



DÜŞÜK IŞIKTA SÜRÜCÜ YORGUNLUK TESPİTİ

Esra KAVALCI YILMAZ

YÜKSEK LİSANS TEZİ

SAVUNMA TEKNOLOJİLERİ ANA BİLİM DALI

SİVAS BİLİM VE TEKNOLOJİ ÜNİVERSİTESİ

LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

TEMMUZ 2022

ETİK BEYAN

Sivas Bilim ve Teknoloji Üniversitesi Lisansüstü Eğitim Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu,

bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

.....
Esra KAVALCI YILMAZ
20/07/2022

DÜŞÜK IŞIKTA SÜRÜCÜ YORGUNLUK TESPİTİ

(Yüksek Lisans Tezi)

Esra KAVALCI YILMAZ

SİVAS BİLİM ve TEKNOLOJİ ÜNİVERSİTESİ

LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

Temmuz 2022

ÖZET

Sürücü yorgunluğunun; sürüş sırasında mikro uykuya geçme, tepki sürelerinde gecikme, dikkat dağınıklığı, şeritten çıkma, trafik uyarı levhalarını kaçırma gibi birçok etkisi görülmektedir. Genellikle bu davranışların sonucu olarak trafik kazaları meydana gelmekte ve birçok can ve mal kaybına neden olmaktadır. Bu aşamada kazaların önlenmesi için en önemli unsurlardan biri sürücünün yorgunluğunun erken tespit edilerek sürücünün uyarılmasıdır. Sürücünün yorgunluğunun en doğru şekilde tespit edilebilmesi için kullanılan yöntem kadar veri kümesi de önem taşımaktadır.

Bu çalışmada, ilk olarak sürücünün yorgunluğunun tespit edilebilmesi için gerçek sürüş anlarını içeren Sivas Bilim ve Teknoloji Üniversitesi Sürücü Yorgunluk Veri Kümesi (SUST-DDD) toplanmıştır. Veri kümesi ‘yorgun’ ve ‘yorgun değil’ olmak üzere iki sınıfa ait her biri 10 saniye uzunluğunda olan toplamda 2074 videodan oluşmaktadır.

İkinci aşamada ise oluşturulan veri kümesi kullanılarak AlexNet, LSTM, VGG16, VGG19, VGGFaceNet ve hibrit derin ağlar gibi derin öğrenme yöntemleri ile sürücülerin uyku durumu tahmin edilmiştir. Çalışma sonucunda oluşturulan veri kümesi ve uygulanan hibrit derin ağ modelinin %98,42 hassasiyet, %98,76 duyarlılık, %98,47 f1 skor ve %98,48 doğruluk değerleriyle yorgunluğu tahmin ettiği görülmektedir.

Bilim Kodu : 10418743

Anahtar Kelimeler : Derin Öğrenme, Sürücü Yorgunluk Tespiti, Yorgunluk Veri Kümesi

Sayfa Adedi : 83

Danışman : Prof. Dr. M. Ali AKÇAYOL

DRIVER DROWSINESS DETECTION IN LOW LIGHT

(M. Sc. Thesis)

Esra KAVALCI YILMAZ

SİVAS UNIVERSITY OF SCIENCE AND TECHNOLOGY

INSTITUTE OF GRADUATE STUDIES

July 2022

ABSTRACT

Driver drowsiness; Many effects such as micro-sleep while driving, delay in reaction times, distraction, leaving the lane, missing traffic warning signs are seen. Most of the time, traffic accidents occur as a result of these behaviors and cause many loss of life and property. In this case, one of the most important elements to prevent accidents is to detect the drowsiness of the driver early and warn the driver. The data set used is as important as the method used in order to determine the driver's drowsiness in the most accurate way.

In this study, firstly, Sivas University of Science and Technology Driver Drowsiness Dataset (SUST-DDD), which includes real driving moments, was collected in order to detect driver drowsiness. The dataset consists of a total of 2074 videos, each 10 seconds long, belonging to two classes, drowsy and 'not drowsy'.

Secondly, using the created dataset, the sleep state of the drivers was estimated with deep learning methods such as AlexNet, LSTM, VGG16, VGG19, VGGFaceNet and hybrid deep networks. As a result of the study, the created dataset and the applied hybrid deep network model estimate drowsiness with 98,42% precision, 98,76% recall, 98,47% f1 score and 98,48% accuracy values.

Science Code : 10418743

Key Words : Deep Learning, Driver Drowsiness Detection, Drowsiness Dataset

Page Number : 83

Supervisor : Prof. Dr. M. Ali AKÇAYOL

TEŞEKKÜR

Çalışmalarımın her aşamasında bilgi ve tecrübelerinden faydalandığım, desteklerini hiçbir zaman esirgemeyen saygıdeğer danışman hocam Prof. Dr. M. Ali AKÇAYOL'a gösterdiği özen, ilgi ve anlayış için çok teşekkür eder ve sonsuz saygılarımı sunarım.

Tez konumun belirlenmesinde yol gösteren Dr. Fatih SAY'a ilgi ve anlayışı için çok teşekkür ederim.

Hayatımın her anında yanımda olup sevgisini, ilgisini, desteğini her zaman hissettiğim sevgili aileme çok teşekkür ederim.

Hayatıma girdiği günden itibaren her zaman beni destekleyen, verdiğim her kararda yanımda yürüyen sevgili eşim Okan YILMAZ'a çok teşekkür ederim.

Hoşgörü ve destekleri için değerli mesai arkadaşlarım Arş. Gör. Hatice AKTAŞ ve Arş. Gör. Ümit CİHAN'a çok teşekkür ederim. |

İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT.....	v
TEŞEKKÜR.....	vi
ÇİZELGELERİN LİSTESİ.....	ix
ŞEKİLLERİN LİSTESİ.....	x
1. GİRİŞ.....	1
2. KAYNAK ARAŞTIRMASI	4
3. MATERYAL ve YÖNTEM	11
3.1. Yorgunluk Tespiti	11
3.2. Sürücü Yorgunluk Tespiti	13
3.2.1. Davranışsal parametrelere dayalı teknikler.....	14
3.2.2. Fizyolojik parametrelere dayalı teknikler	15
3.2.3. Araç parametrelerine dayalı teknikler	16
3.3. Veri Kümesi	16
3.3.1. Sivas Bilim ve Teknoloji Üniversitesi Sürücü Yorgunluk Veri Kümesi:	21
3.4. Derin Öğrenme ile Düşük Işıktaki Sürücü Yorgunluk Tespiti.....	23
3.4.1. Evrişimli Sinir Ağı	23
3.4.2. Tekrarlayan Sinir Ağları	29
3.4.3. Aktivasyon Fonksiyonları	31
3.4.4. Optimizasyon Yöntemleri	34
3.4.5. Kayıp Fonksiyonları.....	35
3.4.6. Geliştirilen Hibrit Model.....	36
4. BULGULAR ve TARTIŞMA.....	38

Sayfa

4.1. VGG16 + LSTM Model Çalışmaları	38
4.2. VGG-19 + LSTM Model Çalışmaları	40
4.3. AlexNet + LSTM Model Çalışmaları	42
4.4. VGGFace + LSTM Model Çalışmaları.....	44
4.5. Tüm Modellerin Karşılaştırmalı Genel Sonuçları.....	46
5. SONUÇ VE ÖNERİLER.....	53
KAYNAKLAR	55
EKLER.....	62

ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 1.1. Sürücü yorgunluğu sebebiyle meydana gelen kazaların yıllara göre dağılımı ..	2
Çizelge 2.1. Davranışsal parametrelere dayalı sürücü yorgunluk tespit çalışmaları karşılaştırması.....	10
Çizelge 3.1. Veri kümelerinin özelliklerinin karşılaştırması	20
Çizelge 4.1. VGG16+LSTM modeli çalışmasından elde edilen en iyi sonuçlar	39
Çizelge 4.2. VGG16+LSTM modelinin en iyi sonucuna ait değerler	40
Çizelge 4.3. VGG19+LSTM modeli çalışmasından elde edilen en iyi sonuçlar	41
Çizelge 4.4. VGG19+LSTM modelinin en iyi sonucuna ait değerler	42
Çizelge 4.5. AlexNet + LSTM modeli çalışmasından elde edilen en iyi sonuçlar	43
Çizelge 4.6. AlexNet+LSTM modelinin en iyi sonucuna ait değerler	44
Çizelge 4.7. VGGFace+LSTM modeli çalışmasından elde edilen en iyi sonuçlar	45
Çizelge 4.8. VGGFace +LSTM modelinin en iyi sonucuna ait değerler.....	46
Çizelge 4.9. Batch değeri 256 için model çalışma sonuçları	47
Çizelge 4.10. Batch değeri 512 için model çalışma sonuçları	50

ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 3.1. Sürücü yorgunluk tespit teknikleri.....	14
Şekil 3.2. Video kayıtları sırasında telefonun pozisyonu	22
Şekil 3.3. Çalışmada kullanılan hibrit model.....	25
Şekil 3.4. Çalışmada kullanılan VGG16 modeli.....	26
Şekil 3.5. Çalışmada kullanılan VGG19 modeli.....	27
Şekil 3.6. Çalışmada kullanılan AlexNet modeli.....	27
Şekil 3.7. Çalışmada kullanılan VGGFace modeli	28
Şekil 3.8. RNN mimari modeli	30
Şekil 3.9. Basamak fonksiyonu grafiği.....	32
Şekil 3.10. ReLU fonksiyonu grafiği.....	33
Şekil 3.11. Sigmoid fonksiyonu grafiği	33
Şekil 3.12. Tanh fonksiyonu grafiği	34
Şekil 3.13. Softmax fonksiyonu grafiği	34
Şekil 3.14. LSTM mimari yapısı.....	37
Şekil 4.1. VGG16+LSTM modelinden elde edilen en iyi doğruluk değerlerinin karşılaştırması	39
Şekil 4.2. VGG19+LSTM modelinden elde edilen en iyi doğruluk değerlerinin karşılaştırması	41
Şekil 4.3. AlexNet+LSTM modelinden elde edilen en iyi doğruluk değerlerinin karşılaştırması	43
Şekil 4.4. VGGFace+LSTM modelinden elde edilen en iyi doğruluk değerlerinin karşılaştırması	45
Şekil 4.5. Batch değeri 256 için a)10, b)20, c)30 çerçeve için model sonuçları.....	49
Şekil 4.6. Batch değeri 512 için a)10, b)20, c)30 çerçeve için model sonuçları.....	52

SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Kısaltmalar	Açıklamalar
CNN	Evrişimli Sinir Ağı (Convolutional Neural Network)
D2CNN-FD	CNN ve Yüz İşareti Tespitine Dayalı Uyuşukluk Tespiti (Drowsiness Detection Based on CNN and Facial Landmark Detection)
D2MLP-FD	MLP ve Yüz İşareti Tespitine Dayalı Uyuşukluk Tespiti (Drowsiness Detection Based on MLP and Facial Landmark Detection)
DNN	Derin Sinir Ağı (Deep Neural Network)
DROZY	ULg Çok Modlu Uyuşukluk Veri Tabanı (ULg Multimodality Drowsiness Database)
EAR	Göz En Boy Oranı (Eye Aspect Ratio)
EEG	Elektroensefalografi
EKG	Elektrokardiogram
EOG	Elektrookülogram
FAA	Federal Havacılık İdaresi (Federal Aviation Administration)
FLD	Yüz Yer İşareti Tespiti (Facial Landmark Detection)
FMRI	Fonksiyonel Manyetik Rezonans Görüntüleme (Functional Magnetic Resonance Imaging)
FTS	Trafik Güvenliği Vakfı (Foundation for Traffic Safety)
GA	Genetik Algoritmalar (Genetic Algorithms)
GRU	Kapılı Tekrarlayan Birim (Gated Recurrent Unit)
HOG	Gradyan Histogramları (Histogram of Gradients)

ILSVRC	ImageNet Büyük Ölçekli Görsel Tanıma Yarışması (ImageNet Large Scale Visual Recognition Challenge)
KNN	k En Yakın Komşular (K-Nearest Neighbors)
KSS	Karolinska Uykuölçümü Ölçeği (Karolinska Sleepiness Scale)
LDA	Lineer Diskriminant Analizi (Linear Discriminant Analysis)
LR	Lojistik Regresyon (Logistic Regression)
LSTM	Uzun Kısa Süreli Bellek (Long Short-Term Memory)
MLP	Çok Katmanlı Algılayıcı (Multilayer Perceptron)
NSC	Ulusal Güvenlik Konseyi (National Security Council)
NTHTSA	Ulusal Otoyol Trafik Güvenliği Yönetimi (National Highway Traffic Safety Administration)
NTHU-DDD	Tsuing Hua Üniversitesi Yorgunluk Tespit Veri Kümesi (The Tsuing Hua University Drowsiness Detection Dataset)
PSG	Polisomnografi
PVT	Psikomotor Vajilans Testi
RELU	Doğrultulmuş Doğrusal Birim (Rectified Linear Unit)
RF	Rastgele Orman (Random Forest)
RLDD	Gerçek Hayat Yorgunluk Veri Kümesi (The Real-Life Drowsiness Dataset)
RNN	Tekrarlayan Sinir Ağı (Recurrent Neural Network)
SAMM	Spontane Hareketler ve Mikro Hareketler (Spontaneous Actions and Micro-Movements)
SGD	Stokastik Gradyan İnişi (Stochastic Gradient Descent)
SMIC	Spontane Mikro İfade Veri Tabanı (Spontaneous Micro-Expression Database)
SS-CNN	Özel Tasarlanmış Sığ Evrişimli Sinir Ağı (Specific Designed Shallow Convolutional Neural Network)
SUST-DDD	Sivas Bilim ve Teknoloji Üniversitesi Sürücü Yorgunluk Veri Kümesi (Sivas University of Science and Technology Driver Drowsiness Dataset)

SVM	Destek Vektör Makinesi (Support Vector Machine)
TSCI	Trafik Güvenliği Kültür Endeksi (Traffic Safety Culture Index)
VGG	Görsel Geometri Grubu (Visual Geometry Group)
YAWDD	Esname Tespiti Veri Kümesi (Yawning Detection Dataset)



1. GİRİŞ

Sürekli değişen sosyal ve ekonomik etkenler nedeniyle ulaşım gereksinimleri, hacmi ve kapsamı hızla artmaktadır. Son zamanlarda ulaşım hayatımızın hemen hemen her alanında önemli bir parçası haline gelmiştir. Karayolu, havayolu, demiryolu ve denizyolu olmak üzere 4 ulaşım türü bulunmakta olup bunlardan en çok kullanılanı karayolu ulaşımıdır. Dünyanın birçok yerinde olduğu gibi ülkemizde de ulaşımın %90'dan fazlası karayolu ile yapılmaktadır. Dünya sıralamasındaki ölüm nedenleri arasında karayollarında meydana gelen trafik kazaları ilk sıralardadır. Bu trafik kazaları genel olarak bir ya da daha fazla aracın dahil olduğu maddi zarar, yaralanma veya ölümle sonuçlanan olaylar olarak ifade edilmektedir [1].

Trafik kazaları maddi kayıpların yanı sıra birçok insanın yaralanmasına hatta ölmesine sebep olabilmektedir. Türkiye İstatistik Kurumu'nun yayınladığı rapora göre 2021 yılında meydana gelen 1 186 353 kazadan 187 963'ü ölümlü yaralanmalı kaza olup bu kazalarda 5 362 kişi hayatını kaybetmiş, 274 615 kişi ise yaralanmıştır. Genel sonuca bakıldığında ise 2021 yılında 2020 yılına kıyasla kazalarda hayatını kaybeden kişi sayısının %10,2 arttığı görülmektedir. Bu kazaların nedenleri incelendiğinde ise sürücü kusurlarının %87,1 oranla birinci sırada yer aldığı görülmektedir [2].

Sürücü kusurları incelendiğinde genel olarak alkollü iken araç kullanma, aşırı hız yapma gibi durumlar düşünülmektedir. Fakat yorgun araç kullanmanın da sürücü kusurlarında birinci sırada olan alkollü araç kullanmaya benzer şekilde tepki süresinde yavaşlık, farkındalığın azalması, odaklanamama gibi etkileri vardır. Bu durum göz önünde bulundurulduğunda yorgun araç kullanmanın da en az alkollü araç kullanmak kadar tehlikeli olduğu söylenebilir. Ulusal Güvenlik Konseyi (National Security Council-NSC)'ne göre yorgun bir şekilde araç kullanma yılda yaklaşık 100 000 kazaya, 71 000 yaralanmaya ve 1 550 ölüme neden olmaktadır. ABD Ulusal Otoyol Trafik Güvenliği Yönetimi (National Highway Traffic Safety Administration-NHTSA)'ne göre sürücü yorgunluğu sebebiyle meydana gelen kaza sayılarının yıllara göre dağılımı Çizelge 1.1'de verilmiştir [3].

Çizelge 1.1. Sürücü yorgunluğu sebebiyle meydana gelen kazaların yıllara göre dağılımı

Yıl	Ölümcül kazalara karışan ve uykulu olan sürücüler	Ölümcül kazalara karışan tüm sürücülerin yüzdesi	Uykulu sürüş içeren ölümler
2018	1 221	%2,4	785
2017	1 319	%2,5	697
2016	1 332	%2,5	803
2015	1 275	%2,6	824
2014	1 306	%2,9	851

Trafik Güvenliği Vakfı (Foundation for Traffic Safety-FTS) on yıldan fazla süredir her yıl Trafik Güvenliği Kültür Endeksi (TSCI) anketi yaparak güvenli olmayan sürüş davranışlarına karşı halkın algı ve tutumlarını derinleştirmeye çalışmaktadır. 2019 yılında yapılan TSCI anketine göre sürücülerin %96'sı uykulu sürüşü çok tehlikeli olarak görmesine karşın bunlardan sadece %29'u uykulu sürücülerin polis tarafından yakalanma riski olduğunu düşünmektedir [4]. 2020 yılında yapılan ankette ise katılımcıların %17,3'ü son 30 günde en az bir kez olmak üzere araç kullanırken gözlerini açık tutmakta zorlandıklarını belirtmişlerdir [5].

