



Sürücülerin Stres Seviyesi Tespiti için Biyo-Sinyallerin Analizi Analysis of Bio-Signals for Drivers' Stress Level Detection

Betül Nurefşan YAMAN ve İdil IŞIKLI ESENER

Elektrik-Elektronik Mühendisliği
Bilecik Şeyh Edebali Üniversitesi
Bilecik, Türkiye

nurefsan.yaman11@gmail.com, idil.isikli@bilecik.edu.tr

Özetçe— Bu çalışmada, stres seviyesi tespiti için EKG, GSR, EMG ve RESP ölçümlerinden literatürde kabul görmüş öznelikler üzerinde Pearson korelasyon analizi ile öznelik seçimi yapılarak elde edilen özneliklerin, tespit çalışmasındaki bireysel performansları incelenmiştir. Bu doğrultuda, EKG, Ayak GSR ve RESP ölçümlerinden sırasıyla, 2-, 1- ve 3-boyutlu öznelik kümeleri oluşturulmuştur. Bu öznelik kümeleri, LLC, k-NN (k=5), RF, DT ve SVM algoritmaları tarafından sınıflandırılmıştır. Ayak GSR ölçümünden oluşturulan öznelik kümesi LLC algoritması kullanıldığında %66,67'lik bir doğruluk oranı ile en iyi başarıyı göstermiştir. Bu sonuç, seçilen özneliklerin beraber kullanıldıklarında stres seviyesini tanımlayıcı olduklarını göstermektedir.

Anahtar Kelimeler — stres tespiti, öznelik seçimi, öznelik korelasyonu.

Abstract— In this study, the individual performances of the selected features, obtained from the ECG, GSR, EMG and RESP measurements by applying Pearson correlation analysis on the features accepted in the literature, were examined for the stress level detection. Accordingly, 2-, 1- and 3-dimensional feature sets were generated from ECG, Foot GSR and RESP measurements, respectively. These feature sets are classified by LLC, k-NN (k = 5), RF, DT and SVM algorithms. The feature set generated from the foot GSR measurement shows the best success with an accuracy of 66.67% when the LLC algorithm is used. This result indicates that the selected features are descriptive for stress level when they are used together.

Keywords — stress detection, feature selection, feature correlation.

I. GİRİŞ

Bireyin fiziksel ve duygusal stresörlere bağlı olarak sergilediği olumsuz duyguları ve beklenmedik davranışları olarak tanımlanan negatif stres (distres), etkisi ve bu etkilerin süresine göre akut, epizodik akut ve kronik stres olarak incelenmektedir [1,2]. Literatürde, karayolu koşulları, trafik yoğunluğu, diğer sürücülerin ve/veya yayaların davranışları

gibi zorlu sürüş sebepleri sonucunda sürücülerin distrese maruz kaldığı ve bu durumun sürüş ihlalleri ve kazalara neden olduğu belirtilmektedir [3-6]. Sürücülerin maruz kaldığı distres, yakın geçmiş veya yakın geleceğe dair günlük yaşam stresörlerinden kaynaklanan ve kısa süreli distres olarak nitelendirilen akut stres tipinde incelenmektedir [5]. Akut stresin, sempatik sinir sistemini uyararak, kan şekeri seviyesi, solunum hızı, kalp atışı, kan basıncı ve kas aktivitesinde yükselmeye, nefes darlığı, terli avuç içi, soğuk eller veya ayaklar, baş dönmesi, göğüs ağrısı, baş ağrısı, göz bebeklerinin büyümesi gibi fizyolojik etkilere sebep olduğu bilinmektedir [7]. Bu fizyolojik etkilerin sayısal analizi için Elektrokardiyogram (EKG) [8-27], Fotopletismogram (PPG) [28], Galvanik Cilt Tepkisi (Galvanic Skin Response – GSR) [8-15, 17, 18, 20, 23, 25-27], Elektromiyogram (EMG) [8, 10-12, 15, 17, 18, 20, 21, 26] ve Solunum (Respiration – RESP) [8, 10-18, 20, 23, 25, 26] algılayıcılarından elde edilen ölçümler kullanılmaktadır.

