

Sürüş Davranış Tespiti ve Tasnifi için Takograflara Yönelik Yeni Bir Algoritma Tasarımı ve Uygulaması

Araştırma Makalesi/Research Article

 Cevat ALTUNKAYA¹,  Ahmet ZENGİN²

¹ Elektrik-Elektronik Mühendisliği, Sakarya Üniversitesi, Sakarya, Türkiye

² Bilgisayar Mühendisliği, Sakarya Üniversitesi, Sakarya, Türkiye

cevat.altunkaya1@ogr.sakarya.edu.tr, azengin@sakarya.edu.tr

(Geliş/Received:26.02.2022; Kabul/Accepted:22.08.2022)

DOI: 10.17671/gazibtd.1079364

Özet— Günümüzde yollardaki araç sayısı arttıkça trafik güvenliğinin önemi de artmaktadır. Birden çok aracın karıştığı trafik kazaları sürücü ve yolcuların hayatını tehdit etmektedir. Takograf kullanımı zorunlu olan kamyon, otobüs gibi ağır vasıta araçlar, trafik kazalarında daha fazla ölüm, yaralanma ve maddi kayıplara yol açmaktadır. Geleneksel takograflar dönüş ve şerit değişiklikleri gibi yanıl manevraların şiddetiyle ilgili herhangi bir bilgi vermemektedir. Agresif sürücü davranışlarının trafik kazaları ve yakıt tüketimine etkisi önemli boyutlarda olabilmektedir. Bu çalışmada ivmeölçer ve jiroskop verilerini kullanarak sürücü davranışını tespit etmek ve derecelendirmek için yeni bir algoritma tasarlanmış ve yeni bir takograf cihazı geliştirilmiştir. Bu amaçla, yanıl manevraların algılanması için takograf cihazına düşük maliyetli bir IMU (Inertial Measurement Unit) sensör modülü eklenmiştir. Sağa-sola dönüşler ve şerit değişiklikleri manevralarını yüksek hassasiyetle tespit etmek için öncelikle jiroskop-Z verileri ile olayların kenarları yakalanır ve başlangıç ve bitiş noktaları belirlenir. Ardından aralıktaki ivmeölçer-X, jiroskop-Z ve hız verilerini bir formülle birleştirilerek yanıl manevraları puanlayan yeni bir algoritma önerilmiştir. Yapılan testlerde algoritmanın dönüşlerin algılanmasında %100, şerit değişikliklerinde %88 doğruluğa yaklaştığı gözlemlenmiştir.

Anahtar Kelimeler: sürüş manevra algılama, agresif sürüş, sürüş puanlama, takograf, sensörler

Design and Implementation of a New Algorithm to Tachographs for Driving Behavior Detection and Classification

Abstract—Today, as the number of vehicles on the roads increases, the importance of traffic safety increases. Traffic accidents involving more than one vehicle threaten the lives of drivers and passengers. Heavy-duty vehicles such as trucks and buses, for which the use of tachographs is mandatory, cause more deaths, injuries and financial losses in traffic accidents. Conventional tachographs do not provide any information on the severity of lateral maneuvers such as turns and lane changes. The effects of aggressive driver behaviors on traffic accidents and fuel consumption can be significant. In this study, a new algorithm was designed and a new tachograph device was developed to detect and rate driver behavior using accelerometer and gyroscope data. For this purpose, a low-cost IMU (Inertial Measurement Unit) sensor module has been added to the tachograph device to detect lateral maneuvers. In order to detect right-left turn and lane change maneuvers with high precision, first the edges of the events are captured with the gyroscope-Z data and the start and end points are determined. Then, a new algorithm that scores lateral maneuvers is proposed by combining the accelerometer-X, gyroscope-Z and speed data in the range with a formula. In the tests performed, it was observed that the algorithm approached 100% accuracy in detecting turns and 88% accuracy in lane changes.

Keywords: driving maneuver detection, aggressive driving, driving scoring, tachograph, sensors

1. GİRİŞ (INTRODUCTION)

Günümüzde yollardaki araç sayısı arttıkça trafik güvenliğinin önemi de artmaktadır. Özellikle kamyon ve otobüs gibi ağır vasıta araçların sebep olduğu kazalardaki kayıplar hem ölüm ve yaralanma hem de maddi hasar bakımından daha yüksektir. İstatistiklere göre kazalar çok yüksek oranda sürücü kusurlarından kaynaklanmaktadır [1]. Karayollarında yük ve yolcu taşımacılığı yapan araçların büyük bir kısmında kullanılması zorunlu olan takograflar, trafik güvenliği için sürücülerin hız, araç kullanma ve dinlenme sürelerinin denetlenebilmesini sağlayan cihazlardır [2]. Mevcut takograflar, trafik kazalarının ve fazla yakıt tüketiminin en önemli nedenleri olan yorgunluk, dikkatsizlik, uykusuzluk, agresif sürüş ve benzeri sürücü davranışları hakkında herhangi bir veri sunmamaktadır. Halbuki birçok kazanın sebebi tehlikeli sürüş davranışlarıdır. Trafik kazaları ve yakıt tüketimini azaltmak amacıyla sürüş manevralarını tespit ederek düzeltmek için birçok çalışma yapılmıştır [3-6]. Doğrusal manevraların tespitinde GPS veya araçtan alınan hız bilgisi yeterli olurken [7] yanal manevraların tespitinde jiroskop, ivmeölçer ve manyetometre gibi sensörler kullanılmıştır [8-12]. Artık hayatımızın vazgeçilmez haline gelen akıllı telefonlar söz konusu sensörlerin hepsini ihtiva ettiği için son dönemde özellikle yanal manevra davranışlarıyla ilgili çalışmaların ana unsuru haline gelmiştir [5,6,13]. Bu çalışmanın amacı ağır vasıtalarda kullanımı zorunlu olan takograf cihazlarına yönelik ivmeölçer ve jiroskop verilerini kullanarak sürücünün yanal manevralarını tespit etmek ve puanlamak için yeni bir algoritma tasarlamaktır.

Çalışma için maliyet, boyut ve montaj kolaylığı nedeniyle üzerinde 3D ivme ölçer, 3D jiroskop, 3D manyetometre ve basınç sensörü içeren 10 DOF IMU sensor modülü takograf cihazına monte edilmiştir. Bu sensörler kullanılarak akıllı telefonlar üzerinde yanal manevraları algılamak için yapılan çalışmalar bulunmaktadır. Bu çalışmaların sürücüyü uyararak sürücü davranışlarını düzeltme [3,4], sürücü davranışlarını tespit ederek sürücüyü etiketleme veya puanlama [5,6,9,14-16,19], yolculuklardaki manevraları inceleyerek sürüş özelliklerini tespit etme [8,11,13,20,21], yolculuklardaki kaza riskini algılama [7,10,17,19], yakıt tüketimini azaltmak için sürüş verilerini istatistiksel olarak inceleme [12] ve sürüş sırasında sürücü dikkat dağınıklığı tespit etme [22] gibi çeşitli alanlara odaklandığı görülmektedir.

Revize edilerek sensör ve hız verilerini yolculuklarda hafızasına kaydetmesi sağlanan test takografından indirilen veriler analiz edilerek yanal manevraları tespit edip puanlayan yeni bir algoritma geliştirildi. Jiroskop-Z verileri taranarak öncelikle kenarlar bulunur. Önceki kenarların durumu da dikkate alınarak kenarın bir şerit değişikliği veya dönüş manevrasına ait olduğuna karar verilir. Ardından dönüş manevralarına jiroskop, ivmeölçer ve hız ortalamalarını içeren bir formülle, şerit değişikliklerine jiroskop eğimi ve hız ortalaması ile puan verilir.

