

Web Tabanlı Sürücü Davranışları Analiz Uygulaması

Nesrin AYDIN ATASOY^{a,*}, Furkan ÇAKMAK^b

^{a,*} Karabük Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği Bölümü, 78050, Karabük, Türkiye.

^b Karabük Üniversitesi Lisansüstü Eğitim Enstitüsü Bilgisayar Mühendisliği Bölümü, 78050, Karabük, Türkiye.

MAKALE BİLGİSİ

Alınma: 29.05.2021
Kabul: 21.09.2021

Anahtar Kelimeler:
Sürücü davranış
sınıflandırma, Sürüş
olayları görselleştirme,
Web tabanlı sürüş
analizi

ÖZ

İnsan faktörü, trafik kazalarına neden olan sebepler arasında ilk sırada yer almaktadır. Özellikle büyük şehirlerde sürücü ve taşıt sayılarının fazla olması trafikte risk oranını artırmaktadır. Günlük hayatta, sürücü davranışları denetlenen sürürlere göre farklılık göstermektedir. Bu nedenle, trafik kazalarının önlenmesinde sürücülerin sürüş esnasındaki davranışlarını tespit etmek önemli bir konu haline gelmiştir. Sürücülerin davranışlarını tespit etmek için akıllı telefon, kamera, ivme ölçer, jiroskop, kontrol alan ağı, ışın algılama mesafe ölçümü, inersiyel ölçme ünitesi gibi cihaz ve sensör yardımıyla sürüş verileri toplanabilir. Sürüşleri tanımlamak ve değerlendirmek için sürücü psikolojisi, çevresel faktörler, yol durumu, araç kinematiği gibi farklı biyolojik ve fizyolojik faktörlerin dikkate alınması gereklidir. Bu çalışmada gerçek trafik ortamlarında kaydedilmiş iki farklı veri setine ait sürüş verileri kullanılmıştır. Her iki veri seti üzerinde ABD Ulusal Karayolu Trafik Güvenliği İdaresine göre sert hızlanma-yavaşlama ve manevra olayları tespit edilmiş ve sürücü davranışı tanımlaması gerçekleştirilmiştir. Geliştirilen web tabanlı yazılım ile araçtan elde edilen verilere göre çıkarılan özellikler grafiksel ve istatistiksel olarak sunulmuştur. Ayrıca, yolculukla ilgili rota, hız, durma ve duraklama gibi olaylar harita üzerinde kullanıcı dostu arayüz ile sürücü davranışlarının tanımlanması için görselleştirilmiştir. Sürüş sonunda sürücünün puan grafiği ve sürüş raporu sonuçları oluşturulmaktadır.

<https://dx.doi.org/10.30855/gmbd.2021.03.09>

Web Based Driver Behaviors Analysis Application

ARTICLE INFO

Received: 29.05.2021
Accepted: 21.09.2021

Keywords:
Driver behavior
classification, Driving
events visualization,
Web-based driving
analysis

ABSTRACT

The human factor ranks first among the causes of traffic accidents. Especially in big cities, the high number of drivers and vehicles increases the risk ratio in traffic. In daily life, driver behavior differs according to supervised driving. For this reason, it has become an important issue to determine the behavior of drivers while driving in the prevention of traffic accidents. In order to detect the behavior of the drivers, driving data can be collected with the help of devices and sensors such as smart phone, camera, accelerometer, gyroscope, control area network, beam detection distance measurement, inertial measurement unit. It is necessary to consider different biological and physiological factors such as driver psychology, environmental factors, road condition, vehicle kinematics in order to define and evaluate drives. In this study, driving data belonging to two different data sets recorded in real traffic environments are used. On both data sets, according to the US National Highway Traffic Safety Administration, severe acceleration-deceleration and maneuvering incidents were detected and driver behavior was defined. With the developed web-based software, the features extracted according to the data obtained from the tool are presented graphically and statistically. In addition, events such as route, speed, stop and stop related to the journey are visualized on the map with a user-friendly interface to define driver behaviors. At the end of the ride, the driver's score graph and driving report results are created.

<https://dx.doi.org/10.30855/gmbd.2021.03.09>

*Sorumlu yazar: nesrinaydin@karabuk.edu.tr

To cite this article: N.A. Atasoy and F. Çakmak, "Web Based Driver Behaviours Analysis Applications", *Gazi Journal of Engineering Sciences*, vol.7, no.3, 264-276, 2021. doi:10.30855/gmbd.2021.03.09

1. GİRİŞ (INTRODUCTION)

Trafik kazaları ülkelerin ve toplumların başlıca sorunlarından biridir. Dünya Sağlık Örgütü (DSÖ) verilerine göre dünyada her yıl yaklaşık 1,35 milyon kişi trafik kazaları nedeniyle hayatını kaybetmektedir [1]. Trafik kazalarının meydana gelmesinde araç yapısı, yol, hava koşulları ve insan faktörü gibi birçok etken vardır. Bu etkenler incelendiğinde ilk sırada insan faktörü yer almaktadır [2]. Amerika Birleşik Devletleri (ABD) Ulaştırma Bakanlığı Federal Karayolu İdaresi 2019 yılı verilerine göre ABD’ de 276 milyon 491 bin 174 kayıtlı araç vardır [3]. Avrupa Otomobil Üreticileri Birliği verilerine göre Avrupa Birliğinde 308 milyon 392 bin 804 kayıtlı araç bulunmaktadır [4]. Türkiye İstatistik Kurumu (TÜİK) verilerine göre 2020 Aralık ayı sonu itibariyle ülkemizde trafiğe kayıtlı 24 milyon 64 bin 532 taşıt bulunmaktadır [5]. Sürücü belgesine sahip kişi sayısı ise 30 milyon 541 bin 611 kişiye ulaşmıştır [6]. Özellikle büyük şehirlerde bulunan sürücü ve taşıtların sayılarına bakıldığında trafikte risk oranı hayli yüksektir. Aynı zamanda sürücülerin, sürücü belgesi alma esnasındaki denetlenen sürüşleri ile günlük hayattaki denetlenmeyen sürüşleri birbirinden oldukça farklılık gösterebilmektedir. Bu bakımdan sürücülerin günlük sürüş davranışlarının incelenmesi ve sürüşlerin denetlenmesi kazaların azalmasında çok önemli bir etkidir. Bu sebeple denetim için yasalarla belirlenmiş bazı ticari araçlarda, araç kullanım süresi, mesafe ve hız bilgilerinin kayıt altına alınması amacıyla takograf adı verilen cihazlar kullanılmaktadır. Ancak diğer araçlar için böyle bir zorunluluk ve denetim mekanizması bulunmamaktadır. Denetlenen parametreler ise insani temel gereksinimlerin sağlanmasına yöneliktir.

Sürücü davranışlarının tanımlanması, sürücü ve trafik durumlarının çeşitli özelliklerine bağlı olmasından dolayı karmaşık bir konu olarak kabul edilir [7]. Sürücü davranışlarının doğru tanımlanması için araçların sürüşle ilgili bilgiler sağlayacak sensör ve donanımlara sahip olmaları gerekir. Sürüş davranışlarını tanımlamak ve değerlendirmek için sürücü psikolojisi, çevresel faktörler, yol durumu, araç kinematığı gibi farklı biyolojik ve fizyolojik faktörlerin dikkate alınması gereklidir [8]. Tüm bu faktörlere dayalı doğru ve eksiksiz bir model oluşturmak oldukça zordur. Sürüş davranışlarının modellenmesi kaza riskinin azaltılmasıyla birlikte enerji verimliliği ve risk analizi gibi çözümler üretilmesine katkı sağlar.

