



SÜRÜCÜ PERFORMANS TAKİP SİSTEMİ

SELMAN AKTAŞ

YÜKSEK LİSANS TEZİ

MEKATRONİK MÜHENDİSLİĞİ ANA BİLİM DALI

Dr. Öğr. Üyesi Bülent TURAN

Ocak - 2020

Her hakkı saklıdır

T.C.
TOKAT GAZİOSMANPAŞA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
MEKATRONİK MÜHENDİSLİĞİ ANA BİLİM DALI

YÜKSEK LİSANS TEZİ

SÜRÜCÜ PERFORMANS TAKİP SİSTEMİ

SELMAN AKTAŞ

TOKAT
Ocak - 2020

Her hakkı saklıdır

Selman AKTAŞ tarafından hazırlanan “**Sürücü Performans Takip Sistemi**” adlı tez çalışmasının savunma sınavı 16 Ocak 2020 tarihinde yapılmış olup aşağıda verilen Jüri tarafından Oy Birliği ile Tokat Gaziosmanpaşa Üniversitesi Fen Bilimleri Enstitüsü MEKATRONİK MÜHENDİSLİĞİ ANA BİLİM DALI ’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Danışman
Dr. Öğr. Üyesi Bülent TURAN
Tokat Gaziosmanpaşa Üniversitesi

Üye
Dr. Öğr. Üyesi Kenan ZENGİN
Tokat Gaziosmanpaşa Üniversitesi

Üye
Dr. Öğr. Üyesi Yavuz ÜNAL
Amasya Üniversitesi

.....

.....

.....

ONAY

.....
Prof. Dr. Çetin ÇEKİÇ
Fen Bilimleri Enstitüsü Müdürü
17/01/2020

TEZ BEYANI

Tez yazım kurallarına uygun olarak hazırlanan bu tezin yazılmasında bilimsel ahlak kurallarına uyulduğunu, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduğunu, tezin içerdği yenilik ve sonuçların başka bir yerden alınmadığını, kullanılan verilerde herhangi bir tahrifat yapılmadığını, tezin herhangi bir kısmının bu üniversite veya başka bir üniversitedeki başka bir tez çalışması olarak sunulmadığını beyan ederim.



SELMAN AKTAŞ

16 Ocak 2019

ÖZET

YÜKSEK LİSANS TEZİ

SÜRÜCÜ PERFORMANS TAKİP SİSTEMİ

SELMAN AKTAŞ

TOKAT GAZİOSMANPAŞA ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ

MEKATRONİK MÜHENDİSLİĞİ ANA BİLİM DALI

(TEZ DANIŞMANI: DR. ÖĞR. ÜYESİ BÜLENT TURAN)

Bu çalışmada sürücü performansından kaynaklı kazaları en aza indirebilmek için, sürücü performansını takip eden görüntü işleme tabanlı bir sistem geliştirilmiştir. Geliştirilen Sürücü Performans Takip Sistemi, sürücü uyku durumunu, dikkatsizliğini ve seyir süresini tespit ve takip eden bir algoritma ile işletilmektedir. Trafik kazalarını azaltmak için, otomotiv endüstrisinde teknoloji kullanımı artarken, en çok kullanılan teknolojilerden birisi de bilgisayarlı görü sistemleridir. Sürücü performansından kaynaklı kazaları önleyebilmek için çeşitli yöntemler geliştirilse de bilgisayarlı görü sistemleri non-invazive özelliklerinden dolayı tercih edilmektedir. Önerilen sistemde, sürücüye müdahale etmeden, sürücü göz, ağız ve baş hareketleri bir kamera ile takip edilir. Göz kapalılığı ve esneme durumları takip edilerek sürücünün uykululuk/yorgunluk tespiti, baş hareketleri takip edilerek dikkatsizlik tespiti ve yüz tanıma yapılarak seyir süresi tespiti yapılmıştır. Göz kapalılığından uykululuk/yorgunluk tespiti için, literatürde çokça geçen PERCLOS (Percent of eye closure) parametresi kullanılmıştır. Ancak esneme tespiti için kullanılan, PERYAWN (Percent of Yawn) parametresi bu çalışmada ilk kez geçmektedir. Benzer şekilde dikkatsizlik tespiti için, PERCAR (Percent of Careless) parametresi de bu çalışmada, ilk kez isimlendirilerek kullanılmıştır. Ayrıca bu çalışmada, diğer çalışmalardan farklı olarak, PCA tabanlı sürücü değişikliği tespiti yapılarak, sürücü seyir süresi belirlenmiştir. Böylece sürücü performans takibine yönelik, ayrı ayrı yapılan farklı çalışmalarda kullanılan parametrelerin birlikte kullanıldığı genel bir Sürücü Performans Takip Sistemi (SPTS) elde edilmiştir. Önerilen bu genel SPTS sistem ile karayollarında, sürücü performansından kaynaklı kazaları, önemli ölçüde azaltılabileceği öngörülmektedir. Bu çalışma sonucunda geliştirilen SPTS tasarımı, öncelikle tüm sürücülü araçlara, ayrıca sürücü ortamına benzeyen her tür çalışma ortamına, performans çıkartımı için uygulanabilir.