T.C. Karayolları Trafik Yönetmeliği araç kullanma ve dinlenme sürelerine ilişkin 98. maddesinde “Ticari amaçla yük taşımacılığı yapan ve azami ağırlığı 3,5 tonu geçen araçların şoförleri ile ticari amaçla yolcu taşımacılığı yapan ve taşıma kapasitesi şoförü dahil 9 kişiyi geçen araçların şoförlerinin 24 saatlik herhangi bir süre içinde; toplam olarak 9 saatten ve devamlı olarak 4,5 saatten fazla araç sürmeleri yasaktır.” ifadesi yer almaktadır. Bu şekilde yorgun sürüş davranışlarının engellenmesi ya da azaltılması amaçlanmaktadır [6].

Yorgun durumda araç kullanan sürücülerde genelde aşağıdaki belirtiler gözlemlenmektedir:

- Sürüşün son birkaç kilometresini hatırlayamama
- Şeritten kayma
- Dikkat azalması
- Sık esneme durumu
- Gözlerin sık sık kapanması, açık tutulamaması
- Trafik ışık veya levhaları kaçırma

- Başı dik tutmakta zorlanma [7]

Bu durumlar göz önüne alındığında, sürücü yorgunluğunun erken tespit edilmesi ve sürücünün uyarılması için geliştirilen sistemler birçok kazanın önlenmesi için en önemli unsurlardan biri olarak her geçen gün daha çok önem kazanmaktadır. Sürücünün göz kapanma, esneme gibi davranış durumlarının; elektro biyosinyaller gibi fizyolojik durumlarının ya da araç kullanma durumlarının izlenmesi gibi farklı teknikler kullanılarak sürücü yorgunluk tespiti çalışmaları yapılmaktadır. Davranış durumlarının izlenmesi; kolay uygulanabilir, düşük maliyetli, dış etkenlerden daha az etkilenen ve sürücüyü rahatsız edecek herhangi bir cihaz kullanmayı gerektirmeyen bir tekniktir. Bu özellikleri sayesinde sürücü yorgunluğu tespit çalışmalarında en çok tercih edilen tekniktir.

Sürücünün yorgunluğunun en doğru şekilde tespit edilebilmesi için kullanılan teknikler kadar veri kümesinin özellikleri de önem taşımaktadır. Mevcut veri kümeleri incelendiğinde çoğunlukla laboratuvar ya da simülasyon ortamında verilerin toplandığı görülmektedir. Kimi veri kümeleri ise okul, ev gibi sosyal ortamlarda sürüş anlarını içermeyen durumlarda toplanmıştır. Çok az bir kısmı ise park halinde bir araçta ya da belirli bir rotada araç kullanırken ve bu sırada telefon ile ilgilenme, bir şeyler yeme gibi güvenli olmayan davranışların sergilenmesi istenerek videolar kaydedilmiş olup ortam araç içi olsa da gerçek/doğal sürüş anlarını kapsamamaktadır. Tüm bu veri setleri değerlendirildiğinde gerçek sürüş anlarını içeren bir veri kümesine ihtiyaç olduğu görülmektedir. Literatürdeki gerçek sürüş videolarından oluşan bir veri seti yoksunluğuna çözüm olarak sürücü yorgunluğunun tespit edilmesi çalışmalarında kullanılabilecek bir veri setinin literatüre kazandırılması çalışmanın motivasyonunu oluşturmaktadır. Bu nedenle bu tez çalışması kapsamında öncelikle bir veri kümesi oluşturulmuştur. Veri kümesi her katılımcının kendi rotasında normal bir sürüş sırasında kaydettiği videolardan oluşan gerçek sürüş anlarından oluşmaktadır. Sonrasında oluşturulan bu veri seti kullanılarak çeşitli derin öğrenme yöntemleri ile sürücü yorgunluk çalışmaları gerçekleştirilmiş ve sonuçlar karşılaştırmalı olarak sunulmuştur.

2. KAYNAK ARAŞTIRMASI

Dünya genelinde ölüm nedenleri incelendiğinde trafik kazalarının 8. sırada yer aldığı belirtilmiş olup önlem alınmaması durumuna ise 5. sıraya kadar yükselebileceği tahmin edilmektedir [8]. Yapılan çalışmalarda kazaya neden olan faktörler incelendiğinde en önemli faktörün insan faktörü olduğu görülmektedir. Bu nedenle de Hasanhanoglu [9] çalışmasında sürücü profillerinin kazaya neden olma ihtimallerini değerlendirmiştir. Çalışma kapsamında farklı bölge ve illerden toplamda 2018 sürücü ile anket çalışması yapmıştır. Yapılan çalışma sonucunda hızlı araç kullanmak (%29), yasalardaki açıklardan yararlanmaya çalışmak (%45) gibi durumların yanı sıra uzun süreli (%84) ve yorgun bir şekilde (%91) araç kullanmak da sürücülerin zayıf yönleri olarak belirlenmiştir.

Bu kapsamda kazaların önlenmesi için sürücü yorgunluğunun erken tespit edilmesi çalışmaları önem kazanmaktadır. Hooda ve diğerleri [10], çalışmalarında yorgunluğun tespiti için yapılan çalışmalarda kullanılan parametreleri karşılaştırmışlardır ve bazı özelliklerin diğer özelliklere kıyasla daha önemli olduğunu belirtmişlerdir. Bu özelliklerden en önemlisi yorgunluğu belirlemek için kullanılan cihazların sürücüyü engellemeyecek şekilde kullanılması olarak vurgulanmıştır. Biyolojik özellikler vücudun iç durumunu birebir gösterdiği için yorgunluk tespiti çalışmalarında en doğru sonucu vereceği tespit edilmiştir. Fakat, biyolojik özellikler için veri toplanması sırasında vücuda elektrotlar ve sensörler bağlanmaktadır ve bu durumda da en önemli özellik olarak belirtilen sürücüyü rahatsız etmemesi durumu göz ardı edilmiş olmaktadır. Ayrıca kullanılan cihazlar pahalı ve karmaşıktır. Araç parametrelerini kullanarak yapılan yorgunluk tespiti çalışmaları ise hava ve trafik koşullarından kolaylıkla etkilenebilmektedir. Bu durumlar değerlendirildiğinde sürücü yorgunluğu tespiti için en uygun özellik fiziksel özellikler olarak görülmektedir. Bu özelliklerin ise aydınlatma koşullarından etkilenmemesi için ise kızılötesi kameralar da kullanılabilmektedir.

Sürücü yorgunluğu çalışmaları Scaccabarozzi ve diğerleri[11], 2016 yılı şubat ayında Milano-Napoli güzergahındaki bir yüksek hızlı trenin 16 saat süren yolculuğu sırasında kaydetmiş oldukları mekanik ölçümlere dayalı veriler üzerinde çalışma yapmışlardır. Koltuğa yerleştirilen düzenekler aracılığıyla basınç, kuvvet, gerinim ve temassız sıcaklık değerleri ölçülerek incelenmiştir. En başarılı sonuçlar basınç ve sıcaklık değerlerinden elde edilmiştir. Çalışma sonucunda, mevcut sürücü yorgunluk tespit sistemlerinin %66'sına kadar iyileşme tespit edilmiştir. Jeong ve arkadaşları [12] ise havacılık kazalarının %70'ten

fazlasının yorgunluk veya yorgunluk gibi insan faktöründen kaynaklandığını belirtmişler ve bu konu üzerinde çalışma yapmışlardır. Simüle edilmiş bir gece uçuşu ortamında 10 katılımcı pilotun Elektroensefalografi (EEG) ve Elektrookülografi (EOG) verileri elde edilerek bu veriler üzerinde çalışma gerçekleştirilmiştir. Çalışmada uykulu ve uyanık olmak üzere zihinsel durum sınıflandırmasının yanı sıra 5 yorgunluk düzeyi için de sınıflandırma işlemleri gerçekleştirilmiştir. Bu 5 yorgunluk düzeyi (çok uyanık, oldukça uyanık, ne uyanık ne de uykulu, uykulu ama uyanık kalma çabası yok ve çok uykulu) Karolinska Uykululuk Ölçeği (Karolinska Sleepiness Scale-KSS) kullanılarak belirlenmiştir. Derin öğrenme yöntemleri kullanılarak sınıflandırma işlemleri gerçekleştirilmiş olup çalışma sonucunda yorgunluk sınıflandırma işlemleri için sadece EEG sinyallerinin kullanılmasının yeterli performans gösterdiği belirlenmiştir. [12]'de belirtilen çalışmaya benzer şekilde Guragain ve arkadaşları [13] da pilot yorgunluğunun kaza sebeplerinden olduğunu ve Federal Havacılık İdaresi (Federal Aviation Administration-FAA) tarafından belirlenen dört yaygın havacılık tehlikesinden biri olarak kabul edildiğini belirtmişler ve pilotların yorgunluk tespiti üzerine çalışmalarını gerçekleştirmişlerdir. Veriler 18 FAA sertifikalı pilotun katılımıyla gece 2:00-6:00 saatleri arasında bir simülasyon ortamında kaydedilmiştir. Katılımcılardan birinin kayıtları sırasında teknik problemler yaşanması, başka bir katılımcının ise mikro uyku durumu gözlemlenmemiş olması nedeniyle çalışmalar 16 katılımcının kayıtları üzerinden yapılmıştır. Son durumda kullanılan veri kümesi 830 EEG (320 uykulu olmayan, 510 uykulu) verisinden oluşmaktadır. Çalışmada 4 farklı algoritmanın performansları değerlendirilmiş olup en yüksek başarıya sahip algoritma için F1 puanı %87,11 olarak hesaplanmıştır.

Sürücü yorgunluğu için yorgunluk ve uyku hali gibi durumlarla yakından ilişkili olan EEG, Elektrokardiogram (EKG) ve Kalp Atış Hızı Değişkenliği (Heart Rate Variability-HRV) gibi biyolojik sinyaller kullanılarak yapılan birçok çalışma bulunmaktadır. Wei ve diğerleri [14], sanal gerçeklik sürüş simülöründe gerçekleştirilen sürüş deneyimleri sırasındaki EEG verilerini analiz ederek yorgunluk ile EEG arasındaki bağlantıları incelemişlerdir. Saçın elektrotlar ve cilt arasındaki ilişkiyi kısıtlaması gerekçesiyle çalışmada kafa derisinin saç içermeyen kısımlarındaki elektrotlardan alınan veriler üzerinde analizler gerçekleştirilmiştir. Sınıflandırma işlemleri için Lineer Diskriminant Analizi (Linear Discriminant Analysis-LDA), k En Yakın Komşular (K-Nearest Neighbors-kNN) ve Destek Vektör Makinesi (Support Vector Machine-SVM) yöntemleri kullanılmıştır. Tateno ve arkadaşları [15] da sürücünün kalp atış hızına dayalı bir çalışma yapmışlardır.

Çalışmada sürücünün nabız ölçümleri için diğer çalışmalardan farklı olarak parmak ucuna takılabilen ve taşınabilir bir ölçüm cihazı kullanmışlardır. Bu yöntemle sürücünün solunum sayısını hesaplamışlardır. Çalışma genel olarak kalp atış hızından hesaplanan solunum sayısının doğruluğu ve solunum sayısına dayalı tespit edilen yorgunluğun doğruluğu olmak üzere 2 farklı doğrulama çalışmasını kapsamaktadır. Çalışma sonucunda hesaplanan solunum hızının gerçek solunum hızı ile tutarlı olduğu fakat solunum hızının yorgunluk tespiti için kullanılacağı sistemlerde doğruluk değerinin artırılması gerektiği sonucuna ulaşılmıştır. Zhu ve arkadaşlarının yapmış oldukları çalışma [16] giyilebilir bir EEG cihazı kullanılarak EEG verilerinin toplanması, sürücünün yorgunluk durumunun tespit edilmesi ve yorgunluk durumuna göre sürücünün erken uyarılması olmak üzere 3 adımdan oluşmaktadır. Çalışmada yazarlar sınıflandırma işlemleri için daha önceki çalışmalarda makine öğrenmesi yöntemlerinin kullanılıyor olmasına rağmen son yıllarda derin öğrenme yöntemlerinin gelişmesiyle birlikte Evrimsel Sinir Ağlarının (Convolutional Neural Network-CNN) bilgisayarlı görme alanlarında yüksek performans gösterdiğini belirtmişlerdir. Bu nedenle de çalışmalarında sınıflandırma işlemleri için Inception ve AlexNet modelini kullanmışlardır. Sınıflandırma işlemi sonucunda sürücünün yorgun olmadığı belirlenirse uyarı ışığı beyaz, sürücünün 3 saniye boyunca yorgun olduğu belirlenirse uyarı ışığı kırmızı yanmaktadır. Uyarı ışığının kırmızı yanma süresi 5 saniyeden fazla olmasına rağmen sürücü EEG sinyallerine göre hala yorgunluk belirtisi gösteriyor ise sesli uyarı verilmektedir. Uyarı ışığı kırmızı yandıktan sonra 5 saniye içinde EEG sinyallerine göre sürücünün yorgun olmadığı tespit edilirse uyarı ışığı yeniden beyaza dönmektedir. Çalışma sonucunda ise Inception modeli ile %95,59 doğruluk elde edilmiştir. Gangadharan ve Vinod [17] çalışmalarında EEG verilerini toplamak için kablosuz bir EEG aracı kullanılmıştır. Veri toplama sırasında EEG verilerinin yanı sıra kalp hızı verileri de kaydedilmiştir. Bu verilerle yorgunluk durumunda kalp hızı ile EEG özellikleri arasındaki ilişkinin incelenmesi amaçlanmıştır. Yorgun olup olmama durumunun sınıflandırılması için ise SVM algoritması kullanılmıştır. Çalışma sonucunda elde edilen başarı oranı %78,3'tür. Işık ve Anagün [18] ise EKG verilerine dayalı sürücü yorgunluk tespit çalışması yapmışlardır. Çalışmada uyku moduna ilişkin EKG kayıtlarının olduğu ve uyanık kişilerin EKG kayıtlarının olduğu 2 farklı veri kümesi kullanılmıştır. Sınıflandırma işlemleri için Uzun Kısa Süreli Bellek (Long Short-Term Memory-LSTM) modeli kullanılmış olup çalışma sonucunda %95,52 doğruluk değeri ile sınıflandırma gerçekleştirilmiştir ve uygulamanın mobil veya web üzerinde kullanımının mümkün olduğu belirtilmiştir.

Araç parametrelerine dayalı sürücü yorgunluk tespit çalışmaları incelendiğinde yorgunluk durumunun şerit pozisyonunda ve direksiyon hareketlerinde daha fazla değişkenliğe neden olduğunu ve bu değişkenliğin sürücü yorgunluk tespit çalışmalarında kullanılabileceği görülmüştür [19]. Vasudevan ve diğerleri [20] araç telemetri verilerini kullanarak sürücü yorgunluğunun belirlendiği bir çalışma yapmışlardır. Çalışmada çeşitli makine öğrenmesi yöntemleri kullanılarak işlemler gerçekleştirilmiştir. Veriler masaüstü bir bilgisayara entegre edilmiş bir oyun konsolundaki sürüşler sırasında kaydedilmiştir. Öncelikle özellik seçimi yapılarak sürücü yorgunluğunu belirleyebilecek en anlamlı veriler çıkarılmıştır. Bu işlem sonucunda direksiyon açısı, yanıl hız ve bu değişkenlerin türevlerinin sürücü yorgunluk tespit çalışmalarında etkili olabileceği ve bu verilerin kullanılması gerektiği kararına varılmıştır. Bu özelliklerin çeşitli kombinasyonları kullanılarak optimum sonuca ulaşılması amaçlanmıştır. Yorgunluk tespiti için ise Lojistik Regresyon (Logistic Regression-LR), SVM, Çok Katmanlı Algılayıcı (Multilayer Perceptron-MLP) ve Rastgele Orman (Random Forest-RF) makine öğrenme yöntemleri kullanılmıştır. Daha iyi performans, daha fazla hesaplama verimliliği ve daha yüksek hassasiyet özelliklerinden dolayı SVM tercih edilmiştir. Çalışma sonucunda direksiyon açısı, yanıl hız ve türevlerinin aynı anda değerlendirildiği özellik kümesinin en iyi performansı gösterdiği belirlenmiştir. Zhenhai ve arkadaşları [21] ise çalışmalarında direksiyon simidi açısal hızının zaman serisi analizine bağlı sürücünün yorgunluğunu tespit etme yöntemi önermişlerdir. Çalışmada sürücü yorgunluk durumunu doğru değerlendirebilmek için sürücünün yüz ifadelerinden yararlanılmaktadır. Çalışma sonucunda yöntemin iyi performans gösterdiği ve gerçek hayatta kullanılabılır olduğu sonucuna ulaşmışlardır. Dehzangi ve Masilamani [22] de aracın hızlanma, frenleme ve direksiyon eksen durumlarına göre sürücünün yorgunluğunun tespit edilmesi üzerine çalışmalarını gerçekleştirmişlerdir. Çalışmada simülasyon ortamında veriler toplanmış olup bu veriler ile sınıflandırma ve regresyon teknikleri kullanılmıştır. Çalışma sonucunda sınıflandırma ile en erken 4,4 saniyede regresyon ile 4,5 saniyede sürücünün durumunun tespit edilebildiği görülmüştür.

