



# DeneySEL Olarak Ölçülen Farklı Sürüş Davranışlarının K En Yakın Komşuluklar Yöntemleriyle Sınıflandırılması

Tuba Nur Serttaş<sup>1\*</sup> ve Fatih Serttaş<sup>2</sup>

<sup>1\*</sup> Afyon Kocatepe Üniversitesi, Teknoloji Fakültesi, Elektrik Elektronik Bölümü, Afyonkarahisar, Türkiye, (ORCID: 0000-0002-6596-7162), [mgul@aku.edu.tr](mailto:mgul@aku.edu.tr)

<sup>2</sup> Afyon Kocatepe Üniversitesi, Mühendislik Fakültesi, Elektrik Bölümü, Afyonkarahisar, Türkiye, (ORCID: 0000-0003-3109-716X), [fserttas@aku.edu.tr](mailto:fserttas@aku.edu.tr)

(1st International Conference on Applied Engineering and Natural Sciences ICAENS 2021, November 1-3, 2021)

(DOI: 10.31590/ejosat.1011026)

**ATIF/REFERENCE:** Serttaş, T. N. & Serttaş, F. (2021). DeneySEL Olarak Ölçülen Farklı Sürüş Davranışlarının K En Yakın Komşuluklar Yöntemleriyle Sınıflandırılması. *Avrupa Bilim ve Teknoloji Dergisi*, (28), 790-794.

## Öz

Bu çalışmada, 13 farklı sürücünün aynı aracı, aynı güzergahta ve aynı çevre koşullarında sürmesi sağlanmıştır. Sürüşler başlamadan araca araç takip cihazı monte edilmiş ve eş zamanlı olarak akıllı telefon uygulaması kullanılmıştır. Sürüşlerin kontrollü bir şekilde gerçekleştirildiği rota, sürüş davranışlarını ortaya çıkarabilecek özelliklere sahip olacak şekilde seçilmiştir. Açısal hız ile ilgili sonuçların doğru bir şekilde alınabilmesi için sağa-sola dönüş ve u dönüşü manevralarının kullanıldığı bölümler bulunmaktadır. Aynı amaçla yolda tümsek, çukur, yaya, araç ve hız limitlerinin olmasına özen gösterilmiştir. Ardından sürücüler agresif, sakin veya normal olarak sınıflandırılmaktadır. Sınıflandırma yöntemi olarak k en yakın komşuluklar metodolojileri kullanılmıştır. Fine KNN yöntemi ile %84,6 doğruluk elde edilmiştir.

**Anahtar Kelimeler:** Sürüş karakteristiği, Sınıflandırma, Fine KNN, Weighted KNN, DeneySEL sürüş.

## Classification of Experimentally Measured Different Driving Behaviors using K Nearest Neighbors Methods

### Abstract

In this study, 13 different drivers were provided to drive the same vehicle on the same route and environmental conditions. Before the rides started, a vehicle tracking device was mounted on the vehicle and a smartphone application was used simultaneously. The route where the driving is carried out in a controlled way has been chosen to have features that can reveal driving behaviors. There are sections where right-left turns and U-turn maneuvers are used to obtain accurate angular velocity results. For the same purpose, care has been taken to ensure bumps, potholes, pedestrian, vehicle, and speed limits on the road. Afterward, drivers are classified as aggressive, calm, or usual. KNN methodologies are used as the classification method. Fine KNN application reaches 84,6% accuracy ratio.

**Keywords:** Driving characteristic, Classification, Fine KNN, Weighted KNN, Experimental driving.

\* Sorumlu Yazar: [mgul@aku.edu.tr](mailto:mgul@aku.edu.tr)