2019, 68 SAYFA

ANAHTAR KELİMELER: Görüntü İşleme, PERCLOS, İleri Sürüş Destek Sistemleri (İSDS), PCA, PERYAWN, PERCAR, Sürücü Performans Takip Sistemi

ABSTRACT

MASTER THESIS

DRIVER PERFORMANCE TRACKING SYSTEM

SELMAN AKTAŞ

**TOKAT GAZIOSMANPASA UNIVERSITY
GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES**

DEPARTMENT OF MECHATRONICS ENGINEERING

(SUPERVISOR: ASST. PROF. DR. BÜLENT TURAN)

In this study, an image processing based system that follows the drive performance has been developed in order to minimize the accidents caused by the drive performance. The developed Driver Performance Monitoring System is operated with an algorithm that detects and monitors driver sleep state, carelessness and driving time. While the use of technology is increasing in the automotive industry to reduce traffic accidents, one of the most widely used technologies is computer vision systems. Although various methods have been developed to prevent accidents due to driver performance, computer vision systems are preferred due to their non-invasive properties. In the proposed system, the eye, mouth and head movements of the driver are monitored with a camera without interfering with the driver. Eye closure and yawning were followed by the determination of drowsiness / fatigue of the driver, carelessness detection by following the head movements, and face recognition by face recognition. PERCLOS (Percent of eye closure) parameter, which is widely used in the literature, was used for the determination of sleepiness / fatigue from eye closure. However, PERYAWN (Percent of Yawn) parameter is used for the first time in this study. Similarly, in order to detect carelessness, PERCAR (Percent of Careless) parameter was used for the first time in this study. In addition, in this study, unlike other studies, the driver travel time was determined by PCA based driver change detection. Thus, a general Driver Performance Monitoring System (SPTS) was obtained for the monitoring of drive performance, in which the parameters used in different studies were used together. With this proposed general SPTS system, it is foreseen that it can significantly reduce accidents caused by driver performance on highways. The SPTS design developed as a result of this study can be applied primarily to all driver vehicles, as well as any work environment similar to the driver environment, for performance extraction.

2020, 68 PAGE

KEYWORDS: Image Processing, PERCLOS, Advanced Driving Assistan Systems(ADAS), PCA, PERYAWN, PERCAR, Drive Performance Monitoring System

ÖNSÖZ

Tüm hayatım boyunca maddi ve manevi desteklerini esirgemeyen aileme teşekkürü bir borç bilirim.

Bu çalışmada benden desteklerini esirgemeyen değerli danışman hocam Dr. Öğr. Üyesi Bülent Turan'a teşekkür ederim.

