

EEG ve EOG Sinyalleriyle Çok Modlu Derin Öğrenme ile Sürücü Yorgunluğu Tahmini

Driver Fatigue Estimation Using Multimodal Deep Learning with EEG and EOG Signals

Şevval Demir, Rumeysa Yapar ve Ahsen Nur Aldas
Bilgisayar Mühendisliği Bölümü
İstanbul Sağlık ve Teknoloji Üniversitesi
İstanbul, Türkiye
sevval.demir1@istun.edu.tr
rumeysa.yapar@istun.edu.tr
ahsen.aldas@istun.edu.tr

Necip Gözüaçık
Yazılım Mühendisliği Bölümü
İstanbul Sağlık ve Teknoloji Üniversitesi
İstanbul, Türkiye
necip.gozuacik@istun.edu.tr

Özetçe— Sürücü yorgunluğu, konsantrasyon kaybına ve algı sınırlanmasına yol açarak kaza riskini artıran kritik bir durumdur. Bu nedenle soruna çözüm bulmak amacıyla araştırmacılar, sürücüdeki yorgunluğu erken tespit etmeye dayalı sistemler üzerinde çalışmaya odaklanmışlardır. Bu çalışmada, SEED-VIG veri seti ile sunulan Diferansiyel Entropi–Doğrusal Dinamik Sistem (DE-LDS) tabanlı Elektroensefalografi (EEG) özellikleri ve Elektrokülografi (EOG) özellikleri kullanılarak sürücü yorgunluk tespiti hedeflenmiştir. Çalışmada kullanılan öznelik havuzu; bant oranları, zamansal delta bileşenleri, hemisferik asimetri ve hareketli standart sapma gibi özellik mühendisliği yöntemleriyle zenginleştirilmiştir. Ayrıca ham sinyal işleme gereksinimini ortadan kaldırarak anlamlı özneliklerin zamansal değişim örüntülerine odaklanılmıştır. Deney sonuçları, yalnızca EEG verisiyle yapılan tahminlerin sınırlı kaldığını, ancak EOG verisinin dahil edilmesiyle performansın belirgin şekilde arttığını göstermiştir. Bu bulgular, EEG ve EOG sinyallerinin sürücü yorgunluğunun kestiriminde birbirini tamamlayıcı bilgiler sağladığını ortaya koymaktadır. Önerilen çok modlu yaklaşım, tek modlu sistemlere kıyasla denekler arası değişkenliğe karşı daha dayanıklı bir yapı sergilemiş ve daha genellenebilir bir takip sistemi sunmuştur.

Anahtar Kelimeler — *eeg; eog; derin öğrenme; makine öğrenmesi; sürücü yorgunluğu; çok modlu tahmin.*

Abstract— Driver fatigue is a critical condition that increases accident risk by causing loss of concentration and perceptual limitations. Therefore, researchers have focused on developing systems aimed at the early detection of driver fatigue. In this study, driver fatigue detection was targeted using Differential Entropy–Linear Dynamic System (DE-LDS) based Electroencephalography (EEG) features and Electrooculography (EOG) features provided by the SEED-VIG dataset. The feature pool employed in the study was enriched through feature engineering methods such as band ratios, temporal delta components, hemispheric asymmetry, and moving standard deviation. Moreover, by eliminating the need for raw signal processing, the focus was directed toward the temporal variation patterns of meaningful features. Experimental results demonstrated that predictions based solely on EEG data remained limited, whereas the inclusion of EOG data significantly improved performance.

These findings reveal that EEG and EOG signals provide complementary information in the prediction of driver fatigue.

The proposed multimodal approach exhibited greater robustness against inter-subject variability compared to unimodal systems and offered a more generalizable monitoring framework.

