doğrulukla sonuçlar elde edilmesi amaçlanmıştır. Uygulamada veri kaynakları, yazılım teknolojileri açık kaynak kod kullanılarak ve tamamen ücretsiz olarak geliştirilmiştir. Araç kullanımının doğallığı ve öngörülemezliği nedeniyle sürüş karakteristiğini belirlemek oldukça zordur. Bu alanda birçok çalışma olmasına rağmen ücretsiz olarak yayınlanan veri kaynağının güvenilir, verilerinin tutarlı ve içeriğinin zengin olması gerekmektedir. Honda Araştırma Enstitüsü ile sözleşme karşılığı erişilen 104 saatlik HDD veri seti ve akıllı telefon uygulaması geliştirilerek toplanan mobil veri seti uygulamamızın veri büyüklüğü model geliştirme ve test aşamalarındaki sınırlılıklarını oluşturmaktadır.

Tez çalışması istatistiksel bilgilerin ve görsel ara yüzün birlikte kullanımı, araç ve sürücü verimliliğinin artırılması, rota optimizasyonunun sağlanması, denetlenen sürücülerin daha güvenli hale getirilerek trafik güvenliğinin artırılması gibi çeşitli iyileştirmelere olanak sağlamaktadır. Bu bilgiler kullanılarak sürücü destek sistemlerinin geliştirilmesi, filo yönetimi, sigorta fiyatlandırılması, yol ve araç düzeyi kontrolü, sürücü denetimi ve sürüş karakterizasyonu sınıflandırma alanlarında gelecekte yapılacak çalışmalara katkıda bulunmaktadır.

KAYNAKLAR

1. İnternet: World Health Organization, "Health topics/Road traffic injuries", <https://www.who.int/news-room/fact-sheets/detail/road-traffic-injuries> (2021).
2. İnternet: Türkiye Emniyet Genel Müdürlüğü, "Faaliyet Raporu", https://www.egm.gov.tr/kurumlar/egm.gov.tr/IcSite/strateji/Planlama/2020_IDARE_FAALİYET_RAPORU.pdf (2021).
3. İnternet: Türkiye İstatistik Kurumu, "Motorlu Kara Taşıtları İstatistikleri Aralık Bülteni", <https://data.tuik.gov.tr/Bulten/Index?p=Road-Motor-Vehicles-June-2021-37428> (2021).
4. İnternet: Türkiye Emniyet Genel Müdürlüğü, "Ülke Geneli Trafik İstatistik Bülteni", <http://trafik.gov.tr/kurumlar/trafik.gov.tr/04-Istatistik/Aylik/Mayis21.pdf>, (2021).
5. Reason, J., Manstead, A., Stradling, S., Baxter, J. and Campbell, K., "Errors and violations on the roads: A real distinction?", *Ergonomics*, 33 (10–11): 1315–1332 (1990).
6. Lawton, R., Parker, D., Manstead, A. S. R. and Stradling, S., "The role of affect in predicting social behaviors: The case of road traffic violations", *Journal Of Applied Social Psychology*, 27 (14): 1258–1276 (2006).
7. Taubman, B. A. O., Mikulincer, M. and Gillath, O., "The multidimensional driving style inventory - scale construct and validation", *Accident Analysis And Prevention*, 36 (3): 323–332 (2004).
8. Newnam, S., Greenslade, J., Newton, C. and Watson, B., "Safety in occupational driving: Development of a driver behavior scale for the workplace context", *Applied Psychology*, 60 (4): 576–599 (2011).
9. Harris, P. B., Houston, J. M., Vazquez, J. A., Smither, J. A., Harms, A., Dahlke, J. A. and Sachau, D. A., "The prosocial and aggressive driving inventory (PADI): A self-report measure of safe and unsafe driving behaviors", *Accident Analysis And Prevention*, 72: 1–8 (2014).
10. Xue, Q., Wang, K., Lu, J. J. and Liu, Y., "Rapid driving style recognition in car-following using machine learning and vehicle trajectory data", *Journal Of Advanced Transportation*, (2):1-11 (2019).