SELMAN AKTAŞ

16 Ocak 2020

İÇİNDEKİLER

Sayfa

ÖZET	i
ABSTRACT.....	ii
ÖNSÖZ	iii
İÇİNDEKİLER.....	iv
SİMGE ve KISALTMALAR	vi
ŞEKİL LİSTESİ.....	vii
ÇİZELGE LİSTESİ.....	viii
1. GİRİŞ	1
2. KAYNAK ÖZETLERİ	5
3. MATERYAL ve YÖNTEM.....	13
3.1. Viola-Jones Algoritması	13
3.2. Gabor Dalgacık Dönüşümleri	20
3.3. PCA (Principal Component Analysis) Yöntemi ile Yüz Tanıma....	22
3.4. Makine Öğrenmesi	24
3.5. Sınıflandırıcılar	25
3.5.1. Bayes sınıflandırıcı	25
3.6.2. Destek vektör makineleri (Support Vektör Machines-SVN) ..	26
3.5.3. Karar ağaçları	27
3.5.4. Yapay sinir ağları.....	29
3.5.5. K-en yakın komşu	30
3.6. Görüntülerin Elde Edilmesi (Face Detection)	32
3.7. Öznitelik Çıkarımı	33
3.8. Sınıflandırma.....	34
3.8.1. ARFF (Attribute Relation File Format) dosyası	35
3.8.2. Sınıflandırma algoritmalarının uygulanması.....	36
3.8.3. Sınıflandırma sonuçlarının karşılaştırılması.....	38
3.8.4. Öznitelik seçimi	40
4.BULGULAR.....	46
4.1. Yüz Tanıma	46

4.2. Dikkatsizlik tespiti.....	47
4.3. Esneme Tespiti.....	47
4.4. Göz kapalılık Tespiti.....	48
4.5. Sürücü Performans Takip Sistemi Algoritması	51
4.6. Sürücü Performans Takip Sistemi	55
5. SONUÇ	61
5.1. Sonuç	61
5.2. Tartışma	62
5.3. Öneriler	63
6. KAYNAKLAR	64
8. ÖZGEÇMİŞ.....	67

SİMGELER ve KISALTMALAR

Kısaltmalar	Açıklama
CLOSDUR	Closed Duration
DVM	Destek Vektör Makineleri
EEG	Elektroensefalografi
EKG	ElektroKardiyografi
EOG	ElektroOkuloGrafı
FACS	Facial Action Coding System
FPS	Frame Per Second
GDD	Gabor Dalgacık Dönüşümü
HCD	Harris Corner Detection
İSDS	İleri Sürücü Destek Sistemleri
KGM	Karayolları Genel Müdürlüğü
MLP	Multi-Layer Perceptron
PCA	Principal Component Analysis
PERCLOS	Percent of Eye Closure
PERCAR	Percent of Careless
PERYAWN	Percent of Yawning
KNN	K-Nearest Neighborhood
SPTS	Sürücü Performans Takip Sistemi
SVM	Support Vektör Machines

ŞEKİL LİSTESİ

<u>Şekil</u>	<u>Sayfa</u>
Şekil 3.1. Haar-benzeri özellikler (Ayvaz ve Gürüler, 2017)	18
Şekil 3.2. Viola-Jones dedektöründe kullanılan dikdörtgenlerin özellikleri (Viola ve Jones, 2001)	18
Şekil 3.3. Görüntünün özelliklerini çıkaran dikdörtgenlerin görüntü üzerine uygulanması (Viola ve Jones, 2001).....	19
Şekil 3.4. Viola-Jones Algoritmasının mantık şeması (Viola ve Jones, 2001).....	20
Şekil 3.5. Farklı açılı ve dalga boylarındaki Gabor dalgacık genlikleri	21
Şekil 3.6. İki farklı sınıf arasında kalan karar doğrusu gösterimi (Sevli, 2019).....	26
Şekil 3.7. Örnek bir karar ağacı algoritması	28
Şekil 3.8. Örnek bir MLP yapısı (Kazan ve Karakoca, 2019).....	29
Şekil 3.9. Örnek iki sınıfın elemanlarının iki boyutlu uzayda dağılımı.....	31
Şekil 3.10. En yakın komşuların belirlenmesi	31
Şekil 3.11. Hazırlanan görüntülerden iki örnek a-kapalı durumdaki göz görüntüsü, b-esneme durumundaki yüz görüntüsü	33
Şekil 3.12. Kapalı bir göz görüntüsüne ait GDD çıktıları	33
Şekil 3.13. Açık bir göz görüntüsüne ait GDD çıktıları	34
Şekil 3.14. Örnek bir esneme durumdaki yüz görüntüsüne ait GDD çıktıları.....	34
Şekil 3.15. Örnek bir esneme olmayan yüz görüntüsüne ait GDD çıktıları	35
Şekil 3.16. Arff dosyası içeriğinin görüntüsü	36
Şekil 4.1. Gözlerin yarı açık durumu (belirsizlik durumu).....	49
Şekil 4.2. Kapalı durumdaki (A) ve açık durumdaki (B) gözlerin tespiti.....	50
Şekil 4.3. Algoritma – 1 (Yüz tanıma).....	53
Şekil 4.4. Algoritma – 2 (SPTS döngü)	54
Şekil 4.5. Uygulamanın sürücü uykululuğunu tespiti, PERCLOS=%20.5.....	56
Şekil 4.6. Esneme durumunda uykululuk uyarısı, PERYAWN=%62	56
Şekil 4.7. Sola bakarken dikkatsizlik durumu, PERCAR=%62	58
Şekil 4.8. Sağa bakarken dikkatsizlik durumu, PERCAR=%62.....	58