## 1. Giriş

Günümüzde artan araç kullanımı beraberinde çeşitli sorunlar getirmektedir. Bu sorunlar çeşitli faktörlerden kaynaklanıyor olsa da sürücü davranışı, yol güvenliğini etkileyen en önemli faktör olarak sayılabilmektedir. Bu nedenle, son zamanlarda sürücü davranışlarının izlenmesi ve tespit edilmesi aktif bir araştırma alanı olmuştur. Sürücülerin sınıflandırılması çalışmalarında çeşitli sınıflandırma yöntemlerini kullanılmaktadır. Daza ve arkadaşları tarafından gerçekleştirilen sürücü davranışı sınıflandırması çalışmasında yapay sinir ağları kullanılarak sürücü dikkatine dayalı bir sınıflandırma gerçekleştirilmiştir (Daza vd., 2011). Gizli Markov Modeli çeşitli çalışmalarda sürücü performans ve sürücü davranışı değerlendirilmesi, sürüş manevra tespiti ve yol durumunun incelenmesi gibi konularda kullanılmıştır (Boyras vd., 2007; Fu vd., 2016; Gadepally vd., 2011; Gadepally vd., 2013; Oliver & Pentland, 2000; Takeda vd., 2011).

Literatürde benzer uygulamalar veya araç sensörlerine sahip sürücüler ve sürücüler anlatan çok sayıda çalışma yer almaktadır. Miyajima ve diğerleri sürücüler arasındaki bireysel farklılıkları, özellikle bir aracı takip ederken, mesafeyi koruma ve yaya alışkanlıklarına dayalı olarak modellemektedir. Ayrıca çalışmada sunulan modelin sürücü özelliklerini ne kadar iyi temsil ettiği de gösterilmiştir (Miyajima vd., 2007). Sakaguchi ve diğerleri, Bayes ağlarını kullanarak bir sürücünün durma davranışını modellemiştir (Sakaguchi vd., 2003), Oliver ve Pentland (2000) ise bu davranışları HMM yöntemini kullanarak modellemiştir. Sürücü davranışları incelendiğinde sadece normal yaşam standartlarında sınıflandırmanın sürücü tanımlaması için yetersiz kalacağı düşünülmektedir. 25 farklı kaza riskinin bulunduğu tehlikeli bir senaryo için sürücülerden alınan verilerin çalışmasında, potansiyel olarak tehlikeli durumların meydana geldiği yerler ile sık sık güçlü fren yapılan alanlar arasında güçlü bir ilişki olduğu sonucuna varılmıştır (Malta vd., 2009). Aynı zamanda trafik kazalarını azaltmak ve sürüş konforunu artırmak için tasarladığımız otomatik sürüş asistanları da sürücüler için olumsuz sonuçlar doğurabiliyor. Acil bir durumda sürücü durumu analiz etmeli ve müdahale etmelidir. Analiz ve müdahale süresi çok kısa olduğu için sürücülerin özelliklerinin belirlenmesi hayati önem taşımaktadır. Otomatik sürüş asistanı ile sürüş, sürücüye fiziksel olarak müdahale etmez, bu nedenle sürücü tanımlaması için sürücülerin görüşleri incelenir. Bu çalışmaya göre araç sürüş asistanında olsa bile sürücünün yolu ve çevresini kontrol etmesi gerekiyor. Bu bağlamda deneklerden alınan sürüş verilerinde şerit değişikliklerinin dikkati incelenmiş ve otomatik sürüş sırasında ön yolda daha az dikkatli olan sürücülerin çevredeki risk faktörlerine karşı daha az duyarlı oldukları gösterilmiştir. ve otomatik sürüş sırasında tutarsız şerit değiştirme kararları verme eğilimindedir (Miyajima vd., 2015). Geliştirilen otonom araçlar ve sürüş asistanları bu sınıflandırmalara dayalı olarak geliştirilmektedir. Skoda, Volkswagen gibi araçlarda bulunan sürüş asistan sistemleri, direksiyon hareketlerini, düzensiz fren sistemini, şerit hareketlerini vb. göz önünde bulundurarak sürücünün uykusunu bulur ve sürücüyü uyarır. Damian Salapatek ve diğerleri, ana bileşen analizi, sinir ağları, gabor filtreleri, frekans uzaysal yöntemlerinden oluşan bir görüntü işleme algoritması uygulayarak vizyon tabanlı bir yaklaşım geliştirmiştir. Gabor filtreleri kullanılarak yüz özellikleri etkin bir şekilde elde edilebilir (Salapatek vd., 2017).