Keywords — *eeg; eog; deep learning; machine learning; driver fatigue; multimodal prediction.*

I. GİRİŞ

Sürücü yorgunluğu; özellikle monoton yol koşulları, gece saatleri ve uzun süreli sürüşler sırasında dikkat düzeyini düşürerek trafik güvenliğini doğrudan tehdit eden, kaza olasılığını artıran ve ciddi yaralanma ya da ölümle sonuçlanabilen kritik bir toplumsal problemdir [1]. Buna paralel olarak yapılan sistematik derlemeler; uyku hali ve sürüş sırasında oluşan uykululuğun trafik kazalarıyla güçlü biçimde ilişkili olduğunu, bu durumun yol güvenliği açısından önemli bir risk teşkil ettiğini doğrulamaktadır. Yetersiz uykuya bağlı yorgunluk, sürücünün nörolojik işlevlerini ve çevresel uyaranlara verdiği tepkiyi zayıflatarak; karar verme, dikkat sürdürme ve güvenli araç kontrolü gibi temel sürüş becerilerini olumsuz etkileyebilmektedir [2].

Son yıllarda bu probleme çözüm geliştirmek amacıyla araştırmacılar, sürücüde oluşan yorgunluk ve uykululuk durumunu erken aşamada tespit edebilecek izleme sistemlerine yönelmiştir [3]. Özellikle EEG, EOG, Elektrokardiyografi (ECG) ve benzeri fizyolojik sinyallere dayalı yaklaşımlar, sürücünün içsel biyolojik durumunu doğrudan yansıtabilmeleri nedeniyle yorgunluk tespitinde giderek daha fazla önem kazanmaktadır [4]. Bu çerçevede, sürücü yorgunluğunun erken tespiti ve uygun uyarı sistemleriyle desteklenmesi hem kaza riskinin azaltılması hem de daha güvenli akıllı ulaşım sistemlerinin geliştirilmesi açısından önemli bir araştırma alanı hâline gelmiştir [5].

Bu çalışma literatüre şu katkıları sunmaktadır: (i) SEED-VIG veri seti üzerinde sürücü yorgunluğunun kestirimi için EEG, EOG ve EEG+EOG veri konfigürasyonlarının karşılaştırmalı olarak değerlendirilmesi, (ii) yorgunluk analizinin sınıflandırma yerine göz kapağının göz bebeği üzerindeki kapanma yüzdesi (PERCLOS) tabanlı sürekli bir

regresyon problemi olarak ele alınması, (iii) modellerin genellenabilirliğinin Leave-One-Subject-Out (LOSO) ile değerlendirilmesi, ve (iv) nörofizyolojik EEG göstergeleri ile davranışsal EOG göstergelerini birlikte işleyen çok modlu bir derin öğrenme yaklaşımının önerilmesi.

II. LİTERATÜR TARAMASI

SEED-VIG veri seti kullanılarak gerçekleştirilen yorgunluk tahmini çalışmaları incelendiğinde, literatürde ağırlıklı olarak EEG veya EEG-EOG tabanlı derin öğrenme mimarilerinin tercih edildiği görülmektedir [6]. Bu çalışmaların büyük bölümü yorgunluğu bir sınıflandırma problemi olarak ele almış, yalnızca sınırlı bir kısmı sürekli yorgunluk düzeyinin tahminine odaklanmıştır. Ayrıca bazı çalışmalar denek içi doğrulama ile raporlanırken, bazıları çapraz-denek genellenabilirliğini hedeflemiştir. Bununla birlikte, SEED-VIG üzerinde yorgunluğu regresyon yaklaşımıyla ele alan, modeli LOSO protokolü ile denek bağımsız biçimde değerlendiren ve EEG, EOG ile EEG+EOG kurulumlarını karşılaştırmalı olarak inceleyen çalışmalar oldukça sınırlıdır. Bu durum, hem çaprazdenek genellenebilirlik hem de farklı biyosinyal modalitelerinin katkısının anlaşılması açısından literatürde önemli bir boşluğa işaret etmektedir.

Bu kapsamda, literatürde öne çıkan çalışmalar incelendiğinde, Shi ve Wang [7], SEED-VIG üzerinde EEG ve EOG sinyallerini birleştirerek multimodal bir yorgunluk tahmin modeli önermiştir. Çalışmada EOG tabanlı göz hareketi özellikleri ile EEG'den elde edilen DE ve PSD özellikleri CAE ve LSTM/Bi-LSTM yapılarıyla işlenmiş, problem regresyon olarak ele alınmıştır. Multimodal yapı başarılı sonuçlar vermiştir. Bununla birlikte değerlendirmelerin denek içi doğrulama ile yapılması, yöntemin çapraz-denek genellenebilirliğini sınırlı bırakmaktadır.