Bu çalışmada, EKG, GSR, EMG ve RESP ölçümlerinden literatürde kabul görmüş özneliklerin birbirleri ve her bir stres seviyesi ile korelasyon analizi yapılarak gerçekleştirilen öznelik seçimi sonucunda elde edilen özneliklerin [7] stres seviyesini belirlemedeki bireysel performansları incelenmiştir. Sınıflandırma aşamasında, daha önce Işıklı Esener'in çalışmasında [7] olduğu gibi, Lojistik Doğrusal Sınıflandırıcı (Logistic Linear Classifier – LLC), k-En Yakın Komşu (k-Nearest Neighbor – kNN), rastgele orman (Random Forest – RF), karar ağacı (Decision Tree – DT) ve Destek Vektör Makineleri (Support Vector Machines – SVM) algoritmaları kullanılmış ve maksimum %66,67'lik bir doğruluk oranı elde edilmiştir. Bu durum, Işıklı Esener [7] tarafından seçilen ve %100 doğruluk oranı sağlayan özneliklerin, beraber kullanıldıklarında stres seviyesini tanımlayıcı olduklarını göstermektedir.

II. MATERYAL VE YÖNTEMLER

A. Veritabanı

Bu çalışmada, sürücülerin stres seviyesi tespiti için MIT-BIH PhysioNet Multi-Parameter Database [29] veritabanı kullanılmıştır. Healey ve Piccard [11] tarafından hazırlanan bu veritabanı, iki dinlenme duruma arasında gerçekleştirilen üç şehir içi ve iki otoban sürüşü sırasında 17 sürücüdün giyilebilir algılayıcılar ile toplanmış, 469 Hz'de örneklenmiş EKG, 15,5 Hz'de örneklenmiş EMG, 31 Hz'de örneklenmiş el ve ayak GSR ve kalp atış hızı (Heart Rate – HR) ölçümlerini içermektedir. Veritabanında, sürücülerin dinlenme durumunda düşük stres (DS) seviyesine sahip olduğu, otoban ve şehir içi sürüşlerinde ise sırasıyla orta stres (OS) ve yüksek stres (YS) seviyelerinden yakındığı belirtilmektedir.

Bu çalışmada, 17 sürücü arasından 10 sürücünün verileri kullanılmıştır [7].

B. Veri ön işleme

1) *EKG*: Taban çizgisi sapmasını (baseline wander) ve kas gürültüsünü gidermek amacı ile EKG ölçümlerine 0,5 Hz ve 4 Hz kesim frekanslarına sahip bir bant-geçiren filtre uygulanmıştır [7]. HR ve kalp atış hızı değişkenliğine (HRV) ilişkin özniteliklerin hesaplanması için, R-tepe noktaları, ters işlenmiş ikinci türev yöntemi [30] kullanılarak tespit edilmiştir [7].

2) *GSR*: Taban çizgisi sapmasının etkisini yok etmek için, el ve ayak GSR ölçümlerine 0,1 Hz ve 1 Hz kesim frekanslarına sahip bir Butterworth bant-geçiren filtre uygulanmıştır [7].

3) *RESP*: Taban çizgisi sapmasının ve vücut hareketlerinden kaynaklanan gürültünün giderilmesi için, RESP ölçümlerine hareketli-ortalama filtresi ve 1 Hz kesim frekansında 10. derece düşük geçiren filtre [23] uygulanmıştır [7].

4) *EMG*: Ani vücut hareketlerinden kaynaklanan gürültünün bastırılması için, EMG ölçümlerine 500 Hz kesim frekanslı Butterworth düşük geçiren filtresi uygulanmıştır [7].

C. Öznitelik çıkarımı

Işık Esener [7] tarafından gerçekleştirilen çalışmada EKG, el ve ayak GSR, RESP ve EMG ölçümlerinden literatürde kabul görmüş öznitelikler çıkarılmış ve bu özniteliklerin birbirleri ve her bir stres seviyesi ile ilişkisi Pearson korelasyon analizi kullanılarak belirlenmiştir.