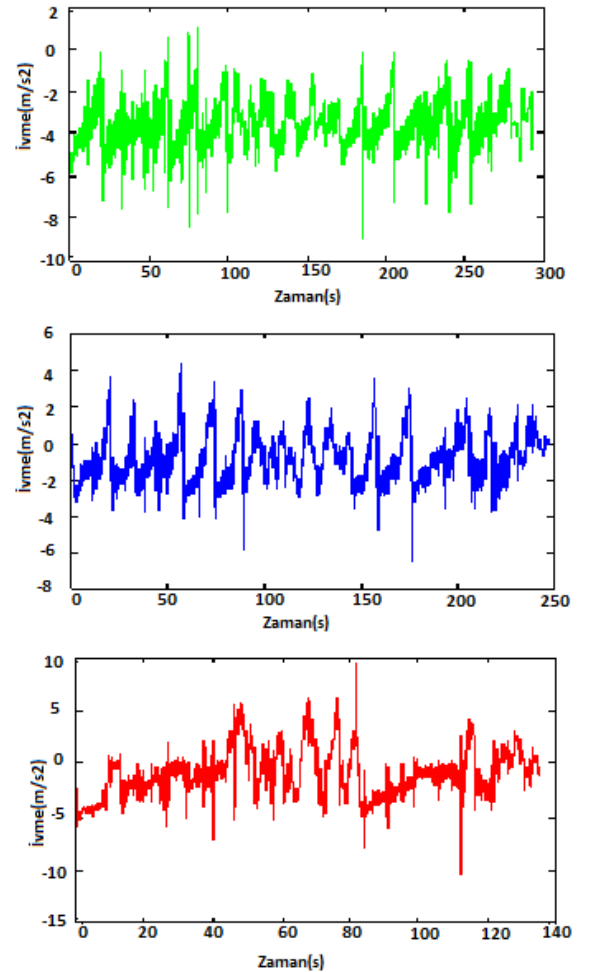
Ayrıca sürücülerin sürüş davranışlarına göre sigorta primi ödemesi gibi uygulamalar da sürücü sınıflandırmanın getirdiği önemli katkılardandır. Mercedes Ayuso ve diğerleri, kullandıkları sigorta poliçesinin uygulanması için bir model geliştirmiştir. Sürücünün sürüş şekli, hız ve mesafe dikkate alınarak Küresel Konumlandırma Sistemi kullanılarak belirlenir (Ayuso vd., 2014).

Bu çalışmada, sürücülerin davranışlarına dayalı sınıflandırılması konusunu ele almaktadır. Çalışmada 3 ayrı sınıf belirlenmiş ve sürücüler belirli özellikleri doğrultusunda bu sınıflara atanmıştır. Sınıflandırma yöntemi olarak kNN kullanılmıştır. Sınıflandırma sonucu daha önceden belirlenen sürücü etiketleri ile uyumluluğu sınıflandırma doğruluğunu ortaya koymuştur. MATLAB programında yer alan 6 farklı kNN sınıflandırıcı (Fine kNN, Medium kNN, Coarse kNN, Csine kNN, Cubic kNN ve Weighted kNN) için sonuçlar karşılaştırılmıştır.


## 2. Materyal ve Metot

### 2.1. Veri Seti

Testlere katılan erkek ve kadın sürücülere birden fazla sürüş yaptırılarak 13 sürücü için veri seti oluşturulmuştur. Veri setinde ivme ve açılma hız verileri yer almaktadır. 3 ayrı sınıfa ait örnek birer sürücüye ait ivme veri grafiği Şekil 1’de ve açılma hız veri grafiği Şekil 2’de verilmiştir.