11. Quek, Z. F. and Eldwin, Ng., "Driver identification by driving style", Technical report in CS 229 Project, *Stanford University*, California, 1-4 (2013)
12. Fugiglando, U., Massaro, E., Santi, P., Milardo, S., Abida, K., Stahlmann, R., Netter, F. and Ratti, C., "Driving behavior analysis through can bus data in an uncontrolled environment", *IEEE Transactions On Intelligent Transportation Systems*, 20 (2): 737–748 (2019).
13. Dong, W., Li, J., Yao, R., Li, C., Yuan, T. and Wang, L., "Characterizing driving styles with deep learning", *arXiv preprint, arXiv:1607.03611* (2016).
14. Quintero, C. G. M., López, J. and Pinilla, A. "Driver behavior classification model based on an intelligent driving diagnosis system", *In 15th International IEEE Conference on Intelligent Transportation Systems*, Anchorage, 894-899 (2012).
15. Van, Ly M., Martin, S. and Trivedi, M. M., "Driver classification and driving style recognition using inertial sensors", *In IVth IEEE Intelligent Vehicles Symposium*, Gold Coast City, 1040-1045 (2013).
16. Siami, M., Naderpour, M. and Lu, J., "A mobile telematics pattern recognition framework for driving behavior extraction", *IEEE Transactions On Intelligent Transportation Systems*, 22 (3): 1459–1472 (2021).
17. Guo, J., Liu, Y., Zhang, L. and Wang, Y., "Driving behaviour style study with a hybrid deep learning framework based on gps data", *Sustainability*, 10 (7): 2351 (2018).
18. Zhang, J., Wu, Z., Li, F., Xie, C., Ren, T., Chen, J. and Liu, L., "A deep learning framework for driving behavior identification on in-vehicle can-bus sensor data", *Sensors*, 19 (6):1356 (2019).
19. Cheng, Z., Patel, M., Buthpitiya, S., Lyons, K., Harrison, B. and Abowd, G. D., "Driver classification based on driving behaviors", *Proceedings of the 21st International Conference on Intelligent User Interfaces*, California, 80-84 (2016).
20. Johnson, D. A. and Trivedi, M., "Driving style recognition using a smartphone as a sensor platform", *In 14th International IEEE Conference On Intelligent Transportation Systems (ITSC)*, Washington, 1609–1615 (2011).
21. Serttaş, T. N., Gerek, Ö. N. and Hocaoğlu, F. O., "Driver classification using k-means clustering of within-car accelerometer data", *In 27th Signal Processing and Communications Applications Conference (SIU)*, Sivas, 1-4 (2019).
22. Serttaş, T. N., Gerek, Ö. N. ve Hocaoğlu, F. O., "Gerçek zamanlı sürüş verileri ile sürücü davranışlarının belirlenmesi", *Afyon Kocatepe University Journal Of Sciences And Engineering*, 19 (3): 676–681 (2019).

23. Oppenheim, I. and Shinar, D., "Human Factors And Ergonomics", Handbook of Traffic Psychology, *Acedemic Press*, Massachusetts, 193–211 (2011).
24. Elander, J., West, R. and French, D., "Behavioral correlates of individual differences in road-traffic crash risk: An examination of methods and findings", *Psychological Bulletin*, 113 (2): 279–294 (1993).
25. Vivoli, R., Bergomi, M., Rovesti, S., Bussetti, P. and Guaitoli, G. M., "Biological and behavioral factors affecting driving safety", *Journal Of Preventive Medicine And Hygiene*, 47 (2): 69–73 (2006).
26. D'Agostino, C., Saidi, A., Scouarnec, G. and Chen, L., "Learning-based driving events classification", *In: 16th International IEEE Conference on Intelligent Transportation Systems (ITSC)*, The Hague, 1778-1783 (2013).
27. İnternet: Sala, J., Cades, D., Douglas, E., Krauss, D., Skow, E., "Human Factors in Transportation", <https://www.exponent.com/services/practices/engineering/human-factors/capabilities/human-factors-in-transportation-accidents> (2021).
28. Murphey, Y.L., Milton, R. and Kiliaris, L. "Driver's style classification using jerk analysis.", *IEEE Workshop on Computational Intelligence in Vehicles and Vehicular Systems (CIVVS)*, Nashville, 23-28. (2009).
29. Kang, H.B., "Various approaches for driver and driving behavior monitoring: A review", *IEEE International Conference On Computer Vision Workshops (ICCVW)*, Sydney, 616–623 (2013).
30. Bolovinou, A., Amditis, A., Bellotti, F. and Tarkiainen, M., "Driving style recognition for co-operative driving: A survey", *The Sixth International Conference on Adaptive and Self-Adaptive Systems and Applications*, Venice, 73-78 (2014).
31. Corti, A., Ongini, C., Tanelli, M. and Savaresi, S. M., "Quantitative driving style estimation for energy-oriented applications in road vehicles", *IEEE International Conference on Systems, Man and Cybernetics (SMC)*, Manchester, 3710-3715 (2013).
32. Fazeen, M., Gozick, B., Dantu, R., Bhukhiya, M. and González, M. C., "Safe driving using mobile phones", *IEEE Transactions On Intelligent Transportation Systems*, 13 (3): 1462–1468 (2012).
33. Stoichkov, R., "Android smartphone application for driving style recognition", Project Thesis, *Department of Electrical Engineering and Information Technology Institute for Media Technology Technical University of Munich*, Munich, 1-59 (2013).
34. Wu, M., Zhang, S. and Dong, Y., "A novel model-based driving behavior recognition system using motion sensors", *Sensors*, 16 (10): 1746 (2016).