2. İLGİLİ ÇALIŞMALAR (RELATED WORKS)

Son yıllarda sürüş davranışıyla ilgili çalışmalar otonom sürüş, sürücü destek ve agresif sürüş tespiti konularında yoğunlaşmıştır. Otonom sürüş çalışmalarında nesnelerin ve yol çizgilerinin algılanmasında genellikle kamera görüntüleri ve LIDAR dönüşleri kullanılmış, görüntü işleme tekniklerinden istifade edilmiştir [27,28]. Sürücü davranışlarına odaklanan çalışmaların bir kısmında biyomedikal sensörler ve görüntü işleme teknikleri de kullanılmıştır [29-31]. Görüntü işleme tekniklerinin yüksek işlem ve hafıza kapasiteli mikrodenetleyiciler veya bilgisayarlar gerektirmesi maliyeti artırmaktadır. Biyomedikal sensörlerin de çoğunun maliyeti yüksektir. Ayrıca birçoğu sürücü üzerine monte edilme gibi kullanım zorluklarına sahiptir.

Düşük maliyetli sensörlerle yapılan yakın alandaki agresif sürüş tespit çalışmaları daha çok sürüş stilini, sürücü davranışını ve kaza riskini algılama ve yakıt tüketimini azaltmaya yönelik yönlendirme ve bilgi vermeye odaklanmıştır. Literatürdeki çalışmalarda virajlar, eğimler, şerit değişiklikleri ve u dönüşleri algılanmaya ve tasnif edilmeye çalışılmıştır. Sadece yanal manevralara odaklanan çalışmalar olduğu gibi doğrusal ve yanal manevralara birlikte odaklanan çalışmalar da mevcuttur. Hız bilgisi genellikle GPS kaynaklarından alınmıştır. Dönüşler, şerit değişiklikleri ve u dönüşleri jiroskop, ivmeölçer ve manyetometrelerle algılanmıştır. Birçok çalışmada sadece jiroskop verileri kullanılmıştır. GPS'den alınan hız verileri yüksek binalar nedeniyle yansımaların çok olduğu şehir merkezlerinde, tünellerde ve sinyallerin zayıf olduğu durumlarda hatalara sebep olmaktadır. Diğer sensörler için araca koordinatları belirlenmiş şekilde monte edilmiş bir cihaz yerine akıllı telefonların kullanılması çalışmaların pratikte uygulanabilirliğini güçleştirmektedir.

Çalışmalarda manevraların başlangıç ve bitiş noktalarını algılamada daha çok belirli bir pencere için basit hareketli ve karesel ortalamaya dayanan uç nokta algılama sistemi [23] veya standart sapma ve benzeri değerlerin eşik değere bağlı kontrolü gibi yöntemler kullanılmıştır. Bazı çalışmalarda kontrol edilen verilerin zamana bağlı dalgaları eşik değer üzerinden incelenmiştir. Bu yöntemlerle özellikle şerit değişikliklerinin çoğunun ve art arda gelen dönüş manevraların bir kısmının algılanması zordur. Bu çalışma kapsamında yapılan testlerde de bu durum görülmüştür. Yanal manevraların başlangıç ve bitiş noktalarının tespitinden sonra manevranın türünün tespit edilmesinde çoklu dalga (art arda gelen dalgaların yorumlanması) [3], bir desen eşleştirme yöntemi olarak Dinamik Zaman Bükme (Dynamic Time Warping - DTW) [4-6,8,13,20] ve K-En Yakın Komşu (K-Nearest Neighbors - K-NN) [5,21] gibi yöntemlerin yanı sıra olasılık ve tahmine dayalı Çok Katmanlı İleri Beslemeli Sinir Ağı (Multilayer Feed Forward Neural Network - FFNN) [23], Gizli Markov Modeli (Hidden Markov Model - HMM) [14,19,20] ve Maksimum Benzerlik (Maximum Likelihood - ML) [6] gibi teknikler de kullanılmıştır.

2011 yılında Johnson ve Trivedi tarafından akıllı telefon ile olaylar jiroskopun dönme enerjisinin basit hareketli ortalamasını kullanan uç nokta algılama yöntemiyle belirli bir pencere için tespit edilmiştir [5]. Daha sonra her üç sensörden (jiroskop, ivmeölçer, manyetometre) her olay için 5 farklı şablon olmak üzere toplam 120 şablon oluşturulmuştur. Desen eşleştirme tekniği DTW ve sınıflandırma yöntemi olarak K-En yakın komşular yöntemlerini kullanarak manevraları ayırt etmişlerdir. Çalışmada dönüşler için maksimum %93 doğruluğa ulaşılmıştır. Birçok farklı şablonun kullanılması akıllı telefonun dışında bir cihaz söz konusu olduğunda gecikmelere ve hatalara sebep olabilecek bir durumdur. Manevra puanlaması normal ve agresif olarak iki kategoride yapılmıştır.

2015 yılında Pholprasit ve arkadaşları tarafından akıllı telefon ile doğrusal ve yanal manevralar algılanmaya çalışılmıştır [4]. İvmeölçer verilerinin standart sapması eşik değer kontrolüne tabi tutularak olaylar algılandıktan sonra DTW desen eşleştirme yöntemi ile manevralar ayrıştırılmış, sadece ivme ölçer kullanılarak maksimum %80 doğruluğa ulaşılmıştır. İvmeölçer verileri jiroskop verilerine göre daha fazla gürültü içerdiğinden standart sapma hesabıyla özellikle şerit değişikliği ve art arda gelen dönüş manevralarının algılanmasında zorluklar bulunmaktadır. Manevraların puanlanması normal ve ani olmak üzere sadece iki kategori için yapılmıştır.

2015 yılında Engelbrecht ve arkadaşları tarafından akıllı telefon vasıtasıyla yanal manevraları algılamak amacıyla olaylar belirli bir pencere için ortalama verilerini kullanarak uç nokta algılama sistemiyle tespit edilip desen eşleştirme (DTW) yöntemi ve bir olasılık yöntemi olan ML ile ayırt edilmiştir [6]. Çalışmada iki yöntemin sonuçları kıyaslanarak ML'nin daha iyi sonuçlar verdiği gösterilmiştir. ML yöntemiyle maksimum %89.1 doğruluğa ulaşılmıştır. Agresif manevraların sınıflandırma doğruluğu normal manevradan daha düşüktür. Agresif manevralar için ayrı şablonlar bulunduğu bazı manevraların kaçırılması veya yanlış kategoride değerlendirilmesi kaçınılmazdır.

2015 yılında Daptardar ve arkadaşları tarafından akıllı telefon vasıtasıyla jiroskop verileri Kalman filtresiyle düzeltildikten sonra saniyelik eğimler hesaplanarak HMM'nin giriş katmanı oluşturulmuş, manevra sınıflandırmada %95 doğruluğa ulaşılmıştır [14]. Manevraların çoğu bir saniyeden daha geniş olduğundan genişliği değişken eğim modeliyle manevra kenarlarının daha iyi yakalandığı bu çalışmada gözlenmiştir.

2016 yılında Ouyang ve arkadaşları tarafından akıllı telefon ile yanal manevraları algılamak için MultiWave ismi verilen yöntemle jiroskop verilerindeki dalgalar için eşik değer kontrolü yapıldıktan sonra art arda gelen dalga şekillerinden manevra türüne karar verilmiş, dönüşlerin algılanmasında %92 doğruluğa ulaşılmıştır [3]. Sıfıra göre eşik değere bakıldığından eşik değere bağımlılık yüksektir.

Art arda gelen dalga formlarından şerit değişikliklerinin algılanması yöntemi ani yön değiştiren veya sağa-sola dönüş sırasında gerçekleşen şerit değişikliklerini algılamada zorlanacaktır.