Korelasyon analizi sonucunda, kalp atış hızının standart sapması (Standard Deviation of Heart Rate – SDHR) ve toplam spektral güç (Total Spectral Power – TP) özniteliklerinin sırasıyla DS ve OS seviyeleri ile çok güçlü ilişkili ve bu seviyelerde diğer öznitelikler ile neredeyse ilişkisiz olduğu tespit edilmiştir [7].

Ayak GSR ölçümlerinden elde edilen maksimum fazik genlik (Maximum Phasic Amplitude – MaxPhAmp) özniteliği OS seviyesi ile çok güçlü ilişkili ve bu seviye ile çok güçlü ilişki gösteren diğer öznitelikler ile neredeyse ilişkisiz olarak belirlenmiştir [7].

Benzer şekilde, 0,2-0,3 Hz arası solunum hızının spektral gücü (RESP power (0.2–0.3)) DS seviyesi ve solunum hızının ilk farkının standart sapması (Standard Deviation of First Difference – SDFD) ve solunum hızının ikinci farkının standart sapması (Standard Deviation of Second Difference – SDSD) da YS seviyesi ile çok güçlü ilişkili bulunurken bu seviyede diğer öznitelikler ile neredeyse ilişkisiz bulunmuşlardır [7].

El GSR ölçümlerinden elde edilen cilt iletkenliği tepki sayısı özniteliği LS seviyesi ile çok güçlü ilişkili olarak belirlendiği halde bu seviye ile çok güçlü ilişki gösteren 0,1-0,2 Hz arası solunum hızının spektral gücü RESP power (0.1–0.2) ve RESP power (0.2–0.3) öznitelikleri ile tam ilişkili olarak belirlenmiştir [7]. Yine El GSR ölçümlerinden elde edilen yarı-toparlanma zamanı toplamı özniteliği MS seviyesi ile çok güçlü ilişkili olarak belirlendiği halde bu seviye ile çok güçlü ilişki gösteren ayak GSR ölçümlerinden elde edilen MaxPhAmp ve ilk farkların ortalaması öznitelikleri ile tam ilişkili olarak belirlenmiştir [7]. Bu nedenlerden ötürü, el GSR ölçümlerinden elde edilen öznitelikler bu çalışmada kullanılmamıştır.

EMG ölçümlerinden elde edilen ortalama karekök özniteliği LS seviyesi ile çok güçlü ilişkili olarak belirlendiği halde bu seviye ile çok güçlü ilişki gösteren diğer öznitelikler ile güçlü ve/veya çok güçlü ilişkili bulunmuştur [7]. Ayrıca, bu ölçümlerden elde edilen hiçbir öznitelik MS ve YS seviyeleri ile çok güçlü ilişkili olarak tespit edilmemiştir [7]. Bu nedenlerden ötürü, EMG ölçümlerinden elde edilen öznitelikler de bu çalışmada kullanılmamıştır.

Bu sonuçlar doğrultusunda, bu çalışmada, EKG ölçümlerinden çıkarılan SDHR ve TP, ayak GSR ölçümlerinden çıkarılan MaxPhAmp ve RESP ölçümlerinden çıkarılan RESP power (0.2–0.3), SDFD ve SDSD öznitelikleri kullanılarak, bu ölçümlerin, stres seviyesi belirlemedeki bireysel performansları incelenmiştir. Bu özniteliklerin her bir stres seviyesi ile olan korelasyon katsayıları Tablo I'de gösterilmektedir.