Wang ve ark. [8], SEED-VIG üzerinde EEG tabanlı üç sınıflı yorgunluk analizi gerçekleştirmiştir. Çalışmada RWECDN, DE ve SQ özellikleri çıkarılmış, bunlar beyin ısı haritaları olarak birleştirilmiş ve CNN-LSTM ile sınıflandırılmıştır. Yöntem çoklu özellik füzyonunun etkili olduğunu göstermektedir. Ancak çalışma sürekli yorgunluk değişimini modellemek yerine ayrık sınıflara odaklanmaktadır.

Siddhad ve ark. [9], SEED-VIG verisi üzerinde EEG kullanarak ikili yorgunluk sınıflandırması için NLMDA-Net modelini önermiştir. Model, ayrılabilir konvolüsyonlar ile dikkat mekanizmalarını birleştirerek EEG'nin uzamsal ve zamansal örüntülerini öğrenmektedir. Çalışma yüksek sınıflandırma başarısı raporlamıştır. Buna karşın eşik tabanlı ikili yapı, yorgunluğun süreklilik gösteren doğasını sınırlı biçimde temsil etmektedir.

Bunun yanı sıra görüntü işleme tabanlı teknikler kullanarak sürücülerin seyir halindeki davranışlarını tahmin etmeye yönelik çalışmalar ile trafik güvenliğinin artırılması hedeflenmiştir [10], [11].

III. METODOLOJİ

Bu çalışmada, sürüş sırasında uyanıklık düzeyinin kestirimi için SEED-VIG veri seti kullanılmıştır. Veri seti, EEG ve EOG sinyallerini içeren toplam 23 deney kaydı ile 0–1 aralığında

PERCLOS tabanlı uyanıklık etiketleri sunmaktadır. EEG için PSD-DE tabanlı spektral öznitelikler, EOG için ise göz kırpması ve sakkad hareketlerini tanımlayan morfolojik öznitelikler kullanılmıştır. Ham EEG ve EOG sinyalleri doğrudan kullanılmamış; veri kümesiyle sunulan öznitelikler temel alınarak bant oranları, zamansal delta bileşenleri, yerel değişkenlik ölçüleri ve hemisferik asimetri gibi ek özellik mühendisliği adımları uygulanmıştır.

Metodolojik akış; özniteliklerin hazırlanması, zamansal bağlamın modele dahil edilmesi ve yorgunluk düzeyinin regresyon temelli yaklaşımlarla kestirilmesi aşamalarından oluşmaktadır. Modellerin denekler arası genelleme gücünü değerlendirmek amacıyla LOSO yöntemi kullanılmıştır. Bu sayede, modellerin daha önce görülmemiş denekler üzerinde de tutarlı tahmin üretme başarısı değerlendirilmiştir. Analizler üç temel başlık altında yürütülmüştür. EEG ve EOG için daha başarılı olan makine öğrenmesi; EEG+EOG füzyonu için ise derin öğrenme tabanlı regresyon yaklaşımları kullanılmıştır.

A. EEG Öznitelik Temsili

SEED-VIG veri kümesinde sunulan DE tabanlı EEG spektral özellikleri kullanılmıştır. Özellik çıkarımında 5 klasik frekans bandı (δ , θ , α , β , γ) ve 2 Hz çözünürlüklü bantlar değerlendirilmiş; temporal, orta hat ve posterior bölgelere ayrı ele alınarak frontal EEG kanalları da özellik setine dahil edilmiştir. Bantlar arası ilişkileri temsil etmek amacıyla θ/β , α/β ve $(\theta+\alpha)/\beta$ oranları oluşturulmuştur. Zamansal dinamikleri yakalamak için özellikler gecikmeli örnekler, birinci fark bileşenleri ve kayan pencere istatistikleri ile genişletilmiş ve özellik boyutu 670'ten 8040'a çıkarılmıştır.