2016 yılında Kumtepe ve arkadaşları tarafından kameradan alınan görsel verilerle aracın CAN-bus (Controller area network-bus) hattından alınan verileri kullanarak belirli bir zaman aralığında sürücünün şerit takip ve öndeki araçlarla mesafesi araç hızı ve devir hızına göre değerlendirilerek davranışın agresif olup olmadığı tespit edilmiştir [29].

2018 yılında Najim Al-Din ve arkadaşları tarafından akıllı telefon vasıtasıyla olaylar kısa süreli enerji ortalamaları kullanılarak uç nokta algılama sistemiyle tespit edilip FFNN yöntemiyle ayırt edilmiştir [23].

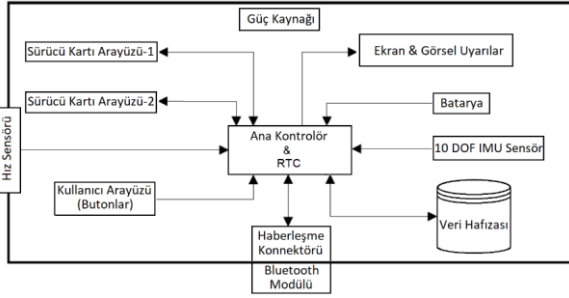
Tablo 1. Manevra algılama kullanılan yöntem ve sensörler (Methods and sensors used in maneuver detection)

Çalışma	Sensörler	Olay algılama tekniği	Manevra sınıflandırma tekniği	Manevra puanlama tekniği
Johnson – Trivedi [5]	GPS, Jiroskop, İvmeölçer, Manyetik	Uç nokta algılama	DTW, k-NN	DTW-şablonlarla (Normal-agresif)
Pholprasit [4]	GPS, Jiroskop, İvmeölçer, Manyetik	Eşik değer algılama	DTW, Desen eşleştirme	Eşik değer kontrolü (Normal-Ani)
Engelbrecht [6]	GPS, Jiroskop, İvmeölçer	Uç nokta algılama	DTW, ML	Hız+jiroskop+ ivme ile formül (Normal-agresif)
Daptardar [14]	GPS, Jiroskop, İvmeölçer,	Eğim kontrolü	HMM (Gizli Markov Modeli)	Doğrusal manevra için formül
Ouyang [3]	GPS, Jiroskop, İvmeölçer	Eşik değer algılama	Çoklu dalga kontrolü	Kullanılmamış
Kumtepe[29]	Kamera, OBD	Görüntü işleme	Görüntü işleme	Öznitelik kıyaslama (Sakin/Agresif)
Najim Al-Din [23]	Jiroskop, İvmeölçer, Manyetik, OBD	Uç nokta algılama	FFNN	Kullanılmamış

Tablo 1 çalışmalarda kullanılan sensör ve teknikleri özetlemektedir. Bu çalışmada yapılan test sonuçlarında özellikle şerit değişikliklerini algılamada manevra desenlerinin manevradan manevraya çok fazla değişiklik göstermesi nedeniyle desen eşleştirme yönteminin uygun olmadığı görülmüştür. Bunun dışında gerçekleşmiş olan veriler üzerinde inceleme yapıldığı için bu çalışmada tahmin ve olasılığa dayalı yöntemlerin kullanılmasına gerek görülmemiştir. Önceki çalışmalarda genellikle doğruluk sonuçlarında yakalanan manevra sayıları dikkate alınmıştır. Bu çalışmada yakalanan manevra sayısının yanı sıra manevra şiddet derecesi karşılaştırılması da yapılmıştır.

3. PROTOTİP TAKOGRAF TASARIMI (PROTOTYPE TACHOGRAPH DESIGN)

Saha testleri için piyasada kullanılan bir takograf üzerinde donanımsal ve yazılımsal değişiklikler yapıldı. Standart bir takograf cihazı, sürücü kimlik kartları vasıtasıyla aracı kullanan sürücülerin hız ve kullanım süre bilgilerini kaydetmektedir [17]. Takografin içine I2C haberleşme arayüzünü kullanarak takografin işlemcisiyle haberleşebilen 10 DOF IMU sensörü yere paralel olacak şekilde monte edildi. Test takografinin blok şeması Şekil 1’de gösterilmiştir.




Şekil 1. Test takograf blok şeması
(Test tachograph block diagram)

Test takograf araca titreşim ve darbelerden etkilenmemesi için Şekil 2’deki gibi araca sağlam bir şekilde monte edilmiştir. Ayrıca Android bir uygulama ile manuel olarak manevra başlangıç, bitişi ve manevra şiddetinin takograf kayıtlarına eklenebilmesi için bluetooth haberleşme donanımı seri port üzerinden takograf cihazına bağlanmıştır. Takografin kayıt kapasitesinin artırılması için ilave hafıza modülü (EEPROM) eklenmiş, böylece takograf ile ilgili donanımsal eklene ve bağlantılar tamamlanmıştır. Takografin yazılımı geliştirilerek her saniye ivmeölçer ve jiroskop verilerinin hafızaya kaydedilmesi sağlandı. Hafıza kapasitesinin 256 kbyte’a çıkarılmasıyla 8 saat civarında bir sürüş kayıt kapasitesine ulaşılmıştır.



Şekil 2. Araca monte edilen takograf cihazı
(Mounted tachograph device to the vehicle)


IMU modülü içinde 3D ivmeölçer ve 3D magnetometer bulunan LSM303DLHC [24] entegresi ile 3D jiroskop L3GD20 [25] entegresi ve BMP180 [26] basınç sensörü bulunmaktadır (Şekil 3). İvmeölçer saniyede 50 defa ölçüm yapacak şekilde, jiroskop saniyede 95 defa ölçüm yapacak şekilde ayarlanmıştır.



Şekil 3. Takografda kullanılan 10 DOF IMU sensör
(10 DOF IMU sensors used in the tachograph)

Hız sinyali test yapılan HYUNDAI Accent Blue model aracın hız göstergesinden 2400 pulse/km şeklinde alınmakta, hız bu katsayıya göre hesaplanmaktadır. Hız dahil bütün sensör verileri saniyede bir okunarak hafızaya kaydedilmiştir. İvmeölçerin her bir ekseninin ölçüm hassasiyeti 12 mg/digit, jiroskopun 8.75 mdps/digit, hız ölçümünün hassasiyeti ise 1,5 km/h’dir. İvmeölçer sensöründen okunan ham veriler g’ye, jiroskop sensöründen okunan ham veriler dps (degree per second)’ye çevrilmektedir.

Şekil 4’ten görüldüğü gibi ivmeölçerin Y eksenini doğrusal ivmelenmeleri, X eksenini yanal ivmelenmeleri, Z eksenini ise yerçekimi veya tersi yöndeki ivmelenmeleri tespit etmektedir. Çalışmada yanal ivmelenmelerin tespiti için X ekseninin kullanılmıştır. X ekseninde sağa dönüş pozitif, sola dönüş negatif değer vermektedir.




Şekil 4. İvmeölçer ve Jiroskop 3 eksen koordinatları
(Accelerometer and Gyroscope 3 axis coordinates)

Sağa veya sola dönüş açıları jiroskopun Z eksenini tespit edildiğinden dönüş açıları için kullanılmıştır. Jiroskopun pozitif dönüş yönü saat yönünün tersi olduğu için sola dönüşler pozitif işaretli, sağa dönüşler negatif işaretlidir.