TABLO I. SEÇİLEN ÖZİNTELİKLERİN HER BİR STRES SEVİYESİ İLE OLAN KORELASYON KATSAYILARI

	DS	OS	YS
SDHR	0.9242	0.1637	0.5361
RESP power (0.2-0.3)	0.8857	0.6233	0.1848
TP	0.1368	0.9999	0.1184
MaxPhAmp	0.1518	0.8847	0.6371
SDFD	0.0265	0.6543	0.9907
SDSD	0.5772	0.2235	0.9842
DS	1.000	0.412	0.416
OS	0.412	1.000	0.592
YS	0.416	0.592	1.000

D. Sınıflandırma

Seçilen özniteliklerin stres seviyesi tespiti için bireysel performansları, LLC, k-NN (k=5), RF, DT ve SVM sınıflandırıcıları kullanılarak 5-katlamalı çapraz-doğrulama yöntemi ile analiz edilmiştir. Performans ölçütü olarak Denklem (1)'de matematiksel ifadesi verilen doğruluk (accuracy – ACC) metriği kullanılmıştır. Denklemde TP, TN, FP ve FN terimleri sırasıyla, doğru pozitif, doğru

negatif, yanlış pozitif ve yanlış negatif sayılarını göstermektedir.

$$\%ACC = \frac{TP + TN}{TP + TN + FP + FN} \cdot 100 \quad (1)$$

III. SONUÇLAR VE TARTIŞMA

A. EKG ölçümü kullanılarak stres seviyesi tespiti

EKG ölçümlerinden çıkartılan SDHR ve TP öznitelikleri kullanılarak gerçekleştirilen sınıflandırma çalışması sonucunda en yüksek doğruluk %60 oranında, kNN, RF ve DT algoritmaları kullanıldığında elde edilmiştir. Bu algoritmalar tarafından oluşturulan karmaşıklık matrisleri Tablo II'de verilmiştir.

TABLO II. EKG ÖZNETELİKLERİ KULLANILARAK STRES SEVİYESİ TESPİTİ ÇALIŞMASINDAN ELDE EDİLEN KARMAŞIKLIK MATRİSLERİ

EKG		Sınıflandırma Sonucu								
		kNN			RF			DT		
		DS	OS	YS	DS	OS	YS	DS	OS	YS
Gerçek Sınıf	DS	4	6	0	5	3	2	7	3	0
	OS	4	6	0	5	3	2	6	3	1
	YS	4	4	2	3	3	4	5	3	2

B. RESP ölçümü kullanılarak stres seviyesi tespiti

RESP ölçümlerinden çıkartılan RESP power (0.2–0.3), SDFD ve SDSD öznitelikleri kullanılarak gerçekleştirilen sınıflandırma çalışması sonucunda en yüksek doğruluk %57,58 oranında, SVM ve RF algoritmaları kullanıldığında elde edilmiştir. Bu algoritmalar tarafından oluşturulan karmaşıklık matrisleri Tablo III'te verilmiştir.

TABLO III. RESP ÖZNETELİKLERİ KULLANILARAK STRES SEVİYESİ TESPİTİ ÇALIŞMASINDAN ELDE EDİLEN KARMAŞIKLIK MATRİSLERİ

RESP		Sınıflandırma Sonucu						
		SVM			RF			
		DS	OS	YS	DS	OS	YS	YS
Gerçek Sınıf	DS	10	0	0	4	4	2	
	OS	8	1	1	4	3	3	
	YS	7	3	0	2	4	4	

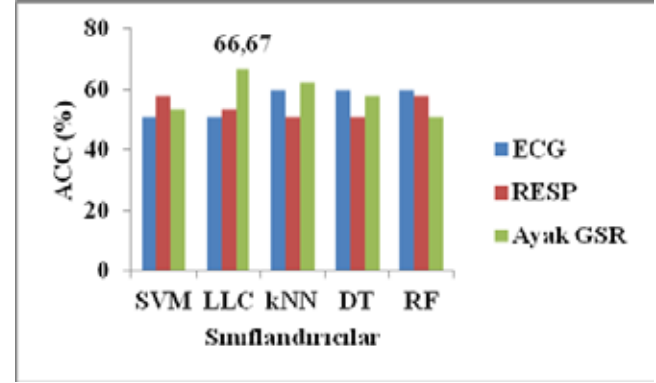
C. Ayak GSR ölçümü kullanılarak stres seviyesi tespiti

Ayak GSR ölçümlerinden çıkartılan MaxPhAmp özniteliği kullanılarak gerçekleştirilen sınıflandırma çalışması sonucunda en yüksek doğruluk %66,67 oranı ile LLC algoritması tarafından sağlanmıştır. Bu algoritma tarafından oluşturulan karmaşıklık matrisi Tablo IV'te verilmiştir.