Filolar, araç kiralama şirketleri ve sigorta şirketleri sürücülerin kaza risklerini istatistiksel olarak belirlenmiş parametrelere göre değerlendirmekte ve bu değerlendirmelere göre fiyatlandırma yapmaktadır. Kamusal ve kurumsal araç filo yönetiminde, taşıt temininin ve kullanımının, sürücülerin ve taşıtların verimlilik gibi süreçlerinin planlanması oldukça önemli bir gerekliliktir. Sürücülerin bireysel araç kullanım davranışları takip edilerek güvenlik, verimlilik ve risk oranları belirlenebilir. Gelecekte taşıt kullanımı sırasında maddi ve manevi hasara neden olacak sürücü davranışları azaltılabilir ya da kontrol edilebilir. Literatürde, anketler ve yapay zekâ yöntemleriyle bu problemlere çözüm arandığı görülmektedir.

Bu çalışmada, sürücü davranışlarının belirlenmesi için sensörlerden alınan veriler ve bu verilerden elde edilen özelliklerle sürücü davranışının sınıflandırması için web tabanlı, kullanıcı dostu grafiksel ve istatistiksel bilgiler sunan bir arayüz geliştirmiştir. Geliştirilen arayüz, sürücü davranışlarını Ulusal Karayolu Trafik Güvenliği İdaresi (National Highway Traffic Safety Administration – NHTSA) yönergelerinde belirtilen kurallara göre sınıflandırmaktadır [9]. Bu belge ABD Ulaştırma Bakanlığı tarafından oluşturulmuştur.

Çalışmanın diğer bölümlerinde, literatürde yapılan çalışmalar, kullanılan veri seti ve yöntemlerin incelenmesi, geliştirilen uygulama ve sonuçların tartışılması sunulmuştur.

2. LİTERATÜR ARAŞTIRMASI (LITERATURE REVIEW)

Literatürde sürücü davranışlarını farklı yaklaşımlarla ve boyutlarla değerlendiren çeşitli çalışmalar bulunmaktadır. Sürücü davranışlarının tespitinde yapılan ilk çalışma bir anket çalışmasıdır. Bilinen ilk sürücü davranışı tanımlama anket çalışması Reason ve arkadaşları tarafından 520 sürücünün katılımıyla gerçekleştirilmiştir. Çalışmada Sürücü Davranışları Anketi (SDA) ile sürücü davranışı tanımlaması yapılmaktadır. Çalışmada sürücünün davranışları kasıtlı ihlaller, dikkatsizlik sonucu yapılan hatalar ve tehlikeli hatalar olarak üç farklı kategoride sınıflandırılmıştır [10]. Lawton ve arkadaşları SDA’ ya yeni maddeler ekleyerek 830 sürücünün katılımıyla yaptıkları anket çalışmasında ihlallerin iki boyutta değerlendirilmesi gerektiğini öne sürmüşlerdir. İhlalleri, saldırgan ihlal ve sıradan ihlal olarak iki boyutta sınıflandırmışlardır [11]. Taubman ve arkadaşları günümüzde halen popüler olan Çok Boyutlu Sürüş Stili değerlendirme anketini

geliştirmişlerdir. Çalışmalarında daha önceki anketlerin sorularına kendi yaklaşımlarını ekleyerek 44 anket sorusu hazırlamışlardır. Anket yanıtları sayesinde sürücünün dikkatsiz, endişeli, kızgın ve sabırlı sürücü davranışından birine sınıflandırılabilceğini iddia etmişler ve halen kullanılmakta olan dört sürücü davranışının temelini oluşturmuşlardır. Yazarlar aynı zamanda bilinçli karar verme, demografik altyapı, karakter, cinsiyet, yaş, eğitim, sürüş deneyimi, araç ve çevreye aşinalık gibi parametrelerin sürücü davranışlarının tespit edilmesindeki etkisine dikkat çekmiştir. [12]. Daha sonraki yıllarda Newnam ve arkadaşları tarafından oluşturulan Kurumsal Sürücü Davranışları Ölçeği [13], Harris ve arkadaşları tarafından geliştirilen Pro-sosyal ve Agresif Sürüş Envanteri [14] yapılan diğer popüler anket çalışmalarıdır. Yapılan tüm anket çalışmaları sürücü davranışı tanımlama kriterleri ve bu kriter seçimlerinin neden yapıldığına genel bir bakış sağlamaktadır.

Tüm anket çalışmalarının ortak özelliği sürücü davranışlarının tanımlanması için çeşitli kriterlerin değerlendirilmesidir. SDA' dan yola çıkarak geliştirilen diğer ölçekler sürücülerin farklı koşullarda farklı davranış örnekleri sergilediklerine işaret etmektedir. SDA ile benzer kriterlere sahip olan ölçeklerde dahi sürücü davranışlarının, trafikte güvenle ilgili konularda daha derinlemesine değerlendirilmesi gerektiği vurgulanmaktadır [12–14]. Aynı zamanda sadece bir anket yardımıyla değerlendirilme yapılması, sürücünün kendine ait profili olumsuz değerlendirmeye amacı taşıyabilir. Bu nedenle sürüş verileriyle desteklenmeyen bu yaklaşım tek başına tutarlı olmamaktadır.

Literatürde diğer yaklaşımlar sürücü davranışlarını yakıt tüketimi, hız, manevra, ivme veya takip mesafesi gibi rakamlarla ifade edilen parametrelerle tanımlamaya odaklanmaktadır. Son yıllarda teknolojinin de gelişmesiyle birlikte sürücü davranışını analiz etmek ve sürücü performansını değerlendirmek için çeşitli ticari ve araştırma amaçlı sistemler önerilmiştir. Geliştirilen sistemlerde Küresel Konumlandırma Sistemi (Global Positioning System – GPS) konumları, Kontrol Alan Ağı (Control Area Network – CAN) verileri, kamera, ses, video, akıllı telefon ve araba simülatörü verileri kullanılmaktadır.

Qingwen ve arkadaşları yaptıkları çalışmada arkadan çarpma kaza risklerine dikkat çekmişlerdir. Köprülere yerleştirilmiş kameralardan alınan görüntülerden oluşan veri setine, video analizi sayesinde sınıflandırma yöntemleri uygulayarak sürüş tarzı tanıma ve sürücü destek sistemleri tasarlamamın

mümkün olabileceğini önermişlerdir. Önerilen çalışmaya göre video kayıtlarındaki araçların güzergahları tespit edilir ve daha sonra aracın önünde veya arkasında bulunan araçla mesafesine bağlı olarak çarpışma riski seviyesi hesaplanır. Ancak yapılan çalışmanın sonucunda sürüş tarzının yol koşulları ve trafik akışından da etkilenebileceği dolayısıyla sürüş tarzını daha doğru tespit edilebilmesi için diğer özelliklerin de eklenmesi gerektiği bildirilmiştir [15]. Fugiglando ve arkadaşları sürücü ve araç arasındaki etkileşimin sürücü davranışlarının sınıflandırılmasında daha başarılı olacağını önermişlerdir. Pedallardan ve direksiyon simidinden alınan verilerin “doğrudan” sürücü hareketlerini ve eylemlerini yansıtırken, hız, motor devri ve ivmesel hareketliliğin hissedilen sürücü hareketlerini temsil ettiğini düşünmüşlerdir. Çalışmada bu fikri desteklemek için 64 sürücüyle araçtaki CAN veri yolu sensörüyle kaydedilen fren pedalı basıncı, gaz pedalı konumu, dakikada devir sayısı, hız, direksiyon simidi açısı, direksiyon simidi momentumu, yanal hızlanma, boylamsal hızlanma verilerini kullanmışlardır. Temel Bileşen Analizi (Principal Component Analysis – PCA) kullanılarak seçilen yedi farklı özellikle sürücü davranışlarını sınıflandırma yöntemi önerilmiştir. Ayrıca, alt örnekleme stratejisinin doğru seçilmesiyle, kümeleme 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 arasındaki ilişkiye dikkat çekerek sürücü davranışı tanımlamanın güçlüğünden bahsetmişlerdir. Bu nedenle sürücü davranışlarının sınıflandırılması için veri setinin daha fazla özellikle zenginleştirilmesi tavsiye edilmiştir [16]. Literatürdeki birçok çalışma daha doğru sınıflandırma için daha çok sensör verisi kullanılmasının faydalı olacağını önermektedir [15–17]. Son yıllarda hızla ilerleyen teknoloji sayesinde mobil cihazlar ile elde edilen veriler üzerinde çalışmalar artmaktadır. Siami ve arkadaşları tarafından yapılan çalışmada, sigorta şirketinde poliçe sahibi kişilerin kaza risklerini tahmin edilmesi için derin öğrenme yöntemi ile bir model önermişlerdir. Tahmin modelinde giriş verileri olarak, sigorta şirketi tarafından yayınlanan 2011 ve 2015 yılları arasında akıllı telefonla kaydedilmiş 2.500 sürücüye ait 50.000 sehayat içeren veri seti kullanılmıştır [18].