Sürücü yorgunluk tespiti yöntemlerinden en çok tercih edileni ise davranışsal parametrelere dayalı yöntemlerdir. Kolay uygulanabilir, düşük maliyetli, dış etkenlerden etkilenmeyen ve sürücüye müdahale etmeyen bir yöntem olması tercih edilme nedenleri arasında sayılabilmektedir. Maior ve diğerleri [23] çalışmalarında sürücülerin Gözlerinin En Boy Oranlarına (Eye Aspect Ratio-EAR) göre yorgunluklarının tespit edilmesi için bir yöntem önermişlerdir. Yöntem temel olarak 3 adımdan oluşmaktadır. İlk olarak sürücünün

gözünün algılanması, sonrasında EAR hesaplaması ve son olarak yorgunluk tespiti yapılmaktadır. Sürücülerin durumlarının sınıflandırılması işlemleri için MLP, RF ve SVM modelleri kullanılmış olup doğruluk ve işlem süresi açısından değerlendirildiğinde en iyi sonuçlar SVM ile elde edilmiştir. Daha sonrasında DROZY veri tabanı kullanılarak yöntem doğrulanmış ve işlem sonucunda %94,44 başarı sağlanmıştır. Liu ve arkadaşları [24] da çalışmalarında sürücünün yorgunluğunu PERCLOS yöntemine dayalı olarak tespit etmişlerdir. PERCLOS birim zamanda göz kapağının açılma ve kapanma oranı olarak tanımlanmakta olup yorgunluk durumunun tespitinde sıklıkla kullanılmaktadır. Çalışmada simülasyon ortamında gece ve gündüz ışıklandırma şartlarında testler yapılmış ve sürücülerin gözlerinin konumu gece şartlarında %96,2 oranında doğru tespit edilmiştir. Sonrasında ise sürücünün yorgunluk durumu üzerine çalışılmış ve bu aşamada da %95,89 doğruluk değeri elde edilmiştir. Bazı çalışmalarda ise sürücünün göz hareketlerine değil diğer bir yorgunluk belirtisi olan esneme durumuna göre sürücülerin yorgunluk tespiti yapılmıştır. Omidyeganeh ve diğerleri [25] sürücülerin öncelikle yüz konumunu tespit etmişlerdir. Önerdikleri yöntem sayesinde ilk yüz tespit edildikten sonra diğer yüzler dikkate alınmayıp işlem sırasında birden çok yüzün olması durumunda sadece sürücünün yüzünün tespit edilmesi sağlanmıştır. Kameraya en yakın sürücünün yüzü olacağı için de tespit edilen ilk yüzün sürücü olduğu varsayımının doğru olacağı belirtilmiştir. Yüz tespiti yapıldıktan sonra ise yüzün alt yarısı hedef bölge olarak belirlenerek esneme durumu incelenmiştir. Çalışma sonunda önerilen yöntemin %75 doğruluk oranıyla esneme tespiti yaptığı görülmüştür. Tipprasert ve arkadaşları [26] da haar benzeri özellikleri kullanarak sürücünün yorgunluğunun tespit edilebileceği bir yöntem önermişlerdir. Düşük ışıktaki sürücünün yorgunluğunun tespit edilmesinin zor olduğunu vurgulayarak çalışmalarını kızılötesi görüntüler ile gerçekleştirmişlerdir. Önerilen yöntem öncelikle haar benzeri özellik kullanarak sürücünün yüz bölgesini tespit ettikten sonra bu bölgeyi alt ve üst yarıya bölmektedir. Sonraki aşamada yine haar benzeri özellikler kullanarak sürücünün gözlerini ve ağzını tespit etmektedir. Son olarak ise yönlendirilmiş Gradyan Histogramları (Histogram of Gradients-HOG) yöntemi kullanılarak elde edilen veriler SVM ile eğitilerek gözlerin kapanması ve esneme durumları tespit edilmiştir. Sonuç olarak, kapalı göz ve esneme algılama için doğruluk oranı %92,5 olarak hesaplanmıştır.

Derin öğrenme algoritmalarının son yıllarda göstermiş olduğu gelişmeler hayatımızın birçok alanında da etkisini göstermektedir. Derin öğrenme çalışmalarının mevcut performans hızı göz önüne alındığında gelecek yıllarda derin öğrenmenin insanların gerçekleştirdiği görevlerin çoğunu gerçekleştireceğine inanılmaktadır. Derin öğrenmedeki

bu gelişmelere paralel olarak görüntü sınıflandırma teknikleri de her geçen gün hızla gelişmektedir [27]. Bu nedenle davranış tespiti çalışmalarında da derin öğrenme yöntemleri sıklıkla tercih edilmeye başlanmıştır. Yu ve diğerleri [28] sürücü yorgunluğunu tespit etmek için CNN tabanlı mobil uygulama olan DrowsyDet'i önermişlerdir. Bu uygulama ilk olarak sürücünün yüzünü algılamaktadır. Sonrasında ise yüz, göz ve ağız durumuna göre sürücüyü normal, esneme ve uyku durumu olarak sınıflandırmaktadır. Uygulama internet gereksinimi duymadan mobil telefon ile gerçek zamanlı kullanılabilir. Önerilen CNN tabanlı DrowsDet ile elde edilen doğruluk oranı %97,8 olarak hesaplanmıştır. Jabbar ve arkadaşları da hesaplama ve depolama kapasitelerinin sınırlı olması nedeniyle mevcut uygulamaların gömülü sistemlerde kullanılamayacağını belirterek daha küçük boyutlu modeller önermişlerdir. Çalışmalarında Yüz Yer İşareti Tespiti (Facial Landmark Detection-FLD) kullanılarak MLP ve CNN tabanlı olarak D2MLP-FLD [29] ve D2CNN-FLD [30] modellerini önermişlerdir. Çalışmalar sonucunda D2MLP-FLD modelinde %81, D2CNN-FLD modelinde ise %83,33'lük başarı elde ettiklerini ve geliştirilen bu modellerin otomobillerin veya mobil cihazların gösterge panellerine entegre edilebileceğini belirtmişlerdir. Flores-Monroy ve arkadaşları ise [31] sürücü yorgunluk tespiti yaparken Özel Tasarlanmış Sığ Evrişimli Sinir Ağı (Specific Designed Shallow Convolutional Neural Network-SS-CNN) modeline dayalı bir yöntem önermişlerdir. Yöntem sürücünün gözünün açık ve kapalı olması durumunu kullanarak sürücü yorgunluğunu tespit etmektedir. Gözün kapalı olması durumu ile göz kırpma arasındaki farkın ayırt edilebilmesi için ise ardışık durumların analiz edilmesi sağlanmıştır. Çalışma sonucunda %98,95 doğruluk değeriyle sınıflandırma işlemleri gerçekleştirilmiştir.

[27]'de görüntü sınıflandırma için CNN tabanlı hibrit yöntemleri karşılaştırmıştır. CNN+KNN, CNN+SVM, MLP+CNN, LSTM+CNN ve CNN+GA hibrit yöntemlerinin karşılaştırıldığı çalışmada en yüksek doğruluğun %99,8 değeri ile LSTM+CNN olduğu belirtilmiştir. Yarlağadda ve ark. [32] çalışmalarında sürücü videolarından öznitelik çıkarma için CNN modeli, ardışık çerçevelerdeki öznitelikleri yorumlama için ise LSTM modeli kullandıkları Conv-LSTM modelini önermişlerdir. Önerilen bu yöntem ile elde edilen doğruluk değeri %97,25 olarak hesaplanmıştır.

Davranışsal parametrelere dayalı sürücü yorgunluk tespiti çalışmaları Çizelge 2.1'de karşılaştırmalı olarak sunulmuştur.

Çizelge 2.1. Davranışsal parametrelere dayalı sürücü yorgunluk tespit çalışmaları karşılaştırması

Yayın Başlığı	Yayınlanma Yılı	Kullanılan Model	Doğruluk
Gömülü Akıllı Kameraları Kullanarak Esneme Tespiti	2016	Viola-Jones	%75,0
Derin Sinir Ağları Tekniklerini Kullanan Android Uygulaması İçin Gerçek Zamanlı Sürücü Yorgunluk Tespiti	2018	D2MLP-FLD	%81,0
Kızılötesi Kamera ile Yorgunluk Analizi İçin Sürücü Gözlerini Kapatma ve Esneme Tespiti Yöntemi	2019	Haar Benzeri Özellik-SVM	%92,5
DrowsyDet: Gerçek Zamanlı Sürücü Yorgunluk Tespiti İçin Mobil Uygulama	2019	CNN-DrowsyDet	%97,8
Android Uygulama İçin Sinir Ağı Tekniklerini Kullanan Sürücü Yorgunluk Algılama Modeli	2020	D2CNN-FLD	%83,33
Göz En Boy Oranını Kullanarak Otonom Uyku Hali Tespiti İçin Gerçek Zamanlı Sınıflandırma	2020	EAR-SVM	%94,44
LSTM ile Yüz Parametrelerini ve RNN'leri Kullanarak Sürücü Yorgunluk Tespiti	2020	Conv-LSTM	%97,25
Görüntü İşlemeye Dayalı Sürücü Yorgunluk Durumunun Erken Uyarısı Üzerine Araştırma	2021	PERCLOS	%95,89
CNN Kullanan Görsel Tabanlı Gerçek Zamanlı Sürücü Yorgunluk Tespit Sistemi	2021	SS-CNN	%98,95

3. MATERİYAL ve YÖNTEM

3.1. Yorgunluk Tespiti

İnsanlar gün içinde aşırı derecede uykulu ya da yorgun hissettikleri dönemler/anlar yaşamaktadırlar. Bu durum yorgunluk olarak tanımlanmaktadır. Yorgunluk, belli belirsiz bir uyku halinden uyanık kalmak için yorgunluk ile mücadele etme durumuna kadar değişkenlik gösterebilmektedir. Yorgunluk durumunun artması, yoğunlaşması durumunda gün içinde uykuya dalma durumları yaşanabilmektedir [33]. Bu durum ise mikro uyku olarak adlandırılmaktadır.

Mikro uyku, 1-30 saniye arasında gerçekleşen geçici bir uyku bölümüdür. İnsanlar yorgun olduğunda, teknik olarak uyanık olmalarına rağmen beyinlerinin bazı bölümleri uykuya dalmaktadır. Mikro uykuya dalan insanlar genellikle bu durumun farkında bile olmamaktadırlar. Kişiler uyanık olduklarını düşünse bile, mikro uyku sırasında beynin bir bölümü kapandığından veya uyuduğundan dolayı beyin tam kapasite çalışmamaktadır. Ayrıca mikro uyku sırasında vücut neler olduğunu fark edip kişiyi tekrar uyandırana kadar farkındalık durumu da geçici olarak devre dışı bırakılmaktadır [34].

Mikro uykunun nasıl meydana geldiği ise beynin beta dalgalarından teta dalgalarına ani bir sıçrayış gerçekleştirmesi olarak açıklanmaktadır. Beta dalgaları, normalde yemek yemek, koşmak, şarkı söylemek gibi aktiviteler sırasında beynin ürettiği dalgalardır. Teta dalgaları ise uyku, dinlenme gibi durumlarda üretilen dalgalardır. Mikro uyku sırasında ölçülen EEG sonuçları incelendiğinde, mikro uykunun beynin derin uykuya geçmeye hazır olduğu 2. evresiyle benzerlik gösterdiği tespit edilmiştir. Beyin uykuya geçmeye hazır hale gelir fakat içinde bulunulan durumlardan dolayı (sürüş sırasında uyumamak, sınav sırasında uyumamak gibi gereklilikler) derin uykuya geçiş yapılamaz. Yani tüm şartlar uykuya geçişi işaret etmesine rağmen beyin uyumaması gerektiğini bilmektedir. Bu nedenle de beyin uyumaması gerektiğini fakat uykuda olduğunu saniyeler içinde fark ettiğinde ani bir sarsılmayla uyanmaktadır [35].

Çeşitli faktörler mikro uykuya yani yorgunluğa sebep olabilmektedir. Bu faktörleri aşağıdaki gibi listeleyebiliriz:

- Yaşam Tarzı: Uzun çalışma saatleri, gece vardiyası yapılması, ağır fiziksel güç gerektiren çalışma şartları gibi durumlar.

- Akıl Sağlığı: Depresyon, kaygı, stres, yas gibi zihinsel, duygusal ve psikolojik durumlar.
- Tıbbi Durumlar: Diyabet, kalp, böbrek ve karaciğer hastalıkları, mineral ve vitamin eksiklikleri, kansızlık vb. tıbbi durumlar.
- İlaç Kullanımı: Sakinleştiriciler, uyku hapları, antidepresanlar gibi ilaçların kullanıldığı durumlar.
- Uyku Bozukluğu: İnsomnia (uykusuzluk, uykuyu sürdürmemeye, uykuya dalmada zorluk), narkolepsi (gün içinde uyanık durumdayken gelişen uyku atakları), huzursuz bacak sendromu (uykuda bacakları hareket ettirme ihtiyacı) gibi durumlar [36].

Bu gibi nedenlerle oluşan yorgunluk durumları uyumak için güvenli bir ortamda televizyon izlerken, kitap okurken yaşanabileceği gibi araba sürerken, ağır iş makineleri kullanırken de yaşanabilir. Araba sürmek, ağır iş makinesi kullanmak gibi durumlar dikkat gerektiren eylemler olup bu eylemler sırasında mikro uykuya dalmak büyük kayıplara neden olabilmektedir. Matematiksel olarak hesaplanacak olursa, 110 km/saat hızla giden bir aracın şoförünün 6 saniye mikro uykuya daldığı düşünülürse bu mikro uyku süresince yaklaşık olarak 180 metre yol gitmiş olacaktır. Bu da ortalama boyutlarda 2 futbol sahası boyutuna denk gelmektedir. Bu mesafe ise kırmızı ışık, şerit değiştirme, dur levhası gibi durumların ihlal edilmesi için yeterli uzunluktadır. Bunun yanı sıra yorgunluk karar verme becerilerini, tepki verme süresini ve sürüş kabiliyetini de etkilemektedir. Uykuya dalma durumu gerçekleşmese bile yorgun bir sürüş birçok tehlikeye yol açabilmektedir [34].

İnsanlardaki yorgunluğun tespit edilmesi için kullanılan birçok yöntem vardır. Yöntemler arasında hangisinin en iyi yöntem olduğu hakkında kesin bir yargı olmamakla birlikte birden fazla yöntemin paralel kullanılması durumunda yorgunluk tespitinin başarı oranı daha yüksek olmaktadır. Yorgunluk tespiti için kullanılan yöntemler aşağıda listelenmektedir:


- Polisomnografi (PSG): Uyku süresince beyin dalgaları, kalp grafisi, solunum durumu, kas durumu, göz hareketleri gibi çeşitli vücut fonksiyonlarının ölçümleri yapılarak kişinin uyku kalitesinin ölçüldüğü uyku testidir.
- Elektroensefalografi (EEG): Kafa derisine bağlı elektrotlar aracılığıyla beyin sinyallerini kaydeden testtir. Mikro uyku sırasında beyin frekanslarının yavaşladığı (alfa dalgalardan beta dalgalara geçtiği) görülmektedir.

- Fonksiyonel Manyetik Rezonans Görüntüleme (fMRI): Kan akışı değişikliklerinin izlenerek beyin aktivitesinin ölçülmesidir. Böylece mikro uyku sırasında beyin aktif bölümlerinin tespiti yapılmaktadır.
- Psikolojik Testler: Reaksiyon süresi testi, uyanıklığı sürdürme testi, çoklu uyku gecikme testi gibi insanların uyaranlara gösterdiği tepki süresinin, uyanık kalma durumlarının, şekerleme ve uyku gecikmesi arasında geçen sürenin ölçüldüğü testlerdir.
- Elektrookülogram (EOG): Gözün önü ve arkası arasında (kornea-retina) sürekli var olan potansiyel elektrik farkından retinanın dinlenme potansiyelinin ölçüldüğü yöntemdir. Gözün odaklandığı nokta sabit olması durumunda odaklanma süresince aynı potansiyel değer elde edilmektedir.
- Göz Video Testi: Yorgunluk tespiti için göz hareketlerinin ve göz kırpma sıklığının ölçüldüğü testlerdir.
- Ağız Esneme Testi: Yorgunluk tespiti için belirli bir süre içerisindeki esneme sıklığının ölçüldüğü testlerdir.
- Konuşma Testleri: İnsanların konuşmaları sırasında konuşmadaki duygu ve vurguların incelendiği testlerdir [37].

3.2. Sürücü Yorgunluk Tespiti

Sürücü yorgunluğunun erken algılanması ve sürücünün uyarılması; kazaların, can ve mal kayıplarının, yaralanmaların önlenmesi açısından büyük önem taşımaktadır. Böylece hem yayalar hem de sürücüler için daha güvenli bir trafik ortamı sağlanmış olacaktır. Yorgunluk, insanların dikkat gerektiren işlere uzun süre maruz kalması durumunda yaşadığı psikolojik ve fizyolojik değişiklikler olarak tanımlanmaktadır. Bunun sonucu olarak insanların bilişsel ve psikomotor yeterliliğinde enerji eksikliğinin yanı sıra uyanıklığın azalması durumu gözlenmektedir. Özet olarak insanların uyumak için yoğun bir istek duyduğu, uyku ve uyanıklık arasında bir durum olarak tanımlanmaktadır [38]. Sürücünün yorgun olması durumunda gözlemlenebilecek belirtiler, tekrarlayan esneme, sinirli hissetme, tepkilerde gecikme, kafa karışıklığı, direksiyon hareketlerinde yavaşlama, sıklıkla göz kırpma, yavaş nefes alma, kalp atış hızında düşme, başın sallanması, şeritten/yoldan çıkma, gaz/fren pedallarını düzensiz kullanma gibi durumlar olarak belirtilmektedir [39]. Sürücü yorgunluğunun erken tespit edilmesi için sürüş sırasında ilgili

parametrelerin izlenmesi sağlanarak bahsedilen bu belirtilerin gözlenmesi durumunda sürücünün uyarılması sağlanmaktadır. Bu kapsamda yapılan çalışmalar incelendiğinde sürücü yorgunluğunun tespiti için genel olarak 3 tekniğin kullanıldığı görülmektedir. Bu teknikler; davranışsal parametrelere dayalı teknikler, araç parametrelerine dayalı teknikler ve fizyolojik parametrelere dayalı teknikler olarak sınıflandırılmaktadır. Sürücü yorgunluk tespit teknikleri ve belirtilen teknikler kapsamında en sık kullanılan parametreler Şekil 3.1’de paylaşılmaktadır.



