

Article Arrival Date

17.02.2021

Article Type

Research Article

Article Published Date

20.03.2022

Doi Number: <http://dx.doi.org/10.38063/ejons.606>

DERİN ÖĞRENME YÖNTEMLERİYLE SÜRÜCÜ YORGUNLUK TESPİTİ: BİR UYGULAMA

N. Fırat ÖZKAN**Berna HAKTANIRLAR ULUTAŞ****Büşra Nur YETKİN**

Eskişehir Osmangazi Üniversitesi, Mühendislik Mimarlık Fakültesi, Endüstri Mühendisliği Bölümü, 26040 Eskişehir

ORCID: 0000-0003-4464-7052, 0000-0002-0026-4925, 0000-0002-4963-5483

ÖZET

Trafik kazaları, uzun yıllardır Dünya'nın her bölgesinde başlıca ölüm ve yaralanma sebepleri arasında yer almakta ve çok çeşitli nedenlerden kaynaklanabilmektedir. Sürücü hatalarının temelinde genellikle yorgunluk ön plana çıkmaktadır. Bu yüzden, sürücünün yorgunluk ve uyuşukluk durumunun belirlenebilmesi için, temel olarak yüz hareketleri ve göz hareketlerine (göz kırpma süresi ve frekansı) odaklanan görüntü işleme tabanlı yaklaşımlar geliştirilmiştir. Fakat göz kırpma, yorgunluk dışında farklı faktörden de etkilenebileceğinden, tek başına bir gösterge olarak kullanımı önerilmez ve teknoloji destekli cihazların kullanımı, görüntü işleme ve yapay zeka uygulamaları ile desteklenmesi gerekir. Bu çalışmada, öncelikle sürücü yorgunluğunun tespit edilmesine yönelik kapsamlı bir literatür araştırması sunulmuş, daha sonra görüntü işlemeye dayalı bir yorgunluk tespit modeli uygulanmıştır. Göz kapağı durumu (açık/kapalı) verilerinden hareketle sürücü yorgunluk tespiti yapılmıştır. Bu çalışmada 4 gönüllü denekten, araç kamerası yardımı ile 1077 görüntü alınarak bir veri tabanı oluşturulmuştur. Derin öğrenme yöntemlerine dayanan model, OpenCv Kütüphanesi yardımıyla görselleştirilmiştir. Yüz algılamada dış etkenler altında YOLOv3 modelinin Viola Jones Algoritmasına göre daha başarılı olduğu belirlenmiştir.

212

Anahtar Kelimeler: Yorgunluk tespiti, Sürücü uyuşukluk durumu, derin öğrenme, YOLOv3, Open Source Computer Vision (OpenCV)

DRIVER FAILURE DETECTION WITH DEEP LEARNING METHODS: AN APPLICATION

ABSTRACT

Traffic accidents have been among the main causes of death and injury in every region of the world for many years and can be based on a wide variety of causes. Fatigue is usually known as the main cause among driver errors. Therefore, image processing-based approaches have been developed to detect driver fatigue and drowsiness that basically focus on face and eye movements (blink duration and frequency). However, since blinking may be resulted from many other factors besides fatigue, it is not suggested to be considered as a single indicator and should be supported by using technology supported devices, image processing, and artificial intelligence applications. This study, first provides a comprehensive literature review on detecting driver fatigue then a fatigue detection model based on image processing is proposed. By use of a model based on deep learning method, is visualized with the help of OpenCv Library. YOLOv3 is identified as more successful than Viola Jones Algorithm for face detection.

Keywords: Fatigue detection, Driver drowsiness status, deep learning, YOLOv3, OpenCv

1.GİRİŞ

Trafik kazalarının sürücü davranışından veya insan faktörlerinden mekanik arızaya, çevre koşullarına ve yol tasarımına kadar çok sayıda faktör ve nedeni vardır. Bu faktörler arasında sürücü hataları ve insan faktörleri, tüm kazaların %93'ü olmak üzere önemli bir bölümünü oluşturmaktadır (Lum ve Reagan, 1995).

Türkiye İstatistik Kurumu (TUIK) 2020 yılı verilere göre trafik kazasına neden olan toplam 177867 kusur incelendiğinde, kusurların %88,3'ünün sürücü kaynaklı olduğu belirtilmiştir. Bu oranın %26'sı ise sürücünün yorgunluk ve uykulu durumundan dolayı meydana geldiği bildirilmiştir (URL 1).

Günümüzde artan trafik yoğunluğu nedeniyle sürücüler yolda çok fazla zaman harcamaktadır. Bu sıra zarfında dikkatsizlik ve yorgunluk sebebiyle sürücü kaynaklı kaza oranı git gide artış göstermektedir. Bir sürücünün yorgunluğunun uyku eksikliği, uzun yolculuk, huzursuzluk, alkol tüketimi ve zihinsel baskı gibi çok çeşitli sebepleri olabilir.

Sürücü yorgunluğunun tespitine yönelik tasarlanan sistemlerinin araçlarda kullanımı, mobil uygulama ve gömülü platformlar yardımıyla, ölümcül kazaların önlenmesine yönelik çalışmalar devam etmektedir. Uyuşukluk tespit sistemi, sürücülerin dikkat seviyesini sürekli olarak inceler ve karayolu güvenliği için herhangi bir ciddi tehdit oluşmadan önce sürücüyü uyarır. Yorgunluğun yollarda yarattığı tehlikelerden dolayı, araştırmacılar sürücü uyuşukluğunu tespit etmek için çeşitli yöntemler geliştirmiştir ve her tekniğin yararları ve kısıtları vardır (Xing, Lv, Cao, Wang, ve Zhao, 2018).

Yöntemler, sürücü yorgunluğu tespiti için kullanılan özelliklere bağlı olarak, sürücünün biyolojik özellikleri, sürücünün fiziksel özellikleri, sürüş sırasında araç özellikleri ve hibrit özellikler olmak üzere incelenebilir. Konunun öneminden dolayı bu alandaki araştırmalar ve veri analiz yöntemleri hızla artarak devam etmektedir.