35. Dhar, P., Shinde, S., Nikhil, J. and Bhaduri, A., "Unsafe driving detection system using smartphone as sensor platform", *International Journal of Enhanced Research in Management and Computer Applications*, 3 (3): 65-70 (2014).
36. Chen, Z., Yu, J., Zhu, Y., Chen, Y. and Li, M., "D3: Abnormal driving behaviors detection and identification using smartphone sensors", *In 12th Annual IEEE International Conference on Sensing, Communication, and Networking (SECON)*, Seattle, 524-532 (2015).
37. Eren, H., Makinist, S., Akin, E. and Yilmaz, A., "Estimating driving behavior by a smartphone", *In IVth IEEE Intelligent Vehicles Symposium*, Alcalá de Henares, 234-239 (2012).
38. Meseguer, J. E., Calafate, C. T., Cano, J. C. and Manzoni, P., "Driving styles: A smartphone application to assess driver behavior", *In 18th IEEE Symposium on Computers and Communications (ISCC)*, Split, 535-540 (2013).
39. Filev, D., Lu, J., Prakah-Asante, K. and Tseng, F., "Real-time driving behavior identification based on driver-in-the-loop vehicle dynamics and control", *IEEE International Conference on Systems, Man and Cybernetics (SMC)*, San Antonio, 2020-2025 (2009).
40. Dörr, D., Grabengieser, D. and Gauterin, F., "Online driving style recognition using fuzzy logic", *In 17th International IEEE Conference On Intelligent Transportation Systems (ITSC)*, Qingdao, 1021–1026 (2014).
41. Manzoni, V., Corti, A., De Luca, P. and Savaresi, S. M., "Driving style estimation via inertial measurements", *In 13th International IEEE Conference on Intelligent Transportation Systems*, Funchal, 777-782 (2010).
42. Choi, S., Kim, J., Kwak, D., Angkititrakul, P. and Hansen, J., "Analysis and classification of driver behavior using in-vehicle can-bus information", *In Biennial workshop on DSP for in-vehicle and mobile systems*, 17-19 (2007).
43. Jain, J. J. and Busso, C., "Analysis of driver behaviors during common tasks using frontal video camera and can-bus information", *IEEE International Conference on Multimedia and Expo*, Barcelona, 1-6 (2011).
44. Kedar-Dongarkar, G. and Das, M., "Driver classification for optimization of energy usage in a vehicle", *Procedia Computer Science*, 8: 388–393 (2012).
45. Kwak, B., Woo, J. and Kim, H. K., "Know your master: Driver profiling-based anti-theft method", *In 14th Annual Conference on Privacy, Security and Trust (PST)*, Auckland, 211-218 (2016).
46. Mudgal, A., Hallmark, S., Carriquiry, A. and Gkritza, K., "Driving behavior at a roundabout: A hierarchical bayesian regression analysis", *Transportation Research Part D-Transport And Environment*, 26: 20–26 (2014).