4. YANAL SÜRÜŞ DAVRANIŞ TESPİTİ VE PUANLAMASI İÇİN YENİ BİR ALGORİTMA (A NEW ALGORITHM FOR DETECTION AND SCORING OF LATERAL DRIVING BEHAVIOR)

Bu bölüm takografdaki hız, jiroskop ve ivmeölçer sensörlerinden alınan verileri kullanarak sürüşlerdeki yanal manevraların agresiflik şiddetinin belirlenmesindeki algoritmayı anlatır. Sensörlerden alınan veriler hız dahil senkronizedir. Hız verisinin GPS yerine araçtaki hız sensörlerinden darbe şeklinde alınması kesintisiz ve gecikmesiz olmasını sağlamaktadır. Şekil 5’te algoritmanın aşamaları gösterilmiştir.



Şekil 5. Algoritma aşamaları
(Algorithm stages)

4.1. Önışleme (Preprocessing)

Manevraların başlangıç ve bitiş noktalarını tespit etmede aracın sağa-sola dönüşlerinin ivme ölçere göre daha gürlütüsüz olarak kaydedildiği Jiroskopun Z eksenini kullanılmaktadır. G_z verisinin kullanılması için birçok filtre denenmiş, filtre kullanmanın şerit değişikliklerini yakalamayı olumsuz etkilediği ve sağa-sola dönüş manevralarının tespitinde filtrenin çok fazla önemi olmadığı gözlenmiştir. Bu nedenlerle çalışmada saniyede bir kaydedilen G_z verileri için filtre kullanılmamıştır.

Cihazın araca montaj pozisyonuna bağlı olarak verilerde kayma olabilmektedir. O nedenle ivmeölçer-X ve jiroskop-Z'in yolculuktaki genel ortalamaları hesaplanır (1)(3). Ardından ofset değerini sıfıra çekmek için okunan verilere aşağıdaki işlem uygulanır (2)(4). Jiroskop Z ve ivmeölçer-X'in sıfır ofset ayarı

$$A_{x-ort} = \frac{1}{N} \sum_{i=1}^N A_x(i) \quad (1)$$

$$A_x(i)_{ofset} = A_x(i) - A_{x-ort} \quad (2)$$

$$G_{z-av} = \frac{1}{N} \sum_{i=1}^N G_z(i) \quad (3)$$

$$G_z(i)_{ofset} = G_z(i) - G_{z-ort} \quad (4)$$

Burada,

A_{x-ort} : Ortalama ivmeölçer-X, g

G_{z-ort} : Ortalama jiroskop-Z, dps


4.2. Olay Algılama Algoritması (Event Detection Algorithm)

Geliştirilen yöntemde başlangıçta manevranın tamamı yerine kenarlara (edge) odaklanılmıştır. Bir dalganın (manevranın) öncelikle kenarlarını bulup daha sonra bu kenarın manevra başlangıcı, manevra bitışı veya müstakil bir şerit değişikliği olduğuna karar verme yoluna gidilmiştir.

4.2.1. Kenar Algılama (Edge Detection)

Kenarların tespiti için sürekli olarak belirli bir aralık içinde maksimum ve minimum noktalar yakalanmaya çalışılmaktadır. Bahsi geçen belirli aralık olarak başlangıçta 7 sn baz alınmaktadır. 7 sn bir kenar için olabilecek geniş bir zaman olarak veriler incelenerek

bulunmuştur. Şekil 6.'da gerçek verilerden algılanan kenarların gösterimine ait bir bölüm bulunmaktadır.




Şekil 6. Algılanan kenarlar
(Detected edges)

7 sn içinde bulunan G_z değerlerinin maksimum ve minimum noktaları arasındaki fark için bir eşik değeri belirlenmiştir. Eşik değeri olarak da yapılan testler sonucu 2 dps değeri kullanılmaya karar verilmiştir. Bu eşik değeri o kadar hassas değildir. Biraz daha azaltılırsa sadece fazladan manevra tespiti yapılmış olur. Agresiflik derecelendirilmesinde fazladan tespit edilen manevralar elenecektir. $G_z(t)_{ofset}$ ($t = 1, 2, \dots, T$) zaman serisinin tamamı olarak varsayarsak, t eksenini boyunca kenar bulmak amacıyla T/k zaman serisi bölümlerine ayrılmıştır. Her bölümde bir k değeri vardır. Her bir kesit için aşağıdaki formülde gösterilen $E(n)$ değeri bulunur (5).

n: Zaman serisindeki kesit numarası

$$E(n) = \max_{1 \leq t \leq k} G_z(t, n)_{ofset} - \min_{1 \leq t \leq k} G_z(t, n)_{ofset} \quad (5)$$

$E(n) >$ Üst Eşik Değeri ($T_{fark} = 2$ dps)




Şekil 7. Fark (Maksimum G_z -Minimum G_z)
(Difference (Maximum G_z -Minimum G_z))

Maksimum ve minimum noktaları arasındaki fark $E(n)$ eşik değerden büyükse ve maksimum-minimum noktalarının işaretleri farklıysa veya en az biri eşik değerden büyükse ileri 3 saniye boyunca maksimum-minimum kontrolüne devam edilir. Böylece maksimum 9 saniye genişliğinde bir kenarı yakalamak mümkündür. 7 sn'den daha kısa sürede fark eşik değerini iki katına ulaşırsa döngüden erken çıkılır. Böylece algoritmanın birinci aşaması olan kenar bulma tamamlanmış olur. Kenarların bulunmasında sıfıra olan mutlak uzaklık yerine maksimum-minimum farklarının dikkate alınması manevraların tespitinde önemli bir avantaj sağlamaktadır (Şekil 7).

4.2.2. Kenar İçi Nokta (In-edge Point)

Maksimum-minimum noktaları bulduktan sonra bu noktalar arasında kalan sifıra en yakın kenar içi noktanın bulunmasında şöyle bir yöntem izlenmektedir. Kenarın maksimum ve minimum noktalarından mutlak değer olarak daha yüksek olandan daha düşük olana doğru ilerleyerek sifıra en yakın nokta bulunmaktadır (6).

$$G_z(t,n)_{\text{nokta}} = \begin{cases} 1, & \text{Eğer } \min_{1 \leq t \leq k} |G_z(t,n)_{\text{offset}}| < \text{Alt Eşik Değer (Tlow=1)} \\ 0, & \text{Diğer} \end{cases} \quad (6)$$

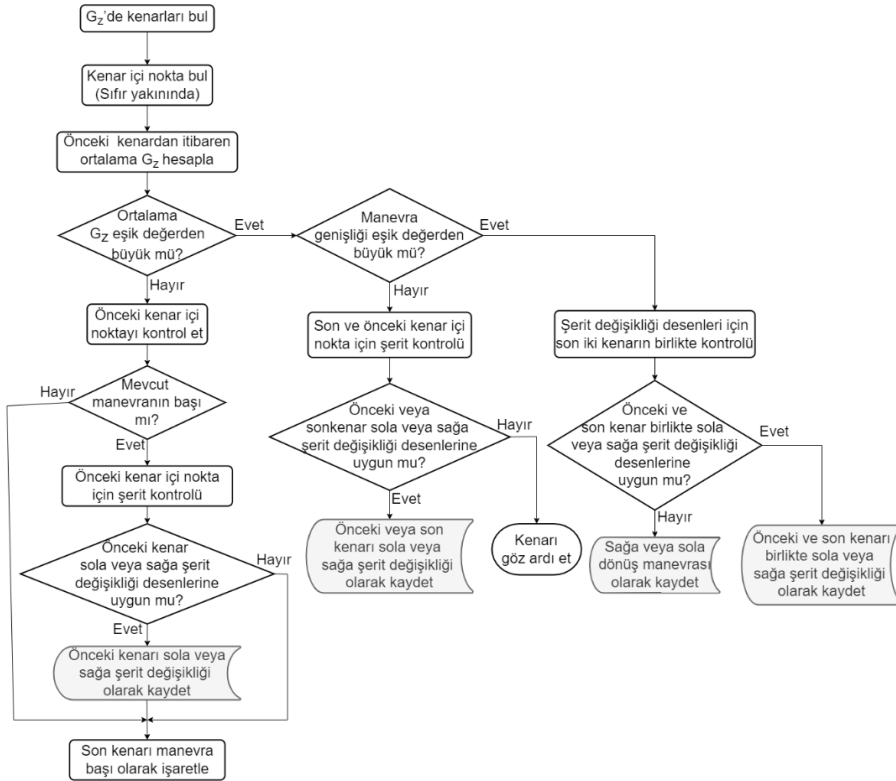


Şekil 8. Kenar içi nokta arama yönleri
(In-edge point search directions)