Literatürdeki çalışmalarda kamuya açık birçok veri seti sürücü davranışı analizinde kullanılmak üzere sunulmuştur. Barreto ve arkadaşları tarafından yayınlanan veri setinde bütünleşik tanı sistemi (On Board Diagnostics – OBD) arabirimi kullanılarak sürücü davranışı analizi için veriler kaydedilmiştir

{Formatting Citation}. Ancak yayınlanan veri setinde kayıp veri miktarının çok olması analiz sonuçları üzerinde önemli bir etki oluşturmaktadır. Bunun sebebi sürücü davranışı analizinde, sürüş olayını temsil edemeyen önemli verilerin olmaması veya çeşitli tekniklerle yeri doldurulamayan verilerin analiz sonuçlarının doğru değerlendirilmesinde olumsuz etkiye sahip olmasıdır. Çalışmada eksik verilerin tamamlanma sürecinde nasıl bir teknik uygulandığı açıklanmamıştır. Bu nedenle veri setinin kullanılması sonucunda başarının güvenilirliği tartışmalıdır. 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 sürücüdün 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 sensörleri sayesinde ivme, açısal hız ve konum verileri kaydedilmiştir [20]. Fakat paylaşılan sürüş verileri 50 km/s hız ve üzerindeki hızlar içindir. Bu hız altındaki başlangıç ve bitiş gibi önemli sürüş olaylarını temsil eden veriler bulunmamaktadır. Bu nedenle gerçek trafik koşullarında bu değerlerin eksikliği tutarlı tespit yapılmasına engel olmaktadır. Ayrıca şehir içi hız limitleri dikkate alındığında veri setinin kullanılabilirliği de tartışmalıdır.

Honda Sürüş Veri Seti (Honda Driving Dataset – HDD), Honda Araştırma Enstitüsü tarafından oluşturulmuş ve araştırmacılarla ücretsiz olarak paylaşılmaktadır [21]. Bu veri seti, kamera ve CAN, GPS, Işın Algılama, Mesafe Ölçümü (Light Detection and Ranging – LIDAR), İnersiyal Ölçme Ünitesi (Inertial Measurement Units – IMU) sensörleri yerleştirilmiş bir araçla ABD' nin San Francisco bölgesinde 104 saatlik sürüş verisinden oluşmaktadır. Sürüşler farklı zaman dilimlerinde, farklı trafik sahneleri, hava koşulları, şehir içi yollar, banliyö ve otoyollar üzerinde gerçekleştirilmiştir. HDD, kurumsal bir araştırma enstitüsü tarafından oluşturulmuş ve güvenilir sürüş bilgileri içeren bir veri seti olması sebebiyle araştırmacılar için önemlidir. Sürücü davranışı analizinde kullanılacak çeşitli veri özelliklerine sahip çok sayıda kamuya açık ve ücretsiz veri seti bulunmaktadır [20–29].

Daha önceki çalışmalar incelendiğinde sürücü davranışlarının analiz edilmesinde kullanılan modeller ve sınıflandırmalar, sürüş detaylarını içeren görsel bir arayüz sunmamaktadır. Bu çalışmada

gerçek sürüş sırasında kaydedilen konum, gaz-fren pedalı, direksiyon açısı-hızı, jiroskop ve ivme ölçer verileri kullanılarak tespit edilen hızlanma, yavaşlama, dönme vb. olayların istatistik, grafik ve harita üzerinde gösterimi gerçekleştirilmiştir. Geliştirilen yazılım NHTSA tarafından tanımlanmış kurallara göre sürüş hakkında istatistiksel bilgiler vermekte ve bu istatistiklere göre sınıflandırma yapmaktadır. Böylece sürücü davranışlarının yol ve zamana bağlı analizini kolaylaştıracak, kullanıcı dostu web tabanlı bir arayüz geliştirilmiştir.

3. MATERYAL ve METOT (MATERIAL and METHOD)

3.1. Veri Seti (Dataset)

Çalışmada, HDD veri seti ile gerçek trafik ortamında Android işletim sistemine sahip akıllı telefonla oluşturduğumuz veriler kullanılmıştır. Literatürdeki çalışmalar incelendiğinde parametre açısından daha zengin veri setleri ile sınıflandırma başarısının artacağı vurgulanmıştır. Ancak çalışmalar incelendiğinde araç ve araç-sürücü etkileşimi ile ilgili en çok parametre içeren veri setinin HDD olduğu görülmektedir. Bu sebeple HDD veri seti çalışmada tercih edilmiştir. Tablo 1' de çalışmada kullanılan veri setlerine ait sensör çeşitleri, yol tipi, sürüş süreleri ve sürüş sınıflandırma özellikleri verilmiştir.

Tablo 1. Çalışmada kullanılan veri seti parametreleri (Dataset parameters used in the study)

Özellikler	HDD	Oluşturulan Veri Seti
GPS	✓	✓
CAN	✓	X
IMU	✓	İvme Ölçer, Jiroskop
LIDAR	✓	X
Kamera	✓	X
Yol Tipi	Şehir içi, Şehir dışı Otoyol, Banliyö	Şehir içi, Şehir dışı, Otoyol
Farklı Sürüş Kaydı	136	20
Sürüş Süresi	104 saat	6 saat
Tarafsız Sürüş Puanlaması	X	✓

3.1.1. Honda sürüş veri seti (Honda driving dataset)

Kamera ve çeşitli sensörler ile (LIDAR, GPS, IMU, CAN) donatılmış bir araçla, gerçek trafik ortamında, farklı hava koşulları ve yol tiplerinde 1 sürücü tarafından toplanan veri setidir. Bu nedenle sürüş olaylarının doğallığını temsil eden farklı senaryolar bulunmaktadır. 27 Şubat 2017-6 Ekim 2017 tarihleri arasında ABD' nin San Francisco bölgesinde şehir içi-dışı, banliyö ve otoyollarda farklı zamanlarda toplam 104 saat ve 136 farklı sürüş kaydedilmiştir. Veri seti içerisinde sürüş zamanı,

araba hızı, gaz pedalı açısı, fren pedalı basıncı, enlem, boylam, direksiyon simidi açısı, direksiyon simidi dönüş hızı ve arabanın yalpalama oranı verileri yer almaktadır. Toplanan ham veriler .csv formatına çevrilerek yayınlanmıştır. Aynı zamanda veri seti, sürüş verilerinin doğruluğunun ve güvenilirliğinin kontrol edilebilmesine olanak sağlayan araç içi kamerayla kaydedilmiş sürüş videolarına sahiptir. Kamuya açık çok sayıda veri seti olmasına rağmen, bu çalışmada en güncel ve gerçek trafik koşullarında kaydedilen HDD veri setinin kullanılması tercih edilmiştir. Ayrıca veri seti, sürücü davranışının sınıflandırılmasını, sürücünün bir sonraki hareketinin tahmin edilmesini, otonom sürüş araştırmaları ve akıllı sürüş sistemlerinin geliştirilmesini hedefleyen araştırmacılar için ölçeklenebilir yaklaşımla hazırlanmıştır [21].