ÇİZELGE LİSTESİ

Çizelge

Sayfa

Çizelge 1.1. Avrupa’da bazı ülkelerde yorgun/uykulu sürücülerden kaynaklı kazalar	1
Çizelge 2.1. 16 MegaPiksel çözünürlüklü kamera ile yapılan testlerin sonucu	11
Çizelge 2.2. MegaPiksel çözünürlüklü kamera ile yapılan testlerin sonucu	11
Çizelge 2.3. İki ayrı donanımdan (sistemden) elde edilen sonuçlar	14
Çizelge 2.4. Real-Time bazında benzer çalışmalarla kıyaslanması (Akı, 2017)	16
Çizelge 3.1. Veri setlerini sınıflandırmak için kullanılan algoritmalar (Sevli, 2019)	37
Çizelge 3.2. Göz kapalılık tespiti verilerinde, sınıflandırma sonuçları	38
Çizelge 3.3. Göz kapalılık tespiti veri setinde model oluşturma süreleri	39
Çizelge 3.4. Esneme tespiti verilerinde sınıflandırma sonuçları	39
Çizelge 3.5. Esneme tespiti verileri için algoritmaların model oluşturma süreleri.....	40
Çizelge 3.6. Göz kapalılığı tespiti verilerinde 12 adet öznitelik ile yapılan sınıflandırmaların sonuçları	41
Çizelge 3.7. Göz kapalılık tespiti verilerinde 12 adet öznitelikle yapılan sınıflandırmaların model oluşturma süreleri	41
Çizelge 3.8. Esneme tespiti verilerinde 12 adet öznitelik ile yapılan sınıflandırmaların sonuçları	42
Çizelge 3.9. Esneme tespiti verilerinde 12 adet öznitelik ile yapılan sınıflandırmaların model oluşturma süreleri	42
Çizelge 3.10. Göz kapalılık tespiti verilerinde, Matlab ile yapılan sınıflandırma sonuçlarının Weka’da alınan sonuçlar ile karşılaştırılması	44
Çizelge 3.11. Göz kapalılık tespiti verilerinde, Matlab ile yapılan sınıflandırma sonuçlarının Weka’da alınan sonuçlar ile karşılaştırılması	44
Çizelge 4.1. Yüz tanıma testlerinin sonuçları	46
Çizelge 4.2. Test videosunun dikkatsizlik durumu sonuçları	47
Çizelge 4.3. Esneme tespiti testi sonuçları	48
Çizelge 4.4. Gözlerin açık durumunun yoğun olduğu videonun test sonuçları.....	49
Çizelge 4.5. Gözlerin kapalı durumunun yoğun olduğu videonun test sonuçları.....	50
Çizelge 4.6. Test çalışmasının sonuç karşılaştırması.....	58
Çizelge 4.7. Test videosunun dikkatsizlik durumu sonuçları	58
Çizelge 4.8. Test videosunun esneme durumu sonuçları.....	59
Çizelge 4.9. Test videosunun Göz kapalılık tespiti sonuçları	60
Çizelge 5.1. Sınıflandırma için kullanılan veri tabanı dağılımı	61