47. Constantinescu, Z., Marinoiu, C. and Vladoiu, M., "Driving style analysis using data mining techniques", *International Journal Of Computers Communications and Control*, 5: 654–663 (2010).
48. Grengs, J., Wang, X. and Kostyniuk, L., "Using GPS data to understand driving behavior", *Journal Of Urban Technology*, 15: 33–53 (2008).
49. Vaitkus, V., Lengvenis, P. and Zylius, G., "Driving style classification using long-term accelerometer information", *In 19th International Conference On Methods And Models In Automation And Robotics (MMAR)*, Miedzyzdroje, 641–644 (2014).
50. Cao, W., Lin, X., Zhang, K., Dong, Y., Huang, S. and Zhang, L., "Poster Abstract: Analysis and evaluation of driving behavior recognition based on a 3-axis accelerometer using a random forest approach", *In 16th ACM/IEEE International Conference On Information Processing In Sensor Networks (IPSN)*, Pittsburgh, 303–304 (2017).
51. Carvalho, E., Ferreira, B. V., Ferreira, J., De Souza, C., Carvalho, H. V., Suhara, Y., Pentland, A. S. and Pessin, G., "Exploiting the use of recurrent neural networks for driver behavior profiling", *IEEE International Joint Conference on Neural Networks (IJCNN)*, Anchorage, 3016-3021 (2017).
52. Chang, K., Oh, B. H. and Hong, K. S., "An implementation of smartphone-based driver assistance system using front and rear camera", *IEEE International Conference on Consumer Electronics (ICCE)*, Las Vegas, 280-281 (2014).
53. Yang, C. Y. and Najm, W., "Examining driver behavior using data gathered from red light photo enforcement cameras.", *Journal Of Safety Research*, 38 (3): 311–321 (2007).
54. Friedrichs, F. and Yang, B., "Camera-based drowsiness reference for driver state classification under real driving conditions", *In IVth IEEE Intelligent Vehicles Symposium*, San Diego, 101-106 (2010).
55. Li, C., Dai, B., Wu, T. and Nie, Y., "Multi-lane detection in urban driving environments employing omni-directional camera", *IEEE International Conference on Information and Automation (ICIA)*, Hailar, 284-289 (2014).
56. Chen, Y., Wang, J., Li, J., Lu, C., Luo, Z., Xue, H. and Wang, C., "LiDAR-video driving dataset: Learning driving policies effectively", *In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Salt Lake City, 5870-5878 (2018).
57. Xiong, H. and Boyle, L. N., "Drivers' adaptation to adaptive cruise control: Examination of automatic and manual braking", *IEEE Transactions On Intelligent Transportation Systems*, 13 (3): 1468–1473 (2012).

58. Lee, H. and Coifman, B., "Using LiDAR to validate the performance of vehicle classification stations", *Journal Of Intelligent Transportation Systems*, 19: 355–369 (2015).
59. Wang, W. and Xi, J., "A rapid pattern-recognition method for driving styles using clustering-based support vector machines", *American Control Conference (ACC)*, Boston, 5270–5275 (2016).
60. Wakita, T., Ozawa, K., Miyajima, C., Igarashi, K., Itou, K., Takeda, K. and Itakura, F., "Driver identification using driving behavior signals", *IEICE Transactions on Information and Systems*, 89 (3): 1188-1194 (2005).
61. Park, S. and Lim, H. K., "Characteristics of elderly drivers' driving behavior and cognition under unexpected event using driving simulator", *SAE Technical Paper*, Series No. 2011-01-0552, (2011).
62. Shiiba, T. and Suda, Y., "Evaluation of drivers' behavior with multibody-based driving simulator", *Multibody System Dynamics*, 17 (2): 195–208 (2007).
63. Chen, L. and Ulsoy, A. G., "Identification of a driver steering model and model uncertainty, from driving simulator data", *Journal Of Dynamic Systems Measurement And Control-Transactions Of The Asme*, 123: 623–629 (2001).
64. Chhabra, R., Verma, S. and Krishna, C. R., "A survey on driver behavior detection techniques for intelligent transportation systems", *In 7th International Conference on Cloud Computing, Data Science and Engineering-Confluence*, Noida, 36-41 (2017).
65. Oh, C., Jung, E., Rim, H., Kang, K. and Kang, Y., "Intervehicle Safety Warning Information System for Unsafe Driving Events", *Transportation Research Record*, 2324: 1–10 (2012).
66. Zaki, M. H., Sayed, T. and Shaaban, K., "Use of drivers' jerk profiles in computer vision-based traffic safety evaluations", *Transportation Research Record*, 2434: 103–112 (2014).
67. Hasan, M., Cuneo, D. and Chachich, A., "Analysis of traffic video to develop driver behavior models for microscopic traffic simulation", *In Proceedings of Conference on Intelligent Transportation Systems*, Boston, 747-752 (1997).
68. Gu, X., Abdel-Aty, M., Xiang, Q., Cai, Q. and Yuan, J., "Utilizing UAV video data for in depth analysis of drivers' crash risk at interchange merging areas.", *Accident Analysis And Prevention*, 123: 159–169 (2019).
69. Deery, H. and Fildes, B., "Young novice driver subtypes: Relationship to high-risk behavior, traffic accident record and simulator driving performance", *Human Factors: The Journal Of Human Factors And Ergonomics Society*, 41: 628–643 (1999).