Şekil 3.1. Sürücü yorgunluk tespit teknikleri

3.2.1. Davranışsal parametrelere dayalı teknikler

Araç içerisine yerleştirilen kameralar aracılığıyla sürücünün hareketlerinin izlenmesine dayanan tekniklerdir. Sürüş sırasında kaydedilen görüntüler bilgisayarlı görü teknikleri ile analiz edilerek sürücünün durumu tespit edilmektedir. Kameranin sürücüyü herhangi bir teması olmaması nedeniyle müdahaleci olmayan yöntem olarak kategorize edilmektedir. Böylece sürücü sürüş sırasında daha rahat olabilecek ve herhangi bir kısıtlama olmadan sürüşüne devam edebilmektedir. Çalışmalarda genellikle göz açıklık durumu, göz kırpma sıklığı, esneme sıklığı, baş hareketleri gibi parametreler incelenmesinin yanı sıra çok nadir

de olsa sürücünün vücut hareketleri [40] incelenerek de sürücü yorgunluk tespiti yapılmaktadır. Aydınlatma koşullarından kolaylıkla etkilenebilen bir yöntem olmasına karşın düşük maliyetli ve müdahaleci olmayan bir yöntem olması nedeniyle çalışmalarda sıklıkla tercih edilmektedir.

Davranışsal Parametrelere Dayalı Teknikler kapsamında yapılmış çalışmalar incelendiğinde en sık kullanılan 3 parametrenin göz, ağız ve baş olduğu görülmektedir.

- **Göz:** Göz kapatma yüzdesi, göz en boy oranı, göz kırpma sıklığı, göz bebeğinin hareketi gibi durumlar incelenerek yorgunluk tespiti yapılabilmektedir. Güneş gözlüğü kullanılması durumunda yorgunluk tespit doğruluğunun düştüğü görülmektedir [30].
- **Ağız:** Ağız açıklığı incelenerek yorgunluk tespiti yapılmaktadır. Konuşma veya şarkı söyleme gibi durumlarının yanı sıra esneme sırasında ağzın fazla açılması [26] durumundan da olumsuz etkilenmektedir.
- **Baş:** Başın sürekli sağa sola sallanması, öne düşmesi gibi durumların incelenmesi ile yorgunluk tespiti yapılmaktadır.

3.2.2. Fizyolojik parametrelere dayalı teknikler

Sürücünün üzerine yerleştirilen cihazlar ile sürücünün HRV, EEG, EKG verileri gibi biyolojik değerlerinin ölçülerek sürücünün yorgunluğunun tespit edildiği müdahaleci tekniklerdir. Sürücü üzerine cihazlar yerleştirilmesi sürücü konforunu olumsuz etkilemektedir ve sistemi sürekli kullanım için elverişsiz hale getirmektedir. Fakat değerlerin dış etkenlerden kolaylıkla etkilenmemesi nedeniyle daha güvenilir sonuçlar elde edilmektedir.

- **EEG (Elektroensefalografi):** İnsanların kafasına yerleştirilen elektrotlar aracılığı ile beyindeki elektriksel dalgalanmaların ölçülmesidir.
- **EKG (Electrocardiography):** Göğsün üzerine yerleştirilen elektrotlar aracılığıyla kalbin elektrik sinyallerinin ölçülmesidir.
- **HRV (Heart Rate Variability):** Kalp hızı değişkenliği, sürücünün bileklerine, boynuna, dirsek içine vb. yerleştirilen cihazlar ile kalp atış hızının zamana bağlı değişiminin ölçülmesi ile hesaplanmaktadır.

3.2.3. Araç parametrelerine dayalı teknikler

Direksiyon simidi, gaz/fren pedalları gibi aracın çeşitli bölgelerine yerleştirilen cihazlar ile aracın şerit değiştirme sıklığı, aracın yoldan çıkması, direksiyon hareketleri, araç hızı değişimi gibi parametrelerin değerlendirilmesi ile yorgunluk tespitinin yapıldığı tekniklerdir. Bu teknik kapsamında kullanılan malzemelerin maliyetli olması ve hava koşulları, yol koşulları, sürücü tecrübesi gibi durumlardan kolay etkilenmesi nedeniyle tercih edilmemektedir.

- Şerit İzleme: Aracın şerit değiştirme hızı, sıklığı ve yoldan çıkma durumlarının incelenmesidir.
- Direksiyon: Direksiyon simidinin hareketi, sürücünün direksiyonu kavrama kuvveti gibi değişkenlerin incelenmesidir.
- Gaz/Fren Pedalları: Araç hızlanma, ani fren yapma gibi durumların incelenmesidir.

Bu yöntemler genel olarak değerlendirildiğinde ortaya çıkan en önemli unsurlardan biri sürücünün yorgunluğunu tespit etmek için kullanılan cihaz ve/veya sensörlerin sürücüyü engellememesi gerektiğidir. Fizyolojik parametrelere dayalı teknikler, vücudun iç durumunu incelediği için doğruluğu en yüksek teknik olmasına rağmen kullanılan cihazlar karmaşık ve pahalıdır. Bu teknik kapsamında en kolay ölçülebilen EKG kişiden kişiye değişiklik gösterebilmektedir ve bu nedenle kişilerin kimliklerinin belirlenmesinde kullanılabilmektedir.

Araç parametrelerine dayalı yöntemler ise hava, yol koşulları gibi dış etkenlerden kolay etkilenebilir olması nedeniyle doğruluk değerleri düşüktür. Bu durumlar göz önünde bulundurulduğunda, davranışsal parametrelere dayalı teknikler sürücü yorgunluğunun tespitinde en etkili yöntemdir [10].

Davranışsal parametrelere dayalı teknikler en etkili ve sık kullanılan yöntem olmasıyla birlikte aydınlatma koşullarından kolay etkilenmek gibi bir dezavantajı vardır. Bu durumun üstesinden gelmek için bazı çalışmalarda kızılötesi görüntüler kullanılmaktadır [26,41–43].

3.3. Veri Kümesi

Sürücü yorgunluk tespiti verileri hangi tekniğin kullanılacağına göre farklılık göstermektedir. Araç parametrelerine dayalı teknikler kullanılarak yapılan çalışmalarda

direksiyon açısı, şerit durumu [44]; aracın hızlanma, frenleme [22] durumları gibi değişkenlerinin incelenerek bu değerlerin yer aldığı veri kümeleri oluşturulmaktadır. Fizyolojik parametrelere dayalı teknikler kullanılması durumunda MMASH [45], MITDB [46], Uyku Biyoradyolokasyon Veritabanı [47] gibi kişilerin biyolojik değerlerinin yer aldığı veri kümeleri kullanılmaktadır. Davranışsal parametrelere dayalı teknikler kapsamında ise insanların yüzünün kameralar aracılığıyla kaydedilerek toplanan veri kümeleri kullanılmakta olup bu şekilde birçok veri kümeleri bulunmaktadır. Bu veri kümelerinden en sık kullanılan birkaç veri kümesinin detayları aşağıda paylaşılmaktadır:

ULg Multimodality Drowsiness Database (DROZY)

DROZY yüz görüntülerinin yanı sıra PSG sinyalleri (Polisomnografi), KSS verileri (Karolinska Uykululuk Ölçeği) ve Psikomotor Vijilans Testi (PVT) verilerini de içermektedir. Veri toplama işlemi yaşları $22,7 \pm 2,3$ olan 3 erkek 11 kadın olmak üzere toplam 14 kişinin katılımıyla gerçekleştirilmiştir. Katılımcıların herhangi bir alkol bağımlılığı, ilaç kullanımı veya uyku bozukluğu olmamasına özen gösterilmiştir. Deneylerden önce katılımcıların son bir hafta düzenli uyku uyumaları, bu süreçte uyku eksikliklerinin olmadığını doğrulamak için de uyku günlüğü tutmaları istenmiştir. Deneyler sessiz izole edilmiş bir laboratuvar ortamında, 28-30 saat kadar sürmüş olup bu süreçte belirli aralıklarla katılımcıların Psikomotor Uyanıklık Testleri (Psychomotor Vigilance Test-PVT), KSS, PSG, yüz görüntü verileri toplanmıştır [48].

The NTH Drowsiness Detection Dataset (NTHU-DDD)

Ulusal Tsuing Hua Üniversitesi Bilgisayarla Görme Laboratuvarı tarafından toplanmış bir sürücü yorgunluk tespiti video veri kümesidir. Veri kümesi, gözlüklü ve gözlüksüz, farklı etnik kökenlerden 36 katılımcının gündüz ve gece koşullarında çekilmiş olan normal sürüş, esneme, kahkaha atma, yavaş göz kırpma, uykuya dalma gibi durumlarını içeren videolarından oluşmaktadır. Videolar katılımcının bir sandalyede oturarak, simüle edilmiş bir direksiyon ve pedallarla oyun oynadığı sırada çekilmiş olup çekimler sırasında katılımcılardan esneme, başını sallama, yavaş göz kırpma gibi yorgunlukla ilgili; gülme, konuşma, iki tarafa bakma gibi yorgunlukla ilgisi olmayan belirli yüz ifadelerini yapmaları talimatı verilmiştir.

Eğitim veri kümesi gözlüklü, gözlüksüz, gözlüklü gece, gözlüksüz gece, güneş gözlüklü olmak üzere toplamda 5 farklı senaryoyu içeren, katılımcılardan 18'inin videolarını içermektedir. Eğitim veri kümesi dışında kalan 18 katılımcının videoları ise değerlendirme ve test veri kümelerinde yer almaktadır.

Videolarda kızılötesi aydınlatma kullanılmış olup videolar AVI formatında ve 640x480 çözünürlüğünde çekilmiştir [49].

The Real-Life Drowsiness Dataset (RLDD)

Veri kümesi toplanırken yazarların hedeflerinden biri de sadece kolay görülebilen aşırı yorgunluk durumunu değil aynı zamanda hafif yorgunluk durumunun da tespit edilebilmesini sağlamaktır. Veri kümesi 60 katılımcının uyanık, düşük uyanık ve yorgun olmak üzere toplamda 3 farklı sınıfa ait videolarından oluşmaktadır. Veri kümesi, 180 tane RGB videodan oluşmakta olup toplamda yaklaşık 30 saat uzunluğundadır. Katılımcılar 20-59 yaşları arasında 5 farklı etnik kökenden olmak üzere 51 erkek ve 9 kadından oluşmaktadır. Katılımcının gözlüklü olduğu 21, önemli ölçüde sakallı olduğu 72 video bulunmaktadır.

Katılımcılardan, onlara tanınan 20 gün süre içerisinde her bir katılımcının kendilerini uyanık, düşük uyanık ve yorgun hissettikleri anlarda, evde veya üniversitede, kamerayı kendilerinden bir kol uzunluğu mesafeye yerleştirerek her iki gözleri görünecek şekilde 3 video çekmeleri istendi. Böylece videolar araç içine yerleştirilmiş bir kamera açısıyla çekilmiş gibi olacaktır [50].

Yawning Detection Dataset (YAWDD)

Veri kümesi, park halindeki gerçek bir arabanın ön aynası ve sürücü paneli olmak üzere iki farklı konumuna yerleştirilen kameralar aracılığıyla çekilmiş videolardan oluşmaktadır. Videolar farklı etnik kökenlerden 57 erkek ve 50 kadın katılımcının gözlüklü/güneş gözlüklü ve gözlüksüz olarak normal sürüş (konuşmadan sessizce), konuşma veya şarkı söyleme, esneme gibi 3 farklı durumunu içermektedir. Veri kümesi oluşturulmasındaki öncelikli hedef esneme tespiti çalışmaları için model ve algoritma geliştirilmesinde ve test edilmesinde kullanılmasıdır. Aynı zamanda yüz ve ağzın tespiti ve izlenmesi için de kullanılabilir [51].

National Cheng Kung University Driver Drowsiness Dataset (NCKUDD)

Veri kümesi, sürücünün önüne yerleştirilen kızılötesi LED ışıklı kamera aracılığıyla 25 kadın ve erkek, Asyalı katılımcının sürüş anında çekilmiş videolarından oluşmaktadır. Videolar hem gün ışığında hem de karanlık ortamda çekilmiştir. Videolar normal sürüş (273), dikkati dağılmış sürüş (147), uykulu sürüş (21), araç kullanırken konuşma (40), araç kullanırken bir şeyler yeme (21), araç kullanırken telefonla oynama (29) ve diğer (112) olmak üzere 7 farklı durum içermekte olup toplamda 643 adettir [52].

Spontaneous Micro-Expression Database (SMIC)

Veri kümesi 6 kadın 10 erkek olmak üzere toplamda 16 katılımcıdan elde edilen 164 mikro-ifade videosundan oluşmaktadır. Video kayıtları sorgu odasına benzer kapalı bir odada gerçekleştirilmiş olup odanın aydınlatması video kayıtları süresince kontrol altında tutulmuştur. Katılımcılara 50 cm uzaklığındaki bir monitörden izletilmek üzere güçlü duygular uyandırabilecek 16 film klibi özenle seçilmiştir. Bu sırada monitörün üzerine yerleştirilen bir kamera aracılığı ile katılımcıların film izleme sürecindeki ifadeleri kaydedilmiştir. Başlangıçta deneye katılan 20 katılımcı (6 kadın 14 erkek) olmasına karşın bunlardan 4'ünün kayıtları incelendiğinde herhangi bir mikro ifade tespit edilemediği için veri setinden çıkarılmıştır. Veri kümesi pozitif (mutlu), negatif (üzgün, öfke, korku, tiksinti) ve sürpriz (şaşkın) olmak üzere 3 sınıfa ayrılmaktadır [53].

Spontaneous Actions and Micro-Movements (SAMM)

Yaşları 19 ve 57 arasında değişen 16 erkek 16 kadın olmak üzere toplamda 32 katılımcı ile gerçekleştirilen deneyler sonucu toplanan bir veri kümesidir. Kültürel açıdan en çeşitli (13 farklı etnik köken) veri kümesidir. Deneyler katılımcıların 32 inç düz ekran televizyonda uyarıları izlediği, led içeren 2 ışıkla aydınlatılan bir odada gerçekleştirilmiştir. Veri seti 159 mikro yüz hareketi ve 7 duygu (öfke, küçümseme, korku, iğrenme, mutluluk, üzüntü, şaşkınlık) içermektedir [54].

Veri kümelerinin karşılaştırmalı özellikleri Çizelge 3.1'de paylaşılmaktadır.

Çizelge 3.1. Veri kümelerinin özelliklerinin karşılaştırması

Veri Kümesi	Katılımcı Sayısı	Deney Ortamı	Durum
DROZY	14	Laboratuvar	Normal/Yorgun
NTHU-DDD	36	Oyun Simülasyonu	Esname/Başını Sallama/Yavaş Göz Kırpma/Gülme/Konuşma/İki Tarafa Bakma
RLDD	60	Ev/Üniversite	Uyanık/Düşük Uyanık/Yorgun
YAWDD	107	Park Halinde Araçta	Normal/Konuşma veya Şarkı Söyleme/Esname
NCKUDD	25	Sürüş Anında Araçta	Normal/Uykulu/ Dikkati Dağılmış/Konuşma/Bir şeyler Yeme/Telefon ile Oynama/Diğer
SMIC	16	Kapalı Bir Odada	Üzgün/Öfkeli/Tiksinti Duyan/Korkmuş/Mutlu/Şaşkın
SAMM	32	Kapalı Bir Odada	Öfkeli/Küçümseyen/Korkmuş/İğrenmiş/Mutlu/Üzgün/Şaşkın

Veri kümeleri genel olarak incelendiğinde çoğu veri kümesinde veriler toplanırken videoların gerçek bir araçtan ziyade laboratuvar ya da simülasyon ortamında çekildiği görülmektedir. Bazı veri kümeleri ise ev, okul vb gibi sosyal çevrede ve araç sürüşüyle alakası olmayan herhangi bir etkinlik sırasında oluşturulduğu görülmektedir. Araç içerisinde kayıtların yapıldığı veri kümelerine bakıldığında ise araç park halinde olup yapay bir sürüş simülasyonu gerçekleştirildiği ya da kayıtların gerçek bir sürüş deneyimi sırasında yapılmasına rağmen telefon ile oynama, bir şeyler yeme gibi durumları içerdiğinden sürüş güvenliğini tehlikeye attığı görülmektedir. Bunlara ek olarak video kayıtları sırasında gerçek bir normal ya da yorgunluk durumu yerine katılımcılara esneme, başını sallama, gülme vb talimatlar verilerek rol yapmaları istenmektedir. Bazı veri kümelerinin ise genel mikro ifade tespitleri için oluşturulmuş olup sürücü yorgunluğu için kullanılamayacağı görülmektedir.

Tüm bu durumlar değerlendirildiğinde gerçek ve güvenli sürüş anlarından oluşan bir veri kümesi ihtiyacı olduğu görülmektedir. Bu çalışmada katılımcıların kendi araçlarında ve kendi istediği rotalardaki sürüş deneyimlerinden oluşan Sivas Bilim ve Teknoloji Üniversitesi Sürücü Yorgunluk Veri Kümesi (Sivas University of Science and Technology Driver Drowsiness Dataset-SUST-DDD) halka açık olarak sunulmaktadır.

3.3.1. Sivas Bilim ve Teknoloji Üniversitesi Sürücü Yorgunluk Veri Kümesi:

SUST-DDD veri kümesi, sürücü yorgunluğunun erken tespiti amacıyla oluşturulmuş gerçek sürüş anlarından oluşan bir sürücü yorgunluk veri kümesidir.

Veri kümesi, yaşları 24 ile 42 arasında değişen 3 kadın 16 erkek olmak üzere toplam 19 sağlıklı katılımcının videolarından oluşmaktadır.