1. GİRİŞ

Sürücü performansı ile ilgili durumları takip eden sistemler, karayollarında sürücülerden kaynaklanan kazaları en aza indirmek için geliştirilirler. Her sene karayollarındaki motorlu araçlar, milyonlarca kaza yaparken, binlerce insan ölmekte ve çok büyük maddi hasarlar oluşmaktadır. Dünya sağlık örgütünün (World Health Organization (WHO)), 2018 yılında yayınladığı raporunda 2000-2016 yılları arası karayollarında gerçekleşen trafik kazaları bahsedilmektedir. Bu rapora göre; karayollarında gerçekleşen trafik kazalarında, 2000 yılında 1.15 milyon, 2016 yılında ise 1.35 milyon insan hayatını kaybetmiştir (WHO 2018). 2004 tarihli raporunda ise trafik kazalarının küresel ekonomiye maliyetinin yaklaşık 500 milyar dolar olduğu belirtilmiştir (WHO 2004). T.C. Karayolları Genel Müdürlüğü (KGM)'nün, 2018 temmuz ayında paylaştığı, 2008-2017 yılları arasında gerçekleşen kazaların özetini veren rapora göreyse, sadece 2017 yılı içerisinde 1.202.716 kaza meydana gelmiştir. Son on yılda (2008-2017) gerçekleşen toplam kaza sayısı ise 11.739.138 olmuştur. Bu kazalarda, 49.656 insan hayatını kaybetmiş ve 2.569.001 insan yaralanmıştır. Bu kazaların %90.3 ü sürücülerden kaynaklı olduğu düşünüldüğünde sürücü performans takibinin önemi daha çok anlaşılmaktadır.

Çizelge 1.1. Avrupa'da bazı ülkelerde yorgun/uykulu sürücülerden kaynaklı kazalar

Ülke	%	Yıl	Kaza Nedeni	Kaza Türü
Fransa	85	2011	Yorgunluk/uykululuk	Sadece ölümlü kazalar
İspanya	45	2010	Yorgunluk/uykululuk ve dikkatsizlik	Genel
Almanya	25	2009	Yorgunluk/uykululuk	Genel
İsveç	15	2011	Yorgunluk/uykululuk	Genel
İtalya	21.9	2001	Yorgunluk/uykululuk	Genel
Finlandiya	17	2010	Yorgunluk/uykululuk	Genel
Avrupa Geneli	20-25	2013	Yorgunluk/uykululuk	Genel

Avrupa Uyku Araştırma Derneğinin 2001-2010 yılları kapsayan bir araştırmada Avrupa'daki bazı ülkelerin sürücü yorgunluğundan kaynaklı kazaların oranları çizelge 1.1'de verilmiştir (Akerstedt, ve ark., 2013).

ABD'de yapılan bir araştırmada ise 2011 yılı için oluşan kazaların %16.5 i sürücü yorgunluğundan kaynaklandığı belirtilmiştir. ABD'nin 2011 yılı motorlu karayolu taşıt kazalarının 230 milyar dolara mal olduğunu açıklamıştır (Tefft, 2012). Avrupa Birliği ise 2007 yılı için motorlu karayolu taşıtkazalarının 160 milyar dolar maliyeti olduğunu açıklamıştır (Tefft, 2012).

Dünya genelinde uykulu sürücülerin neden olduğu kaza oranları incelendiğinde %15-25 arasında olduğu anlaşılmaktadır.Tablo-1 de örnek verilen ülkelerin sundukları raporlarda sadece uykulu sürücülerin neden olduğu kaza oranları verilmiş ve bu oranlar %15-25 arasında değişkenlik göstermektedir. Ancak İspanya'nın sunduğu raporda, hem uykulu sürücülerin hem de dikkatsiz durumdaki sürücülerin neden olduğu kazalar verilmekte ve bu oran %45'tir.