Çalışmanın ikinci bölümde, sürücü yorgunluğu hakkında temel bilgiler ve bu alanda kullanılan yöntemler özetlenmiştir. Üçüncü bölümde, sürücü yorgunluk verilerinin değerlendirilmesinde de kullanılan yöntemler incelenmiştir. Dördüncü bölümde, derin öğrenme yöntemleri kullanılarak, yüz tanıma ve göz durum kayıtlarına dayalı uygulama adımları yer almaktadır. Beşinci bölümde elde edilen sonuçlar tartışılmaktadır. Son bölümde ise genel bir değerlendirme yapılarak izleyen çalışmalar için öneriler sunulmaktadır.

2. SÜRÜCÜ YORGUNLUK TESPİTİNE YÖNELİK YÖNTEMLER

2.1.Fizyolojik Özelliklere Dayalı Sürücü Yorulma Tespiti

Fizyolojik sinyaller, sürücü uyanıklık düzeyini ölçmek için kullanılabilir, çünkü bu sinyaller, Şekil 2'de gösterildiği gibi yorgunluk ve uyuşukluk durumlarının erken belirlenmesini sağlayan beyin, gözler, kaslar ve kalp gibi organları ölçer. Fizyolojik sinyaller, sürücü uyuşukluğu ile görünür etkileşim gösteren organlardan kaydedilebilir. Bunlar:

Beyin aktivitesi: Elektroensef alografi (EEG) veya Yakın Kızılötesi Spektroskopisi (NIRS) ile yakalanabilir.

Oküler aktivite: Elektrookülografi (EOG) ile ölçülür.

Kas Tonu: Elektromiyografi (EMG) sinyali kullanılarak kaydedilebilir.

Kardiyak aktivite: Elektrokardiyografi (EKG) ve Kan Basıncı sinyalleri ile izlenir.

Solunum: Solunum çabasını, burun ve oral hava akışını, kan gazını ve uyku horlamagürültüsünü ölçerek.

Elektro dermal aktivite: galvanik cilt yanıtı ve cilt direnci ve iletkenlik ile ölçülür (AlZu'bi, Al-Nuaimy ve Al-Zubi, 2013).

2.1.1.EEG Tabanlı Sürücü Yorgunluğu Tespiti

Elektroensefalogram (EEG) sinyallerini kullanan sürücülerin yorgunluk tespit sistemi, sürücülerin yorgunluğundan kaynaklanan yol kazalarını önlemek için önerilmektedir (Rahim, Dalimi ve Jaafar, 2015). Önerilen yöntem ilk önce farklı uyuşukluk seviyeleri ile ilgili endeksi bulur. Sistem, düşük maliyetli bir tek elektrotlu nöro sinyal toplama cihazı tarafından hesaplanırdı olarak EEG sinyalini

alır. Önerilen yöntemi değerlendirmek için, farklı uyuşukluk seviyelerinde benzetilmiş araç sürücüsü için belirlenen veriler yerel olarak toplanmaktadır. Sonuçlar, önerilen sistemin tüm yorgunluk göstergeleri tespit edebildiğini göstermektedir.

2.1.2. Nabız Sensörü Yöntemi

Sürücülerin fiziksel koşullarına odaklanmanın dışında uyuklu sürücülerin kızılötesi kalp atış hızı sensörleri veya nabız sensörleri kullanılarak da sürücü yorgunluğu algılanabilir (AlZu'bi, Al-Nuaimy ve Al-Zubi, 2013). Nabız değeri, sürücülerin parmağından ya da elinden ölçülebilir. Kandaki oksijen miktarındaki dalgalanma, sensör yardımıyla algılanır, Kalp atım hızı, kalp atım hızı değişkenliği frekans değerleri, yazılım yardımıyla işlenir. Deneysel sonuçlar, düşük-yüksek frekans oranının, sürücülerim uyanık olma durumundan uyuklu durumuna geçtikçe azaldığını ve zamanında bir uyarı gönderilirse birçok trafik kazasından kaçınılabileceğini göstermektedir.

2.1.3. Giyilebilir Sürücü Uyuşukluk Tespit Sistemleri

Sürücülerin uyuşukluğunu tespit etmek için mobil tabanlı uygulamalar geliştirilmiştir. Giyilebilir yapıdaki uyuşukluk tespit sistemleri yaygınlaşmaktadır (Leng, Giin ve Chung, 2015). Sistem kendi kendine tasarlanan bilek bandını kullanmakta, Fotoplethysmografi sinyali (Photoplethysmography, PPG) ve galvanik cilt tepki sensöründen oluşmaktadır ve cep telefonlarına yerleşik olan hareket sensörleriyle derlenebilir. Toplanan veriler, ana değerlendirme birimi olarak görev yapan mobil cihaza iletilir. Deneysel sonuçlar, önerilen sistemin doğruluğunun %98.02' ye ulaştığını göstermektedir. Cep telefonu, sürücüyü uyarmak için grafiksel ve titreşimli alarm üretebilir.

2.1.4. Kablosuz Giyilebilir Yöntem

Sürücülerden kaynaklanan yol kazalarından kaçınmak üzere, Bio-harness olarak isimlendirilen giyilebilir uyuşukluk tespit sistemi fikri önerilmiştir (Warwick, Symons, Chen ve Xiong, 2015). İlk aşamada, sürücünün fizyolojik verileri derlenir, daha sonra EKG, kalp atış hızı, duruş ve uyuşuklukla ilgili diğer temel parametreleri tahminlemek için veriler analiz edilir. İkinci aşamada, uyuşukluk tespit algoritması dayanarak, uyuklu sürücülerini uyarmak için mobil uygulamaların geliştirilmesini kapsamaktadır.

2.1.5. Somatik Sensör İle Tespit Sistemi

Araç hareket halindeyken uyuşukluğu tespit etmeyi amaçlayan sistem, harici donanım (sensörler ve kamera), veri işleme modülü ve alarm ünitesinden oluşmaktadır (Chellappa, Joshi ve Bharadwaj, 2016). Nabız hızı, esneme, kapalı gözler, açık kırpma süresi ve diğerleri gibi fizyolojik ve fiziksel faktörler somatik sensör kullanılarak sürekli izlenir. İşlem modülü uyuşukluğu tespit etmek için faktörlerin birleşimini kullanır. Sonunda uyarı birimi sürücüyü belirtilerin ciddiyetine göre birçok aşamada uyarır.