3.1.2. Oluşturulan veri seti (Created dataset)

Çalışma için oluşturulan mobil uygulama ile gerçek trafik ortamında Karabük ili sınırları içerisinde şehir içi-dışı ve otoyol üzerinde, farklı hava koşullarında ve farklı saat dilimlerinde 1 sürücü tarafından kaydedilmiştir. 2020 Model 1.5 TSI motor ve DSG şanzımanlı Škoda Superb araçla Android 10 Q işletim sistemli Xiaomi Redmi Note 9 4GB RAM ve 128GB hafızaya sahip akıllı telefonda bulunan GPS, ivme ölçer ve jiroskop sensörleriyle toplam 6 saat ve 20 farklı sürüş verisi toplanmıştır. Veri seti içerisinde hız, enlem-boylam, rakım, 3 eksenli ivme, 3 eksenli jiroskop ve sürücü puanlaması özellikleri bulunmaktadır. Veri seti oluşturmak için farklı zamanlarda bilinçli olarak farklı tipte sürüşler gerçekleştirilmiştir. Mobil uygulamayla kaydedilen sürüş kayıtları daha sonra SQLite (DB browser) uygulamasıyla bilgisayarın işleyebileceği .csv formatına dönüştürülmüştür.

3.2. Veri Ön İşleme (Data Pre-Processing)

Veri ön işleme süreci, veri analizindeki kritik süreçlerden biridir. Kullanılacak verilerin analiz edilmeden önce kaliteli, tutarlı, güncel, 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 doğrudan etkilidir [30–32]. Bu nedenle çalışmada Şekil 1’ de gösterilen veri ön işleme adımları takip edilmiştir.



Şekil 1. Veri ön işleme adımları (Data pre-processing steps)

3.2.1. Veri temizleme (Data cleaning)

Kaydedilen veriler her zaman anlamlı olmamaktadır. Veriler ölçüm hatası, alet, bilgisayar ya da insan hatasından kaynaklı bazen gürültülü, tutarsız, tekrar eden, eksik veya hatalı olarak kaydedilebilir. Veri temizleme adımında bu veriler düzeltilebilir, veri kümesinden atılabilir, eksik değerlerin yerine sabit, ortalama, tahmini değerler eklenebilir. Bu verilerin analiz edilmeden önce çıkarılması ya da düzeltilmesi analiz sonuçlarının doğruluğu ve güvenilirliği açısından oldukça önemlidir [33].

3.2.2. Veri birleştirme (Data integration)

Farklı kaynaklardan alınan verilerin birlikte değerlendirilmesi için uygun formatta birleştirilerek bir bütün haline getirilmesi veri birleştirme işlemidir [31]. Birden fazla veri kümesinin birleştirilmesi sırasında aynı niteliğe sahip fakat farklı isimlerle temsil edilen özellikler olabilmektedir. Birbiriyle yüksek derecede korelasyonu olan iki niteliğin aynı anda kullanılması gereksiz veri oluşturmaktadır. Farklı kaynaklardan gelen verilerin birleştirilmesi, tutarsızlıkları ve gereksiz verileri önlemeye, veri madenciliği hız ve kalitesini iyileştirmeye katkı sağlamaktadır.

3.2.3. Veri dönüşümü (Data transformation)

Veri setlerinde işlenecek değişkenlerin değer aralıkları farklı olabilmektedir. Değişkenlerin, ortalama ve varyansları farklı olduğu durumlarda büyük ortalama veya varyansa sahip değişkenlerin sonuç üzerindeki etkisi daha fazla olmakta ve diğer özelliklerin etkisi önemli ölçüde azalmaktadır. Yapay zekâ uygulamalarında hangi değişkenin etkisinin ne olacağı modelin öğrenme algoritmasıyla ortaya çıktığı için başlangıç koşullarında değişkenlerin etkilerinin benzer olmasını sağlamak gerekmektedir. Bu durum özellikle nümerik veya istatistiksel yöntemlerle korelasyonu, doğrudan tespit edilmemiş veri setlerinde çok daha önemli bir gereklilik haline gelmektedir. Farklı değer aralıklarına sahip değişkenlerin birlikte değerlendirilmesi için normalizasyon, standardizasyon, ondalık ölçekleme gibi yöntemler uygulanabilir [34].

3.3. Özellik Çıkarma (Feature Extraction)

Veri madenciliği, makine öğrenimi, örüntü tanıma ve görüntü işleme alanlarında kullanılan özellik

çıkarma, ham verilerden türetilmiş yeni değerler oluşturulması işlemidir. Ham verilerden türetilen özellik tek başına ham verileri temsil edebiliyorsa, ham veriler yerine türetilen özellik kullanılarak boyut indirilmesi, değilse veri zenginleştirme işlemi gerçekleştirilmiş olur [35].

3.4. Veri Görselleştirme (Data Visualization)

Görselleştirme, sayısal veya karmaşık bilgilerin görsel olarak temsil edilmesini ve anlaşılabilirliğini arttıran bir yöntemdir. Veri görselleştirme ise veriyi veya süreci düzenleme, yapılandırma, değerlendirme ve iletişim kurma amacıyla hedeflenen kitleye şekiller, animasyonlar, grafikler vb. görsel materyaller kullanarak anlatma biçimidir [36]. Ayrıca birden fazla verinin birlikte değerlendirilmesine olanak sağlayarak korelasyon gibi ilişkilerin görsel olarak sunulmasını kolaylaştırmaktadır.

4. UYGULAMA (APPLICATION)

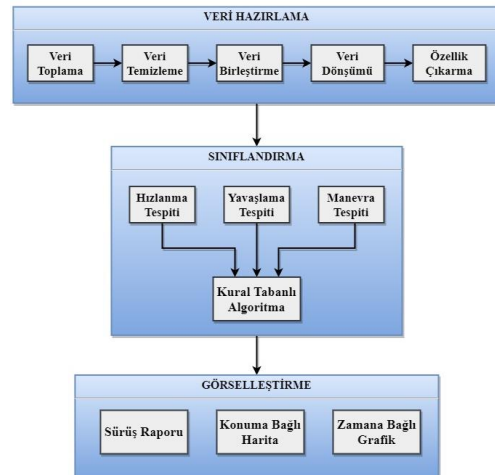
Web tabanlı sürücü davranışı tanımlama sistemi, sürüş olaylarını NHTSA kurallarına göre sınıflandıran, sunduğu görsellerle sürüş olaylarının kolay analiz edilebilir olmasını sağlayan bir ara yüz uygulamasıdır. Uygulama, farklı yazılım dilleri ve kütüphaneler bir arada kullanılarak web tabanlı olarak geliştirilmiştir. Tablo 2’ de kullanılan yazılım dilleri, kütüphaneler ve tercih edilen versiyonları verilmektedir. Uygulama geliştirmede kullanılan teknolojiler ve kütüphaneler açık kaynak kodlu ve ücretsizdir.