TABLO IV. AYAK GSR ÖZNETELİKLERİ KULLANILARAK STRES SEVİYESİ TESPİTİ ÇALIŞMASINDAN ELDE EDİLEN KARMAŞIKLIK MATRİSLERİ

Ayak GSR		LLC		
		DS	OS	YS
Gerçek Sınıf	DS	1	2	7
	OS	1	6	3
	YS	0	2	8

Seçilen özniteliklerin LLC, k-NN, RF, DT ve SVM algoritmaları ile sınıflandırılması sonucu elde edilen ACC değerleri Şekil 1'de gösterilmektedir.



Şekil 1. Stres seviyesi tespiti doğruluk oranları.

IV. SONUÇ

Bu çalışmada, stres seviyesi tespiti için EKG, GSR, EMG ve RESP ölçümlerinden literatürde kabul görmüş öznitelikler üzerinde Pearson korelasyon analizi ile öznitelik seçimi yapılarak elde edilen özniteliklerden sırasıyla 2-, 1- ve 3-boyutlu öznitelik kümeleri oluşturularak, bu kümelerin tespit çalışmasındaki bireysel performansları incelenmiştir.

EKG ölçümlerinden oluşturulan 2-boyutlu öznitelik kümesi stres seviyesini en yüksek %60 doğruluk oranı ile tespit etmiştir. Tablo II'de verilen karmaşıklık matrisleri incelendiğinde, seçilen EKG özniteliklerinin tüm stres seviyelerini genel olarak DS seviyesi olarak tanımladığını göstermektedir. Bu durum, DS seviyesi ile yüksek ilişkili olan SDHR özniteliklerinin OS seviyesi ile yüksek ilişkili olan TP özniteliklerine göre daha baskın olduğunu düşündürmektedir. YS seviyesinin tespit edilememesi ise, seçilen özniteliklerin bu seviye ile ilişkisinin düşük olmasından kaynaklanmaktadır.

RESP ölçümlerinden oluşturulan 3-boyutlu öznitelik kümesi stres seviyesini en yüksek %57,78 doğruluk oranı ile tespit etmiştir. Tablo III'te verilen karmaşıklık matrisleri incelendiğinde, seçilen RESP özniteliklerinin, EKG özniteliklerinde olduğu gibi, tüm stres seviyelerini genel olarak DS seviyesi olarak tanımladığını göstermektedir. Bu durum, DS seviyesi ile yüksek ilişkili olan RESP power (0.2-0.3) özniteliklerinin, YS seviyesi ile yüksek ilişkili olan SDFD ve SDSD özniteliklerine göre daha baskın olduğunu düşündürmektedir. OS seviyesinin tespit edilememesi ise, seçilen özniteliklerin bu seviye ile ilişkisinin güçlü olmamasından kaynaklanmaktadır.

Ayak GSR ölçümlerinden oluşturulan 1-boyutlu öznitelik kümesi ise stres seviyesini en yüksek %66,67 doğruluk oranı ile en başarılı tespiti gerçekleştirmiştir. Tablo IV'te verilen karmaşıklık matrisi incelendiğinde, seçilen MaxPhAmp özniteliklerinin, OS ve YS seviyelerini belirlemede başarılı olduğunu göstermektedir. Bu sonuç, Tablo IV'de verilen korelasyon katsayılarını doğrular niteliktedir. MaxPhAmp özniteliklerinin DS seviyesi ile ilişkisinin zayıflığı, bu seviyenin tespit edilememesiyle kendini göstermektedir.