70. Kumar, P., Ranganath, S., Weimin, H. and Sengupta, K., "Framework for real-time behavior interpretation from traffic video", *IEEE Transactions On Intelligent Transportation Systems*, 6 (1): 43–53 (2005).
71. Kuhler, M. and Karstens, D., "Improved driving cycle for testing automotive exhaust emissions", *SAE Technical Paper*, Series No.780650, (1978).
72. Ericsson, E., "Variability in urban driving patterns", *Transportation Research Part D: Transport And Environment*, 5 (5): 337–354 (2000).
73. Langari, R. and Won, J. S., "Intelligent energy management agent for a parallel hybrid vehicle-part I: system architecture and design of the driving situation identification process", *IEEE Transactions On Vehicular Technology*, 54 (3): 925–934 (2005).
74. Huang, X., Tan, Y. and He, X., "An intelligent multifeature statistical approach for the discrimination of driving conditions of a hybrid electric vehicle", *IEEE Transactions On Intelligent Transportation Systems*, 12 (2): 453–465 (2011).
75. Guardiola, C., Pla, B., Blanco-Rodriguez, D. and Reig, A., "Modelling driving behaviour and its impact on the energy management problem in hybrid electric vehicles", *International Journal Of Computer Mathematics*, 91: 147–156 (2014).
76. Lenaers, G., "Real life CO 2 emission and consumption of four car powertrain technologies related to driving behaviour and road type", *SAE Technical Paper*, Series No. 2009-24-0127, (2009).
77. Syed, F. U., Filev, D. and Ying, H., "Fuzzy rule-based driver advisory system for fuel economy improvement in a hybrid electric vehicle", *Annual Meeting of the North American Fuzzy Information Processing Society*, San Diego, 178-183 (2007).
78. Neubauer, J. and Wood, E., "Accounting for the variation of driver aggression in the simulation of conventional and advanced vehicles", *National Renewable Energy Laboratory (NREL)*, Golden, 1-8 (2013).
79. Ericsson, E., "Independent driving pattern factors and their influence on fuel-use and exhaust emission factors", *Transportation Research Part D: Transport And Environment*, 6 (5): 325–345 (2001).
80. Doshi, A. and Trivedi, M. M., "Examining the impact of driving style on the predictability and responsiveness of the driver: Real-world and simulator analysis", *In IVth IEEE Intelligent Vehicles Symposium*, La Jolla, 232-237 (2010).
81. Syed, F. U., Filev, D., Tseng, F. and Ying, H., "Adaptive real-time advisory system for fuel economy improvement in a hybrid electric vehicle", *Annual Meeting of the North American Fuzzy Information Processing Society*, New