Tahminleme için Ridge ve HistGradientBoosting regresyon modellerinden oluşan bir ensemble yaklaşımı kullanılmıştır. Ridge genel eğilimleri modellerken, gradient boosting yüksek boyutlu özellik uzayındaki karmaşık örüntüleri öğrenmektedir. Nihai kestirim bu iki modelin ağırlıklı birleşimi ile elde edilmiş, tahminlere nedensel hareketli ortalama uygulanarak zaman içindeki kararlılık artırılmıştır.

Performans LOSO yöntemi ile değerlendirilmiş ve Pearson = 0.7551, Kök Ortalama Kare Hata (RMSE) = 0.1976 elde edilmiştir. Sonuçlar EEG'nin uyanıklık düzeyi tahmininde anlamlı bilgi taşıdığını, ancak performansın bireyler arası değişkenliğe duyarlı olduğunu göstermektedir.

B. EOG Öznitelik Temsili

EOG analizinde, göz kırpması ve sakkadik hareketleri tanımlayan morfolojik öznitelikler kullanılmış; bunlar gecikmeli örnekler, birinci fark bileşenleri ve kayan pencere istatistikleri ile zamansal bağlam açısından zenginleştirilmiştir. Böylece yalnızca anlık göz hareketi değil, kısa süreli zamansal değişimler de modele yansıtılmıştır.

Tahminleme aşamasında, Extra Trees, HistGradientBoosting, Ridge ve CatBoost regresörlerinden oluşan bir katmanlı yapı kullanılmıştır. Temel modellerin gruptabanlı katlamalardan elde edilen tahminleri üzerinden örnek bazında uyarlanabilir ağırlıklar öğrenilerek nihai çıktı dinamik bir ensemble ile üretilmiştir.

LOSO değerlendirmesinde önerilen model Pearson = 0.8201 ve RMSE = 0.1345 performansı elde etmiştir. Sonuçlar, EOG temelli göstergelerin sürekli yorgunluk kestiriminde

güçlü bir potansiyel taşıdığını, ancak performansın denekler arası değişkenlikten etkilendiğini göstermektedir.

C. EEG+EOG Öznitelik Temsili

Bu çalışmada EEG ve EOG öznitelikleri birlikte kullanılmış ve zamansal örüntülerin daha iyi temsil edilebilmesi için çeşitli özellik mühendisliği adımları uygulanmıştır.

EEG Öznitelik Seti (175 Boyut): Veri seti, 17 EEG kanalına ait DE-LDS tabanlı özellikleri delta, teta, alfa, beta ve gama bantlarında sunmaktadır. Bu özellikler her zaman adımında 85 boyutlu bir EEG temsil vektörü oluşturmakta olup, yorgunlukla ilişkili nörofizyolojik örüntüleri daha etkin temsil edebilmek amacıyla çeşitli özellik mühendisliği adımlarıyla zenginleştirilmiştir.:

- Bant Oranları: Literatürde yorgunluk sırasında teta bandındaki artış ve alfa bandındaki baskılanma rapor edildiğinden [12], bantlar arası ilişkileri temsil etmek amacıyla alfa/teta ve beta/alfa oranları hesaplanmış ve 34 boyutlu özellik vektörü elde edilmiştir.
- Zamansal Delta (Δ): Zamansal değişimleri modellemek amacıyla ardışık zaman adımları arasındaki farklar hesaplanarak alfa ve teta bantları için 34 boyutlu zamansal delta özelliği oluşturulmuştur.
- Yerel Değişkenlik: EEG sinyalindeki kısa süreli dalgalanmaları temsil etmek amacıyla 5 zaman adımı hareketli pencere üzerinden standart sapma hesaplanmış ve 17 boyutlu yerel değişkenlik özelliği elde edilmiştir.
- Hemisferik Asimetri: Sol ve sağ hemisfer aktivitesi arasındaki farkın bilişsel yük ile ilişkili olduğu bilinmektedir [13]. Bu nedenle sol ve sağ kanal gruplarının ortalama aktivitesi kullanılarak 5 boyutlu hemisferik asimetri özelliği hesaplanmıştır.