Şekil 1. Farklı sınıflarda yer alan sürücülere ait ivme değerleri (sakin, normal ve agresif)



Şekil 2. Farklı sınıflarda yer alan sürücülere ait açısal hız değerleri (sakin, normal ve agresif)

## 2.2. k-En Yakın Komşu Yöntemi(kNN)

K-en yakın komşu yöntemi, gözlemlerin yapılacağı sınıfı ve k değerine göre en yakın komşuyu belirleyen bir sınıflandırma yöntemidir. Gözlemlere veya nesnelere arasındaki mesafeye göre sınıflandırmaya yapan denetimli veri madenciliği algoritmalarından biridir. Yöntem, örüntü tanıma, yapay zeka, veri madenciliği, istatistik, bilişsel psikoloji, tıp ve biyoinformatik gibi birçok alanda kullanılmaktadır (Özkaya ve Seyfi, 2021; Fix ve Hodges, 1951). K-en yakın komşu algoritması, sınıflandırmayı mesafe veya yakınlık hesaplamasına göre yapar. Özetle, bu sınıflandırma algoritması "örnek uzayda birbirine yakın olan nesnelere muhtemelen aynı kategoriye ait olduğu" fikrine dayanmaktadır.

Algoritmanın amacı, bireyleri veya nesnelere önceden belirlenmiş sınıflara veya gruplara bu nesnelere özelliklerini kullanarak en doğru şekilde atamaktır. Yöntem ayrıca yeni bir gözlemin sınıflandırılmasına da izin verir. Öğrenme veri seti yardımıyla, sınıflandırılacak gözlem, en yakın k gözlem arasından en benzerleri ile aynı veri setinde sınıflandırılır.

K-en yakın komşu algoritması, sınıflandırmayı mesafe veya yakınlık hesaplamasına göre yapar. Özetle, bu sınıflandırma algoritması "örnek uzayda birbirine yakın olan nesnelere muhtemelen aynı kategoriye ait olduğu" fikrine dayanmaktadır.

Bu yöntem yapılırken aşağıdaki adımlar gerçekleştirilir (Cover and Hart; 1967).

1. Yeni gözlemin veri setindeki tüm gözlemlere uzaklığı hesaplanır,
2. Bu mesafe değerleri sıralanır,
3. En küçük mesafeli k gözlem seçilir,
4. k gözleminde, çoğunluk oylama kategorisi sınıf değeridir.

Çalışmada kullanılan 6 farklı kNN algoritması için MATLAB programında verilen bilgiler şu şekilde sıralanmaktadır:

(i) Fine KNN: İnce ayrıntılı hale getiren en yakın komşu sınıflandırıcı

komşu sayısı 1 olarak ayarlanmış sınıflar arasındaki farklar.

(ii) Medium KNN: Daha azını yapan en yakın komşu sınıflandırıcı

komşu sayısı 10'a ayarlanmış bir İnce KNN'den farklar.

(iii) Coarse KNN: Komşu sayısı 100 olarak ayarlanmış, sınıflar arasında kaba ayırım yapan en yakın komşu sınıflandırıcı.

(iv) Cosinus KNN: Kosinüs uzaklığı metriğini kullanan en yakın komşu sınıflandırıcı.

(v) Cubic KNN: Kübik mesafe metriğini kullanan en yakın komşu sınıflandırıcı.

(vi) Weighted KNN: Uzaklık ağırlıklandırmasını kullanan en yakın komşu sınıflandırıcı

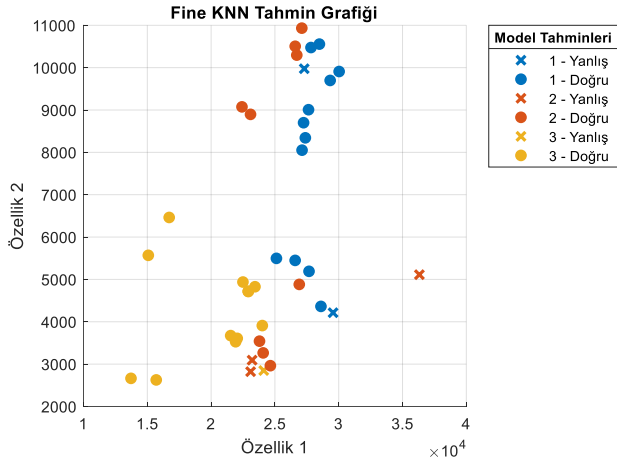
## 3. Araştırma Sonuçları ve Tartışma

Farklı kNN yöntemleri ile gerçekleştirilen sınıflandırma sonuçları Tablo 1'de gösterilmiştir. Bu veriler için en düşük sınıflandırma doğruluğu Coarse kNN yöntemi ile elde edilirken ek yüksek sınıflandırma yüzdesi %84,6 doğruluk ile Fine kNN yöntemidir.