Çalışmada CSS ve Bootstrap web sayfası tasarımını düzenlemek amacıyla kullanılmıştır. JS, web ön yüzünde bulunan işlevlerin (buton, animasyon, efekt vb.) web tarayıcılarında çalıştırılmasını sağlar. Chart jquery, leaflet, paparse JS kütüphaneleridir. Chart JS, sürüş verilerinin grafikler üzerinde görselleştirilmesi için kullanılmıştır. Web sayfasında yer alan buton olayları ve görsel efektlerin (animasyon, açılır pencere, kayan görsel) oluşturulması ve dinamik olarak kullanılması için jquery JS kütüphanesi kullanılmıştır. Konum değişkenlerinin haritada 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 yazılım diliyle, veri tabanı bağlantısı ve çalıştırılan veri tabanı sorgusu sonuçlarının web sayfasında gösterilmesi sağlanmıştır.

Uygulama 4 kısımdan oluşmaktadır. İlk kısımda veriler ön işleme adımlarından geçer ve özellik çıkarımı yapılır. İkinci kısımda GPS koordinatlarına göre aracın izlediği rota görselleştirilerek hız ve konum bilgisine göre gerçek sürüş simülasyonu gerçekleştirilmektedir. Uygulamanın üçüncü kısmında sürüş esnasında gerçekleşen olaylara ait veriler ve çıkarılan özellikler ile harita görseli oluşturulmaktadır. Uygulamanın son kısmında ise veri ön işleme ve görselleştirme süreçlerinden geçirilmiş sürüş verileri için NHTSA tarafından belirlenmiş kriterlere göre sürüşe puan verilerek sınıflandırma yapılmaktadır. Uygulamanın genel yapısı Şekil 2’ de verilmiştir.

Tablo 2. Uygulamada kullanılan yazılımlar, kütüphaneler ve versiyonları (Software, libraries and versions used in the application)

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
Javascript (JS)	ECMA Script 2020
Jquery	3.3.1
Leaflet	1.7.1
PapaParse	5.0.0
PostgreSQL	12.6.0



Şekil 2. Uygulama sistem tasarımı (Application system design)

HDD veri setinden hız, GPS, IMU verileri alınmış ve hız, hızlanma, yavaşlama, enlem, boylam, aracın boyolsal, yanal, dikey (roll, pitch, yaw)

eksenlerindeki hareket değişkenleri seçilmiştir. Çalışmada kullanılan diğer veri setinin oluşturulması için Android işletim sisteminde çalışan mobil bir uygulama geliştirilmiştir. Şekil 3' te veri kaydı için geliştirilen mobil uygulamanın ekran görüntüleri yer almaktadır.



Şekil 3. Mobil uygulama ekran görüntüleri a) Veri kayıt başlatma ekranı b) Veri tabanı kayıtlarını listeleme ve harici hafızaya kaydetme ekranı (Mobil application screenshots a) Data recording start screen b) List database records and save to external storage screen)

Araçta sabit konumda duran Android işletim sistemine sahip akıllı telefonda bulunan GPS, 3 eksenli ivmeölçer ve 3 eksenli jiroskop sensörleriyle, enlem, boylam, hız, açılal hız ve zaman verileri 1 Hz. frekans aralıklarıyla veri tabanına kaydedilmiştir. Gün içerisinde farklı zaman dilimlerinde gerçekleştirilen her sürüş olayı tarih ve saat verisi sayesinde birbirinden ayrılarak veri tabanında saklanmıştır.

Veri setindeki GPS sensöründen elde edilen enlem ve boylam verilerinden, openstreetmap tarafından sağlanan leaflet JS kütüphanesi kullanılarak rakım bilgisi elde edilmiş bu sayede yol koşulları daha çok detay içerecek şekilde zenginleştirilmiştir. Bu zenginleştirme işlemi hem HDD hem de kendi oluşturduğumuz veri seti için gerçekleştirilmiştir.

Telefon hafızasında tablolar halinde bulunan veri tabanı kayıtları .csv formatına dönüştürülmüştür. Daha sonra PapaParse JS kütüphanesi kullanılarak bu dosyaların web uygulamasına yüklenmesi sağlanmıştır. Zaman değeri ve sürücü bilgilerine göre, gün içerisinde farklı zaman dilimlerinde toplanan ayrı veriler jquery JS kütüphanesi kullanılarak sıralı

verilere dönüştürülmüş ve günlük sürüşler birleştirilmiştir. Birleştirilen sürüş kayıtları veri temizleme ve veri dönüşümü adımları için hazır hale getirilmiştir.

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 (SeksanDart – 84) düzeltilmiştir. Bu sayede ham veriden güvenilir ve doğru sonuç almayı zorlaştırıcı veriler temizlenmiştir.

Değer aralıkları önemli ölçüde farklı olan hız, ivme, jiroskop, eğim, mesafe ve yalpalanma oranı varyans değerlerinin fazla uzak olması nedeniyle ortalama, varyans, standart sapma ve standardizasyon dönüşümleri için Eş. (1), Eş. (2), Eş. (3) ve Eş. (4) kullanılmıştır.

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

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

$$\sigma = \sqrt{\frac{\sum_{i=1}^n (x_i - \mu)^2}{n}} \quad (3)$$


$$X_{std} = \frac{x - \mu}{\sigma} \quad (4)$$

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

Veri setinde bulunan enlem, boylam değişkenlerinden mesafe, rakım ve eğim özelliği, hız değişkenlerinden hızlanma ve yavaşlama özellikleri, ivmeölçer ve jiroskop değişkenlerinden yalpalanma (yaw, pitch, row) özelliği çıkarılmıştır. Özellik çıkarımı sayesinde veri seti zenginleştirilerek harita ve grafik görsellerinde açıklanabilirlik haritası olarak sunulan sürüşe ait bilgiler görselleştirilmiş, aynı zamanda NHTSA yönergelerinde belirtilen hızlanma, yavaşlama ve dönme olaylarının tespiti için gerekli girdiler elde edilmiştir.

Şekil 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 enlem-boylam-rakım ve zaman bilgileri leaflet kütüphanesi kullanılarak harita üzerinde görselleştirilmiştir. Aynı zamanda hız, hızlanma, yavaşlama, mesafe, ivme, jiroskop (3 eksenli), enlem, boylam, rakım, eğim ve sürücü puanı değerleriyle

Chart JS kütüphanesi kullanılarak grafikler oluşturulmuştur.

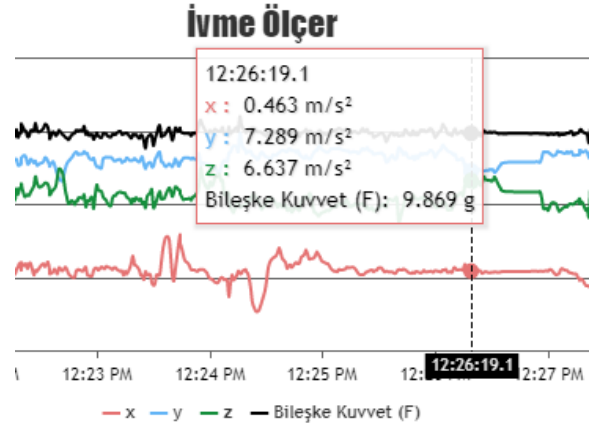


Şekil 4. Sürücülerin sürüş bilgilerinin çağrılması
(Retrieval drivers' driving informations)


5. DENEYSEL SONUÇLAR (Experimental Results)

İvmenin, X (yanal) eksenindeki değişimi, aracın şerit değiştirmesini ve manevra yapmasını temsil etmektedir. Y (boylamsal) eksenindeki ivme değişiminden hızlanma ve yavaşlama olayları tespit edilmektedir. Z (dikey) eksenindeki ivme değişimi, yokuş (rakım) inişi veya çıkışında gerçekleşen hıza bağlı yer değişimini temsil etmektedir. Tüm bu sürüş verileri uygulama içerisinde grafikler yardımıyla görselleştirilmektedir. Uygulamada, araca ait ivme (X, Y, Z eksen) değerleri Şekil 5' te verilmiştir. Birim zamandaki hız ve bu bilgiden türetilen hızlanma ve yavaşlama değerleri Şekil 6' da verilmiştir.