Veri toplama

Bu bölümde, SUST-DDD veri kümesi için videoların nasıl toplandığı anlatılmaktadır. Çalışma Sivas Bilim ve Teknoloji Üniversitesi Bilimsel Araştırma ve Yayın Etiği Kurulu tarafından onaylandıktan sonra her bir katılımcının onay formunu imzalaması istenmiştir. Çalışmaya 24-42 yaş aralığında, 16 erkek 3 kadın olmak üzere B sınıfı ehliyet sahibi 19 kişi katılım sağlamıştır. Katılımcılardan arabalarının ön camına yapıştırdıkları bir telefon tutucuya telefonlarını yerleştirerek, sürüş sırasında yüzleri görünecek şekilde video çekmeleri istendi. Çekimler sırasında kamera pozisyonunu gösteren görsel Şekil 3.2’de paylaşılmıştır. Bu işlemler için her sürücüye 3 hafta süre verildi. Böylece kendilerini gerçekten yorgun/normal hissettikleri bir zamanda, baskı olmadan video çekmeleri sağlandı. Sürüş sırasında katılımcılardan herhangi bir rota izlemesi istenmedi. Kendi isteklerine göre normal gün akışında gitmeleri gereken rotalar sırasında hiçbir ek yaptırım olmadan sürüşlerinin bir kısmını kameraya kaydettiler. Katılımcıların dikkat etmesi gereken tek unsur kayıtların gün doğumu veya gün batımına yakın saatlerde (güneş ışığına çok maruz kalmadan, düşük ışık koşulunu doğal akışında yakalamış olmak için) çekilmesi gerekliliğidir. Videoların katılımcıların da tercihine bağlı olarak genellikle normal sürüş için işe gidiş gibi daha dinç hissedilen saatler ve yorgun sürüş için ise gün sonu yorgunluğunun yoğun olduğu işten dönüş saatlerinde çekilmiş olmasıyla birlikte şehirler arası yolculukların başlangıçlarında (normal) ve sonuna yakın saatlerde (yorgun) kaydedilmiş olanları da bulunmaktadır. Her katılımcı kendi araçlarında kendi telefonları ile çekimleri gerçekleştirdikten sonra videolar ile her videonun karşılığı olan etiketleri harici bellekler aracılığıyla ilettiler.



Şekil 3.2. Video kayıtları sırasında telefonun pozisyonu

Veri önışleme

Her katılımcı videosunu kendi telefonu ile kaydettiğı için videolar arasında format, boyut ve kalite farklılıkları bulunmaktadır. Tüm katılımcılar videolarını teslim ettikten sonra videolar çoğunluk olarak mp4 formatında olduğundan farklı formatta olan videolar da mp4 formatına dönüştürülmüştür. Sonrasında videolar seslerinden de arındırılarak boyutlarının küçültülmesi sağlanmıştır. Son olarak her biri yaklaşık 10 dakika uzunluğunda ve farklı boyutlardaki videolar 10 saniye uzunluğunda ve 224x224x3 boyutunda videolara bölündü. Tüm bu işlemler sonrasında veri setinde 10 saniye uzunluğunda ve 224x224x3 boyutunda 2074 video bulunmaktadır.

Veri kümesi detayları

Veri kümesi 224x224x3 boyutunda 2074 RGB videodan oluşmaktadır. Her videonun uzunluğu 10 saniyedir. Videolar yorgun ve normal olarak 2 sınıfta sınıflandırılmış olup, 2074 videonun 975 tanesi yorgun sürüş, 1099 tanesi ise normal sürüş olarak etiketlenmiştir. 2074 videonun 368 tanesinde sürücü gözlüklüdür. Veri kümesinin toplam boyutu 4,77 Gigabayttır.

Jüri değerlendirmesi

Videolar katılımcı tarafından kaydedildikten sonra katılımcının belirttiği etiketleriyle birlikte teslim alınmıştır. Yapılan ön işlem sonrasında elde edilen 10 saniyelik videolar katılımcının belirttiği etiketten bağımsız olarak jüri tarafından yorgun/normal olarak değerlendirilmiştir. Jüri gönüllü 3 kişiden oluşmakta olup her video izlenerek jüri üyeleri tarafından yorgun-yorgun değil olarak oy vermeleri istenmiştir. Jüri üyelerinin birbirlerinin fikirlerinden etkilenmemesi amacıyla oylama işlemleri ayrı ayrı kağıtlara yazılarak yapılmıştır. Kararsız kalınması durumunda videoların istendiği kadar tekrar izlenmesi, ileri-geri sarılması imkanları sunulmuştur. Bu işlemler sonucunda da video oy çoğunluğu olan sınıfa dahil edilmiştir. Böylece veri kümesinin insan bakış açısına göre değerlendirilmesi sağlanmıştır. Gözlemciler 2 erkek 1 kadın gönüllüden oluşmakta olup; gazetecilik, uluslararası ilişkiler ve bilgisayar programcılığı bölümlerindendir.

3.4. Derin Öğrenme ile Düşük Işıktaki Sürücü Yorgunluk Tespiti

CNN ve Tekrarlayan Sinir Ağı (Recurrent Neural Network-RNN) çeşitli amaçlar için kullanılmakta olan temel Derin Sinir Ağı (Deep Neural Network-DNN) mimari türleridir. CNN evrişim kullanarak verilerin özelliklerini çıkarmaktadır ve bu özelliklere göre verileri sınıflandırmaktadır. Bu özelliği nedeniyle bilgisayarlı görü alanlarında sıklıkla kullanılan önemli bir modeldir. RNN ise sıralı ve tekrarlı veri kümelerindeki öğrenme için özelleşmiş bir DNN türüdür. Bu nedenle genellikle doğal dil işleme çalışmalarında tercih edilen önemli bir modeldir [55].

3.4.1. Evrişimli Sinir Ağı

Son dönemlerde, evrişimli sinir ağları makine öğrenimi ve özellikle de bilgisayarla görme alanlarında büyük başarılar elde etmiştir. Araştırmacıların evrişimli sinir ağlarını kullanmasında en önemli etkenlerinden biri de özellik çıkarma işlemlerindeki başarısıdır. CNN, özellikle görüntü analizi uygulamaları için tasarlanmış bir derin sinir ağı olmasının yanı sıra doğal dil işleme gibi verilerin sıralı işlenmesi ve analizi gibi çalışma alanlarında da yüksek başarı kapasitesi olduğu belirlenmiştir [56]. CNN mimari modeli evrişim

katmanı, havuzlama katmanı ve sınıflandırma katmanı olmak üzere her katmanın ayrı, özel bir işlevinin olduğu 3 tür katmandan oluşmaktadır. CNN'nin yapı taşı olan evrişimsel katman, giriş görüntüsünün özelliklerini algılayarak belirli özelliklerin çıktısı da daha baskın olmasını sağlamaktadır. Havuzlama katmanı, genellikle bir evrişim katmanından sonra, öncesindeki katman çıktısının önemli özelliklerini çıkarmak amacıyla kullanılmaktadır. Böylece hem işlem gücü azaltılmaktadır hem de gereksiz özellikler çıkarılarak önemli özelliklere odaklanılmaktadır. En son matris halindeki girdi tek vektör haline getirilerek her bir pikselin ayrı nörona girdi olarak iletiildiği bir veya daha fazla tamamen bağlı katmanı içeren sınıflandırma katmanı bulunmaktadır. Son olarak bu girdiler kullanılarak sınıflandırma işlemleri gerçekleştirilmektedir [38].

Çalışmada sürücü yorgunluk tespiti yapılırken öncelikle CNN modelleri ile girdi videolarından özellik çıkarma yapılmaktadır, sonrasında ise CNN model çıktıları LSTM modeline girdi olarak alınıp zamansal özellikleri de dikkate alınarak videolar sınıflandırılmaktadır. Kullanılan hibrit modelin genel gösterimi Şekil 3.3'te paylaşılmaktadır.




Şekil 3.3. Çalışmada kullanılan hibrit model

Bazı derin öğrenme modelleri aşağıda kısaca açıklanmıştır:

VGG-16

Oxford Üniversitesi bilim insanlarından Karen Simonyan ve Andrew Zisserman'ın 2014 yılındaki çalışmalarında önerdikleri bir evrişimli sinir ağı modeli olan VGG16'nın ImageNet veri kümesi (1 000 sınıf ve 14 milyondan fazla görüntü) ile yapılan çalışma sonucunda %92,7 test doğruluğuna ulaştığı görülmektedir. Adında yer alan 16 sahip olduğu ağırlıklı katman sayısına denk gelmektedir. Filtre boyutları evrişimsel katmanda 3x3, havuz katmanında ise 2x2'dir. Çıktı değerleri için ise 2 tam bağlantılı katman ve 1


softmax katmanına sahiptir [57]. Fakat çalışmamızda softmax katmanını kullanmadan tam bağlantılı katman çıkışı LSTM modeline girdi olarak iletilmektedir. Kullanılan VGG16 modeli Şekil 3.4'te sunulmaktadır.



Şekil 3.4. Çalışmada kullanılan VGG16 modeli

VGG19


Oxford Üniversitesi bilim insanları tarafından 2014 yılında önerilen VGG derin öğrenme modelinin 19 katmanlı olan bir derin öğrenme ağıdır. 5 aşamalı evrişim katmanı, 5 havuz katmanı ve 3 tam bağlantılı katman içeren ve görüntünün detay özelliklerini yakalamak için 3x3, havuz katmanı için ise 2x2 boyutunda filtre kullanan bir modeldir. Evrişim derinliği 64'ten 512'ye çıkarılarak özelliklerin daha iyi çıkarılmasını sağlamaktadır. Havuz katmanında maksimum havuzlama, aktivasyon fonksiyonu olarak ise Doğrultulmuş Doğrusal Birim (Rectified Linear Unit-ReLU) kullanılmaktadır. 3 tam bağlantılı katmandaki düğüm sayıları sıralı olarak 4096, 4096 ve 1000'dir. 224x224 boyutunda alınan girdi görüntüsü ağın son katmanında softmax regresyon sınıflandırıcı kullanılarak olasılığa göre sınıflandırılmaktadır [58]. Çalışmada kullanılan modelde ise 2. tam bağlantılı katman çıktıları softmax sınıflandırıcı yerine LSTM modeline girdi olarak iletilmektedir. Mimarinin genel yapısı Şekil 3.5'te sunulmuştur.



Şekil 3.5. Çalışmada kullanılan VGG19 modeli

AlexNet


ImageNet Büyük Ölçekli Görsel Tanıma Yarışması (ImageNet Large Scale Visual Recognition Challenge-ILSVRC) her yıl düzenlenen, büyük ölçekli nesne algılama ve görüntü sınıflandırma algoritmalarının değerlendirildiği bir yarışmadır. 2012 yılında AlexNet modelinin yaratıcısı Krizhevsky bu yarışmayı büyük farkla kazanmıştır. AlexNet modeli 5 evrişim katmanından ve 3 tam bağlantılı katmandan oluşmakta olup giriş görüntüsü olarak 227x227x3 boyutlarında veri kullanmaktadır. Tam bağlantılı katmanlardaki nöron sayısı sırası ile 4096, 4096 ve 1000'dir [59]. Çalışmada kullanılan model Şekil 3.6'da sunulmuş olup modelden de görüleceği gibi 2. Tam bağlantılı katman çıktıları LSTM modeline girdi olarak iletilmiştir.



Şekil 3.6. Çalışmada kullanılan AlexNet modeli

VGGFace (DeepFace)

Oxford Üniversitesi Görsel Geometri Grubu (Visual Geometry Group-VGG) tarafından DeepFace olarak sunulmuş, derin bir evrişimli sinir ağıdır. Araştırma makalesinde DeepFace olarak sunulmuş olmasına rağmen araştırmacılar tarafından VGGFace olarak anılmaktadır. Model oluşturulurken VGG16 temel olarak alınmıştır. Model vahşi veri setindeki yüzler üzerinde 2622 sınıf için sınıflandırma yapılacak şekilde eğitilmiştir. Giriş verisi boyutları VGG16'da da olduğu gibi $224 \times 224 \times 3$ 'tür [60]. Modelde sırasıyla 4096, 4096 ve 2622 nörona sahip 3 tam bağlantılı katman bulunmaktadır. Çalışmada kullanılan modelde son tam bağlantılı katmandan 2622 çıktı softmax yerine LSTM modeline girdi olarak iletilmektedir. Çalışmada kullanılan VGGFace modeli Şekil 3.7'de sunulmuştur.



Şekil 3.7. Çalışmada kullanılan VGGFace modeli

GoogleNet:

2014 yılında düzenlenen ILSVRC14'te Inception kod adı ile önerilen GoogleNet derin evrişimli sinir ağı modeli %5,7 hata oranı ile yarışmada birinci olmuştur [61]. Model sonundaki pahalı tam bağlantılı katmanları her bir özellik haritasının ortalama değerini alan basit bir ortalama havuz katmanı ile değiştiren ilk CNN modelidir. Bu sayede modelde kullanılan parametre sayısı önemli ölçüde azalmakta ve böylece daha hızlı bir eğitim aşaması sağlanmış olmaktadır. Toplamda 22 ağı katmanına sahip olan modelin evrişim katmanında 1×1 , 3×3 ve 5×5 boyutlarında filtreler kullanılarak özellik haritası çıkarılmaktadır. Havuzlama katmanında kullanılan filtre boyutu ise 3×3 'tür [62].

ResNet:


Derin sinir ağlarında ağ katmanı sayısı arttıkça öznitelik bilgisi çıkarma başarısı da artmaktadır. Fakat, ağ derinliği arttıkça gradyan kaybolması/gradyan patlaması ve model bozulmaları yaşanabilmektedir. Bu gibi durumlarda hatalar artmakta ve doygunluktan sonra sınıflandırma başarısı düşmektedir. ResNet modeli bu sorunlara bir çözüm olarak önerilmiştir [63]. Bu sorunlardan kaçınmak için her blok giriş ve çıkışı arasında ağda artık bir bağlantı sunulmaktadır. Bu sayede ağ yapısı kaybolmadan derin bir ağ elde edilebilmektedir [64].

3.4.2. Tekrarlayan Sinir Ağları

RNN, geleneksel sinir ağı mimarisinin gizli katman bileşenlerinin sayısının artırılarak genişletilmesiyle oluşturulan derin öğrenme modelidir. RNN'nin en önemli farkı önceki bilgileri tutabileceği bir bellek içermesidir. Bu sayede işlemler sırasında veri sıralamasını da dikkate almaktadır. Geri yayılım sürecinde gizli katman çıktılarının mevcut gizli katmana geri besleme yapma özelliği sayesinde önceki bilgiler de ağı dahil edilmektedir. Bu durumda Şekil 3.8'de de gösterildiği gibi çıktı sadece mevcut girdi bilgilerine göre değil önceki adımın nöron durumuna da bağlı üretilmektedir. Bu özelliği sayesinde sıralı verilerin analizinde kullanılabilmektedir. Bu da tekrarlayan sinir ağlarını geleneksel sinir ağlarından ayıran en önemli özelliktir. Diğer bir farkı ise geleneksel sinir ağları belirli bir giriş sayısı ile sınırlı iken tekrarlayan sinir ağlarında böyle bir kısıtlamanın olmamasıdır.

RNN'ler giriş bileşenlerinin ve çıktılarının sayılarına göre 4 farklı türde incelenmektedir:

- Birebir RNN, Vanilla RNN olarak da bilinen bir giriş ve bir çıktıya sahip olan RNN türüdür.
- Birden çoğa RNN, bir girdi işlendikten sonra birkaç çıktı üretilmektedir.
- Çoktan bire RNN, tek bir çıktı üretilmesi için birden çok giriş verisi kullanılmaktadır.
- Çoktan çoğa RNN, birkaç girdi verisinden birkaç çıktı üretilmektedir [65].



Şekil 3.8. RNN mimari modeli

Uzun Kısa Süreli Bellek:

RNN'ler güçlü mimari yapılar olmasına rağmen kaybolan ve patlayan gradyan problemleri gibi dezavantajları vardır. Bu nedenle de daha önceki bilgileri hatırlayamadığı için eğitim sırasında sorunlar yaşanabilmektedir. Bu kaybolan ve patlayan gradyan problemlerini çözmek amacıyla LSTM mimarisi geliştirilmiştir [66].

LSTM, 1997 yılında Hochreiter ve Schmidhuber tarafından önerilmiş olup uzun süreli bağılıkların öğrenilmesi için özelleştirilmiş bir tekrarlayan sinir ağı modelidir. İçerdiği hafıza hücresi sayesinde bilgileri uzun süre koruyabilmektedir. Fakat RNN ile karşılaştırıldığında daha karmaşık bir ağ yapısına sahiptir. LSTM modelinin unutma kapısı, giriş kapısı ve çıkış kapısı olmak üzere 3 katmanı vardır ve her bir kapı farklı görevi yerine getirmektedir.

- Unutma kapısı, önceki adımlardan hangi bilgilerin hatırlanması hangilerinin ise unutulması gerektiğine karar veren kapıdır. Önceki hücreden gelen bilgi ve mevcut bilginin sigmoid aktivasyon fonksiyonuna göre sonucuna bakılarak karar vermektedir.
- Giriş kapısı, hangi bilgilerin kabul edileceğine karar verilip belirlenen bilgilerin ağa eklendiği kapıdır.
- Çıkış kapısı ise güncellenmiş bilginin mevcut zaman bilgisinden sonraki zaman bilgisine aktarılmasını sağlayan kapıdır. Sigmoid fonksiyonu kullanarak hangi bölümlerin çıktı alınıp bir sonraki hücreye girdi olarak iletileceğine ya da sonucun tahminine yönelik karar vermektedir [67].

Kapılı Tekrarlayan Birim:

LSTM modelinin basitleştirilmiş bir versiyonu olarak Kapılı Tekrarlayan Birim (Gated Recurrent Unit-GRU) sunulmuştur. Böylece hücre parametreleri sayısı, hesaplama karmaşıklığı ve işlem süresi azalmıştır. LSTM yapısına kıyasla GRU'da sıfırlama kapısı ve güncelleme kapısı olmak üzere sadece 2 kapı bulunmaktadır [68].

- Güncelleme kapısı, LSTM modelinde giriş ve unut kapılarına benzer şekilde çalışmaktadır. Hangi bilgilerin unutulup hangilerinin unutulacağına karar vererek önceki zaman adımlarından ne kadar bilginin gelecek adımlara iletilmesi gerektiğini belirleyen kapıdır.
- Sıfırlama kapısı, ne kadar geçmiş bilgilerin unutulacağına karar veren kapıdır.

Bu iki kapının en önemli özelliği ise, daha sonraki tahminler için önemli bilgileri çıkarıp sonraki hücreye iletmeden önce geçmiş bilgileri uzun vadede tutmak için eğitilebilmeleridir [69].