Tablo 1. Sürüş verilerinin test edildiği sınıflandırma yöntemleri karşılaştırması

KNN Yöntem Türü	Komşu Sayısı	Mesafe Metriği	Başarı Oranı
Fine KNN	1	Öklid	%84,6
Medium KNN	10	Öklid	%71,8
Coarse KNN	100	Öklid	%33,3
Cosinus KNN	10	Kosinüs	%64,1
Cubic KNN	10	Minkowski	%66,7
Weighted KNN	10	Öklid	<b>%82,1</b>

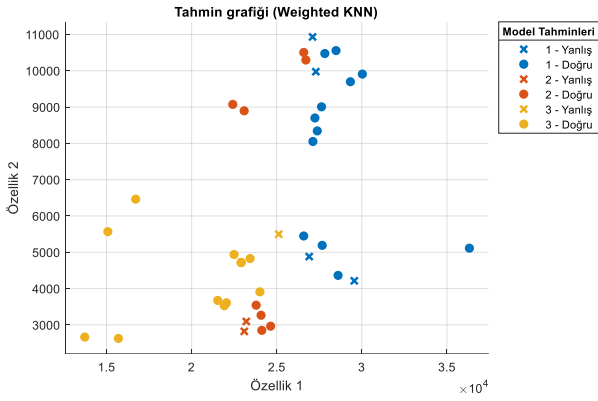
Sürücü sınıflandırma başarısı en yüksek iki kNN yöntemine ait grafikler sırasıyla sunulmuştur. Doğru ve yanlış tahmin edilen sürücülere ait dağılım grafiği Şekil 3'te ve Şekil 4'te sırasıyla "Fine kNN" ve "Weighted kNN" yöntemleri için verilmiştir.



Şekil 3. Fine KNN için dağılım grafiği




Şekil 6. Weighted KNN için karışıklık matrisi



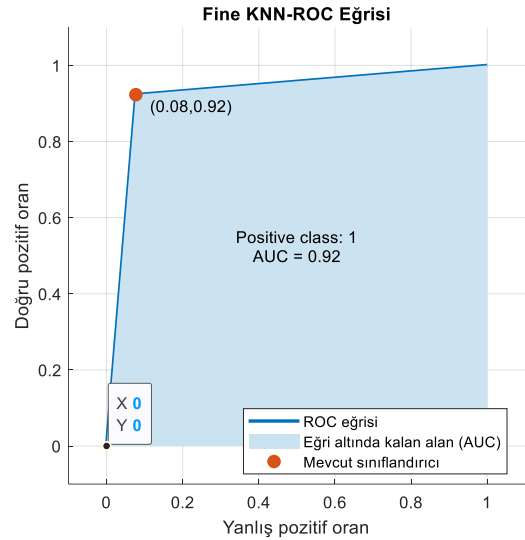
Şekil 4. Weighted KNN için dağılım grafiği

Şekil 5’ te verilen sınıf matrisi incelendiğinde sakin sınıfta yer alan onüç sürücünden onikisi doğru tahmin edilirken bir sürücü sınıf 2 olarak tahmin edilmiştir. Aynı şekilde normal sürüş davranışı gösteren sınıf 2 deki sürücülerden dokuz sürücü doru sınıfta yer alırken iki sürücü Sınıf 1 ve bir sürücü Sınıf 3e atanmıştır. Benzer olarak agresif sürücülerin bulunduğu Sınıf 3’ e ait oniki sürücü doğru iki sürücü yanlış sınıfa atanmıştır. Şekil 6’de de Weighted kNN yöntemi için sınıf matrisi görülmektedir.