2.2. Araçsal Özelliklere Dayalı Sürücü Yorgunluk Tespiti

Araç dışı denetlemeye dayalı sistemler, aracın şerit çizgileri dâhilinde ilerleyip ilerlemediğini, sürekli ve düzenli şerit ihlalini ve karanlık ortamda durmalambası ışıklarından hareketle öndeki araçla mesafenin korunup korunmadığını kontrol etmektedir (Chen, Chiang, Chiang, Liu, Yuan, Wang, 2012).

Araç içi ve araç dışı denetlemenin birlikte kullanılması daha güvenilir sonuçlara ulaşılmasına katkı sağlar. Göz kapanması, esneme, başın eğilmesi gibi yorgunluk belirtilerinin tespiti yapılırken eşzamanlı olarak ikinci kamera ile yolu gözleyerek şerit takibi yapılmaktadır (Ahmed, Emon ve Hossain, 2014).

Araçsal özelliklere dayalı sürücü yorgunluk tespitinde yaygın olarak, direksiyon simit hareketi, araç sapması ve konumu ve araç hızı ve hızlanma verileri kullanılmaktadır.

Direksiyon simiti hareketi: Sürüş davranışını değerlendirmede, direksiyon simiti geri dönüş sayısı, direksiyon düzeltme süreleri ve aracın sarsıntılı hareketini içeren anormal sürüşe ilişkin metrikler kullanılabilir (Borghini, Astolfi, Vecchiato, Mattia ve Babiloni, 2014).

Araç sapması ve konumu: Aracın yolun orta şeridine göre konumu veya şerit konumunun standart sapması olarak bilinen metriklere dayanmaktadır (Peng, Boyle ve Hallmark, 2013; Morris ve Pilcher, 2015).

Araç hızı ve hızlanma: Sürücünün uyanıklık seviyesi ile bir ilişkisi olduğunu ve uyuklu sürücünün genellikle hızlandığını göstermiştir. Bu yaklaşım, araç hızı, hızlanma oranı ve hızlanma pedalı

üzerindeki baskıdır.

2.3.Fiziksel Özelliklere Dayalı Sürücü Yorulma Tespiti

Sürücünün yorgunluk ve uyuşukluk seviyesini tespit etmek üzere kullanılacak en yaygın yöntemler, ilgili verinin kamera ile izlenmesidir. Sürücü anormal davranışlarını ölçerek uyku hale geldiğinde gözle görülür yorgunluk ve uyku hali belirtileri görülebilir.

Yüz algılama, son yıllarda bilgisayarla görme ve örüntü tanımanın araştırma alanları arasında yer almaktadır. Yüz tanıma, insanları ve etkileşimlerini, ifadeleri ve duyguları ile birlikte yorumlamak için veri sağladığından büyük ilgi görmektedir. Farklı ölçek ve pozda görünen yüzleri algılamada kullanılmak üzere çok sayıda algoritma geliştirilmiştir.

Yüz ifadeleri: Sürücü yorgunluk/uykululuk halini tespit edebilmek için, gözlerin açık ve kapalılığı ile ilgili olarak göz kapalılık oranı (Percentage of Eye Closure, PERCLOS) ve esneme tespiti için PERYAWN (ağız açıklık oranı) yöntemleri kullanılabilir. Yorgunluk tespitinde yaygın olarak kullanılır (Zhu ve Lan, 2014).

Ağız ve esneme analizi: Yorgunluk sorununu önlemek için, ağız ve esneme analizine dayanarak sürücü yorgunluğu tespit sistemi önerilmiştir (Saradadevi ve Bajaj, 2008). Öncelikle, sürücü görüntülerinde ağız algılanır ve izlenir. Daha sonra, ağız ve esneme görüntüleri SVM kullanılarak eğitilir. Esnemeyi tespit etmek ve sürücüyü uyarmak için ağız bölgelerini sınıflandırmak için kullanılır. Sistem, esnemeyi algılayarak, yorgunluğu tespit eder ve sürücüyü uyarır.

Kafa pozisyonu: Sürücü yorgunluğunu algılamada önemli bir göstergedir. Gerçek zamanda gözle görülür durumda olan, kafa pozisyonudur. Sürücü uyku pozisyonuna geçtiği anda istemsizce boyun kasları zayıflar ve kafa sağa, sola yalpalanmaya ya da olduğu noktada sabitlenebilir. Kafa pozisyonuna göre sürücü hareketlerini algılayarak %89 civarında başarı elde edilmiştir (Tawari, Ashish, Martin, ve Trivedi, 2014).

Tablo 2’ de fiziksel özelliklere dayanılarak gerçekleştirilen çalışmalar özetlenmiştir.

Tablo 2. Fiziksel özellik kullanılarak gerçekleştirilmiş sürücü yorgunluk tespiti çalışmaları

Referans	Metrik	Metod	Sınıflandırma	Başarımlar (%)	Uygulama Alanı
[46]	Yüz Durumu	Tensor Flow	ANN, CNN	98,02	PC
[47]	Ağız ve Göz Durumu	AdaBoost	CNN, SVM, LSTM, Lojistik Regresyon	94,42	DAVIS 346
[48]	Ağız, Göz, Yüz ve Burun Durumu		Bagging, Rassal Ağaç, SVM	98	
[49]	Göz Durumu	PERCLOS, AECT	CNN	86	NVID IA GTX 1060 CUDA
[50]	HRV, EEG	PERCLOS		93,09	Akıllı Telefon
[51]	Göz ve Yüz Durumu	OPENCV	Haar Cascade	%11 iyi tespit %28 kötü tespit	Android işletim sistemi
[52]	Göz ve Ağız Durumu		Linear SVM, LDA, Karar Ağacı	93,56	PC
[53]	Göz Durumu	Mean Shift Algoritması		97	PC
[54]	Göz kapalılığı ve esneme		Binary SVM with Linear Kernel	94,58	
[55]	Göz Durumu	AdaBoost, LBF ve PERCLOS	SVM	95	
[56]	PERCLOS	AdaBoost, PCA ve LDA, PERCLOS	SVM	95	
[57]	Göz durumu ve kafa pozisyonu		HMM	97.7	
[58]	Göz bakışları	Viola and Jones Algorithm	CNN	98.32	PC