Önerilen sistemde uykulu sürücü tespiti ile birlikte, dalgın ve dikkatsiz sürücü tespiti, aynı zamanda sürücü seyir süresi tespiti de yapılabilecektir. Bu nedenle önerilen sistem, karayollarında motorlu araçların yaptığı kazaların yaklaşık yarısına doğrudan ilgilidir. Geliştirilecek sistemin performans düşüklüğü esnasında sürücüyü uyararak bu sebeple meydana gelen kaza oranlarının azalmasına katkı sağlayacağı düşünülmektedir. Ayrıca ilerleyen çalışmalarda sürücü görüntülerinin ve performans verilerinin kayıt altına alınması ile sürücülerin daha bilinçli araç kullanmalarına katkı sağlayabilir. Böylece yorgun sürücülerin direksiyon başına geçmeleri noktasında caydırıcı bir etki oluşturabilir.Bu etki de göz önüne alındığında, önerilen sistem karayollarında motorlu araçların yaptığı kazaların yarısından fazlasına etki edebileceği öngörülmektedir.

Gerek akademik gerekse endüstride ürüne önüştürmüş genel çalışmalarda sürücü takip sistemleri; Sürücü sürüş tekniğinin ve reflekslerinin izlenmesi, Electroensafalografi (EEG) analizi ve görüntü işleme tabanlıdır.

EEG analizi yöntemleri, sürücüyle sürüş esnasında fiziksel temas halinde oldukları için invaziv (müdahaleci) yöntemlerdir. Örneğin EEG analizi yönteminde sürücünden EEG parametrelerinin okunabilmesi için, sürücünün başına, parmaklarına ve benzeri yerlerine EEG cihazının sinyal okuma aparatları takılmalıdır. Literatürde görüldüğü kadarıyla invaziv yöntemler kullanılarak sürüş performansının tespitinde başarılı sonuçlar alınmasına rağmen (Fluetra ve Bosmiya, 2013), müdahaleci yöntemler oldukları için tercih edilmemektedirler (Vicente ve ark., 2016).

Görüntü işleme tabanlı sistemler ise non-invaziv (müdahaleci olmayan) sistemlerdir. Görüntü işleme tabanlı sistemlerde sürücünden anlık görüntüler alan bir kamera ve kameranın bağlı bulunduğu bir veri analiz-yönetim sistemi bulunur. Buda sürücüye herhangi bir müdahalede bulunmadığı için non-invaziv olarak adlandırılır.

Sürücünün sürüş tekniğini öğrenmeye yönelik olan, sürücü sürüş tekniğinin ve reflekslerinin izlenmesi tabanlı yöntemler de, hem non-invaziv hem de invaziv grubuna girmektedir. Örneğin sürücünün direksiyon kırma hareketlerini ve/veya gaz-fren değiştirme hareketlerini gömülü bir sistemle algılayıp sürücüye müdahale etmeyebilir ki bu non-invaziv bir sistem olur. Ancak bu yöntemlerde, sistemin önce sürücünün sürüş tekniğini öğrenmesi gerekir. Bunun içinde, sürüşün başlangıçta belirli bir süresi öğrenmeye ayrılır. Bu yöntemin sakıncası, sürücü sürüşe zaten yorgun olarak başlamış olabilir.

Ancak sürücünün parmak veya eline takılan herhangi bir verici ile direksiyon hareketlerinin izlenmesi ise invaziv olarak geçer.

Ramazan ve ark.(2019), yaptıkları araştırmada sürücü yorgunluk/uykululuk tespit tekniklerini,

- 1) Davranışsal parametreye dayalı teknikler (Görüntü işleme tabanlı)
- 2) Araç parametrelerine dayalı teknikler (sürücü sürüş tekniği ve reflekslerinin izlenmesi tabanlı)
- 3) Fizyolojik parametrelere dayalı teknikler (sürücü kalp atış hızı, solunum hızı, nabız hızı vb. durumlarının izlenmesi tabanlı) olmak üzere üç gruba ayırmışlardır.