Manevra başında ileriye doğru tarayarak sifıra yakın nokta bulunduğunda titreşimler nedeniyle kenar noktasının tespitinde hatalar olabilmekte, daha geride bir nokta bulunabilmektedir. Bu nedenle Şekil 8’de gösterildiği gibi kenar manevra başı ise geriye doğru, manevra sonu ise ileriye doğru tarama söz konusudur.

4.3. Manevra Sınıflandırma (Maneuver Classification)

Şekil 9’da manevra sınıflandırma algoritmasının akış diyagramında gösterildiği gibi sifıra en yakın olarak bulunan kenar içi noktanın önceki değerlere bakılarak manevra başı veya manevra sonu olup olmadığı incelenir. Algoritma bulunan noktanın bir manevra kenarı olmayıp şerit değişikliği olduğunu tespit ederse şerit değişikliği parametresi olarak bulunan bu sifıra en yakın noktayı değil kenarın başlangıç ve bitiş noktalarını kaydeder. Dar (3 sn ve altı) manevralar ile öncesinde ve sonrasında belirli bir ortalama eşik değerin üstünde bir darbe olmayan kenarlar şerit değişikliği kategorisinde incelenmektedir.



Şekil 9. Manevra sınıflandırma algoritması akış diyagramı
(Flowchart of maneuver classification algorithm)

Eş zamanlı olarak tespit edilen kenar içi sifıra yakın noktadan itibaren G_z değerleri toplanmaktadır. Böylece herhangi bir anda bir kenar içi noktaya ulaşıldığında bir


önceki kenar içi noktadan itibaren toplam G_z değeri ve nokta sayısı (N) bilinmektedir. Bu sayede aşağıdaki formüle görülen ortalama dönüş açısı (θ_{ort}) bulunur (7)

$$\theta_{ort} = \frac{\sum_i^N G_z(i,n)}{N} \quad (7)$$

Ortalama dönüş açısı θ_{ort} belirli bir eşik değerinin altında ise kenar noktası manevra başı, üstünde ise manevra sonu olarak değerlendirilecektir (8).


$$n = \begin{cases} \text{Manevra başı, } \theta_{ort} < \text{Eşik Değer} \\ \text{Manevra sonu, } \text{Diğer} \end{cases} \quad (8)$$

Çalışmada manevraların algılanması için önce kenar, ardından kenar içi nokta bulunduktan sonra iki kenarın arasındaki ortalama değere bakılarak manevra tespit edilmektedir. Sağa ve sola şerit değişiklikleri zamana bağlı G_z değerlerinde en fazla 3-4 saniye içindeki bir değişikliğe yol açmaktadır. Şerit değişiklikleri iki kenarı olan manevralar yerine herhangi bir manevraya ait olmayan müstakil kenarların veya çok dar olan (3 sn ve altı) manevraların incelenmesiyle tespit edilmektedir. Şekil 10'da yolculuk verilerinde algoritma tarafından başlangıç ve bitiş noktaları işaretlenen manevraların bir bölümü gösterilmiştir.



Şekil 10. Manevra başlangıç-bitiş noktalarının algılanması
(Detection of maneuver start-end points)

Şerit değişikliği deseni (Lane Change Pattern): Manevraya ait olmadığı anlaşılan bir kenarın şerit değişikliği olup olmadığını tespit için başlangıç ve bitiş noktalarının ötesine bakılmaktadır. Yapılan incelemelerde sağa ve sola şerit değişikliklerinin Şekil 11'deki gibi bir desene sahip olduğu görülmüştür.



Şekil 11. Şerit değişikliği desenleri
(Lane change patterns)

Kenarlar bulunduktan hemen sonra manevra kontrolü yapılmadan önce kenarların 2-3 saniye devamı da kaydedilmektedir. Böylece kenarlara göre yapılan manevra kontrolünden sonra müstakil olduğu anlaşılan bir kenar için maksimum-minimum noktalarının devamına bakılarak şerit değişikliği kontrolü yapılmaktadır. Şekil 12'deki G_z yolculuk grafiğinde sadece şerit değişikliklerinin işaretlendiği bir bölüm görülmektedir.



Şekil 12. Şerit değişikliği kenar noktalarının algılanması
(Detection of lane change edge points)

4.4. Agresif Sürüş Puanlama (Aggressive Driving Scaling)

4.4.1. Dönüş Manevralarının Puanlanması (Scoring Turn Maneuvers)

Yanal dönüş manevralarının agresiflik derecesinin saptanmasında sadece jiroskop-Z verisinin yeterli olmadığı gözlenmiştir. İlave olarak yanal ivmelenme ve hız verilerinin de dikkate alınması doğruluğu artırmaktadır. Hız bilgisinin dikkate alınması konusunda herhangi bir tereddüt yoktur. Çünkü yanal manevra şiddetinin yüksek hızlarda oluşturduğu tehlike ile düşük hızlarda oluşturduğu tehlike farklıdır. Yapılan testler ivmeölçer verilerinin hesaba katılmasının da manevra şiddetini belirlemede doğruluğu artırdığını göstermiştir. Bu amaçla her bir manevrada jiroskop-Z, ivmeölçer-X ve hızın ortalama değerleri aşağıdaki formülle birleştirilerek manevranın GAS (Gyro-Accelometer-Speed) değeri bulunmaktadır (9).

$$GAS(n) = (G_{z-ort}(n) - D \cdot A_{x-ort}(n)) \cdot F \cdot Hız_{ort}(n) \quad (9)$$

n: Manevra indexi

$G_{z-ort}(n)$: İki kenar arasındaki manevranın ortalama G_z değeri

$A_{x-ort}(n)$: İki kenar arasındaki manevranın ortalama A_x değeri

$Hız_{ort}$: İki kenar arasındaki manevranın ortalama hız değeri

D: Manevranın ortalama A_x değerinin katsayısı. Büyüklüğü iki katına çıkarmak için G_z genel karekök ortalamasının A_x genel karekök ortalamasına (10) oranı olarak hesaplanmaktadır (11).

$$RMS(G_z) = \sqrt{\frac{\sum_i^n G_z(i)^2}{n}}, \quad RMS(A_x) = \sqrt{\frac{\sum_i^n A_x(i)^2}{n}} \quad (10)$$

$$D = RMS(G_z) / RMS(A_x) \quad (11)$$

F: Manevranın ortalama hız değerinin katsayısı. Yolculuktaki genel ortalama hız değeri dikkate alınarak GAS değerini 100'e ölçeklemek amacıyla ortalama için 50 değeri referans alınmak suretiyle F katsayısı aşağıdaki formülle bulunur (12).

$$F = (1/Hız_{gen-ort}) * 50 / (2 * RMS(G_z)) \quad (12)$$

GAS formülünde G_z ortalama değerleri ana referans olarak alınmış, G_z 'ye göre ters işaretli olan A_x ortalama değerleri eksi işaretli belirli bir katsayı ile çarpılarak G_z ortalamalarına eklenmektedir. Böylece yolculuktaki genel ortalamalar dikkate alındığında G_z büyüklükleri iki katına çıkmaktadır. Her bir manevra için bulunan GAS değerlerinin işareti yanal manevranın yönünü, büyüklüğü agresiflik derecesini belirlemektedir. GAS değerinin işareti pozitif ise sola dönüş, negatif ise sağa dönüş manevrasındır.