Bu işlemler ile 85 boyutlu temel EEG özellikleri 90 boyutlu türetilmiş özelliklerle genişletilmiş ve toplamda 175 boyutlu EEG temsil vektörü elde edilmiştir.

EOG Öznitelik Seti (48 Boyut): Veri setinde göz kırpması oranı, genliği ve süresi gibi 36 EOG özelliği bulunmaktadır. Zamansal değişimleri yakalayabilmek için ilk 12 özelliğin temporal deltası hesaplanmış ve toplam 48 boyutlu EOG temsil vektörü oluşturulmuştur.

Zamansal Segmentasyon: Yorgunluk zamana bağlı gelişen bir süreç olduğundan, modelin zamansal bağımlılıkları öğrenmesi için veri üzerinde 20 zaman adımı kayan pencereler uygulanmıştır. Her pencere ardışık EEG ve EOG özellik dizilerini içermekte ve pencerenin son zaman adımındaki PERCLOS değeri hedef değişken olarak kullanılmaktadır. Bu işlem sonucunda 23 denekten toplam 19.895 örnek elde edilmiştir.

D. Çok Modlu Tahmin

Önerilen modelde EEG ve EOG verileri iki ayrı giriş kolunda Conv1D katmanları ile işlenmiş ve elde edilen temsiller birleştirilmiştir. EEG kolundaki Conv1D katmanları

zaman serisi içindeki kısa süreli değişimleri ve bantlar arası ilişkileri öğrenmeyi amaçlamaktadır. Ardından uygulanan gating mekanizması, özellik haritalarını ağırlıklandırarak modelin daha ayırt edici örüntülere odaklanmasını sağlamaktadır. Öğrenme sürecinin kararlılığını artırmak amacıyla Batch Normalizasyonu uygulanmıştır. EOG özellikleri ise ayrı bir giriş kolunda Conv1D ve Batch Normalizasyon katmanları ile işlenmiştir. Daha sonra EEG ve EOG temsilleri birleştirilmiştir. Birleştirilen özellik dizisi zamansal bağımlılıkları modelleyebilmek için iki katmanlı BiLSTM ağına verilmiştir. Bu yapı geçmiş ve gelecek zaman bağlamını birlikte değerlendirerek daha zengin bir zamansal temsil oluşturmaktadır. Son aşamada elde edilen temsil vektörü Dense katmanı üzerinden işlenmiş ve sigmoid aktivasyonlu çıkış katmanı ile PERCLOS değeri regresyon çıktısı olarak üretilmiştir. Model, tahmin edilen ve gerçek PERCLOS değerleri arasındaki farkı minimize etmek amacıyla Ortalama Kare Hata (MSE) kayıp fonksiyonu ile eğitilmiştir.

E. Model Eğitimi ve Değerlendirme

Model PERCLOS tahmini için regresyon problemi olarak ele alınmıştır. Eğitim sürecinde Adam optimizasyon algoritması (öğrenme oranı 0.0004) kullanılarak model 40 epoch ve 128 batch boyutu ile eğitilmiş, aşırı öğrenmeyi önlemek için erken durdurma taktiği uygulanmıştır. Denekler arası genellenebilirliği değerlendirmek için deneyler LOSO protokolü ile gerçekleştirilmiştir. Bu yöntemde her iterasyonda bir denek test kümesi olarak ayrılmış ve kalan deneklerin verileri model eğitimi için kullanılmıştır. Model performansı RMSE, Ortalama Mutlak Hata (MAE) ve Pearson Korelasyon Katsayısı (PCC) metrikleri kullanılarak değerlendirilmiştir.