Araç Parametrelerine Dayalı Teknikler

Sürücü sürüş tekniği ve refleks takibi ile yapılan bu sistemlerde, sürücünün, hızlanma, fren yapma ve yön değiştirme gibi sürüş parametrelerinin izlenmesiyle, elde edilen yorgunluk/uykululuk tespit etme yöntemidir (Deshmukh ve ark., 2011). Bu yöntemde sürücü arabayı sürmeye başladığında, ilk olarak belli bir süre, sürücünün sürüş tekniği hafızaya alınır. Daha sonra sürücünün yapacağı hızlanma, fren yapma, yön değiştirme gibi sürüş tekniği parametreleri bu ilk veriler ile sürekli karşılaştırılır. Yorgun düşen sürücülerde daha ağır hareketler veya tam tersi daha ani hareketler olur. (Takei ve Furukawa, 2005).

Bu yöntemde sürücü yorgunluk/uykusuzluk hali ve sürücü değişikliği tespit edilebilir. Sürücü performansına etki eden dalgınlık, başka yöne bakma, telefona bakma, yemek yeme gibi durumlar ise kontrol edilemez. Ayrıca bu yöntemde sistem kurulumu araç içine müdahale şeklinde olacağından, diğer sistemlere oranla daha zordur. Yine bu sistemde her sürücünün sürüş tekniği farklı olduğundan, sisteme müdahale etmeden her sürücünün sürüş tekniğine göre yorgunluk/uykululuk tespiti yapması çok zordur. Bu sebepler göz önüne alındığında bu sistem de pek tercih edilmemiştir (Vitable ve ark., 2011). Ayrıca sürücü yorgun ya da uykulu iken ilk kez direksiyon başına geçerse veya aracı durdurup dinlenmeden tekrar hareket ederse sistem sürücünün yorgun andaki sürüş tekniği ve reflekslerini öğreneceği için yorgunluk ve uykululuk durumunda gerekli uyarıları veremeyecektir.

Fizyolojik Parametrelere Dayalı Teknikler

Bu yöntemde EEG, Elektrokardiyografi (EKG), Elektrookulografi (EOG) ve benzeri tıbbi cihazlar kullanılarak, insanların, kan akış hızı beyin aktiviteleri, kalp atış hızı gibi fizyolojik parametreleri ölçerek, uykululuk/yorgunluk tespiti yapmaya çalışılır (Pal ve ark., 2008). Bu yöntem ile uykulu sürücü tespitinde çok başarılı olunmuştur. Yöntem kullanılarak yapılan testlerde tespit yüzdesi %100'e yakın olup, diğer yöntemlere göre daha yüksektir (Hong ve ark. 2005) (Zhang ve ark., 2014). Bu yöntemde, kullanılan sistem donanımının pahalılığı ve müdahaleci (invaziv) bir yöntem olması sebebiyle tercih edilmemektedir. Sürücü uyku takibi yapmak için, fizyolojik ölçüm cihazından,

sürücünün belli vücut bölgelerine kablolar, elektrotlar vs. çekilerek, sürücüyle sürekli etkileşimde bulunulur. Bu normal sürüş şartlarına uygun olmadığından, bu tür sistemlerin gerçek hayata uygulanabilirliği açısından tercih edilmez ve gerçek sürüş ortamına uydurulması diğer yöntemlere göre çok daha zordur. Ayrıca bu yöntemde sadece sürücü yorgunluk/uykusuzluk hali tespit edilebilir. Sürücü performansına etki eden dalgınlık, başka yöne bakma, telefona bakma, yemek yeme gibi durumlar bu alandaki mevcut çalışmalar ile kontrol edilemez.