3.4.3. Aktivasyon Fonksiyonları

Yapay sinir ağlarında üretilen çıktıların bir sonraki katmana iletilmesi sırasında kullanılan fonksiyonlardır. Belirlenen bir eşik değerine göre çıktıların bir sonraki katmana iletilip iletilmemesine karar verilmektedir. Bu karar aşamaları da aktivasyon fonksiyonları tarafından gerçekleştirilmektedir. Yapay sinir ağları çoğunlukla doğrusal değildir ve bu nedenle aktivasyon fonksiyonunun da lineer olmayan bir fonksiyon seçilmesi ağı daha etkili işlenmesinde etkin rol oynamaktadır. Aktivasyon fonksiyonlarında diğer önemli özellik ise fonksiyon türevinin kolay alınabilir olması gerekliliğidir. Bunun nedeni öğrenme sırasında geri yayılım algoritmasının kullanımı için fonksiyonun türevinin alınmasıdır. Böylece işlem hızı artmaktadır [70].

Basamak Aktivasyon Fonksiyonu:

İkili değer alan bir fonksiyon olup ikili sınıflandırma işlemlerinde kullanılmaktadır. Girdinin sıfırdan büyük ya da küçük olma durumuna göre 1 ya da 0 değerini almaktadır.

Fonksiyon türevi 0 olması nedeniyle gizli katmanlarda kullanıma uygun olmayıp genellikle çıkış katmanlarında kullanılmaktadır [71].




Şekil 3.9. Basamak fonksiyonu grafiği

Doğrultulmuş Doğrusal Birim Aktivasyon Fonksiyonu:

Basit ve doğrusal olmaması nedeniyle verimli bir aktivasyon fonksiyonu olarak kabul edilen ReLU yapay sinir ağlarında yaygın olarak kullanılmaktadır. Özellikle görüntü işleme çalışmalarında en popüler aktivasyon fonksiyonu olarak kabul edilmiştir. Girdi negatif olduğunda çıktı sıfır, negatif olmadığında ise çıktı girdiye eşittir. ReLU'nun negatif olmayan girdilerin çıktıya eşit olması özelliği gradyan kaybolması durumunu azaltmak gibi bir avantaj sağlamaktadır. Fakat girdilerin negatif olması durumunda fonksiyon türevinin de sıfır olması geri yayılım esnasında parametrelerin güncellenmemesine neden olmaktadır. Dolayısıyla öğrenme işlemi de gerçekleşmemiş olur. Bu problem ölmekte olan ReLU (Dying ReLU) sorunu olarak adlandırılmakta olup çözüm olarak Sızdıran ReLU (Leaky ReLU) ve Üstel Doğrusal Birimler (Exponential linear units) gibi ReLU varyasyonları önerilmiştir [72].


- Sızdıran ReLU: Negatif girdiler için sıfıra yakın çıktı üreten ReLU varyasyonu fonksiyondur.
- Üstel Doğrusal Birimler: Negatif girdiler için de bir eğime sahip olup negatif girdiler için de çıktıları sorunsuz üretebilen fonksiyondur.



Şekil 3.10. ReLU fonksiyonu grafiği

Sigmoid Aktivasyon Fonksiyonu:


Bazı çalışmalarda Lojistik aktivasyon fonksiyonu olarak da ifade edilmektedir. Olasılıksal bir yaklaşım sergilemekte olup çıktının ait olduğu sınıfa dair olasılıksal sonuç sunmaktadır. Çıktı olarak $[0,1]$ aralığında sayı üretmektedir [73].



Şekil 3.11. Sigmoid fonksiyonu grafiği

Hiperbolik Tanjant (tanh) Aktivasyon Fonksiyonu:


Derin öğrenme çalışmalarında sıklıkla kullanılan tanh aktivasyon fonksiyonu gerçek değerli bir sayıyı $[-1,1]$ aralığında bir çıktı olarak sunmaktadır. Çıktının -1 veya 1'e yakın olması durumunda gradyanın sıfıra yaklaşması nedeniyle kaybolan gradyan sorunu yaşanabilmektedir [74].



Şekil 3.12. Tanh fonksiyonu grafiği

Softmax Aktivasyon Fonksiyonu:

Derin ağlarda sınıflandırma işlemleri gerçekleştirileceği zaman kullanılmaktadır. Softmax sonucunda sınıflara ait olma olasılık değerleri üretilmektedir. Girdinin her bir sınıfa ait olma olasılığı üretilmektedir. Olasılık değerlerine göre en yüksek olasılığa sahip olunan sınıfa göre sınıflandırma yapılmaktadır [75].



Şekil 3.13. Softmax fonksiyonu grafiği

3.4.4. Optimizasyon Yöntemleri

Derin öğrenme çalışmalarında hata oranını minimuma indirmek ve en iyi sonucu elde etmek en önemli faktörlerden biridir. Bu nedenle çalışma sırasında meydana gelebilecek hataları en aza indirmek için gradyan iniş (Gradient Descent) olarak da bilinen optimizasyon yöntemleri kullanılmaktadır [76].

Stokastik Gradyan İnişi Optimizasyon Yöntemi:

SGD, her eğitim örneği için parametreleri yeniden güncelleyen, hızlı bir yöntemdir. Çalışma sırasında her adımda güncelleme yapmaktadır. Bu sık güncellemeler yüksek varyansa sebep olmaktadır ve bunun sonucu olarak da kayıp fonksiyonlarında salınım gerçekleşmektedir. Bu salınımlar sayesinde daha iyi yerel minimumlar bulunmaktadır [77].

Adam Optimizasyon Yöntemi:

Derin öğrenme yaklaşımları için tasarlanmış olup uyarlanabilir bir öğrenme oranı yöntemidir. En önemli özelliklerinden biri çeşitli parametreler için bireysel uyarlanabilir öğrenme oranları bulmasıdır. Adam optimizasyon yöntemi her yinelemede sonuçların tahmini için üstel olarak hareketli ortalama kullanmaktadır [78].

RMSProp Optimizasyon Yöntemi:

Geçmişin atılarak sadece son gradyan bilgisinin tutulduğu, gradyanların üstel ağırlıklı bir ortalama ile toplandığı optimizasyon yöntemidir [79].

3.4.5. Kayıp Fonksiyonları

Kayıp fonksiyonu, tahmin edilen değer ve gerçek değer arasındaki farkın değerlendirilmesi için kullanılan fonksiyonlardır. Derin öğrenme yöntemlerinde kullanılan ağırlık kaybı en aza indirgenmesi amaçlanmaktadır. Eğitim sırasında her aşamada kaybın biraz daha sıfıra yaklaşması beklenmektedir [80].

İkili Çapraz Entropi:

Sınıflandırma hedefinin $\{0,1\}$ aralığında olduğu ikili sınıflandırma işlemleri için tasarlanmıştır. Matematiksel olarak maksimum olasılığın değerlendirilmesi işlemidir ve özellikle iki sınıflı sınıflandırma işlemlerinde ilk olarak tercih edilmesi gereken kayıp

fonksiyonudur. Verinin sınıfının tahmin edilmesi için gerçek ve tahmin olasılıksal dağılımların farkına göre hesaplanmaktadır [81].

Çok Sınıflı Çapraz Entropi:

Çok sınıflı sınıflandırma işlemlerinde kullanılan kayıp fonksiyonudur. Tüm sınıflar için gerçek değerler ve tahmin edilen değerlerin olasılıksal dağılımları arasındaki ortalama farka göre hesaplanmaktadır [81].

Ortalama Kare Hata Kaybı:

Tahmin edilen değer ile gerçek değer arasındaki farkın karesi alınarak hesaplanan kayıp fonksiyonudur. Fark ne kadar küçük olursa modelin tahmin edilen değerinin doğruluğu o kadar iyi olur [82].

Ortalama Kare Logaritmik Hata Kaybı:

Ortalama kare hata kaybı işleminde fark büyük olduğunda kare alma işlemi çok büyük hatalara neden olmaktadır. Bu hata durumunu biraz yumuşatmak amacıyla tahmin edilen değerlerin her birinin doğal logaritması hesaplandıktan sonra ortalama hata karesinin hesaplandığı kayıp fonksiyonudur 0.

3.4.6. Geliştirilen Hibrit Model

Çalışmada öncelikle çeşitli CNN modelleriyle (VGG16, VGG19, AlexNet, VGGFace) veri setinin girdilerinden özellik çıkarımı yapılmaktadır. Sonrasında bu modellerin son tam bağlantılı katman çıktıları softmax katmanına girdi olarak iletilmesi gerekirken LSTM ağına iletilmektedir. Sonrasında veriler LSTM modelinde işlenerek sınıflandırma işlemleri gerçekleştirilmektedir. Kullanılan hibrit model Şekil 3.2’de sunulmuş olup LSTM mimari yapısı ise Şekil 3.14’te sunulmuştur.

Layer (Type)	Output Shape	Parameters
LSTM	(None, 512)	9439232
Dense	(None, 512)	262656
Activation	(None, 512)	0
Dense	(None, 64)	32832
Activation	(None, 64)	0
Dense	(None, 2)	130
Activation	(None, 2)	0

Şekil 3.14. LSTM mimari yapısı

VGG16, VGG19 ve AlexNet mimarilerinin çıktı sayısı 4096 iken VGGFace mimarisi için 2622'dir. LSTM girdi boyutu (frame sayısı, CNN den gelen girdi sayısı) olarak belirlenmiştir. LSTM modeli 1 LSTM ve 3 yoğun katmandan oluşmaktadır. Yoğun katmanlarda sırası ile ReLU, Sigmoid ve Softmax aktivasyon fonksiyonları kullanılmaktadır. Kayıp fonksiyonu olarak ikili çapraz entropi, ortalama kare hatası ve logaritmik ortalama kare hatası kullanılmıştır. Optimizasyon yöntemi olarak ise SGD ve Adam optimizasyon yöntemleri kullanılmıştır. Son olarak eğitim sürecinde k katlı çapraz doğrulama yöntemi kullanılarak sınıflandırma işlemleri gerçekleştirilmiştir.

4. BULGULAR ve TARTIŞMA

Çalışmada ilk olarak sürücü yorgunluk tespit çalışmalarında kullanılabilmesi amacıyla gerçek sürüş anlarından oluşan SUST-DDD veri kümesi oluşturulmuştur. Daha sonra bu veri kümesi kullanılarak 4 farklı hibrit derin öğrenme modeli ile sürücü yorgunluk tespit çalışması yapılmış ve sonuçlar değerlendirilmiştir.

Çalışmalar sırasında videolar ilk aşamada 10, 20 ve 30 çerçeveye ayrılarak işlenmiştir. Çalışmada optimizasyon yöntemi olarak adam ve SGD; kayıp fonksiyonu olarak ise İkili Çapraz Entropi (Binary Cross Entropy-BCE), Ortalama Kare Hata Kaybı (Mean Squared Error-MSE) ve Ortalama Kare Logaritmik Hata Kaybı (Mean Squared Logarithmic Error-MSLE) fonksiyonları kullanılmıştır. Eğitim işlemleri 100, 200, 300 epoch ve 256, 512 batch boyutlarıyla gerçekleştirilmiştir.

Bu bölümde model sonuçları detaylı bir şekilde anlatılmaktadır.

4.1. VGG16 + LSTM Model Çalışmaları


Veri kümesinde yer alan her bir videodan 10 çerçeve elde edilmektedir ve VGG16 derin öğrenme modeline girdi olarak verilmektedir. Eğitimden sonra softmax katmanından önceki tam bağlantılı katman çıktısı olarak 4096 özellik LSTM modeline iletilmektedir. LSTM girdisi çerçeve sayısı x özellik sayısı (10,4096) boyutlarındadır. Bu aşamada LSTM modeli BCE, MSE, MSLE olmak üzere 3 farklı kayıp fonksiyonu; adam ve SGD olmak üzere 2 farklı optimizasyon yöntemi ile farklı değişkenler kullanılarak derlenmiştir. Sonrasında ise 100, 200 ve 300 epoch değerleri ve 256, 512 batch değerleri ile eğitimler gerçekleştirilmiş ve sınıflandırmalar yapılmıştır. Bu işlemler daha sonra her bir videodan 20 ve 30 çerçeve elde edilerek de tekrarlanmıştır.

Çerçeve ve kayıp fonksiyonu değişkenleri sabit alınarak en iyi sonucun elde edildiği değişken tablosu Çizelge 4.1’de paylaşılmıştır. Tüm bu doğrulukların karşılaştırması Şekil 4.1’de sunulmuştur. Çizelge ve şekil incelendiğinde SGD optimizasyon yöntemi ile başarılı sonuçlar elde edilemediği tüm başarılı değerlerin adam optimizasyon yöntemi kullanılarak elde edildiği görülmektedir. Bunlara ek olarak 300 epoch ve 512 batch değerleri ile derlenen çalışmanın çoğunlukla yüksek başarı elde ettiği görülmektedir. VGG16+LSTM modelinden elde edilen en yüksek doğruluk olan %98,12 değerinin elde

edildiği koşullardaki hassasiyet, duyarlılık ve fl skor değerleri çizelge 4.2’de paylaşılmıştır.

Çizelge 4.1. VGG16+LSTM modeli çalışmasından elde edilen en iyi sonuçlar

Çerçeve Sayısı	Kayıp Fonk.	Opt. Yöntemi	Epoch	Batch	Doğruluk
10	BCE	adam	300	256	%95,58
	MSE	adam	200	512	%97,21
	MSLE	adam	300	512	%97,64
20	BCE	adam	100	512	%97,52
	MSE	adam	300	512	%97,09
	MSLE	adam	100	512	%97,33
30	BCE	adam	300	256	%96,13
	MSE	adam	100	512	%96,61
	MSLE	adam	300	512	%98,12



Şekil 4.1. VGG16+LSTM modelinden elde edilen en iyi doğruluk değerlerinin karşılaştırması

Çizelge 4.2. VGG16+LSTM modelinin en iyi sonucuna ait değerler

Doğruluk	Hassasiyet	Duyarlılık	F1 Skor
%98,12	%98,30	%98,16	%98,11

4.2. VGG-19 + LSTM Model Çalışmaları


VGG16+LSTM modelinde gerçekleştirilen işlemler aynı sırada ve aynı değerlerle gerçekleştirilmiştir. VGG19 modelinden elde edilen özellik sayısı da VGG16 modeli ile aynı değerde olup 4096 adettir.

Bu model çalıştırılarak elde edilen en iyi sonuçlar ve bu sonuçların elde edilmesinde kullanılan değişken değerleri Çizelge 4.3'te detaylandırılmıştır. Bu en iyi doğruluk değerlerinin karşılaştırıldığı grafik Şekil 4.2'de paylaşılmıştır.

Çizelge 4.3 incelendiğinde bu model için de en iyi değerlerin adam optimizasyon yöntemi ile elde edildiği görülmektedir. Optimizasyon yöntemi değişkeninin yanı sıra genel olarak 300 epoch ve 512 batch değerleri kullanıldığında yüksek başarı sağlandığı tespit edilmektedir. VGG19+LSTM modelinden elde edilen en yüksek doğruluk olan %98,48 değerinin elde edildiği koşullardaki hassasiyet, duyarlılık ve f1 skor değerleri çizelge 4.4'de paylaşılmıştır.

Çizelge 4.3. VGG19+LSTM modeli çalışmasından elde edilen en iyi sonuçlar

Çerçeve Sayısı	Kayıp Fonk.	Opt. Yöntemi	Epoch	Batch	Doğruluk
10	BCE	adam	300	256	%93,95
	MSE	adam	200	512	%97,94
	MSLE	adam	300	512	%98,48
20	BCE	adam	300	256	%96,67
	MSE	adam	300	512	%97,70
	MSLE	adam	200-300	512	%97,52
30	BCE	adam	300	256	%94,07
	MSE	adam	300	512	%97,52
	MSLE	adam	100-300	512	%96,49



Şekil 4.2. VGG19+LSTM modelinden elde edilen en iyi doğruluk değerlerinin karşılaştırması

Çizelge 4.4. VGG19+LSTM modelinin en iyi sonucuna ait değerler

Doğruluk	Hassasiyet	Duyarlılık	F1 Skor
%98,48	%98,42	%98,76	%98,47

4.3. AlexNet + LSTM Model Çalışmaları


VGG16+LSTM ve VGG19+LSTM modelleri ile aynı çalışmalar gerçekleştirilmiştir. Bu modelde de diğer modellerde olduğu gibi LSTM modeline iletilen özellik sayısı 4096'dır.

AlexNet+LSTM modeli kullanıldığında hesaplanan en yüksek doğruluk değeri ve bu doğruluk değerinin elde edilmesinde kullanılan değişken değerleri Çizelge 4.5'te detaylandırılmıştır. Bu doğruluk değerlerinin karşılaştırılması Şekil 4.3'teki grafikte paylaşılmıştır.

Önceki modellerde olduğu gibi bu modelde de en iyi sonuçların alındığı optimizasyon yönteminin adam olduğu ve diğer değişken değerleri Çizelge 4.5'te görülmektedir. En yüksek doğruluk değeri olan %95,64 sonucunun elde edildiği eğitim değerlerinin ise 300 epoch ve 256 batch değerleri olduğu tespit edilmiştir. Bu değişken değerleri kullanıldığında elde edilen hassasiyet, duyarlılık ve f1 skor değerleri ise Çizelge 4.6'da sunulmuştur.

Çizelge 4.5. AlexNet + LSTM modeli çalışmasından elde edilen en iyi sonuçlar

Çerçeve Sayısı	Kayıp Fonk.	Opt. Yöntemi	Epoch	Batch	Doğruluk
10	BCE	adam	100	256	%85,60
	MSE	adam	200	512	%94,62
	MSLE	adam	300	512	%95,64
20	BCE	adam	100	256	%88,63
	MSE	adam	200	512	%94,67
	MSLE	adam	100	512	%85,43
30	BCE	adam	100	512	%90,45
	MSE	adam	200	512	%83,59
	MSLE	adam	200	512	%90,39



Şekil 4.3. AlexNet+LSTM modelinden elde edilen en iyi doğruluk değerlerinin karşılaştırması

Çizelge 4.6. AlexNet+LSTM modelinin en iyi sonucuna ait değerler

Doğruluk	Hassasiyet	Duyarlılık	F1 Skor
%95,64	%96,25	%95,34	%95,64

4.4. VGGFace + LSTM Model Çalışmaları


VGGFace+LSTM modelinde diğer modellerden farklı olarak VGGFace modelinden çıktı olarak alınıp LSTM modeline iletilen özellik sayısı 2622'dir. Diğer tüm işlem ve değişkenler diğer modellerde olduğu şekilde derlenerek sınıflandırma işlemleri gerçekleştirilmiştir.