3 eksenli (X- Y- Z) jiroskop sensörüyle toplanan veriler Şekil 7' de gösterilmiştir. Jiroskop verileri, aracın yalpalanma (sert kalkış-duruş) ve sarsılma (sağa-sola dönüş, tümsekten veya çukurdan geçiş) hareketlerini tespit etmek için kullanılmıştır. Boylamsal (X) eksen değerleriyle ani şerit değiştirme ya da tümsek ve çukur geçişlerinde sarsılma olayları, yatay eksen (Y) değerleriyle ani hızlanma-yavaşlama olayları, dikey eksen (Z) değerleriyle ani manevra (dönüş) olayları tespit edilmektedir.



Şekil 5. Aracın ivme (X- Y- Z eksen) grafiği
(Acceleration (X-Y-Z axis) graph of the vehicle)




Şekil 6. Aracın hız, hızlanma ve yavaşlama grafiği
(Speed, acceleration and deceleration graph of the vehicle)




Şekil 7. Jiroskop verileri (X- Y- Z eksen) grafiği
(Gyroscope data (X-Y-Z axis) graph)

Aracın konum (enlem, boylam, rakım) değerleri Şekil 8' de verilmiştir. Görselleştirmede kullanılan enlem ve boylam değerleriyle şerit değiştirme, dönme, yön bilgileri tespit edilmektedir. Rakım değeriyle tümsek ya da çukur geçişleri ve yokuş inişi ya da çıkış hareketleri tespit edilmektedir.



Şekil 8. Aracın konum (enlem, boylam, rakım) grafiği (Location (latitude, longitude, altitude) graph of the vehicle)

Mesafe ve eğim değerleri Şekil 9’ da verilmiştir. Eğim değerleri, hızlanma, yavaşlama değerleriyle birlikte ele alındığında; rampa yollarda sürücünün iniş veya çıkış sırasındaki davranışının değerlendirilebilmesi için zenginleştirilmiş ek bilgiler sağlamaktadır. Mesafe değerleri kullanılarak sürüşün gerçekleştiği toplam yol uzunluğu ve birim zamandaki mesafe bilgisi elde edilmektedir.




Şekil 9. Aracın aldığı mesafe ve yolun eğim grafiği (Cover a distance by the vehicle and slope graph of the road)

Şekil 10’ da sürücülerin zamana bağlı kümülatif sürüş puanları gösterilmiştir. Verilen kümülatif sürüş puanları aracın ne kadar çevreci kullanıldığını göstermektedir.


Şekil 11’ de sürüşün gerçekleştiği zamana bağlı rota, başlangıç ve bitiş konumları harita üzerinde işaretlenerek görselleştirilmiştir. Harita üzerinde yer alan araç konumu işaretçisine tıkladığında anlık olarak sürüş zamanı, konumu ve hız bilgileri açılır pencerede gösterilmektedir. Zamana ve konuma bağlı hız bilgisi sayesinde sürücünün yol üzerinde hangi hızla aracı sürdüğü ve hangi konumda olduğu bilgisi

gösterilmektedir. Aynı zamanda harita üzerindeki başlangıç (mavi), duraklama (kırmızı) ve bitiş (yeşil) işaretçilerinin üzerine tıkladığında bu noktaların konum bilgileri bununla birlikte sürücünün nerede ne kadar süre duraklama gerçekleştirdiği ve duraklama zaman aralıkları verilmektedir.



Şekil 10. Sürücü puanları grafiği (Driver scores graph)

Şekil 11’ de sürüşün gerçekleştiği zamana bağlı rota, başlangıç ve bitiş konumları harita üzerinde işaretlenerek görselleştirilmiştir. Harita üzerinde yer alan araç konumu işaretçisine tıkladığında anlık olarak sürüş zamanı, konumu ve hız bilgileri açılır pencerede gösterilmektedir. Zamana ve konuma bağlı hız bilgisi sayesinde sürücünün yol üzerinde hangi hızla aracı sürdüğü ve hangi konumda olduğu bilgisi gösterilmektedir. Aynı zamanda harita üzerindeki başlangıç (mavi), duraklama (kırmızı) ve bitiş (yeşil) işaretçilerinin üzerine tıkladığında bu noktaların konum bilgileri bununla birlikte sürücünün nerede ne kadar süre duraklama gerçekleştirdiği ve duraklama zaman aralıkları verilmektedir.



Şekil 11. Harita işaretçileri ve açılır bilgi pencereleri (Map makers and pop-up information windows)

Tablo 3’te yer alan NHTSA yönergelerine göre, güvenli olmayan sürücülerin 2,7448 m/s²’den daha fazla hızlanma yaptıkları, 3,0398 m/s²’den daha az yavaşlama yaptıkları, 6,7056 m/s’den yüksek süratle dönüş yaptıkları ve bu olayları sıklıkla tekrar ettikleri istatistiksel yöntemlerle tespit edilmiştir [9].

Çalışmada, NHTSA yönergelerine uygun olarak belirlenen kurallara göre sürüşler sınıflandırılmıştır.

Tablo 3. NHTSA sürüş karakterizasyon kuralları (NHTSA driving characterization rules)

Sürüş Karakteri	Hızlanma	Yavaşlama	Dönüş
Sert	$x > 2,7448$ m/s ²	$x > 3,0398$ m/s ²	$x > 6,7056$ m/s ²
Normal	$x = 2,7448$ m/s ²	$x = 3,0398$ m/s ²	$x = 6,7056$ m/s ²
Sakin	$x < 2,7448$ m/s ²	$x < 3,0398$ m/s ²	$x < 6,7056$ m/s ²

Uygulanan kural tabanlı yöntemle sürüşlerin zaman, hız, hızlanma, yavaşlama, eğim, rakım, mesafe, ivme (X, Y, Z) ve jiroskop (X, Y, Z) değişkenleri birlikte değerlendirilerek sürücülerin sürüş boyunca ortalama hız, en yüksek hız, sert hızlanma, sert yavaşlama, toplam sürüş süresi, toplam alınan yol istatistikleri elde edilmiştir. Şekil 12’ de sürücülerin istatistiklere göre hesaplanan sürüş raporu uygulama ekranları gösterilmektedir Harita, grafik ve sürüş raporu sonuçları birlikte değerlendirilerek sürücü davranışları tanımlanması için açıklayıcı bilgiler sağlanmıştır.



Şekil 12. Sürücülerin sürüş raporu sonuçları (Drivers' driving report results)

6. SONUÇ ve TARTIŞMA (CONCLUSION and DISCUSSION)

Yapılan çalışmada gerçek trafik koşullarında GPS, IMU, CAN sensörleriyle kaydedilmiş verilerden oluşan kamuya açık veri seti ve mobil uygulama geliştirilerek oluşturulan veri seti ile NHTSA yönergelerine uygun olarak belirlenen kurallara göre sürücü davranışını temsil eden ortak özellikler (hızlanma-yavaşlama, sağa-sola dönüş, rampa iniş-çıkış, durma-duraklama) tespit edilmiştir. Aynı

zamanda mevcut verilerden yeni özellikler türetilerek sürücü davranışı sınıflandırılmıştır. Uygulama sayesinde sürücünün; Anlık hızı, Ortalama ve en yüksek hızı, Anlık hızlanma-yavaşlama, Sert hızlanma-yavaşlama sıklığı, Birim zamanda aldığı yol uzunluğu, Toplamda aldığı yol uzunluğu, Yolun anlık eğimi, Aracının yalpalanma-sarsılma şiddeti, Hareket başlangıç ve bitiş konumları, Duraklama konumu ve süresi, Ortalama sürücü puanı bilgileri elde edilmiştir. Geliştirilen web ara yüzünde, harita ve grafiklerle bu bilgiler görselleştirilmiştir.