[59]	Göz durumu	Viola and Jones Algorithm, AdaBoost, PERCLOS	SVM, LBP	80	
[60]	Göz açıklığı		HOG ve SVM	91.6	
[61]	Biyolojik ve Fiziksel yaklaşımlar	KSS	M-SVM	95.8	PC
[62]	Ağız ve Esneme Durumu	Viola Jones Algorithm, AdaBoost, RDF Kernel	SVM	81	
[63]	Kafa Hareket Durumu	Constrained Local Model and pictorial structural matching	-	89-96	
[64]	Esneme	YCbCr Color Space, Canny edge	HAAR	80	

3. SÜRÜCÜ YORGUNLUK VERİLERİNİN DEĞERLENDİRİLMESİNE YÖNELİK YÖNTEMLER

Sürücü yorgunluğunu belirlemek üzere derlenen verilerin uygun yöntemlerle analize edilmesi gerekir. Yaygın olarak kullanılan yöntemler, matematiksel model tabanlı uygulamalar, kural tabanlı uygulamalar ve makine öğrenmesi tabanlı uygulamalar olmak üzere üç temel başlık altında özetlenebilir.

Matematiksel modellere dayalı uygulamalar kapsamındaki biyo-matematiksel modeller, uyku döngüsünün bireysel performans üzerindeki etkisini araştırır. Yorgunluk ve performans kalite riskini tahmin etmek üzere, uyku süresi, uyanıklık süresi ve uyku geçmişi gibi girdiler incelenir.

Kural tabanlı uygulama, uzman sistem uygulamalarında nispeten daha az zorlayıcı yaklaşımlardan biridir. Karmaşık uzman sistemler için, bulanık çıkarım sistemleri tercih edilebilir (Cateni, Colla, Vannucci, ve Borselli, 2012).

Makine öğrenimine dayalı uygulamalar, laboratuvar ortamında ya da yol testlerinde elde edilen kapsamlı sürüş verileri üzerine eğitilmiş veriler sonucunda elde edilen algoritmalarıdır. Temsil seviyeleri ve özellik türetme için kullanılan tekniğe bağlı olarak sığ ve derin modeller başlıkları altında incelenebilir.

2.1. Makine Öğrenimine Dayalı Uygulamalar

2.1.1. Sığ Modeller

Sığ modeller, düşük karmaşıklıkla yeterli düzeyde tahmin yeteneği sağlar. Birkaç katmandan oluşur ve sınırlı eğitim verisi gerektirir. Fakat, önceden tanımlanmış ayırıcı özellikler gerektirir. Sığ modeller arasında yer alan Yapay Sinir Ağları (YSA), bir gizli katman ve Destek Vektör Makinesi (Support Vektör Machine, SVM) olarak tanımlanabilir. SVM, sürücü durumunu farklı yorgunluk seviyelerine göre sınıflandırmak için birçok yorgunluk tespit sisteminde kullanılmıştır. İki grup sınıflandırma problemi için özel olarak tasarlanmıştır. SVM, Derin modellerin geliştirilmesi sürücü yorgunluğu tespitini de büyük ölçüde etkilemiştir (Azim, Jaffar ve Mirza, 2014).

2.1.2. Derin Öğrenme Modelleri

Derin öğrenme modelleri, göreve özgü yöntemler yerine verilerin öğrenme temsiline içerir. Sığ modellerin aksine, derin modeller özellikleri eğitim verilerinden çıkarma özelliğine sahiptir. Çok katmanlı ileri beslemeli bir YSA olan Evrişimli Sinir Ağı (Convolutional Neural Network, CNN) özellikle görüntü analizlerinin gerçekleştirilmesi amacıyla yaygın olarak kullanılmaktadır. Tam bağlı katmanı, aktivasyon katmanı, sınıflandırıcı katman, havuzlama katmanı ve bunlara ek katmanlarda, her katman kendi işlevini yürüterek sınıflandırıcı katmanda sonuç üretilmektedir (Sikander ve Anwar, 2019). Sürücü yorgunluğu belirlemede kullanılan en eski derin öğrenme modelleridir.

Derin öğrenme sistemlerinde, doğru sonuçlar elde etmek için veri miktarının fazla olması gerekir. Örneğin, bir yüz tanıma programı yüzlerin kenarlarını ve çizgilerini, daha sonra yüzlerin daha önemli kısımlarını ve son olarak yüzlerin genel temsillerini tespit etmeyi ve tanımayı öğrenerek çalışır. Zamanla, program kendini eğitir ve doğru cevap olasılığı artar. Bu durumda, yüz tanıma programı yüzlerizamanla doğru bir şekilde tanımlayacaktır.

YSA yardımı ile etiketlenmemiş verileri bu verilerdeki örnekler arasındaki benzerliklere göre

gruplandırmak ya da sıralamak mümkündür. Sınıflandırma durumunda, bu veri kümesindeki örnekleri farklı kategorilere sınıflandırmak için ağı etiketli bir veri kümesi üzerinde eğitmek mümkündür.

CNN uyuşukluk tespiti için özelliklerin öğrenilmesinde kullanılmıştır (Doudou, Bouabdallah ve Berge-Cherfaoui, 2020). Katmanlardan ilki sürücü durumunu uykulu veya uykusuz olarak sınıflandırır. Yüz, Viola-Jones yöntemi kullanılarak algılanır ve özelliklerinin çıkarılması için bir CNN'e beslenir. Gizli katmanlardan çıkan bilgi çıkarılan özellikler olarak kabul edilir. Softmax katmanı, çıkarılan özellikler konusunda eğitilir. Kanal Bazında evrişimli sinir ağları (Channel based CBonvolutional Neural Network, CCNN) sürücülerin yorgunluk tespiti için CNN'den daha iyi sonuçlar vermektedir.