IV. DENEYSEL SONUÇLAR


Deneyler Google Colab ortamında GPU desteği kullanılarak gerçekleştirilmiş ve model TensorFlow kütüphanesi ile eğitilmiştir. Çalışmada temel mimari olarak Conv1D tabanlı CNN katmanları ve BiLSTM katmanlarından oluşan bir CNN-BiLSTM yapısı kullanılmıştır. Önerilen EEG+EOG çok modlu yaklaşımın performansı farklı veri işleme ve değerlendirme yaklaşımları ile karşılaştırılmıştır. Tablo I'de sunulan sonuçlar incelendiğinde, önerilen Dual-Input EEG-EOG çok modlu yaklaşımının LOSO doğrulama protokolü altında diğer yaklaşımlara kıyasla daha iyi performans sergilediği görülmektedir. Yaklaşım, RMSE = 0.1278 ve MAE = 0.1071 değerleri ile hata metriklerinde en düşük sonuçları elde ederken, PCC = 0.8930 ile en yüksek korelasyon değerine ulaşmıştır. Bu bulgular, EEG ve EOG sinyallerinin birlikte kullanılmasının sürücü yorgunluğunun kestiriminde daha güçlü ve genellenebilir bir temsil sağladığını göstermektedir. Ayrıca LOSO protokolü altında elde edilen bu sonuçlar, önerilen yaklaşımın farklı denekler arasında tutarlı bir performans gösterebildiğini ortaya koymaktadır.

TABLO I. LOSO DOĞRULAMA PROTOKOLÜ ALTINDA FARKLI YAKLAŞIMLARIN PERFORMANSLARI

Yaklaşım	RMSE	MAE	PCC
Hibrit Denek-Uyumlu Normalizasyon	0.1342 ± 0.0518	0.1106 ± 0.0494	0.8865 ± 0.0780


İkili LOSO Doğrulama Protokolü	0.1429 ± 0.0598	0.1188 ± 0.0553	0.8522 ± 0.1206
Önerilen Dual-Input EEG-EOG	0.1278 ± 0.0644	0.1071 ± 0.0587	0.8930 ± 0.0872

Şekil 1’de gerçek ve tahmin edilen PERCLOS değerlerinin zamansal karşılaştırması verilmiştir. Sonuçlar modelin sürücü yorgunluğundaki zamansal değişimleri başarılı biçimde takip edebildiğini göstermektedir. Yüksek yorgunluk seviyelerinin görüldüğü bölgelerde tahmin edilen değerlerin gerçek değerlerle büyük ölçüde örtüştüğü gözlenmektedir. Bazı zaman adımlarında küçük sapmalar oluşsa da model genel olarak yorgunluk seviyesindeki artış ve azalış trendlerini doğru biçimde yakalayabilmektedir.



Şekil. 1. Gerçek ve Tahmin Edilen PERCLOS Değerlerinin Zamansal Karşılaştırılması

Şekil 2’de ise LOSO protokolünde elde edilen denek bazlı PCC performansı sunulmaktadır. Sonuçlar, modelin deneklerin büyük çoğunluğunda yüksek korelasyon değerleri elde ettiğini ve farklı bireyler arasında tutarlı bir performans sergilediğini ortaya koymaktadır. Bu bulgular, EEG ve EOG bilgilerinin birlikte kullanılmasının sürücü yorgunluğu kestiriminde daha güçlü ve genellenebilir bir temsil sağladığını ifade etmektedir.



Şekil. 2. LOSO Doğrulama Protokolü Altında Elde Edilen Denek Bazlı PCC Performansı

V. ÇIKARIMLAR

Çalışmada sürücü yorgunluğunun kestirimi için EEG, EOG ve EEG+EOG veri konfigürasyonları değerlendirilmiştir. Sonuçlar, EOG tabanlı modellerin davranışsal göstergeler, EEG tabanlı modellerin ise nörofizyolojik göstergeler üzerinden yorgunluk kestirimine katkı sağladığını göstermiştir. En yüksek performansın EEG ve EOG özelliklerinin birlikte kullanıldığı