4.4.2. Şerit Değişikliklerinin Puanlanması (Scoring Lane Changes)

Şerit değişikliği manevralarının büyüklüğü sağa-sola dönüş manevralarından farklı olarak bulunan kenarın eğimiyle tespit edilmektedir. Çalışmada GSS (Gyro-Slope-Speed) olarak adlandırılan büyüklük eğimin yüksekliğine ve aralığın ortalama hızına bağlı olarak değişmektedir (13). Eğim söz konusu olduğu için şerit değişikliklerine ait büyüklükler işaretsizdir.

$$GSS(n) = \frac{\max G_z(n) - \min G_z(n)}{\Delta t} \cdot F \cdot Hız_{ort}(n) \quad (13)$$

n: Şerit değişikliği indeksi

F: Manevranın ortalama hız değerinin katsayısı.

Şerit değişikliğindeki F katsayısı bulunurken büyüklük olarak maksimum minimum fark değerleri kullanıldığından uyumlu olması için yolculuktaki G_z verilerine ait RMSD (G_z) standart sapma değeri referans alınmaktadır.

$$RMSD(G_z) = \sqrt{\frac{\sum_i^n (G_z(i) - G_{z,gen-ort})^2}{n}} \quad (14)$$

Yolculuktaki genel ortalama hız değeri dikkate alınarak GSS değerini 100'e ölçeklemek amacıyla ortalama için 50 değeri referans alınarak F katsayısı aşağıdaki formülle bulunur (15).

$$F = (1/Hız_{gen-ort}) \cdot 50 / (2 \cdot RMSD(G_z)) \quad (15)$$

Şerit değişikliklerinin yönü yukarıda anlatılan sağa ve sola şerit değişikliği desenlerinden bulunmaktadır. Algoritma bir kenarın veya dar bir manevranın şerit değişikliği olduğuna karar verdiğinde sağa veya sola hangi yöne olduğuna da karar vermektedir. Algoritma tarafından tespit edilen yanal manevralar ve manevraların puan aralığı üç kademe olarak Tablo 2'de verilmiştir.

Tablo 2'de sağa-sola dönüş manevraları ve sağa-sola şerit değişikliklerine ait büyüklüklerin aralığı üç kademe için verilmiştir. Elde edilen GAS ve GSS büyüklüklerini daha fazla kademelendirmek mümkündür. Algoritma ile yanal manevraların agresiflik derecesine odaklanıldığından U dönüşleri ayrı bir kategori olarak değil, sağa veya sola dönüş olarak kaydedilmiştir.

5. DENEYLER (EXPERIMENTS)

Bu bölümün amacı test takografında kaydedilen sensör verilerinin algoritmada denenmesidir.

Tablo 2. Algılanan yanal manevraların tasnifi
(Classification of detected lateral maneuvers)

	TR	TL	LCR	LCL
Kullanılan sensörler	Jiroskop-Z, İvme ölçer-X, Hız		Jiroskop-Z, Hız	
Düşük	>-60	<60	<12	
Orta	<=-60 >-100	>=60 <100	>=12 <24	
Yüksek	<=-100	>=100	>=24	
Puanlama birimi	GAS		GSS	
TR : Sağa dönüş TL : Sola dönüş LCR: Sağa şerit değişikliği LCL: Sola şerit değişikliği GAS: Dönüş manevra puanı GSS: Şerit değişikliği puanı				

5.1. Deneysel kurulum (Experimental Setup)

İçine 10-DOF IMU sensör modülü eklenen test takografı HYUNDAI Accent Blue model araca Şekil 13'teki gibi monte edilmiş, hız sinyali araç göstergesinin de bağlı olduğu ABS müşirinden alınmıştır.



Şekil 13. Araca monte edilen takograf cihazı
(Vehicle-mounted tachograph device)

Bluetooth haberleşme donanımı eklenen takograf, Android uygulama ile haberleşmeye uygun hale getirilmiştir. Şekil 14'te ara yüzü gösterilen uygulama ile araçta hareket halinde iken bir manevra gerçekleştirileceği zaman manevranın başlangıcında uygulamada ilgili tuşa basılarak takograf kayıtlarına manevra başlangıcının, manevra bittiği anda ise gerçekleşen manevranın şiddetine bağlı olarak normal, orta veya agresif olmak üzere üç farklı kademedeki bitiş noktasının etiketlenmesi sağlanmıştır. Böylece sürüş sırasında istenilen manevraların insan iradesiyle etiketlenebilmesi mümkün hale getirilmiştir.

Bu amaçla Yalova-Sakarya arasında 3833 saniyelik (yaklaşık 1 saat 5 dakika), 85 km'lik bir yolculuk güneşli havada, asfalt yolda yapılmıştır. Şekil 15'te gösterilen güzergahta virajların ve trafik ışıklarının olduğu bölümler de mevcuttur.



Şekil 14. Manevraların etiketlendiği uygulama ara yüzü
(Application interface where maneuvers are labeled)



Şekil 15. Yalova-Sakarya yolculuk rotası
(Yalova-Sakarya trip route)

Yolculukta hız ile birlikte jiroskop ve ivmeölçerin 3 eksen verileri her saniye hafızaya kaydedilmiştir. Yolculuk tamamlandıktan sonra bu veriler takografıdan bilgisayara aktarıldıktan ve ham veriler uygun birimlere çevrildikten sonra algoritmada denenmiştir.

Yapılan testlerde saniyede bir kaydedilen ham veriler filtrelenerek de denemeler yapılmış fakat o durumda özellikle şerit değişikliklerinin çoğunun kaçırıldığı gözlenmiştir. Veriler içinde yolculuk sırasında manuel olarak kaydedilen manevralar da bulunduğu için algoritmanın bulduğu sonuçlarla manuel olarak etiketlenen manevraların kıyaslanabilmesi mümkün olmuştur.

5.2. Sonuçlar (Results)


Yapılan yolculukta uygulama üzerinden bütün yanal manevralar etiketlenmemiş, belirli miktardaki bir manevra için etiketleme işlemi yapılmıştır. Yolculuk sırasında erken veya geç basmadan kaynaklanan etiketlemedeki kaymalar, bilgisayar ortamında veriler incelenerek kolayca düzeltilebilmiştir.