4.UYGULAMA

Derin öğrenme yöntemleriyle, sürücünün araç kullanma konumunda yüzünün algılanması, daha sonra algılanan yüzde göz ve ağız durumunun belirlenmesi, göz için, açık kapalı durumunu ve ağız için esneme durumu olup olmadığını bilgisi derlenebilir. Böylece, sürücünün yorgun, yorgun değil ya da uyku durumunda olup olmadığı video kayıtları yardımıyla tespit edilebilir.

4.1.Yüz Algılama Yönteminin Belirlenmesi

Literatürde çok sayıda yüz algılama algoritması yer almaktadır. Hız, doğruluk oranı ve çalışılacak ortamın donanımsal özellikleri dikkate alınarak uygun algoritma belirlenebilir. Yüz algılama özellik tabanlı ve görsel tabanlı olarak iki başlık altında gruplanabilir. Özellik tabanlı algoritmalarda Viola Jones Algoritması öne çıkmaktadır. Görsel tabanlı yüz algılama algoritmaları arasında makine öğrenmesi kapsamında yer alan SVM, YSA yaygın olarak uygulanmaktadır.

4.1.1.Viola Jones Algoritması

2001 yılında Paul Viola ve Micheal Jones tarafından geliştirilen OpenCV kütüphanesinde yer alan algoritmadır. Eğitim ve tanıma olarak iki adımda çalışmaktadır. İlk adım algoritma eğitilip, tanıma adımında eğitilen model ile tanıma işlemi yapılır.

ViolaJones dedektörü, Haar-cascade dedektörü fonksiyonlarının benzerini kullanır. Haarcascade dedektöründen farklı olarak, görüntünün özelliklerini çıkaran 24x24 çözünürlüğünde, dört adet dikkörtgen kullanır.

4.1.2.Derin öğrenme yöntemleri ile yüz algılama

Nesne tanıma modelleri ile eğitim ve test işlemlerini gerçekleştirebilmek için uyumlu derin öğrenme kütüphaneleri kullanmak gerekmektedir. Bu alanda Pytorch, Tensorflow, Darknet, Darkflow, Caffe gibi birçok derin öğrenme kütüphaneleri yer alır. Pytorch ana kütüphane, C ile yazılmış ve Lua destekli bir yapıya sahiptir ve GPU desteği ile de ön plandadır. Tensorflow kütüphanesi, Google tarafından tasarlanan bir üründür. Açık kaynak kodlu olup ticari amaçlıda kullanılabilir. Aynı zamanda keras kütüphanesinin temelinde çalışır. Darknet kütüphanesi, C ve CUDA ile yazılmıştır. YOLO serilerinde çok sık olarak kullanılmasından dolayı ün kazanmıştır. GPU desteği yer almaktadır.

You Only Look Once (YOLO): YOLOv3'nun diğer algoritmalar a kıyasla, hız ve doğruluk açısından daha iyi durumdadır (URL 2). Resim, tek seferde nöral ağıdan geçirerek resimdeki tüm nesnelerin sınıfı ve koordinatları tahmin edebilir. Tahmin temelinde, nesne tespitinin tek bir regresyon problemi olarak ele alması yatmaktadır. Girdi resmi öncelikle BxB' lik ızgaralara bölünür. Bu ızgaralar 3x3, 9x9 ve 15x15 vb. yapıda olabilir. Her bir ızgara kendi içinde, nesnenin olup olmadığını, varsa orta noktasının uzunluklarını verir. Algoritma, her ızgara için ayrı bir tahmin vektörü oluşturur. Bunların her birinin içinde güven skoru hesaplanır. Güven skoru, modelin geçerli ızgara içinde nesne bulunup bulunmadığından ne kadar emin olduğunu temsil eder (0 ise kesinlikle yok 1 ise kesinlikle var). Eğer nesne olduğunu düşünürse de bu nesnenin gerçekten o nesne olup olmadığından ve etrafındaki kutunun koordinatlarından ne kadar emin olduğunu gösterir. Modelde kaç farklı sınıf varsa o kadar tahmin değeri yani bağıl sınıf olasılığı çıkarılır. Çıkan sonuçlara göre genel güven skoru hesaplanır. (Güven skoru = Kutu Güven Skoru x Bağıl Sınıf Olasılığı, Kutu Güven Skoru = P(nesne) . IoU, P(nesne) = Kutuda nesne var mı yok mu olasılığı. IoU = Ground truth ile tahmin edilmiş kutu arasındaki IoU değeri). Çıktı vektöründe, her bir ızgara sadece 1 tane nesne tanımlayabilir.

Bu çalışma kapsamında yüz görüntüleri üzerinde eğitilmiş YOLOV3 modeli kullanılmıştır. Modelin eğitimini WIDER FACE veri seti kullanılarak yapılmıştır. Model, sürücünün yorgunluğunu tespitinde

kullanılmak üzere görüntüdeki yüzleri tespit etmektedir.

4.2. Viola Jones Algoritmasıyla Yüz Algılama

OpenCV kütüphanesi ile desteklenen önceden eğitilmiş Haarcascade modeli ile yüz tespiti yapılmıştır. Yüzün kamera dik şekilde bakması sonucunda yüz tespiti başarılı bir şekilde gerçekleştirilir. Tespit edilen yüz hatları, kare ile çerçecelenmiştir ve Şekil 11’de temsil edilmektedir.



Şekil 11. Yüz tespitinde örnek kare

4.3. Veri Setinin Oluşturulması

Sürücü uykulu algılama veri seti, çeşitli yüz özellikleri, yaş grupları ve dört farklı senaryoya sahip kadın ve erkek sürücülerden oluşmaktadır. Senaryolar, sürücülerin gözlüklü ve gözlüksüz halini içerdiğinden, her video iki durumu içerebilir. Veri toplamada kullanılan sürücü özellikleri Tablo 3’de verilmiştir. Veriler Piranha 1315 Full HD araç içi yol kayıt kamerası ile avi formatında derlenmiştir. Hazır olan bu veri kümesindeki videolardan saniyede 30 görüntü çekildi. Karışık durumlardan alınan 30000 görüntü elde edilmiştir.