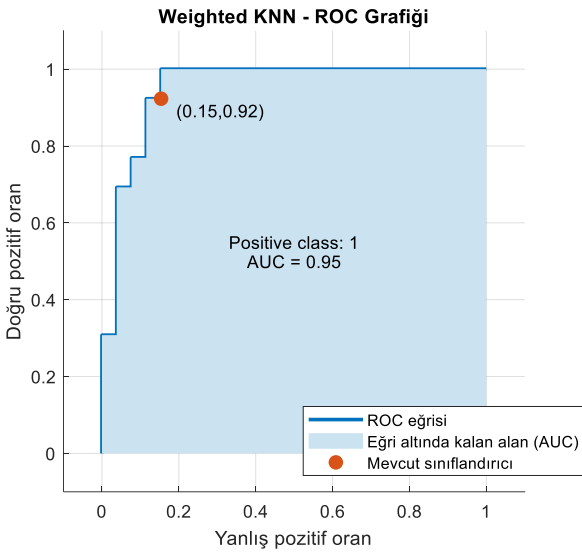


Şekil 5. Fine KNN için karışıklık matrisi

Şekil 7 ve Şekil 8’ de iki yönteme ait ROC eğrileri görülmektedir. ROC eğrileri, sınıflandırma yöntemleri için oldukça kritik bir performans belirteçidir. ROC bir olasılık eğrisidir ve altında kalan alan olan AUC, ayrılabilirliğin derecesini veya ölçüsünü temsil etmektedir. ROC eğrisinde X ekseninde YPO (Yanlış Pozitif Oran) ve Y ekseninde ise GPO (Gerçek Pozitif Oranı) bulunmaktadır. Eğrinin altında kalan alan arttıkça, sınıflar arasında ayırt etme performansı da artmaktadır. GPO duyarlılık değeridir. Yani araç sürücüsü sınıfını tespit edebilme oranıdır. YPO ise yanlış sınıflandırma yapma oranını ifade etmektedir.



Şekil 7. Fine KNN için ROC Eğrisi



Şekil 8. Weighted KNN için ROC Eğrisi

## 4. Sonuç

Farklı yaş ve cinsiyetlerde, farklı sürüş karakteristikleriyle (sakin, normal ve agresif) araç kullanan 13 kişinin, sürüş esnasında araç takip cihazı ve akıllı telefonlardaki sensörler yardımıyla, ivmeleri ve 3 boyutlu açışal hızları ölçülerek kaydedilmiştir. Elde edilen sürüş verileri; sakın, normal ve agresif olmak üzere 3 sınıfa ayrılacak şekilde, güncel KNN sınıflandırma yöntemleriyle test edilmiştir. Yöntemlerin içerisinde en iyi sınıflandırma başarısını gösteren “Fine KNN” (%84,6) ve “Weighted KNN” (%82,1) olarak gözlenmiş ve sınıflandırma sonuçları grafiksel metalarla sunulmuştur.

Sürücülerin sürüş eğilimleri araçtan elde edilen hız, ivme, açışal hız gibi verilerle açık şekilde ortaya konulabilmektedir. Bu veriler sürücünün fren-gaz pedalı kullanım sıklığı ve bu pedalların sert-yumuşak kullanımını, direksiyon manevra kabiliyeti gibi davranışlar için bilgi taşımaktadır. Bu veriler uygun yöntemlerle irdelenerek sürücüler farklı kriterlere dayalı olarak sınıflandırılabilirler.

Elektrikli ve otonom araçlara olan rağbetin gün geçtikçe artması, sürüş karakteristiklerinin modellenerek sınıflandırılması konularını daha da önemli hale getirmektedir. Bu nedenle başarılı sinyal işleme yöntemlerinin belirlenerek, gömülü sistemlere entegre şekilde çalışması kritik bir olgudur. Gelecek çalışmalarda, araçlar üzerinde çalışabilen, yüksek doğrulukta sınıflandırma yapan bir sistemin; kişi tanımlama, kişiye özel sürüş modu belirleme işlemlerini yapması planlanmaktadır.