çok modlu derin öğrenme yapısında elde edilmesi, bu iki bilgi kaynağının birlikte değerlendirilmesinin daha güçlü bir temsil oluşturduğunu ortaya koymaktadır. Bununla birlikte bazı deneklerde gözlenen performans farklılıkları, bireyler arası fizyolojik değişkenliğin model genelleme başarısını etkileyebildiğini göstermektedir. SEED-VIG veri seti üzerinde LOSO protokolü ile sürekli PERCLOS regresyonu gerçekleştiren çalışmaların sınırlı olduğu göz önüne alındığında, bu çalışma EEG, EOG ve çok modlu yaklaşımları aynı çerçevede değerlendirerek özgün bir katkı sunmaktadır. Gelecek çalışmalarda attention veya Transformer tabanlı mimarilerin araştırılması, modelin farklı veri setleri üzerinde genellenebilirliğinin incelenmesi ve transfer öğrenme yaklaşımlarının değerlendirilmesi planlanmaktadır. Gelecek çalışmalarda attention veya Transformer tabanlı mimarilerin araştırılması, modelin farklı veri setleri üzerinde genellenebilirliğinin incelenmesi ve çoklu veri setleri ile transfer öğrenme yaklaşımlarının değerlendirilmesi önemli geliştirme alanları olarak görülmektedir.

KAYNAKLAR

- [1] J. Horne and L. Reyner, "Vehicle accidents related to sleep: A review," *Occupational and Environmental Medicine*, vol. 56, no. 5, pp. 289–294, May 1999, doi: 10.1136/oem.56.5.289.
- [2] S. Saleem, "Risk assessment of road traffic accidents related to sleepiness during driving: A systematic review," *Eastern Mediterranean Health Journal*, vol. 28, no. 9, pp. 695–700, Sep. 2022, doi: 10.26719/emhj.22.055.
- [3] M. E. Howard and J. M. Cori, "Time for sleep science to wake up to drowsy driver monitoring," *Sleep*, vol. 47, no. 2, p. zsad324, Feb. 2024, doi: 10.1093/sleep/zsad324.
- [4] A. A. Saleem, H. U. R. Siddiqui, M. A. Raza, F. Rustam, S. Dudley, and I. Ashraf, "A systematic review of physiological signals based driver drowsiness detection systems," *Cognitive Neurodynamics*, vol. 17, no. 5, pp. 1229–1259, 2023, doi: 10.1007/s11571-0.
- [5] C. Hasanhanoglu, "Trafik güvenliğinde sürücü profilinin önemi ve Türkiye’deki sürücü profilinin belirlenmesinde SWOT analizi," *Uluslararası Sosyal Bilimler Akademik Araştırmalar Dergisi*, vol. 6, no. 1, pp. 36–51, 2022.
- [6] Wei-Long Zheng and Bao-Liang Lu, "A multimodal approach to estimating vigilance using EEG and forehead EOG," *Journal of Neural Engineering*, vol. 14(2), p. 026017, 2017.
- [7] J. Shi ve K. Wang, "Fatigue driving detection method based on TimeSpace-Frequency features of multimodal signals," *Biomed. Signal Process. Control*, 2023, doi:10.1016/j.bspc.2023.104744.
- [8] K. Wang vd., "EEG-based fatigue state evaluation by combining complex network and frequency-spatial features," *J. Neurosci. Methods*, 2025.
- [9] G. Siddhad vd., "Awake at the Wheel: Enhancing Automotive Safety through EEG-Based Fatigue Detection," *arXiv*, 2024.
- [10] H. Etcibaşı, A. Kayabaşı, and G. T. Doğan, "Detecting Improper Driving via Frozen CLIP," in *Proc. 2023 31st Signal Processing and Communications Applications Conference (SIU)*, pp. 1–4, 2023, doi: 10.1109/SIU59756.2023.10223836.
- [11] A. H. Erdem and A. T. Çelebi, "Enhancing Road Scene Visibility by Removing Sun and Headlight Glare in ADAS Camera Images with Image Fusion," in *Proc. 2024 32nd Signal Processing and Communications Applications Conference (SIU)*, pp. 1–4, 2024.
- [12] B. T. Jap, S. Lal, P. Fischer, and E. Bekiaris, "Using EEG spectral components to assess algorithms for detecting fatigue," *Expert Systems with Applications*, vol. 36, no. 2, pp. 2352–2359, 2009.
- [13] R. J. Davidson, "What does the prefrontal cortex 'do' in affect: Perspectives on frontal EEG asymmetry research," *Biological Psychology*, vol. 67, no. 1–2, pp. 219–233, 2004.