VGGFace+LSTM modeli kullanılarak yapılan çalışmalarda elde edilen en yüksek doğruluk ve ilgili çalışmaya ait değişken değerleri Çizelge4.7'de sunulmuştur. Bu çizelgede yer alan en iyi doğruluk değerlerinin karşılaştırması Şekil 4.4'teki grafikte yapılmıştır.

Son model olan VGGFace+LSTM modelinde de önceki tüm modelde olduğu gibi iyi sonuçlar için adam optimizasyon yönteminin kullanıldığı görülmektedir. Bu model ile elde edilen en yüksek doğruluk değeri %96,79 olup 300 epoch ve 256 batch değerleri kullanıldığında elde edilmiştir. Bu doğruluk değerinin elde edildiği çalışmaya ait hassasiyet, duyarlılık ve f1 skor değerleri Çizelge 4.8'de ayrıca paylaşılmıştır.

Çizelge 4.7. VGGFace+LSTM modeli çalışmasından elde edilen en iyi sonuçlar

Çerçeve Sayısı	Kayıp Fonk.	Opt. Yöntemi	Epoch	Batch	Doğruluk
10	BCE	adam	300	256	%96,79
	MSE	adam	100	512	%96,00
	MSLE	adam	200	512	%86,21
20	BCE	adam	100	512	%94,91
	MSE	adam	300	512	%96,43
	MSLE	adam	300	512	%90,86
30	BCE	adam	300	256	%92,19
	MSE	adam	300	512	%93,53
	MSLE	adam	200	256	%90,38



Şekil 4.4. VGGFace+LSTM modelinden elde edilen en iyi doğruluk değerlerinin karşılaştırması

Çizelge 4.8. VGGFace +LSTM modelinin en iyi sonucuna ait değerler


Doğruluk	Hassasiyet	Duyarlılık	F1 Skor
%96,79	%97,12	%96,79	%96,78

4.5. Tüm Modellerin Karşılaştırmalı Genel Sonuçları


Tüm bu sonuçlar genel hatlarıyla incelendiğinde SGD optimizasyon yöntemi ile başarılı sonuçlar elde edilemediği görülmektedir. Tüm modeller için başarılı sonuçların 300 epoch değeri ile elde edildiği ve çoğunlukla MSLE kayıp fonksiyonu kullanıldığı tespit edilmektedir. Bu değişken değerlerinin etkisi göz önünde bulundurularak epoch değeri 300, kayıp fonksiyonu MSLE ve optimizasyon yöntemi ise adam sabit alınarak sonuçlar batch değeri 256 için Çizelge 4.9’da, batch değeri 512 için ise Çizelge 4.10’da sunulmuştur. Çizelge 4.9’daki değerler Şekil 4.5’te, Çizelge 4.10’daki değerler ise Şekil 4.6’da grafiklerle görselleştirilmiştir.

Çizelge 4.9. Batch değeri 256 için model çalışma sonuçları


Çerçeve Sayısı	Model	Doğruluk	Hassasiyet	Duyarlılık	F1 Skor
10	AlexNet+LSTM	%67,52	%67,52	%96,72	%56,24
	VGG16+LSTM	%94,01	%94,63	%93,83	%93,98
	VGG19+LSTM	%95,88	%97,20	%95,05	%95,87
	VGGFace+LSTM	%79,79	%78,85	%78,85	%75,87
20	AlexNet+LSTM	%57,01	%57,47	%94,21	%42,22
	VGG16+LSTM	%93,16	%92,29	%95,30	%93,12
	VGG19+LSTM	%93,29	%95,58	%91,81	%93,24
	VGGFace+LSTM	%86,67	%87,31	%96,92	%83,47
30	AlexNet+LSTM	%52,17	%42,51	%80,00	%34,27
	VGG16+LSTM	%93,28	%92,45	%95,36	%93,23
	VGG19+LSTM	%93,64	%95,27	%92,65	%93,63
	VGGFace+LSTM	%53,20	%53,20	%1	%34,71



(a)




(b)




Şekil 4.5. Batch değeri 256 için a)10, b)20, c)30 çerçeve için model sonuçları

Çizelge 4.10. Batch değeri 512 için model çalışma sonuçları


Çerçeve Sayısı	Model	Doğruluk	Hassasiyet	Duyarlılık	F1 Skor
10	AlexNet+LSTM	%95,64	%96,25	%95,34	%95,64
	VGG16+LSTM	%97,64	%97,70	%97,81	%97,62
	VGG19+LSTM	%98,48	%98,42	%98,76	%98,47
	VGGFace+LSTM	%73,83	%65,72	%73,70	%67,37
20	AlexNet+LSTM	%75,13	%77,90	%91,69	%67,82
	VGG16+LSTM	%96,85	%96,32	%97,93	%96,83
	VGG19+LSTM	%97,52	%97,70	%97,60	%97,50
	VGGFace+LSTM	%90,86	%90,59	%91,70	%90,81
30	AlexNet+LSTM	%84,44	%83,91	%95,50	%80,30
	VGG16+LSTM	%98,12	%98,30	%98,16	%98,11
	VGG19+LSTM	%96,49	%96,39	%97,06	%96,47
	VGGFace+LSTM	%60,39	%60,83	%97,29	%45,51



(a)



(b)



Şekil 4.6. Batch değeri 512 için a)10, b)20, c)30 çerçeve için model sonuçları

Tüm bu değerlendirmelere göre en iyi sonuç %98,48 doğruluk, %98,42 hassasiyet, %98,76 duyarlılık ve %98,47 fl skor değerleri ile VGG19+LSTM modeli kullanılarak elde edilmiştir. Bu değerler 10 çerçeve sayısı, adam optimizasyon yöntemi, MSLE kayıp fonksiyonu, 300 epoch ve 512 batch değerleri kullanıldığında elde edilmiştir.

VGG16+LSTM modeli ise az bir fark ile ikinci en iyi model olarak değerlendirilmiştir. VGG16+LSTM modeli ile elde edilen en iyi doğruluk değeri %98,12, hassasiyet %98,30, duyarlılık %98,16 ve f1 skor %98,11 olarak hesaplanmıştır. Bu model değişkenlerinin VGG19+LSTM modelinin en iyi sonuç elde ettiği değişkenlerden tek farkının çerçeve sayısının 30 olması olarak görülmektedir. Diğer değişkenlerin ise her iki modelin en iyi değerleri için aynı olduğu görülmektedir.

5. SONUÇ VE ÖNERİLER

Yapılan çalışmalar incelendiğinde SGD optimizasyon yöntemi kullanıldığında başarılı sonuçlara ulaşılamadığı bunun yerine adam optimizasyon yöntemi kullanıldığında daha başarılı sonuçlar elde edildiği görülmektedir.

SGD optimizasyon yöntemi kullanıldığında, AlexNet+LSTM modeli için elde edilen en yüksek doğruluk değeri %90,69 olup bu değer 20 çerçeve sayısı, MSE kayıp fonksiyonu, 300 epoch değeri ve 512 batch değeri kullanıldığı durumda elde edilmiştir. VGG16+LSTM modeli için en yüksek doğruluk değeri 10 çerçeve sayısı, MSE kayıp fonksiyonu, 300 epoch ve 512 batch değeri kullanıldığında %85,67 olarak hesaplanmıştır. VGG19+LSTM modeli ile elde edilen en başarılı doğruluk da %95,21 olarak hesaplanmıştır. Bu değer için 20 çerçeve sayısı, MSLE kayıp fonksiyonu, 100 epoch ve 512 batch değeri kullanılmıştır. VGGFace+LSTM modeli kullanıldığında ise en yüksek doğruluk değeri %53,44 olup 3 farklı senaryoda bu değer elde edilmiştir. Bu çalışmaların üçünde de çerçeve sayısının 30, epoch değerinin 200 olduğu; çalışmaların birinde MSE kayıp fonksiyonu, 512 batch kullanılırken diğer ikisinde MSLE kayıp fonksiyonu ile 256 ve 512 batch kullanıldığı görülmüştür. SGD optimizasyon yöntemi kullanılan çalışmalar genel olarak değerlendirildiğinde en yüksek başarının %95,21 doğruluk değeri ile VGG19+LSTM modeliyle elde edildiği görülmektedir. Ek olarak en yüksek doğrulukların elde edildiği değişken durumları göz önünde bulundurulduğunda genel olarak MSE kayıp fonksiyonu kullanıldığı ve batch değerinin 512 olduğu görülmektedir.

Adam optimizasyon yöntemi kullanıldığında ise, AlexNet+LSTM modeliyle en yüksek doğruluk %95,64 olarak hesaplanmış olup bu süreçte çerçeve sayısının 10, kayıp fonksiyonunun MSLE, epoch değerinin 300 ve batch değerinin ise 512 olarak kullanıldığı görülmektedir. VGG16+LSTM modeli kullanıldığında ise çerçeve sayısı 30 olup diğer değişken değerlerinin AlexNet+LSTM modelinin en başarılı durumunda olduğu gibi MSLE kayıp fonksiyonu, 300 epoch ve 512 batch olduğu görülmektedir. VGG19+LSTM modelinin en iyi sonuç verdiği durumda kullanılan değişkenler de AlexNet+LSTM modelinin en iyi sonuç verdiği durum ile birebir aynı olup VGG19+LSTM modeli ile elde edilen doğruluk değeri %98,48 olarak hesaplanmıştır. VGGFace+LSTM modeli ile ise en iyi sonuç %96,9 doğruluk değeri ile elde edilmiş olup 10 çerçeve sayısı, BCE kayıp fonksiyonu, 300 epoch ve 256 batch kullanıldığı görülmektedir. Modellerden elde edilen bu sonuçlar genel olarak değerlendirildiğinde adam optimizasyon yöntemi kullanılması

durumunda en başarılı sonucun VGG19+LSTM modeliyle elde edilmiş olup doğruluk değerinin %98,48 olarak hesaplandığı görülmektedir.

Genel kapsamıyla değerlendirildiğinde adam optimizasyon yöntemi ile SGD optimizasyon yöntemine, 300 epoch değeri ile 100 ve 200'e, 512 batch değeri ile ise 256'ya kıyasla daha iyi sonuçlar elde edildiği belirlenmiştir. Modeller kapsamında bir değerlendirme yapıldığında ise AlexNet+LSTM modeli ve VGGFace+LSTM modelleri ile yapılan çalışmaların diğer modellere kıyasla daha düşük sonuçlar sağladığı görülmektedir. En başarılı sonuçlar VGG19+LSTM modeli ile elde edilirken VGG16+LSTM modeli ile de oldukça başarılı sonuçlar elde edilmiştir.



KAYNAKLAR

1. Sungur, İ., Akdur, R., & Piyal, B. (2014). *Analysis of Traffic Accidents in Turkey*. <https://doi.org/10.17098/amj.65427>
2. TÜİK Kurumsal. (n.d.). Retrieved June 23, 2022, from <https://data.tuik.gov.tr/Bulten/Index?p=Karayolu-Trafik-Kaza-Istatistikleri-2021-45658>
3. *Drowsy Driving 2021 Facts & Statistics | Bankrate*. (n.d.). Retrieved June 23, 2022, from <https://www.bankrate.com/insurance/car/drowsy-driving-statistics/#warning>
4. *2019 Traffic Safety Culture Index - AAA Foundation for Traffic Safety*. (n.d.). Retrieved June 23, 2022, from <https://aaafoundation.org/2019-traffic-safety-culture-index/>
5. *2020 Traffic Safety Culture Index - AAA Foundation for Traffic Safety*. (n.d.). Retrieved June 23, 2022, from <https://aaafoundation.org/2020-traffic-safety-culture-index/>
6. *Karayolları Trafik Yönetmeliği*. (n.d.). Retrieved June 23, 2022, from <https://www.mevzuat.gov.tr/mevzuat?MevzuatNo=8182&MevzuatTur=7&MevzuatTertip=5>
7. Prof.Dr. Oğuz O. Erdinç / *Uyku ve Sürücülük*. (n.d.). Retrieved June 23, 2022, from <https://www.oguzerdinc.com/tr/article/desc/11004/uyku-ve-suruculuk.html>
8. Özen, M., & Zorlu, F. (2018). An analysis of crash rates and the crash pattern on state highways in Turkey. *Teknik Dergi/Technical Journal of Turkish Chamber of Civil Engineers*, 29(5). <https://doi.org/10.18400/tekderg.308318>
9. Hasanhanoglu, C. (2022). Trafik Güvenliğinde Sürücü Profilinin Önemi Ve Türkiye'deki Sürücü Profilinin Belirlenmesinde Swot Analizi. In *Journal Of International Social Sciences Academic Researches*.
10. Hooda, R., Joshi, V., & Shah, M. (2022). A comprehensive review of approaches to detect fatigue using machine learning techniques. In *Chronic Diseases and Translational Medicine* (Vol. 8, Issue 1). <https://doi.org/10.1016/j.cdtm.2021.07.002>
11. Scaccabarozzi, D., Mazzola, L., Bocciolone, M. F., Resta, F., & Saggin, B. (2017). Monitoring of train driver's alertness: A feasibility study. *I2MTC 2017 - 2017 IEEE International Instrumentation and Measurement Technology Conference, Proceedings*. <https://doi.org/10.1109/I2MTC.2017.7969912>
12. Jeong, J. H., Yu, B. W., Lee, D. H., & Lee, S. W. (2019). Classification of drowsiness levels based on a deep spatio-temporal convolutional bidirectional lstm network using electroencephalography signals. *Brain Sciences*, 9(12). <https://doi.org/10.3390/brainsci9120348>
13. Guragain, B., Rad, A. B., Wang, C., Verma, A. K., Archer, L., Wilson, N., & Tavakolian, K. (2019). EEG-based Classification of Microsleep by Means of Feature Selection: An Application in Aviation. *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*. <https://doi.org/10.1109/EMBC.2019.8856429>
14. Wei, C. S., Wang, Y. te, Lin, C. T., & Jung, T. P. (2018). Toward Drowsiness Detection Using Non-hair-Bearing EEG-Based Brain-Computer Interfaces. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 26(2). <https://doi.org/10.1109/TNSRE.2018.2790359>

15. Tateno, S., Guan, X., Cao, R., & Qu, Z. (2018). Development of Drowsiness Detection System Based on Respiration Changes Using Heart Rate Monitoring. *2018 57th Annual Conference of the Society of Instrument and Control Engineers of Japan, SICE 2018*. <https://doi.org/10.23919/SICE.2018.8492599>
16. Zhu, M., Chen, J., Li, H., Liang, F., Han, L., & Zhang, Z. (2021). Vehicle driver drowsiness detection method using wearable EEG based on convolution neural network. *Neural Computing and Applications*, 33(20). <https://doi.org/10.1007/s00521-021-06038-y>
17. Gangadharan K, S., & Vinod, A. P. (2022). Drowsiness detection using portable wireless EEG. *Computer Methods and Programs in Biomedicine*, 214. <https://doi.org/10.1016/j.cmpb.2021.106535>
18. Işık, Ş., & Anagün, Y. (2021). A Deep Learning Based Sleepness And Wakefulness Detection For Drivers. *Eskişehir Osmangazi Üniversitesi Mühendislik ve Mimarlık Fakültesi Dergisi*, 29(3). <https://doi.org/10.31796/ogummf.891255>
19. Liu, C. C., Hosking, S. G., & Lenné, M. G. (2009). Predicting driver drowsiness using vehicle measures: Recent insights and future challenges. *Journal of Safety Research*, 40(4). <https://doi.org/10.1016/j.jsr.2009.04.005>
20. Vasudevan, K., Das, A. P., Sandhya, B., & Subith, P. (2017). Driver drowsiness monitoring by learning vehicle telemetry data. *Proceedings - 2017 10th International Conference on Human System Interactions, HSI 2017*. <https://doi.org/10.1109/HSI.2017.8005044>
21. Zhenhai, G., Dinhdat, L., Hongyu, H., Ziwen, Y., & Xinyu, W. (2017). Driver drowsiness detection based on time series analysis of steering wheel angular velocity. *Proceedings - 9th International Conference on Measuring Technology and Mechatronics Automation, ICMTMA 2017*. <https://doi.org/10.1109/ICMTMA.2017.0031>
22. Dehzangi, O., & Masilamani, S. (2018). Unobtrusive Driver Drowsiness Prediction Using Driving Behavior from Vehicular Sensors. *Proceedings - International Conference on Pattern Recognition, 2018-August*. <https://doi.org/10.1109/ICPR.2018.8545427>
23. Maior, C. B. S., Moura, M. J. das C., Santana, J. M. M., & Lins, I. D. (2020). Real-time classification for autonomous drowsiness detection using eye aspect ratio. *Expert Systems with Applications*, 158. <https://doi.org/10.1016/j.eswa.2020.113505>
24. Liu, G., Yan, D., & Chen, Z. (2021). Research on Early Warning of Driver Fatigue Status Based on Image Processing. *Proceedings of the 33rd Chinese Control and Decision Conference, CCDC 2021*. <https://doi.org/10.1109/CCDC52312.2021.9601394>
25. Omidyeganeh, M., Shirmohammadi, S., Abtahi, S., Khurshid, A., Farhan, M., Scharcanski, J., Hariri, B., Laroche, D., & Martel, L. (2016). Yawning Detection Using Embedded Smart Cameras. *IEEE Transactions on Instrumentation and Measurement*, 65(3). <https://doi.org/10.1109/TIM.2015.2507378>
26. Tipprasert, W., Charoenpong, T., Chianrabutra, C., & Sukjamsri, C. (2019). A Method of Driver's Eyes Closure and Yawning Detection for Drowsiness Analysis by Infrared Camera. *2019 1st International Symposium on Instrumentation, Control, Artificial*