Veri setinde bulunan tüm görüntülere etiketleme işlemi yapılmıştır. Etiketlemenin amacı, göz kapağı durumundan hareketle kapalı, göz bebeği durumundan hareketle açık olarak tanımlamanın sağlanmasıdır.

Tablo 3. Veri toplamada kullanılan sürücüler

No	Cinsiyet	Yaş	Gözlük	Veri Toplama Aralığı
1	Erkek	28	Var	07:00-12:00
2	Erkek	30	Yok	12:00-17:00
3	Erkek	24	Yok	12:00-17:00
4	Erkek	35	Var	07:00-12:00
5	Erkek	29	Yok	17:00-22:00
6	Erkek	30	Var	07:00-12:00
7	Erkek	32	Yok	12:00-17:00
8	Erkek	27	Yok	17:00-22:00
9	Erkek	38	Var	17:00-22:00
10	Erkek	36	Yok	12:00-17:00
11	Kadın	29	Var	17:00-22:00
12	Kadın	32	Var	12:00-17:00
13	Kadın	29	Yok	12:00-17:00
14	Kadın	36	Yok	12:00-17:00
15	Kadın	24	Yok	17:00-22:00
16	Kadın	25	Yok	17:00-22:00
17	Kadın	30	Var	07:00-12:00
18	Kadın	31	Var	07:00-12:00
19	Kadın	28	Var	07:00-12:00
20	Kadın	35	Yok	12:00-17:00

4.4. Model Mimarisinin Oluşturulması

Modelin ağ yapısı YSA ve CNN' dan meydana gelir. CNN hareketle oluşturulan modelde, evrişim katmanı, ortaklama katmanı, 37 normalizasyon katmanı ve tam bağlı katmanlar yer almaktadır. Tam tam bağlı katmanların yapısında yapay nöronlardan meydana gelmektedir. Genel olarak kullanılan katmanlarda; öğrenme oranını artırma, bilgi kaybını önleme, aşırı ezberleme gibi durumları önlemek için bazı düzenleme yöntemleri kullanılmıştır. Özniteliklerin doğru oluşumu için ağ mimarisi ve eğitim algoritmasını oluşturan hiper parametreler, veri seti ve çalışılan ortam ele alınarak geliştirilmiştir. Konvolüsyon katmanlarında, giriş olarak verdiğimiz 48x48x1 boyutundaki görüntülere göre uygun filtre boyutu (3x3) ve sayıları belirlenmiştir. Konvolüsyon katmanlarında doğrusal olmayı artırma açısından ReLU aktivasyon fonksiyonu kullanılmıştır. ReLU gelen değerlerin pozitif ya da negatif olması kontrol edilir. Gelen değer, 0' dan küçük ise 0 olarak, 0' dan büyük ise olduğu gibi geçirir. Konvolüsyon katmanlarının ardından normalizasyon katmanları kullanılmıştır. Bu normalizasyon katmanı ile giriş ve çıkışların haricinde istenilen katmanlar arasında da normalizasyon gerçekleştirilmiş olur.

Birden fazla havuzlama metodu vardır. Oluşturulan mimaride benzer havuzlama (same padding) metodu kullanılmıştır. Yani resim çerçevesinin dört bir yanı sıfırlar ile doldurularak bilgi kaybının önüne geçilmiş olur. Havuzlama katmanlarında ise 2x2 boyutunda filtreler kullanılmıştır. Öteleme (Strides) adımları 1 seçilmiştir. Bu şekilde özellik haritalarının boyutları azaltılarak, daha kontrol edilebilir ve hızlı bir eğitim gerçekleştirilir. Aynı zamanda maksimum havuzlama ile boyut azaltılarak aşırı ezberleme, gereksiz detaylara aşırı takılma gibi overfitting problemi de çözülmüş olur. Düğüm seyreltme katmanı; veri setimizdeki görsellerin sayısına bağlı olarak nöron ve katman sayıları belirlenmiştir. Aynı zamanda overfitting (aşırı ezberleme), genelleştiremememe problemini önlemek için düğüm seyreltme katmanı kullanılmıştır. Bu sayede eğitim işlemi, her döngüde rastgele olarak belirlenen nöronlar inaktif hale getirilerek, yapılmış olur. Bunun sayede eğitim sonucu ile test sonuçlarının birbirlerine daha yakın olduğu gözlemlenmiştir. Çıkış katmanında ise ikili sınıflandırma yapıldığından nöron sayısı 2 olmak zorundadır. Aynı zamanda bu katmanda softmax aktivasyon fonksiyonu 38 kullanılmıştır. Softmax ile gelen tahmin değerleri 0 ile 1 arasına atanır ve 2 sınıf için belirlenen değerlerin toplamı 1 e aittir. Bu değerler arasında hangisi daha en yüksek ise o nöron aktif olur. Sınıflandırma sonucunda, nöronda belirtilen sınıf çıktı olur.

4.5. Yorgunluk Tespiti Modeli için Eğitim

Evrişimli sinir ağları hazırlanmış olan veri setlerine ait 48x48 piksel boyutundaki gri tonlamalı görüntüler üzerinde eğitilmiştir. Göz kapağının açık ve kapalı olduğu 2052 adet eğitim ve 1074 adet test görüntüsü kullanılmıştır. Eğitim, Nvidia GeForce GTX 950M grafik kartına sahip olan bilgisayar ortamında gerçekleştirilmiştir.