## Kaynakça

- Ayuso, M., Guillén, M., & Pérez-Marín, A. M. (2014). Time and distance to first accident and driving patterns of young drivers with pay-as-you-drive insurance. *Accident Analysis & Prevention*, 73, 125-131.
- Boyras, P., Acar, M., & Kerr, D. (2007, June). Signal modelling and hidden markov models for driving manoeuvre recognition and driver fault diagnosis in an urban road scenario. In 2007 IEEE Intelligent Vehicles Symposium (pp. 987-992). IEEE.

- Daza, I. G., Hernández, N., Bergasa, L. M., Parra, I., Yebes, J. J., Gavilán, M., ... & Sotelo, M. A. (2011, October). Drowsiness monitoring based on driver and driving data fusion. In 2011 14th International IEEE Conference on Intelligent Transportation Systems (ITSC) (pp. 1199-1204). IEEE.
- Fix, E., & Hodges, J. L. (1989). Discriminatory analysis. Nonparametric discrimination: Consistency properties. *International Statistical Review/Revue Internationale de Statistique*, 57(3), 238-247.
- Fu, R., Wang, H., & Zhao, W. (2016). Dynamic driver fatigue detection using hidden Markov model in real driving condition. *Expert Systems with Applications*, 63, 397-411.
- Gadepally, V., Kurt, A., Krishnamurthy, A., & Özgüner, Ü. (2011, October). Driver/vehicle state estimation and detection. In 2011 14th International IEEE Conference on Intelligent Transportation Systems (ITSC) (pp. 582-587). IEEE.
- Gadepally, V., Krishnamurthy, A., & Ozguner, U. (2013). A framework for estimating driver decisions near intersections. *IEEE Transactions on Intelligent Transportation Systems*, 15(2), 637-646.
- Malta, L., Miyajima, C., & Takeda, K. (2009). A study of driver behavior under potential threats in vehicle traffic. *IEEE Transactions on Intelligent Transportation Systems*, 10(2), 201-210.
- Miyajima, C., Nishiwaki, Y., Ozawa, K., Wakita, T., Itou, K., Takeda, K., & Itakura, F. (2007). Driver modeling based on driving behavior and its evaluation in driver identification. *Proceedings of the IEEE*, 95(2), 427-437.
- Miyajima, C., Yamazaki, S., Bando, T., Hitomi, K., Terai, H., Okuda, H., ... & Takeda, K. (2015, June). Analyzing driver gaze behavior and consistency of decision making during automated driving. In 2015 IEEE Intelligent Vehicles Symposium (IV) (pp. 1293-1298). IEEE.
- Oliver, N., & Pentland, A. P. (2000, October). Graphical models for driver behavior recognition in a smartcar. In Proceedings of the IEEE Intelligent Vehicles Symposium 2000 (Cat. No. 00TH8511) (pp. 7-12). IEEE.
- Oliver, N., & Pentland, A. P. (2000, June). Driver behavior recognition and prediction in a SmartCar. In Enhanced and Synthetic Vision 2000 (Vol. 4023, pp. 280-290). International Society for Optics and Photonics.
- Özkaya, U., & Seyfi, L. (2021). Yere Nüfuz Eden Radar B Tarama Görüntülerinin Az Parametreye Sahip Konvolüsyonel Sinir Ağı İle Değerlendirilmesi. *Geomatik*, 6(2), 84-92.
- Sakaguchi, Y., Okuwa, M., Takiguchi, K. I., & Akamatsu, M. (2003). Measuring and modelling of driver for detecting unusual behavior for driving assistance. In Proceedings: International Technical Conference on the Enhanced Safety of Vehicles (Vol. 2003, pp. 7-p). National Highway Traffic Safety Administration.
- Saġapatek, D., Dybaġa, J., Czapski, P., & Skalski, P. (2017). Driver drowsiness detection systems. *Zeszyty Naukowe Instytutu Pojazdów/Politechnika Warszawska*, 3(112), 41-48.
- Takeda, K., Hansen, J. H., Boyraz, P., Malta, L., Miyajima, C., & Abut, H. (2011). International large-scale vehicle corpora for research on driver behavior on the road. *IEEE Transactions on Intelligent Transportation Systems*, 12(4), 1609-1623.