- Intelligence, and Robotics, ICA-SYMP 2019.* <https://doi.org/10.1109/ICA-SYMP.2019.8646001>
27. Suganthi, M., & Sathiaselvan, J. G. R. (2020). An Exploratory of Hybrid Techniques on Deep Learning for Image Classification. *4th International Conference on Computer, Communication and Signal Processing, ICCCSPP 2020.* <https://doi.org/10.1109/ICCCSP49186.2020.9315270>
 28. Yu, C., Qin, X., Chen, Y., Wang, J., & Fan, C. (2019). Drowsydet: A mobile application for real-time driver drowsiness detection. *Proceedings - 2019 IEEE SmartWorld, Ubiquitous Intelligence and Computing, Advanced and Trusted Computing, Scalable Computing and Communications, Internet of People and Smart City Innovation, SmartWorld/UIC/ATC/SCALCOM/IOP/SCI 2019.* <https://doi.org/10.1109/SmartWorld-UIC-ATC-SCALCOM-IOP-SCI.2019.00116>
 29. Jabbar, R., Al-Khalifa, K., Kharbeche, M., Alhajyaseen, W., Jafari, M., & Jiang, S. (2018). Real-time Driver Drowsiness Detection for Android Application Using Deep Neural Networks Techniques. *Procedia Computer Science, 130.* <https://doi.org/10.1016/j.procs.2018.04.060>
 30. Jabbar, R., Shinoy, M., Kharbeche, M., Al-Khalifa, K., Krichen, M., & Barkaoui, K. (2020). Driver Drowsiness Detection Model Using Convolutional Neural Networks Techniques for Android Application. *2020 IEEE International Conference on Informatics, IoT, and Enabling Technologies, ICIoT 2020.* <https://doi.org/10.1109/ICIoT48696.2020.9089484>
 31. Flores-Monroy, J., Nakano-Miyatake, M., Sanchez-Perez, G., & Perez-Meana, H. (2021). Visual-based Real Time Driver Drowsiness Detection System Using CNN. *CCE 2021 - 2021 18th International Conference on Electrical Engineering, Computing Science and Automatic Control.* <https://doi.org/10.1109/CCE53527.2021.9633082>
 32. Yarlagaadda, V., Koolagudi, S. G., Kumar M V, M., & Donepudi, S. (2020). Driver Drowsiness Detection Using Facial Parameters and RNNs with LSTM. *2020 IEEE 17th India Council International Conference, INDICON 2020.* <https://doi.org/10.1109/INDICON49873.2020.9342348>
 33. *Drowsiness: Causes, Treatments, and Prevention | American Sleep Association.* (n.d.). Retrieved June 23, 2022, from <https://www.sleepassociation.org/sleep-disorders/more-sleep-disorders/drowsiness-causes-treatments-prevention/>
 34. *Feeling drowsy? Learn the dangers of microsleep.* (n.d.). Retrieved June 23, 2022, from <https://www.alaskasleep.com/blog/feeling-drowsy-learn-the-dangers-of-microsleep>
 35. *Mikro Uyku Nedir? - Evrim Ağacı.* (n.d.). Retrieved June 23, 2022, from <https://evrimagaci.org/mikro-uyku-nedir-7593?t=1649156959169>
 36. *Drowsiness: Causes, Treatments, and Prevention.* (n.d.). Retrieved June 23, 2022, from <https://www.healthline.com/health/drowsiness#treatment>
 37. *Microsleep - Wikipedia.* (n.d.). Retrieved June 23, 2022, from <https://en.wikipedia.org/wiki/Microsleep>
 38. Guarda, L., Tapia, J., Droguett, E. L., & Ramos, M. (2022). A Novel Capsule Neural Network Based Model for Drowsiness Detection Using Electroencephalography Signals. <http://arxiv.org/abs/2204.01666>

39. Meiring, G. A. M., & Myburgh, H. C. (2015). A review of intelligent driving style analysis systems and related artificial intelligence algorithms. *Sensors (Switzerland)*, 15(12). <https://doi.org/10.3390/s151229822>
40. Cetinkaya, M., & Acarman, T. (2021). Driver activity recognition using deep learning and human pose estimation. *2021 International Conference on INnovations in Intelligent SysTems and Applications, INISTA 2021 - Proceedings*. <https://doi.org/10.1109/INISTA52262.2021.9548625>
41. Mahmoud, M. S., Jarndal, A., Alzghoul, A., Almahasneh, H., Alsayouf, I., & Hamid, A. K. (2021). Driver Drowsiness Detection System using Deep Learning based on Visual Facial Features. *Proceedings - International Conference on Developments in ESystems Engineering, DeSE, 2021-December*. <https://doi.org/10.1109/DESE54285.2021.9719409>
42. Kim, K. J., Lim, K. T., Baek, J. W., & Shin, M. (2021). Low-Cost Real-Time Driver Drowsiness Detection based on Convergence of IR Images and EEG Signals. *3rd International Conference on Artificial Intelligence in Information and Communication, ICAIIC 2021*. <https://doi.org/10.1109/ICAIIIC51459.2021.9415193>
43. Revelo, A., Alvarez, R., & Grijalva, F. (2019). Human Drowsiness Detection In Real Time, Using Computer Vision. *2019 IEEE 4th Ecuador Technical Chapters Meeting, ETCM 2019*. <https://doi.org/10.1109/ETCM48019.2019.9014884>
44. Abas, A., Mellor, J., & Chen, X. (2014). Non-intrusive drowsiness detection by employing Support Vector Machine. *ICAC 2014 - Proceedings of the 20th International Conference on Automation and Computing: Future Automation, Computing and Manufacturing*. <https://doi.org/10.1109/IConAC.2014.6935484>
45. Rossi, A., da Pozzo, E., Menicagli, D., Tremolanti, C., Priami, C., Sîrbu, A., Clifton, D. A., Martini, C., & Morelli, D. (2020). A public dataset of 24-H multi-levels psycho-physiological responses in young healthy adults. *Data*, 5(4). <https://doi.org/10.3390/data5040091>
46. Moody, G. B., & Mark, R. G. (2001). The impact of the MIT-BIH arrhythmia database. In *IEEE Engineering in Medicine and Biology Magazine* (Vol. 20, Issue 3). <https://doi.org/10.1109/51.932724>
47. Tataraidze, A., Korostovtseva, L., Anishchenko, L., Bochkarev, M., Sviryaev, Y., & Ivashov, S. (2016). Bioradiolocation-based sleep stage classification. *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS, 2016-October*. <https://doi.org/10.1109/EMBC.2016.7591321>
48. Massoz, Q., Langohr, T., Francois, C., & Verly, J. G. (2016). The ULg multimodality drowsiness database (called DROZY) and examples of use. *2016 IEEE Winter Conference on Applications of Computer Vision, WACV 2016*. <https://doi.org/10.1109/WACV.2016.7477715>
49. Weng, C. H., Lai, Y. H., & Lai, S. H. (2017). Driver drowsiness detection via a hierarchical temporal deep belief network. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 10118 LNCS. https://doi.org/10.1007/978-3-319-54526-4_9
50. Ghoddoosian, R., Galib, M., & Athitsos, V. (2019). A realistic dataset and baseline temporal model for early drowsiness detection. *IEEE Computer Society Conference*

- on Computer Vision and Pattern Recognition Workshops, 2019-June. <https://doi.org/10.1109/CVPRW.2019.00027>
51. Abtahi, S., Omidyeganeh, M., Shirmohammadi, S., & Hariri, B. (2014). YawDD: A yawning detection dataset. *Proceedings of the 5th ACM Multimedia Systems Conference, MMSys 2014*. <https://doi.org/10.1145/2557642.2563678>
 52. Chiou, C. Y., Wang, W. C., Lu, S. C., Huang, C. R., Chung, P. C., & Lai, Y. Y. (2020). Driver Monitoring Using Sparse Representation with Part-Based Temporal Face Descriptors. *IEEE Transactions on Intelligent Transportation Systems*, 21(1). <https://doi.org/10.1109/TITS.2019.2892155>
 53. Li, X., Pfister, T., Huang, X., Zhao, G., & Pietikainen, M. (2013). A Spontaneous Micro-expression Database: Inducement, collection and baseline. *2013 10th IEEE International Conference and Workshops on Automatic Face and Gesture Recognition, FG 2013*. <https://doi.org/10.1109/FG.2013.6553717>
 54. Davison, A. K., Lansley, C., Costen, N., Tan, K., & Yap, M. H. (2018). SAMM: A Spontaneous Micro-Facial Movement Dataset. *IEEE Transactions on Affective Computing*, 9(1). <https://doi.org/10.1109/TAFFC.2016.2573832>
 55. Choi, D. J., Han, J. H., Park, S. U., & Hong, S. K. (2020). Comparative Study of CNN and RNN for Motor fault Diagnosis Using Deep Learning. *2020 IEEE 7th International Conference on Industrial Engineering and Applications, ICIEA 2020*. <https://doi.org/10.1109/ICIEA49774.2020.9102072>
 56. Bouhsissin, S., Sael, N., & Benabbou, F. (2021). Enhanced VGG19 Model for Accident Detection and Classification from Video. *Proceedings - 2021 International Conference on Digital Age and Technological Advances for Sustainable Development, ICDATA 2021*. <https://doi.org/10.1109/ICDATA52997.2021.00017>
 57. MUTLU, M., ÖZDEM, K., & AKCAYOL, M. A. (2021). Derin Öğrenme ile Kuş Türü Sınıflandırma: Karşılaştırmalı Bir Çalışma. *Journal of Polytechnic*. <https://doi.org/10.2339/politeknik.904933>
 58. Xia, Y., Cai, M., Ni, C., Wang, C., Shiping, E., & Li, H. (2019). A Switch State Recognition Method based on Improved VGG19 network. *Proceedings of 2019 IEEE 4th Advanced Information Technology, Electronic and Automation Control Conference, IAEAC 2019*. <https://doi.org/10.1109/IAEAC47372.2019.8998029>
 59. Mashrur, F. R., Dutta Roy, A., & Saha, D. K. (2019). Automatic Identification of Arrhythmia from ECG Using AlexNet Convolutional Neural Network. *2019 4th International Conference on Electrical Information and Communication Technology, EICT 2019*. <https://doi.org/10.1109/EICT48899.2019.9068806>
 60. Hasan, M. M., Hossain, M. A., Srizon, A. Y., Sayeed, A., Ahmed, M., & Haquek, M. R. (2021). Improving Performance of a Pre-trained ResNet-50 Based VGGFace Recognition System by Utilizing Retraining as a Heuristic Step. *24th International Conference on Computer and Information Technology, ICCIT 2021*. <https://doi.org/10.1109/ICCIT54785.2021.9689918>
 61. İnik, Ö., & Ülker, E. (2017). Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri. *Gaziosmanpaşa Journal of Scientific Research*, 6(3).
 62. Ibrahim, Y., Wang, H., & Adam, K. (2020). Analyzing the Reliability of Convolutional Neural Networks on GPUs: GoogLeNet as a Case Study. *2020 International*

- Conference on Computing and Information Technology, ICCIT 2020.* <https://doi.org/10.1109/ICCIT-144147971.2020.9213804>
63. Tan, G., & Yang, Z. (2021). Autonomous Bridge detection based on ResNet for multiple damage types. *2021 IEEE 11th Annual International Conference on CYBER Technology in Automation, Control, and Intelligent Systems, CYBER 2021.* <https://doi.org/10.1109/CYBER53097.2021.9588187>
 64. Zhang, Z. (2021). ResNet-Based Model for Autonomous Vehicles Trajectory Prediction. *2021 IEEE International Conference on Consumer Electronics and Computer Engineering, ICCECE 2021.* <https://doi.org/10.1109/ICCECE51280.2021.9342418>
 65. Majid, R., & Santoso, H. A. (2021). Conversations Sentiment and Intent Categorization Using Context RNN for Emotion Recognition. *2021 7th International Conference on Advanced Computing and Communication Systems, ICACCS 2021.* <https://doi.org/10.1109/ICACCS51430.2021.9441740>
 66. Shen, Z., Fan, X., Zhang, L., & Yu, H. (2022). Wind speed prediction of unmanned sailboat based on CNN and LSTM hybrid neural network. *Ocean Engineering, 254.* <https://doi.org/10.1016/j.oceaneng.2022.111352>
 67. Abebe, M., Noh, Y., Kang, Y.-J., Seo, C., Kim, D., & Seo, J. (2022). Ship trajectory planning for collision avoidance using hybrid ARIMA-LSTM models. *Ocean Engineering, 256,* 111527. <https://doi.org/10.1016/j.oceaneng.2022.111527>
 68. Ayzel, G., & Heistermann, M. (2021). The effect of calibration data length on the performance of a conceptual hydrological model versus LSTM and GRU: A case study for six basins from the CAMELS dataset. *Computers and Geosciences, 149.* <https://doi.org/10.1016/j.cageo.2021.104708>
 69. Liu, X., Lin, Z., & Feng, Z. (2021). Short-term offshore wind speed forecast by seasonal ARIMA - A comparison against GRU and LSTM. *Energy, 227.* <https://doi.org/10.1016/j.energy.2021.120492>
 70. SER, G., & BATI, C. T. (2019). Derin Sinir Ağları ile En İyi Modelin Belirlenmesi: Mantar Verileri Üzerine Keras Uygulaması. *Yüzüncü Yıl Üniversitesi Tarım Bilimleri Dergisi.* <https://doi.org/10.29133/yyutbd.505086>
 71. ERTAYLAN, A., AKTAŞ, Ö., & DOĞAN, Y. (2021). Yapay Sinir Ağları ile Piyasa Takas Fiyatı Tahminlemesi. *Deu Muhendislik Fakultesi Fen ve Muhendislik, 23(67).* <https://doi.org/10.21205/deufmd.2021236708>
 72. Hu, Z., Li, Y., & Yang, Z. (2019). Improving Convolutional Neural Network Using Pseudo Derivative ReLU. *2018 5th International Conference on Systems and Informatics, ICSAI 2018.* <https://doi.org/10.1109/ICSAI.2018.8599372>
 73. KAYTAN, M., AYDİLEK, İ. B., YEROĞLU, C., & KARCI, A. (2022). Sigmoid-Gumbel: Yeni Bir Hibrit Aktivasyon Fonksiyonu. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi.* <https://doi.org/10.17798/bitlisfen.990508>
 74. Li, X., Hu, Z., & Huang, X. (2020). Combine Relu with Tanh. *Proceedings of 2020 IEEE 4th Information Technology, Networking, Electronic and Automation Control Conference, ITNEC 2020.* <https://doi.org/10.1109/ITNEC48623.2020.9084659>
 75. Kagalkar, A., & Raghuram, S. (2020). CORDIC Based Implementation of the Softmax Activation Function. *2020 24th International Symposium on VLSI Design and Test, VDAT 2020.* <https://doi.org/10.1109/VDAT50263.2020.9190498>

76. Seyyarer, E., Ayata, F., Uçkan, T., & Karci, A. (2020). Derin Öğrenmede Kullanılan Optimizasyon Algoritmalarının Uygulanması Ve Kıyaslanması. *Anatolian Journal of Computer Sciences*, 5(2).
77. SEVLİ, O., & KEMALOĞLU, N. (2020). Turkish Sign Language digits classification with CNN using different optimizers. *International Advanced Researches and Engineering Journal*, 4(3). <https://doi.org/10.35860/iarej.700564>
78. Sen, S. Y., & Ozkurt, N. (2020). Convolutional Neural Network Hyperparameter Tuning with Adam Optimizer for ECG Classification. *Proceedings - 2020 Innovations in Intelligent Systems and Applications Conference, ASYU 2020*. <https://doi.org/10.1109/ASYU50717.2020.9259896>
79. Zaheer, R., & Shaziya, H. (2019). A Study of the Optimization Algorithms in Deep Learning. *Proceedings of the 3rd International Conference on Inventive Systems and Control, ICISC 2019*. <https://doi.org/10.1109/ICISC44355.2019.9036442>
80. Luo, X., Li, J., Chen, M., Yang, X., & Li, X. (2021). Ophthalmic Disease Detection via Deep Learning with a Novel Mixture Loss Function. *IEEE Journal of Biomedical and Health Informatics*, 25(9). <https://doi.org/10.1109/JBHI.2021.3083605>
81. *How to Choose Loss Functions When Training Deep Learning Neural Networks*. (n.d.). Retrieved June 24, 2022, from <https://machinelearningmastery.com/how-to-choose-loss-functions-when-training-deep-learning-neural-networks/>
82. Li, H., Yu, H., Rao, T., Shang, J., & Shen, F. (2021). Effects of Different Loss Functions on the Classification Performance of Hybrid Networks. *Proceedings - 2021 3rd International Conference on Machine Learning, Big Data and Business Intelligence, MLBDBI 2021*. <https://doi.org/10.1109/MLBDBI54094.2021.00101>

EKLER

Veri sahibi açık rıza beyan formları teze ek olarak dosya halinde verilmiştir.

|



ÖZGEÇMİŞ

Kişisel Bilgiler

Soyadı, adı :
 Uyruğu : T.C.
 Doğum tarihi ve yeri :
 Medeni hali : Evli
 Telefon :
 Faks : -
 e-mail :



Eğitim

Derece	Eğitim Birimi	Mezuniyet Tarihi
Yüksek lisans	SBTÜ/ Savunma Teknolojileri	2022
Lisans	Ege Üniversitesi / Bilgisayar Mühendisliği	2016
Lise	Nevzat Karabağ Anadolu Öğretmen Lisesi	2008

İş Deneyimi

Yıl	Yer	Görev
2020-Halen	Sivas Bilim ve Teknoloji Üniversitesi	Araştırma Görevlisi
2017-2020	Etiya Bilgi Teknolojileri	Çözüm Destek Uzmanı

Yabancı Dil

İngilizce

Yayınlar

- Katırcı, R., Yılmaz, E. K., Kaynar, O., & Zontul, M. (2021). Automated evaluation of Cr-III coated parts using Mask RCNN and ML methods. *Surface and Coatings Technology*, 422. <https://doi.org/10.1016/j.surfcoat.2021.127571>

- Yilmaz, E.K. and Akcayol, M.A., "SUST-DDD: A Real-Drive Dataset for Driver Drowsiness Detection.", The 31st Conference of Open Innovations Association FRUCT.,Helsinki, Finland, 27-29 April 2022

Hobiler

Kayak, Gezi, Kitap Okuma |





**SİVAS
BİLİM VE TEKNOLOJİ
ÜNİVERSİTESİ**

KÖKLERDEN GÖKLERE...