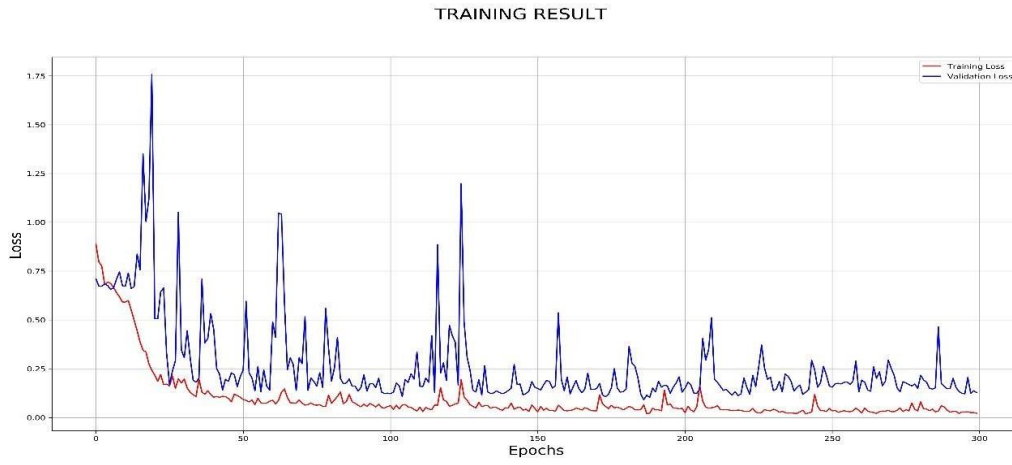
Eğitim işlemi sırasında her iterasyonda rastgele olarak 32 görüntü evrişimli sinir ağlarına verilmiştir. Batch yani iterasyon sayısı 64 belirlenmiştir. Bu iterasyonların bir kısmı var olan veri seti üzerinden kalan kısmı ise veri çoğaltma yöntemi ile oluşturulan veri setinden gerçekleştirilmiştir. 64 iterasyon sonunda 1 epoch tamamlanmış olmaktadır. Eğitim işlemi de 450 epoch kadar sürdürülmüştür. Eğitim sonucunda eğitim başarısı yaklaşık olarak %97, test veri seti üzerinde %95 başarı elde edilmiştir.

5. BULGULAR VE TARTIŞMA

Eğitim, hazırlanmış olan veri seti kullanılarak yapılmıştır. Başarı ve kayıp grafikleri Şekil 12 ve Şekil 13'de gösterilmiştir. Eğitim başarıımı yüksek kayıp değeri de istenilen seviyededir. Başarı ve kayıp değerlerinde oluşan dalgalanmanın sebebi ise veri setinin kısıtlı miktarda olmasıdır.

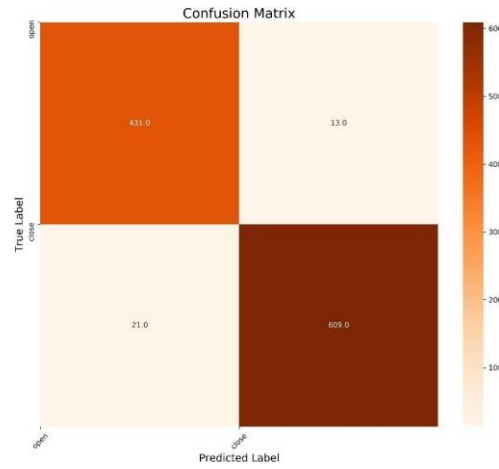


Şekil 12. Eğitim başarıml grafiđi



Şekil 13. Eğitim kayıp grafiđi

Şekil 14’de gösterilen confusion matrix ele alınarak modelin performansı incelenirse; modelin iki sınıf içinde başarılı olduđu görölmektedir.




Şekil 14. Eğitimin confusion matrix

Eđitilen Model Üzerinden Yorgunluk Tespiti

Yazılım Python dilinde gerçekleştirilmiştir. İlk aşamada yüz tespiti modelinin ađırlık dosyası

kullanılarak yüz bölgesi bulunur. Yüz bölgesinin koordinatları alınır. Koordinatlar kullanılarak yüz bölgesi görüntüden kesilip, boyutu 48x48 olarak ayarlanır. Bu işlem yüz bölgesinin göz kapaklarının sınıflandırılması için gereklidir. Çünkü eğitilen yorgunluk tespiti modeli 48x48 gri tonlu görüntüler kullanılarak eğitim yapılmıştır. Elde edilen 48x48 boyunda yüz görüntüsünden göz kapakların durumu tahmini yapılır. Tahmin olasılığı ve tahmin sınıf belirlenir. Yüz bölgesinin koordinatları kullanılarak orijinal görüntüdeki yüz çerçevesi çıkarılır. Sürücü yorgunluk modeli gözleri kapalı tahmininde bulunduğu anda score değerinde artış gerçekleşir. Model gözleri açık tahmininde bulunduğu anda score değerinde azalma gerçekleşir. Score değeri belirlenen eşik değerini aştığı durumda alarm devreye girer.

Geliştirilen demodan farklı kişiler ve ortamlarda alınan görüntüler üzerinde testi Şekil15 a ve b'de gösterilmiştir.



Şekil 15. Test Görüntüsü (a)



Şekil 15. Test görüntüsü (b)

6.SONUÇ VE ÖNERİLER

Yüz algılama için farklı algoritmalar mevcuttur. Bu çalışmada iki farklı yüz algılama metodu kullanılmıştır ve karşılaştırılmıştır. Viola Jones Algoritması ile 10000 resim üzerinden yapılan eğitim sonucu yüz üzerinden çıkartılan özellikler doğrultusunda genelleştirme yapabilen bir algoritmadır. Yüz, göz, burun gibi vücut yapılarını bulmak için Viola Jones Algoritması ile eğitilmiş hazır ağırlık dosyaları mevcuttur. Bu ağırlık dosyası kullanılarak hızlı bir şekilde yüz algılama işlemi yapılabilir. Viola Jones Algoritması, hızlı ve rahat bir şekilde algılama yaptığı ancak görüntüyü tam karşıdan alamadığı durumlar, farklı parlaklık koşulları gibi etkenler başarı durumunu olumsuz etkilemektedir. Çalışmada kullanılan diğer yüz algılama algoritması derin yöntemleri ile geliştirilen YOLOv3 modelidir. WIDER FACE veri seti kullanılarak YOLOv3 ağırlıkta eğitilen model yüz algılaması için kullanılmıştır. Yüz algılamada dış etkenler altında YOLOv3 modeli Viola Jones algoritmasına göre daha başarılıdır.

Bu çalışmada göz kapağı durumu yorumlanarak sürücü yorgunluk tespiti yapılmıştır. Çalışmanın ilk kısmında araç kamerası ile 20 farklı kişiden video görüntüleri alınmıştır. Videolardan görüntü kareleri (frame) elde edilmiştir. Bu görüntüler tek tek incelenerek, etiketlenmesine karar verilen görüntüler ayrılmıştır. Ayrılan görüntüler göz kapağı durumuna göre açık ve kapalı olarak sınıflandırma işlemi yapılmıştır.