- York, 1-6 (2009).
82. Xu, L., Hu, J., Jiang, H. and Meng, W., "Establishing style-oriented driver models by imitating human driving behaviors", *IEEE Transactions On Intelligent Transportation Systems*, 16 (5): 2522–2530 (2015).
 83. Miyajima, C., Nishiwaki, Y., Ozawa, K., Wakita, T., Itou, K., Takeda, K. and Itakura, F., "Driver modeling based on driving behavior and its evaluation in driver identification", *Proceedings Of The IEEE*, 95 (2): 427–437 (2007).
 84. Huang, J., Chen, Y., Peng, X., Hu, L. and Cao, D., "Study on the driving style adaptive vehicle longitudinal control strategy", *IEEE/CAA Journal Of Automatica Sinica*, 7 (4): 1107–1115 (2020).
 85. Padmarajan, B. V., McGordon, A. and Jennings, P., "An investigation on the effect of driver style and driving events on energy demand of a PHEV", *World Electric Vehicle Journal*, 5: 173–181 (2012).
 86. Lee, T. and Son, J., "Relationships between driving style and fuel consumption in highway driving", *SAE Technical Paper*, Series No. 2011-28-0051, (2011).
 87. Karginova, N., Byttner, S. and Svensson, M., "Data-driven methods for classification of driving styles in buses", *SAE Technical Paper*, Series No. 2012-01-0744, (2012).
 88. Syed, F., Nallapa, S., Dobryden, A., Grand, C., McGee, R. and Filev, D., "Design and analysis of an adaptive real-time advisory system for improving real world fuel economy in a hybrid electric vehicle", *SAE Technical Paper*, Series No. 2010-01-0835, (2010).
 89. Wang, R. and Lukic, S. M., "Review of driving conditions prediction and driving style recognition based control algorithms for hybrid electric vehicles", *IEEE Vehicle Power and Propulsion Conference*, Chicago, 1-7 (2011).
 90. Gilman, E., Keskinarkaus, A., Tamminen, S., Pirttikangas, S., Rönning, J. and Riekki, J., "Personalised assistance for fuel-efficient driving", *Transportation Research Part C: Emerging Technologies*, 58: 681–705 (2015).
 91. Augustynowicz, A., "Preliminary classification of driving style with objective rank method", *International Journal Of Automotive Technology*, 10 (5): 607–610 (2009).
 92. Lei, Y., Liu, K., Fu, Y., Li, X., Liu, Z. and Sun, S., "Research on driving style recognition method based on drivers' dynamic demand", *Advances In Mechanical Engineering*, 8 (9): 1–14 (2016).
 93. Ramanishka, V., Chen, Y. T., Misu, T. and Saenko, K., "Toward driving scene understanding: A dataset for learning driver behavior and causal reasoning", *Proceedings Of The IEEE Computer Society Conference On Computer*

Vision And Pattern Recognition, Salt Lake City, 7699–7707 (2018).

94. Da Silveira Barreto, C. A., Xavier-Júnior, J. C., Canuto, A. M. P. and Da Silva, I. M. D., "A Machine learning approach based on automotive engine data clustering for driver usage profiling classification", *Proceedings Of The National Meeting Of Artificial and Computational Intelligence (ENIAC)*, Porto Alegre, 174-185 (2018).
95. Rettore, P. H. L., Campolina, A. B., Souza, A., Maia, G., Villas, L. A. and Loureiro, A. A. F., "Driver authentication in VANET's based on intra-vehicular sensor data", *IEEE Symposium on Computers and Communications (ISCC)*, Natal, 78-83 (2018).
96. Bärghman, J., Nes, N., Christoph, M., Jansen, R., Heijne, V., Carsten, O., Dotzauer, M., Utech, F., Svanberg, E., Cocron, P. M., Forcolin, F., Kovaceva, J., Guyonvarch, L., Hibberd, D., Lotan, T., Winkelbauer, M., Sagberg, F. and Fox, C., "The UDRIVE dataset and key analysis results; Deliverable 41.1 of the EU FP7 project UDRIVE Consortium", *European Commission*, Brussels, (2017).
97. Kaiser, C., Festl, A., Pucher, G., Fellmann, M. and Stocker, A., "The vehicle data value chain as a lightweight model to describe digital vehicle services", *In 15th International Conference on Web Information Systems and Technologies*, 68-79 (2019).
98. Jain, A., Koppula, H. S., Soh, S., Raghavan, B., Singh, A. and Saxena, A., "Brain4Cars: Car that knows before you do via sensory-fusion deep learning architecture", *arXiv Preprint*, arXiv:1601.00740, (2016).
99. Santana, E. and Hotz, G., "Learning a driving simulator", *arXiv Preprint*, arXiv:1608.01230, (2016).
100. Romera, E., Bergasa, L. M. and Arroyo, R., "Need data for driver behaviour analysis? Presenting the public UAH-DriveSet", *In IEEE 19th International Conference on Intelligent Transportation Systems (ITSC)*, Rio de Janeiro, 387-392 (2016).
101. Schneegass, S., Pfleging, B., Broy, N., Schmidt, A. and Heinrich, F., "A data set of real world driving to assess driver workload", *Proceedings of the 5th International Conference on Automotive User Interfaces and Interactive Vehicular Applications*, Eindhoven, 150-157 (2013).
102. Hansen, J.H.L., Busso, C., Zheng, Y. and Sathyanarayana, A., "Driver modeling for detection and assessment of driver distraction: Examples from the UTDrive test bed", *IEEE Signal Processing Magazine*, 34 (4): 130-142 (2017)
103. Mirza, S., Mittal, S. and Zaman, M., "A review of data mining literature", *International Journal Of Computer Science And Information Security*, 14 (11): 437–442 (2016).