Elde edilen sonuçlar doğrultusunda, Ayak GSR ölçümünün stres seviyesi tespitindeki bireysel performansı en yüksek bulunmuşsa da, seçilen öznelikler tek bir stres seviyesini belirlemede güçlü olduğundan, başarı oranı %70'i geçememiştir. Üç öznelik kümesinin birlikte kullanıldığında %100 doğruluk oranı sağlanması gerçeği [7], seçilen özneliklerin birlikte kullanılması gerektiğini doğrulamaktadır.

Kaynaklar

- [1] Selye, H. "Stress without distress" Psychopathology of Human Adaptation Serban G. (Eds.). Springer, Boston, MA, 137-146, 1976.
- [2] Rastgoo, M. N., Nakisa, B., Rakotonirainy, A., Chandran, V., & Tjondronegoro, D. "A critical review of proactive detection of driver stress levels based on multimodal measurements" ACM Computing Surveys, 51, 1-35, 2018.
- [3] Beirness, D. J. "Do we really drive as we live? The role of personality factors in road crashes. Alcohol, Drugs, and Driving: Abstracts and Reviews," 9 (3):129-143, 1993.
- [4] Simon, F. & Corbett, C. "Road traffic ending, stress, age, and accident history among male and female drivers" Ergonomics, 39 (5): 757-780, 1996.
- [5] Miller, L. H., Smith, A. D., & Rothstein, L. "The Stress Solution: An Action Plan to Manage the Stress in Your Life reprint ed.," Pocket Books, New York, 1994.
- [6] Rodrigues, J. G. P., Kaiseler, M., Aguiar, A., Cunha, J. P. S., & Barros, J. "A mobile sensing approach to stress detection and memory activation for public bus drivers" IEEE Transactions on Intelligent Transportation Systems, 16, 3294-3303, 2015.
- [7] Işıklı Esener, İ. "A Novel Stress-Level-Specific Feature Ensemble for Drivers' Stress Level Recognition". Bilecik Şeyh Edebali Üniversitesi Fen Bilimleri Dergisi, 6 (1), 12-23. DOI: 10.35193/bseufbd.554791. 2019.
- [8] Katsis, C. D., Katertsidis, N., Ganiatsas, G., & Fotiadis, D. I. "Toward emotion recognition in car-racing drivers: A biosignal processing approach", IEEE Transactions on Systems, Man, and Cybernetics - Part A. 38 (3): 502-512, 2008.
- [9] Rigas, G., Katsis, C. D., Bougias, P., & Fotiadis, D. I. "A Reasoning-Based Framework for Car Driver's Stress Prediction.", 16. Mediterranean Conference on Control and Automation, 25-27 June, Ajaccio, France, 627-632, 2008.
- [10] Healey, J. & Picard, R. "SmartCar: Detecting Driver Stress", 15. International Conference on Pattern Recognition, 3-7 September, Barcelona, Spain, 4, 218-221, 2002.
- [11] Healey, J. A. & Picard, R. W. "Detecting stress during real-world driving tasks using physiological sensors", IEEE Transactions on Intelligent Transportation Systems, 6 (2):156-166, 2005.
- [12] Akbaş, A. "Evaluation of the physiological data indicating the dynamic stress level of drivers", Scientific Research and Essays, 6 (2):430-439, 2011.
- [13] Rigas, G., Goletsis, Y., Bougias, P., & Fotiadis, D. I. "Towards driver's state recognition on real driving conditions" International Journal of Vehicular Technology, 2011, 1-14.
- [14] Rigas, G., Goletsis, Y., & Fotiadis, D. "Real-time driver's stress event detection", IEEE Transactions on Intelligent Transportation Systems, 13 (1), 221-234, 2012.
- [15] Deng, Y., Wu, Z., Chu, C. H., & Yang, T. "Evaluating Feature Selection for Stress Identification" IEEE 13. International Conference on Information Reuse & Integration, 8-10 August, Las Vegas, NV, USA, 584-591, 2012.
- [16] Soman, K., Alex, V., & Srinivas, C. "Analysis of Physiological Signals in Response to Stress using ECG and Respiratory Signals of Automobile Drivers", 2013 International Multi-Conference on Automation, Computing, Communication, Control and Compressed, 22-23 March, Kottayam, Kerala, India, 574-579:2013.