Literatürde sürücülerin davranışlarının sınıflandırılması için zengin veri seti kullanmanın sınıflandırma başarısı açısından faydalı olacağı önerilmiştir [15]–[17]. Özellik çıkarımı adımı veri setindeki değişkenlerle türettiğimiz yeni bilgiler sayesinde sürücü davranışını tespit edecek ek bilgiler çıkarılmıştır. Hız değerleriyle hızlanma ve yavaşlama bilgileri, jiroskop ve ivme ölçer değerleriyle yalpalanma-sarsılma bilgileri elde edilmiştir. Literatürden farklı olarak enlem ve boylam değişkenleriyle duraklama, anlık mesafe ve rakım bilgileri elde edilmiştir. Ayrıca rakım özelliği kullanılarak rakım ve yolun eğimi bilgileri elde edilmiş bu sayede tümsek, çukur ve rampa tespiti yapılmıştır. Bu bilgiler ışığında sürücü destek sistemlerinin geliştirilmesi, otonom sürüş kabiliyetlerinin artırılması, filo yönetimi, yol-araç-sürücü denetimi ve sürücü davranışlarının sınıflandırılması alanlarında gelecekte yapılacak çalışmalara katkıda bulunmaktadır. Aynı zamanda istatistiksel bilgilerin ve görsel ara yüzün birlikte kullanımı, karayolu taşımacılığında verimliliğin artırılması, rota optimizasyonun sağlanması, sürücülerin geliştirilmesi gibi çeşitli iyileştirmelere olanak sağlar.

Çalışma, binek otomobiller dikkate alınarak geliştirilmiştir. Motosiklet, kamyon, kamyonet, minibüs, otobüs gibi diğer araçlar için kurallar değişiklik gösterecektir. Değişikliklerin tespiti için veri toplanması ve kuralların oluşturulması gerekmektedir. Ayrıca sürüşün analizi için farklı senaryolara göre farklı araçlarla veri seti oluşturulması, bu alanda yapılacak çalışmalara ışık tutacaktır. Literatürdeki verilerde sürücü-araç etkileşimi çok sınırlı olarak bulunmaktadır. Çalışmada tarafımızdan oluşturulan veri seti de cep telefonu sensörleri ve kullanıcı etkileşimi ile toplanmıştır. Bunun sebebi farklı marka ve model araçlardaki puanlamanın NHTSA yönergelerine göre oluşturulan puanlama ile korelasyonunun yüksek olduğunu göstermektedir.

Gelecek çalışmalarda sürücü davranışını temsil eden bilgilerin farklı coğrafi koşulları [37] dikkate alarak daha fazla zenginleştirilmesi, sürücü davranışlarının yapay zeka ve farklı veri madenciliği algoritmaları analizi [38] ile web uygulamasının daha fazla geliştirilmesi hedeflenmektedir.

ÇIKAR ÇATIŞMASI BİLDİRİMİ (CONFLICT OF INTEREST STATEMENT)

Bu çalışmanın yazarları arasında herhangi bir çıkar çatışması yoktur.

KAYNAKLAR (REFERENCES)

- [1] World Health Organization, “Health topics/Road traffic injuries”, *who.int*, 2021. [Online]. Available: <https://www.who.int/health-topics/road-safety>. [Accessed: Jan. 01, 2021].
- [2] Türkiye Emniyet Genel Müdürlüğü, “Trafik İstatistik Bülteni”, *trafik.gov.tr*, 2020. [Online]. Available: <http://trafik.gov.tr/kurumlar/trafik.gov.tr/04-Istatistik/Aylik/Aralik20.pdf>. [Accessed: Jan. 01, 2021].
- [3] U.S. Department Of Transportation Federal Highway Administration, “State Motor Vehicle Registrations”, *fhwa.dot.gov*, 2019. [Online]. Available: <https://www.fhwa.dot.gov/policyinformation/statistics/2019/pdf/mv1.pdf>. [Accessed: Jan. 3, 2021].
- [4] European Automobile Manufacturers’ Association “ACEA Report Vehicles in use Europe 2019”, *acea.auto*, 2019. [Online]. Available: https://www.acea.auto/files/ACEA_Report_Vehicles_in_use-Europe_2019.pdf. [Accessed: Jan. 3, 2021].
- [5] Türkiye İstatistik Kurumu, “Karayolu Trafik Kazası İstatistikleri”, *data.tuik.gov.tr*, January 26, 2021. [Online]. Available: <https://data.tuik.gov.tr/Bulten/Index?p=Motorlu-Kara-Tasitlari-Aralik-2020-37410>. [Accessed: Feb. 12, 2021].
- [6] Türkiye Emniyet Genel Müdürlüğü, “Trafik İstatistik Bülteni”, *trafik.gov.tr*, 2021. [Online]. Available: <http://trafik.gov.tr/kurumlar/trafik.gov.tr/04-Istatistik/Aylik/ocak21.pdf>. [Accessed: Feb. 10, 2021].
- [7] R. Vivoli, M. Bergomi, S. Rovesti, P. Bussetti, and G. M. Guaitoli, “Biological and behavioral factors affecting driving safety”, *Journal of Preventive Medicine and Hygiene*, vol. 47, no. 2, pp. 69–73, June 2006, doi: 10.15167/2421-4248/jpmh2006.47.2.47.
- [8] C. D’Agostino, A. Saidi, G. Scouarnec, and L. Chen, “Learning-based driving events classification”, in *16th International IEEE Conference on Intelligent Transportation Systems, ITSC 2013, 6-9 October 2013, The Hague, Netherlands*, pp. 1778-1783, doi: 10.1109/ITSC.2013.6728486.
- [9] S. G. Klauer, T. A. Dingus, V. L. Neale, J. D. Sudweeks, and D. J. Ramsey, “Comparing Real-World Behaviors of Drivers with High Versus Low Rates of Crashes and Near Crashes”, *nhtsa.gov*, 2009. [Online]. Available: <https://www.nhtsa.gov/sites/nhtsa.gov/files/811091.pdf>. [Accessed: February 10, 2021].
- [10] J. Reason, A. Manstead, S. Stephen, J. Baxter, and K. Campbell, “Errors and violations on the roads: A real distinction?”, *Ergonomics*, vol. 33, no. 10-11, pp. 1315–1332, Oct-Nov 1990, doi: 10.1080/00140139008925335.
- [11] R. Lawton, D. Parker, A. S. R. Manstead, and S. G. Stradling, “The role of affect in predicting social behaviors: The case of road traffic violations”, *Journal of Applied Social Psychology*, vol. 27, no. 14, pp. 1258–1276, July 1997, doi: 10.1111/j.1559-1816.1997.tb01805.x.
- [12] O. Taubman-Ben-Ari, M. Mikulincer, and O. Gillath, “The multidimensional driving style inventory - Scale construct and validation”, *Accident Analysis and Prevention*, vol. 36, no. 3, pp. 323–332, May 2004, doi: 10.1016/S0001-4575(03)00010-1.
- [13] S. Newnam, J. Greenslade, C. Newton, and B. Watson, “Safety in Occupational Driving: Development of a Driver Behavior Scale for the Workplace Context”, *Applied Psychology*, vol. 60, no. 4, pp. 576–599, October 2011, doi: 10.1111/j.1464-0597.2011.00448.x.
- [14] Paul B. Harris, John M. Houston, Jose A. Vazquez, Janan A. Smither, Amanda Harms, Jeffrey A. Dahlke, and Daniel A. Sachau, “The Prosocial and Aggressive Driving Inventory (PADI): A self-report measure of safe and unsafe driving behaviors”, *Accident Analysis and Prevention*, vol. 72, pp. 1–8, Nov. 2014, doi: 10.1016/j.aap.2014.05.023.
- [15] Q. Xue, K. Wang, J. J. Lu and, Y. Liu, “Rapid Driving Style Recognition in Car-Following Using Machine Learning and Vehicle Trajectory Data”, *Journal of Advanced Transportation*, vol. 2019, pp. 1–11, January 2019, doi: 10.1155/2019/9085238.