Tablo 3. Algoritmanın manevra sayısı tespit doğruluğu
(Maneuver count detection accuracy of the algorithm)

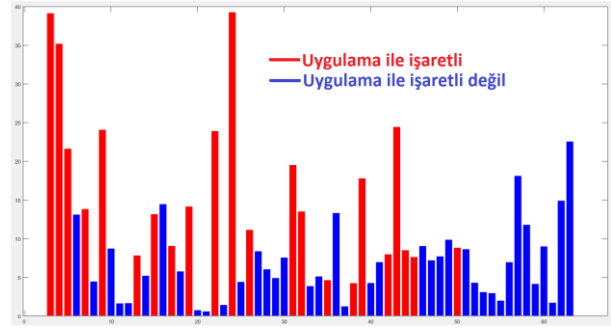
	Yanal Manevra Sayıları			
	TR	TL	LCR	LCL
Manuel kaydedilen	22	20	12	18
Algoritmanın yakaladıkları	22	20	8	13
Algoritma toplam	53	56	31	30
Yönü yanlış	0	0	0	2
Dönüş algılanan şeritler	3	4		
Şerit algılanan dönüşler			0	0
Algılanmayanlar	0	0	0	2
Doğruluk (%)	100	100	66,66	72,22

Algoritma test sonuçlarının detaylı verildiği Tablo 3'te manuel şerit değişikliği olarak etiketlendiği halde algoritmanın sağa-sola dönüş olarak kaydettiği 7 manevra bulunmaktadır. Bu manevraların dalga genişliği limit değerlerden fazladır. Dalganın geniş olması şerit değişikliği manevralarının agresif olmayacağı şeklinde yorumlanabilir. Kaçırılan şerit değişikliklerinin agresiflik açısından düşük puanlı oldukları hesaplanmıştır. Dolayısıyla söz konusu şerit değişikliklerinin sağa-sola dönüş manevraları olarak algılanması da doğru olarak kabul edildiğinde LCR için doğruluk oranı %100'e, LCL için ise %88.88'e çıkmaktadır. Fakat LCL sayılarından iki tanesinin yanlış bir şekilde LCR olarak kaydedildiğini de belirtmek gerekir. Tespit edilen manevra sayıları açısından sonuçlar değerlendirildiğinde algoritmanın sağa-sola dönüş manevralarında oldukça başarılı olduğu, şerit değişikliklerinde büyük oranda başarılı olduğu görülmektedir. Yapılan önceki çalışmalarda da yanal manevralar algılanırken şerit değişikliklerinde sorunlar yaşandığı anlaşılmıştır.

Yalova-Sakarya yolculuğunda algoritma tarafından yakalanan bütün manevraların puanları hesaplanmıştır. Hesaplanan puanlara ait grafikler Şekil 16 ve Şekil 17'de verilmiştir. Dönüş manevralarındaki GAS değerleri yönlü oldukları için grafikte eksenin üst tarafındaki (pozitif) çubuklar sola dönüş büyüklüklerini, alt tarafındaki (negatif) çubuklar sağa dönüş büyüklüklerini göstermektedir.



Şekil 16. Algoritmanın yakaladığı dönüş manevralarının GAS değerleri
(GAS values of turning maneuvers detected by the algorithm)



Şekil 17. Algoritmanın yakaladığı şerit değişikliklerinin GSS değerleri
(GSS values of lane changes detected by the algorithm)

Şerit değişikliklerindeki GSS değerleri eğime bağlı olduklarından yönlü değildir. Fakat algoritma şerit değişikliklerinde söz konusu kenarların maksimum ve minimum noktalarının önce veya sonra olmasına göre yönü tespit ederek kaydetmektedir.

Grafiklerden uygulama ile işaretlenmeyen mavi çubuklu manevra büyüklüklerinin genel olarak kırmızılardan daha kısa olduğu görülmektedir. Dönüş manevralarının ve şerit değişikliklerinin puanlarının doğruluk değerlendirmesi yapılırken olay bitiminde üç kademedeki şiddet etiketlemesi sırasında araç hızının dikkate alınmadığını, sadece hissedilen dönüş sertliğine göre karar verildiğini belirtmek gerekir. Bu durum Tablo 4'de gösterilen sonuçlara yansımıştır.

Tablo 4. Algoritmanın manevra şiddet doğruluğu
(Maneuvering intensity accuracy of the algorithm)

	Toplam Yanal Manevra Sayıları			
	TR	TL	LCR	LCL
Düşük	41	37	42	
Orta	11	16	14	
Yüksek	1	3	5	
Manuel kayıtlarda algoritmanın yakalama oranları				
Düşük	11/14	8/10	5/14	
Orta	5/7	4/7	2/7	
Yüksek	0/1	0/3	-	
Doğruluk(%)	72,72	60	33,33	
Puan birimi	GAS		GSS	

6. DEĞERLENDİRMELER (CONCLUSIONS)

Çalışma ile karayollarında insan ve yük taşımacılığı yapan ağır vasıta araçlarda kullanımı zorunlu olan takografların sürüşlerle ilgili hız ve süre denetiminin yanı sıra sürüşün nasıl yapıldığına dair agresiflik derecesi hakkında bilgi verilmesi sağlanarak sürücü kaynaklı kazaların ve yakıt tüketiminin azaltılması hedeflenmiştir. Çalışmada sürücünün inisiyatifinde olan akıllı telefon yerine ağır vasıta araçlarda kullanımı zorunlu olan takograf cihazlarının kullanılması çalışmaya pratik hayata uygulanabilirlik özelliği katmaktadır. Literatürdeki manevra sınıflandırma çalışmalarında genellikle olasılık, desen eşleştirme ve yapay zekâ teknikleri kullanılmıştır. Bu yöntemler çoğunlukla yüksek hafıza ve işlem

kapasitesine sahip cihazlar gerektirir. Bu çalışmada geliştirilen algoritma düşük işlem ve hafıza kapasiteli takograf cihazına bile kolaylıkla uygulanabilmektedir.

Önceki çalışmalardan farklı olarak manevra başlangıç ve bitiş noktalarının daha yüksek doğrulukla yakalanmasına yönelik yeni bir kenar algılama yöntemi sunulmuştur. Önceki çalışmalardaki en önemli problemlerden biri şerit değişikliklerinin algılanmasındaki yetersizlikti. Geliştirilen algoritma ile kenarların şerit değişikliği açısından öncelikle incelenmesi sayesinde şerit değişiklikleri daha yüksek oranda yakalanmaktadır. Şerit değişikliklerinin dönüş manevrası olarak kaydedilmesi mümkün olsa da kaçırılma oranı düşüktür. Dönüş manevraları çok yüksek doğrulukla yakalanmaktadır.

Yanal manevraların agresif olmayanları da algoritma tarafından yakalanabildiği için manevra agresiflik puan skalasının doğruluğu yüksektir. Manevra agresiflik derecesinin puanlamasında hız da formüle dahil edildiğinden kaza riski daha gerçekçi bir şekilde tespit edilmektedir. Manevraların agresiflik puanlamasının yapılması, sürüşlerin puanlanabilmesinin, sonrasında sürücünün puanlanabilmesinin yolunu açacaktır.

KAYNAKLAR (REFERENCES)