- [17] Singh, M. & Bin Queyam, A. "A novel method of stress detection using physiological measurements of automobile drivers" International Journal of Electronics Engineering, 5 (2):13-20, 2013.
- [18] Deng, Y., Wu, Z., Chu, C. H., Zhang, Q., & Hsu, D. F. "Sensor feature selection and combination for stress identification using combinatorial fusion" International Journal of Advanced Robotic Systems, 10, 306-313, 2013.
- [19] Wang, J. S., Lin, C. W., & Yang, Y. T. C. "A k-nearest-neighbor classifier with heart rate variability feature-based transformation algorithm for driving stress recognition. Neurocomputing", 116, 136-143, 2013.
- [20] Avcı C., Akbaş, A., & Yüksel, Y. "Evaluation of Statistical Metrics by using Physiological Data to Identify the Stress Level of Drivers", 3. International Conference on Environment, Chemistry and Biology, 29-30 November, Port Louis, Mauritius, 124-128, 2014.
- [21] Soman, K., Sathya, A., & Suganthi, N. "Classification of Stress of Automobile Drivers using Radial Basis Function Kernel Support Vector Machine", 2014 IEEE International Conference on Information Communication & Embedded Systems, 27-28 February, Chennai, India, 1-5, 2015.
- [22] Keshan, N., Parimi, P.V., & Bichindaritz, I. "Machine Learning for Stress Detection from ECG Signals in Automobile Drivers", 2015 IEEE International Conference on Big Data, 29 October-1 November, Santa Clara, CA, USA, 2661-2669, 2015.
- [23] Lanatà, A., Valenza, G., Greco, A., Gentili, C., Bartolozzi, R., Bucchi, F., Frendo, F., & Scilingo, E. P. "How the autonomic nervous system and driving style change with incremental stressing conditions during simulated driving", IEEE Transactions on Intelligent Transportation Systems, 16 (3):1505-1517, 2015.
- [24] Heikoop, D. D., de Winter, J. C. F., Arem, B., & Stanton, N. A. "Effects of platooning on signal-detection performance, workload, and stress: A driving simulator study", Applied Ergonomics, 60, 116-127, 2016.
- [25] Chen, L., Zhao, Y., Ye, P., Zhang, J., & Zou, J. "Detecting driving stress in physiological signals based on multimodal feature analysis and kernel classifiers", Expert System with Applications, 85, 279-291, 2017.
- [26] Ollander, S., Godin, C., Charbonnier, S., & Campagne, A. "Feature and Sensor Selection for Detection of Driver Stress" 3. International Conference on Physiological Computing Systems, 27-28 July, Lisbon, Portugal, 115-122, 2016.
- [27] Urbano, M., Alam, M., Ferreira, J., Fonseca, J., & Simões, P. "Cooperative Driver Stress Sensing Integration with Ecall System for Improved Road Safety" 17. International Conference on Smart Technologies, 6-8 July, Ohrid, Macedonia, 883-888, 2017.
- [28] Singh, R. R., Conjeti, S., & Banerjee, R. "A comparative evaluation of neural network classifiers for stress level analysis of automotive drivers using physiological signals", Biomedical Signal Processing and Control, 8 (6):740-754, 2013.
- [29] Goldberger A. L., Amaral L. A. N., Glass L., Hausdorff J. M., Ivanov P. Ch., Mark R. G., Mietus J. E., Moody G. B., Peng C-K., & Stanley H. E. "PhysioBank, PhysioToolkit, and PhysioNet: components of a new research resource for complex physiologic signals", Circulation, 101 (23):215-220, 2000.
- [30] Deshmukh, S. V. "Study of online driver distraction analysis using ECG-dynamics", Master of Science Thesis, University of Michigan, Computer and Information Sciences, Dearborn, Michigan, 2018.