- [16] F. Umberto, M. Emanuele, S. Paolo, M. Sebastiano, A. Kacem, S. Rainer, N. Florian, and R. Carlo, "Driving Behavior Analysis through CAN Bus Data in an Uncontrolled Environment", *IEEE Transactions on Intelligent Transportation Systems*, vol. 20, no. 2, pp. 737–748, October 2017, doi: 10.1109/TITS.2018.2836308.
- [17] T. Toledo, O. Musicant, and T. Lotan, "In-vehicle data recorders for monitoring and feedback on drivers' behavior", *Transportation Research Part C: Emerging Technologies*, vol. 16, no. 3, pp. 320–331, June 2008, doi: 10.1016/j.trc.2008.01.001.
- [18] M. Siami, M. Naderpour, and J. Lu, "A Mobile Telematics Pattern Recognition Framework for Driving Behavior Extraction", *IEEE Transactions on Intelligent Transportation Systems*, vol. 22, no. 3, pp. 1459–1472, March 2021. doi: 10.1109/TITS.2020.2971214.
- [19] C. Barreto, J. Xavier-Júnior, A. Canuto, and I. da Silva, "A Machine Learning Approach Based on Automotive Engine Data Clustering for Driver Usage Profiling Classification", in *Proceedings of the XV National Meeting of Artificial and Computational Intelligence, October 2018, São Paulo, Brazil*, 2018, pp. 174–185. doi: <https://doi.org/10.5753/eniac.2018.4414>.
- [20] E. Romera, L. M. Bergasa, and R. Arroyo, "Need data for driver behaviour analysis? Presenting the public UAH-DriveSet", in *IEEE Conference on Intelligent Transportation Systems, ITSC 2016, December 2016, Rio de Janeiro, Brazil*, 2016, pp. 387–392, doi: 10.1109/ITSC.2016.7795584.
- [21] V. Ramanishka, Y. T. Chen, T. Misu, and K. Saenko, "Toward Driving Scene Understanding: A Dataset for Learning Driver Behavior and Causal Reasoning", in *Conference on Computer Vision and Pattern Recognition, CVPR 2018, June 2018, Salt Lake City, UT, USA*, 2018, pp. 7699–7707, doi: 10.1109/CVPR.2018.00803.
- [22] Y. Chen, J. Wang, J. Li, C. Lu, Z. Luo, H. Xue, and C. Wang, "LiDAR-Video Driving Dataset: Learning Driving Policies Effectively", in *Conference on Computer Vision and Pattern Recognition, CVPR 2018, June 2018, Salt Lake City, UT, USA*, 2018, pp. 5870–5878, doi: 10.1109/CVPR.2018.00615.
- [23] P. HL Rettore, A. Campolina, A. Guilherme Maia, L. A. Villas, and A. AF Loureiro, "Driver Authentication in VANETs based on Intra-Vehicular Sensor Data", in *IEEE Symposium on Computers and Communications, ISCC 2018, June 2018, Natal, Brazil*, 2018, pp. 78–83. doi: 10.1109/ISCC.2018.8538506.
- [24] J. Bärgrman et al., "The UDRIVE dataset and key analysis results", *erticonetwork.com*, 2017. [Online]. Available: <https://erticonetwork.com/wp-content/uploads/2017/12/UDRIVE-D41.1-UDrive-dataset-and-key-analysis-results-with-annotation-codebook.pdf>. [Accessed: March 12, 2021].
- [25] C. Kaiser, A. Festl, G. Pucher, M. Fellmann, and A. Stocker, "The vehicle data value chain as a lightweight model to describe digital vehicle services", in *15th International Conference on Web Information Systems and Technologies, January 2019, Vienna, Austria*, pp. 68–79, doi: 10.5220/0008113200680079.
- [26] A. Jain, H. S. Koppula, S. Soh, B. Raghavan, A. Singh, and A. Saxena, "Brain4Cars: Car That Knows Before You Do via Sensory-Fusion Deep Learning Architecture", *brain4cars.com*, 2016. [Online]. Available: <http://brain4cars.com/>. [Accessed: Feb. 05, 2021].
- [27] B. II Kwak, J. Y. Woo, and H. K. Kim, "Know your master: Driver profiling-based anti-theft method", in *14th Annual Conference on Privacy, Security and Trust, PST 2016, April 2016, United States*, pp. 211–218, doi: 10.1109/PST.2016.7906929.
- [28] S. Schneegass, B. Pflöging, N. Broy, A. Schmidt, and F. Heinrich, "A data set of real world driving to assess driver workload", in *5th International Conference on Automotive User Interfaces and Interactive Vehicular Applications, AutomotiveUI 2013, October 28 – 30, 2013, Eindhoven, Netherlands*, pp. 150–157, doi: 10.1145/2516540.2516561.
- [29] P. Angkititrakul et al., "Getting Start with UTDrive: Driver-Behavior Modeling and Assessment of Distraction for In-Vehicle Speech Systems", in *8th Annual Conference of the International Speech Communication Association, Interspeech 2007, 27-31 August, 2007, Antwerp, Belgium*, pp. 1334–1337, doi: 10.1.1.100.1333.
- [30] S. Mittal, M. Shuja, and M. Zaman, "A Review of Data Mining Literature", *International Journal of Computer Science and Information Security (IJCSIS)*, vol. 14, no. 11, pp. 437–442, November 2016.
- [31] S. Ramírez-Gallego, B. Krawczyk, S. García, M. Woźniak, and F. Herrera, "A survey on data preprocessing for data stream mining: Current status and future directions", *Neurocomputing*, vol. 239, pp. 39–57, May 2017. doi: 10.1016/j.neucom.2017.01.078.

[32] S. Alasadi, “Review of Data Preprocessing Techniques in Data Mining”, *Journal of Engineering and Applied Sciences*, vol. 12, no. 16, pp. 4102–4107, September 2017.
doi: 10.3923/jeasci.2017.4102.4107.

[33] T. Dasu ve T. Johnson, *Exploratory Data Mining and Data Cleaning*, John Wiley & Sons, Inc., 2003, pp. 1–16.

[34] A. Oğuzlar, “Veri Ön İşleme”, *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, cilt 0, sayı 21, ss. 67–76, Ekim 2003.

[35] M. Pechenizkiy, S. Puuronen, and A. Tsymbal, “Feature Extraction For Classification In The Data Mining Process”, *International Journal on Information Theories & Applications*, vol. 10, no.1, pp. 271–278, 2003.

[36] A. Gürler, A. S. Yılmaz, ve M. Tekerek, “Veri Görselleştirme ve İnfografikler”, *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*, c. 21, sayı 2, ss. 131–148, Haz. 2018.
doi: 10.17780/ksujes.391274.

[37] Ö. Uyurca ve İ. Atılğan , “Trafik Denetiminde Coğrafi ve İklimsel Koşulların Etkilerinin İncelenmesi”, *Gazi Mühendislik Bilimleri Dergisi*, c. 2, sayı. 2, ss. 107-127, Haz. 2016.

[38] G. Doğrul, D. Akay ve M. Kurt , “Trafik Kazalarının Birliktelik Kuralları İle Analizi”, *Gazi Mühendislik Bilimleri Dergisi*, c. 1, sayı. 2, ss. 265-283, Haz. 2015.

This is an open access article under the CC-BY license
(<https://creativecommons.org/licenses/by/4.0/>)