CNN ile bir ağ mimarisi oluşturulmuş ve hiper parametreler belirlenerek eğitimler gerçekleştirilmiştir. Eğitim sonucunda ulaşılan isabet oranını 64 arttırmak, overfitting problemlerini çözmek için

parametreler ve ağ mimarisi üzerinde oynamalar yapılmıştır. Aynı zamanda modelden bağımsız olarak düzenleme metotları da kullanılmıştır. Bunların sonucunda yaklaşık eğitim ve test setinde %96'luk bir doğruluk oranına ulaşılmıştır.

Geliştirilen demoda seçilen yüz algılama algoritmaları karşılaştırılması yapılmıştır. Viola Jones Algoritmasında yüz tespiti ile göz tespiti de yapılması göz kapağının sınıflandırma duyarlılığını artırmıştır. Bu yüzden Viola Jones Algoritmasının YOLOv3 algoritmasına göre daha duyarlı ve verimli çalıştığı belirtilebilir.

İzleyen çalışmalarda, daha yüksek çözünürlüklü kamera ve farklı aydınlatma (normal, kötü, parlak) koşullarında veri derlenebilir. Bu çalışmada kullanılan kamera, deneklerin tam karşısında konumlandırılmıştır. Yüz yönünü ve göz kapağı hareketini izleyerek sürücünün uykululuk, yorgunluk ve dikkatsizlik durumunu tespit etmeye çalışmak üzere gerçek zamanlı veri derleme üzerine de çalışmalar tasarlanabilir.

KAYNAKÇA

Ahmed, R., Emon, K.E.K., ve Hossain, M.F. (2014). Robust driver fatigue recognition using image processing. *3rd Int. IEEE Conference on Informatics Electronics & Vision*, 1-6.

AlZu'bi, H. S., Al-Nuaimy, W., ve Al-Zubi, N. S. (2013). EEG-based driver fatigue detection. *Proc. 6th Int. Conf. Develop. Syst. Eng. (DESE)*, 111-114.

Azim, T., Jaffar, M. A., ve Mirza, A. M. (2014). Fully automated real time fatigue detection of drivers through fuzzy expert systems. *Appl. Soft Comput.*, 18, 25–38.

Borghini, G., Astolfi, L., Vecchiato, G., Mattia, D., ve Babiloni, F. (2014). Measuring neurophysiological signals in aircraft pilots and car drivers for the assessment of mental workload fatigue and drowsiness. *Neurosci. Biobehav.* 44, 58–75.

Cateni, S., Colla, V., Vannucci, M., ve Borselli, A. (2012). Fuzzy inference systems applied to image classification in the industrial field. *Fuzzy Inference System - Theory and Applications*.

Chellappa, Y., Joshi, N. N., ve Bharadwaj, V. (2016). Driver fatigue detection system. *Proc. IEEE Int. Conf. Signal Image Process. (ICSIP)*, 655-660.

Chen, Y.L., Chiang, H. H., Chiang, C.Y., Liu, C.M., Yuan, S.M., ve Wang, J.H., (2012). A vision-based driver nighttime assistance and surveillance system based on intelligent image sensing techniques and a heterogamous dual-core embedded system architecture. *Sensors*, 12, 2373–2399.

Doudou, M., Bouabdallah, A. ve Berge-Cherfaoui, V. (2020). Driver drowsiness measurement technologies: current research, market solutions, and challenges. *Int. J. ITS Res.* 18, 297–319.

Ji Q., Zhu Z., ve Lan P. (2004). Gerçek zamanlı müdahaleci olmayan izleme ve sürücü yorgunluğunun tahmini. *IEEE Trans Veh Technol* 53 (4): 1052–1068.

Leng, L. B., Giin, L. B., ve Chung, W.-Y. (2015). Wearable driver drowsiness detection system based on biomedical and motion sensors. *Proc. IEEE Sensors*, 1-4.

Lum, H. ve Reagan, J. A. (1995). Interactive highway safety design model: Accident-predictive module. *Public Roads Mag.*, 58, 3.

Morris DM, Pilcher JJ, ve Switzer FS III. (2015). Lane heading difference: An innovative model for drowsy driving detection using retrospective analysis around curves. *Accid Anal Prev.* 117-24.

Peng, Y., Boyle, L.N., ve Hallmark, S.L. (2013). Driver's lane keeping ability with eyes off road: insights from a naturalistic study. *Accid. Anal. Prev.* 50, 628–634.

Rahim, H. A., Dalimi, A., ve Jaafar, H. (2015). Detecting drowsy driver using pulse sensor. *J.Technol.*, 73 (3), 5-8.

Saradadevi, M., Bajaj, P. (2008). Driver fatigue detection using mouth and yawning analysis. *Int. J. Comput. Sci. Netw. Secur.*, 8, 183-188.

Sikander, G., ve Anwar, S. (2019). Driver fatigue detection systems: a review. *IEEE Transactions on Intelligent Transportation Systems*, 20, 2339-2352.

Tawari, A., Martin, S., ve Trivedi, M. M. (2014). Continuous head movement estimator for driver assistance: issues, algorithms, and on-road evaluations. *IEEE Transactions on Intelligent Transportation Systems*, 15 (2), 818-830.

URL 1: <https://www.tuik.gov.tr/>

URL 2: <https://medium.com/deep-learning-turkiye/yolo-algoritmas%C4%B1n%C4%B1-anlamak-290f2152808f> (Ziyaret Tarihi: Mayıs2021)

Xing, Y., Lv, C., Cao, D., Wang, H., ve Zhao, Y. (2018). Driver workload estimation using a novel hybrid method of error reduction ratio causality and support vector machine. *Measurement*, 114, 390-397.

Warwick, B., Symons, N., Chen, X., ve Xiong, K. (2015). Detecting driver drowsiness using wireless wearables. *Proc. 12th Int. Conf. Mobile Ad Hoc Sensor Syst. (MASS)*, 585-588.