- [1] Internet: T.S. Institute, <https://data.tuik.gov.tr/Bulten/Index?p=Karayolu-Trafik-Kaza-Istatistikleri-2019-33628>, 19.5.2021.
- [2] Internet: C. I. R. (EU), Implementing Regulation (EU) No 165/2014 of the European Parliament and of the Council laying down the requirements for the construction, testing, installation, operation and repair of tachographs and their components, https://www.legislation.gov.uk/eur/2016/799/pdfs/eur_20160799_2018-04-17_en.pdf, 19.5.2021.
- [3] Z. Ouyang, J. Niu, Y. Liu ve J. Rodrigues, "Multiwave: A Novel Vehicle Steering Pattern Detection Method based on Smartphones", **IEEE International Conference on Communications (ICC)**, Kuala Lumpur, Malezya, 1-7, 22-27 Mayıs 2016.
- [4] T. Pholprasit, W. Choochaiwattana ve C. Saiprasert, "A Comparison of Driving Behaviour Prediction Algorithm Using Multi-Sensory Data on a Smartphone", **IEEE/ACIS 16th International Conference on Software Engineering, Artificial Intelligence, Networking and Parallel/Distributed Computing (SNPD)**, Takamatsu, Japonya, 1-6, 1-3 Haziran 2015.
- [5] D. A. Johnson ve M. M. Trivedi, "Driving style recognition using a smartphone as a sensor platform", **14th International IEEE Conference on Intelligent Transportation Systems (ITSC)**, Washington, DC, ABD, 1609-1615, 5-7 Ekim 2011.
- [6] J. Engelbrecht, M. J. Booysen, G-J. van Rooyen ve F. Bruwer, "Performance Comparison of Dynamic Time Warping (DTW) and a Maximum Likelihood (ML) Classifier in Measuring Driver Behavior with Smartphones", **IEEE Symposium Series on Computational Intelligence**, Cape Town, Güney Afrika, 427-433, 7-10 Aralık 2015.
- [7] B. Fernandes, V. Gomes, J. Ferreira ve A. Oliveira, "Mobile Application for Automatic Accident Detection and Multimodal Alert", **IEEE 81st Vehicular Technology Conference (VTC Spring)**, Glasgow, Birleşik Krallık, 1-5, 11-14 Mayıs 2015.
- [8] H. Eren, S. Makinist, E. Akin ve A. Yılmaz, "Estimating Driving Behavior by a Smartphone", **Intelligent Vehicles Symposium**, Alcalá de Henares, İspanya, 234-239, 3-7 Haziran 2012.
- [9] Y. Wang, T. Zhao, F. Tahmasbi, J. Cheng, Y. Chen ve J. Yu, "Driver Identification Leveraging Single-turn Behaviors via Mobile Devices", **29th International Conference on Computer Communications and Networks (ICCCN)**, Honolulu, HI, ABD, 1-9, 3-6 Ağustos 2020.
- [10] F. Li, H. Zhang, H. Che ve X. Qiu, "Dangerous Driving Behavior Detection Using Smartphone Sensors", **IEEE 19th International Conference on Intelligent Transportation Systems (ITSC)**, Rio de Janeiro, Brezilya, 1902-1907, 1-4 Kasım 2016.
- [11] J. Paefgen, F. Kehr, Y. Zhai ve F. Michahelles, "Driving Behavior Analysis with Smartphones: Insights from a Controlled Field Study" **Proceedings of the 11th International Conference on Mobile and Ubiquitous Multimedia**, Ulm, Almanya, 1-8, 4 Aralık 2012.
- [12] Y. A. Alqudah ve B. H. Sababha, "A Statistical Approach to Estimating Driving Events by a Smartphone", **International Conference on Computational Science and Computational Intelligence**, Las Vegas, NV, ABD, 1021-1025, 15-17 Aralık 2016.
- [13] X. Liu, H. Mei, H. Lu, H. Kuang ve X. Ma, "A Vehicle Steering Recognition System Based on Low-Cost Smartphone Sensors", **MPDI sensors**, 17(3), 633, 2017.
- [14] S. Daptardar, V. Lakshminarayanan, S. Reddy, S. Nair, S. Sahoo ve P. Sinha, "Hidden Markov Model based Driving Event Detection and Driver Profiling from Mobile Inertial Sensor Data", **IEEE Sensors**, Busan, Kore (Güney), 1-4, 1-4 Kasım 2015.
- [15] A. Bhatt, V. Dave, Y. Panchamia ve P. P. Thakre, "Analyzing Behavioral Attributes of Drivers and Implementing Safe Driving Model", **IEEE International Conference on Vehicular Electronics and Safety (ICVES)**, Viyana, Avusturya, 228-232, 27-28 Haziran 2017.
- [16] H. R. Eftekhari ve M. Ghatee, "Hybrid of discrete wavelet transform and adaptive neuro fuzzy inference system for overall driving behavior recognition", **Transportation Research Part F: Traffic Psychology and Behaviour**, 58(1), 782-796, 2018.
- [17] G. Castignani, T. Derrmann, R. Frank ve T. Engel, "Driver Behavior Profiling Using Smartphones: A Low-Cost Platform for Driver Monitoring", **IEEE Intelligent Transportation Systems Magazine**, 7(1), 91-102, 2015.
- [18] R. Sun, Q. Cheng, F. Xie, W. Zhang, T. Lin ve W. Y. Ochieng, "Combining Machine Learning and Dynamic Time Wrapping for Vehicle Driving Event Detection Using Smartphones", **IEEE Transactions On Intelligent Transportation Systems**, 22(1), 194-207, 2019.
- [19] E. G. Mantouka, E. N. Barmounakis ve E. I. Vlahogianni, "Identification of driving safety profiles from smartphone data using machine learning techniques", **Safety Science**, 119, 84-90, 2019.

- [20] Y.-C. Tsai, W.-H. Lee ve C.-M. Chou, "A Safety Driving Assistance System by Integrating In-Vehicle Dynamics and Real-Time Traffic Information", **IEEE 8th International Conference on Awareness Science and Technology**, Taichung, Tayvan, 416-421, 8-10 Kasım 2017.
- [21] K. B. Ahmed, B. Goel, P. Bharti, S. Chellappan ve M. Bouhorma, "Leveraging Smartphone Sensors to Detect Distracted Driving Activities", *IEEE Transactions On Intelligent Transportation Systems*, 20(9), 3303-3312, 2019.
- [22] L. Lamel, L. Rabiner, A. Rosenberg ve J. Wilpon "An improved endpoint detector for isolated word recognition", *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 29(4), 777-785, 1981.
- [23] M. S. N. Al-Din, "Calibration and Pre-Processing Techniques for A Smartphone-Based Driving Events Identification and Classification System", **IEEE Electron Device Kolkata Conference**, Kolkata, Hindistan, 396-402, 24-25 Kasım 2018.
- [24] Internet: STMicroelectronics, Ultra-compact high-performance eCompass module: 3D accelerometer and 3D magnetometer, <https://www.st.com/resource/en/datasheet/lsm303dlhc.pdf>, 19.5.2021.
- [25] Internet: STMicroelectronics, MEMS motion sensor: three-axis digital output gyroscope, <https://www.st.com/en/mems-and-sensors/l3gd20.html>, 19.5.2021.
- [26] Internet: B. S. GmbH, BMP180 Digital pressure sensor, <https://cdn-shop.adafruit.com/datasheets/BST-BMP180-DS000-09.pdf>, 19.5.2021.
- [27] S. Fadadu, S. Pandey, D. Hegde, Y. Shi, F. C. Chou, N. Djuric ve C. V. Gonzales, "Multi-View Fusion of Sensor Data for Improved Perception and Prediction in Autonomous Driving", **2022 IEEE/CVF Winter Conference on Applications of Computer Vision (WACV)**, Waikoloa, HI, ABD, 3292-3300, 3-8 Ocak 2022.
- [28] G. Yenikaya, E. Düven, A. Üzgeç ve E. Yürüklü, "Sürücü Davranış Karakteristiklerinin Tanımlanması İçin Görü Temelli Bir Sürüş Sisteminin Tasarlanması", **OTEKON 2010**, 3 Haziran 2010.
- [29] Ö. Kumtepe, E. Yüncü ve G. B. Akar, "Agresif Sürüş Tespiti İçin Çok Modlu Bir Yaklaşım", **2016 24th Signal Processing and Communication Application Conference (SIU)**, Zonguldak, Türkiye, 3292-3300, 729-732 Mayıs 2016.
- [30] M. H. Z. M. Fodli, F. H. K. Zaman, N. K. Mun ve L. Mazalan "Driving Behavior Recognition using Multiple Deep Learning Models", **2022 IEEE 18th International Colloquium on Signal Processing & Applications (CSPA)**, Selangor, Malaysia, 138-143, 12 Mayıs 2022.
- [31] A.Ç. Seçkin, "Otonom Araçların Görsel Eğitimi için EEG, EMG ve IMU ile Etiketleme Sistemi", *Bilişim Teknolojileri Dergisi*, 12(4), 299-305, 2019.