104. Ramírez-Gallego, S., Krawczyk, B., García, S., Woźniak, M. and Herrera, F., "A survey on data preprocessing for data stream mining: Current status and future directions", *Neurocomputing*, 239: 39–57 (2017).
105. Alasadi, S., "Review of data preprocessing techniques in data mining", *Journal Of Engineering And Applied Sciences*, 12: 4102–4107 (2017).
106. Dasu, T. and Johnson, T., "Exploratory Data Mining and Data Cleaning: An Overview", *Exploratory Data Mining and Data Cleaning*, *John Wiley and Sons.*, 479:1–16 (2003).
107. Oğuzlar, A., "Veri ön işleme", *Erciyes Üniversitesi İktisadi Ve İdari Bilimler Fakültesi Dergisi*, (21): 67–76 (2003).
108. Pechenizkiy, M., Puuronen, S. and Tsymbal, A., "Feature extraction for classification in the data mining process", *International Journal "Information Theories and Applications*, 10 (1): 271–278 (2003).
109. Kibar, P. ve Akkoyunlu, B., "Eğitimde Bilgi Görselleştirme: Kavram Haritalarından İnfografiklere", *Eğitim Teknolojileri Okumaları*, Ankara, 271–287 (2015).
110. Gürler, A., Yılmaz, A. S. ve Tekerek, M., "Veri görselleştirme ve infografikler", *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*, 21 (2): 131–148 (2018).
111. Klauer, S. G., Dingus, T. A., Neale, V. L., Sudweeks, J. D. and Ramsey, D. J., "Comparing Real-World Behaviors of Drivers with High Versus Low Rates of Crashes and Near Crashes", *National Highway Traffic Safety Administration*, Washington, 1-204 (2009).
112. Toledo, T., Musicant, O. and Lotan, T., "In-vehicle data recorders for monitoring and feedback on drivers' behavior", *Transportation Research Part C: Emerging Technologies*, 16 (3): 320–331 (2008).

ÖZGEÇMİŞ

Furkan ÇAKMAK ilk, orta ve lise öğrenimini Bursa'da tamamladı. 2013 yılında Karabük Üniversitesi Bilgisayar Mühendisliği (İngilizce) Bölümü'nde öğrenimine başlayıp 2018 yılında iyi derece ile mezun oldu. 2018 yılında Karabük Üniversitesi Lisansüstü Eğitim Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı'nda yüksek lisans öğrenimine başladı. 2019 ve 2020 yıllarında Karabük Ticaret ve Sanayi Odası'nda yazılım geliştirme, eğitim ve danışmanlık hizmeti verdi. 2021 yılında TÜBİTAK Ulusal Elektronik ve Kriptoloji Araştırma Enstitüsü'nde göreve başladı ve halen çalışmaya devam etmektedir.