Davranışsal parametrelere dayalı (Görüntü İşleme Tabanlı) teknikler

Üçüncü yöntem ise görüntü işleme yoluyla sürücünün yüz şekli göz kapakları vb. takip edilerek uykululuk ve yorgunluk tespiti çalışmaları yapılmıştır. Yapılan araştırmalarda anlaşılmıştır ki sürücü performans takibi için en ideal çözümler non-invaziv (müdahalesiz) çözümlerdir. Fizyolojik parametrelere dayalı sistemlerin invaziv ve pahalı oluşu, araç parametrelerine dayalı tekniklerin ise zor kurulumu ve düşük performansından dolayı, hem non-invaziv hem de kolay kurulumu sahip bir çözüm sunan görüntü işleme tekniği ile yapılacak sistemin, SPTS sistemler içerisinde en uygun çözüm olacağını göstermektedir. Daha önce görüntü işleme kullanılarak bazı çalışmalar yapılmıştır. Ancak yapılan çalışmalarda, verim oranının düşük olması ve uykusuzluk tespiti, dikkatsizlik tespiti, dalgınlık tespiti, seyir süresi tespiti ve sürücü tanıma uygulamalarının ayrı ayrı projeler halinde sunulması çalışmaları yapılmıştır. Bu nedenle yapılan çalışmalar sürücü performansının takibi alanındaki ihtiyaca cevap verememişlerdir.

Bu tür çalışmalarda genel olarak standart kameralar kullanılmakla beraber, kızılötesi IR kameralar ve stereo kameralar da kullanılır. Kamerada kalite arttıkça, tespit yüzdesi de aynı oranda artmaktadır. Örneğin 30 fps'lik bir kamera ile 120 fps'lik bir kamera arasında önemli farklar oluşacaktır. Kaliteli kameralar kullanılarak, fizyolojik parametrelere dayalı sistemlerdeki yüksek tespit oranlarına yaklaşılabılır.

Bu tez çalışmasında görüntü işleme tabanlı bir sürücü performans takip sistemi önerilmektedir. Sürücüyü karşıdan görecektir şekilde yerleştirilen bir kameradan alınacak

görüntüler ile sürücünün dikkatsizlik, dalgınlık, uykululuk/yorgunluk ve sürücü seyir süresi tespiti yapılacaktır.

Bu çalışmada sürücü yüz tespiti viola-jones algoritması kullanılarak yapılacaktır. Tespit edilen yüzün durumuna göre, sistem sürücünün dikkatsiz veya dalgın olduğuna karar verecektir. Diğer yandan ise sürücünün son görüntüsü hafızada tutularak, yüz değişikliği tespit edildiğinde, bu tespit sürücü değişikliği olarak algılanacak ve sistem sürücü seyir süresi tespitini yapacaktır.

Sürücü yorgunluk/uykululuk halini tespit edebilmek için, gözlerin açık ve kapalılığı ile alakalı PERCLOS (göz kapalılık oranı) ve esneme tespiti için PERYAWN (ağız açıklık oranı) yöntemleri kullanılacaktır. Bir insanın gözlerinin, belirli bir süre içerisindeki kapalı olma oranı olan PERCLOS, çoğu sistemde uykululuk ölçü parametresi olarak kullanılır. Önerilen sistem görüntü işleme tabanlı olduğundan PERCLOS yönteminin daha başarılı olacağı düşünülmüş ve seçilmiştir. Bu çalışmada, gözleri sınıflandırmak için 1000 açık ve 1000 kapalı olmak üzere 2000 göz görüntüsü, esneme için de benzer şekilde 1000 esneme görüntüsü ve 1000 esnemey olmayan durumdaki görüntü olmak üzere 2000 görüntü ile veri tabanında toplamda 4000 görüntü kullanılmıştır. Görüntüler farklı ırk ve etnik gruplardan olmak üzere, gerek internet ortamından gerekse gönüllü olarak, 50 farklı kişiden alınmıştır. Veri tabanındaki 4000 görüntüye Gabor filtreleri uygulanarak, veri setleri oluşturulmuştur. Daha sonra bu veri setlerine çeşitli sınıflandırıcı algoritmaları uygulanarak, verimliliği en yüksek sınıflandırıcı algoritması seçilmiştir. Belirlenen algoritma ile esneme tespiti ve göz açık/kapalılık tespiti için ayrı ayrı test çalışmaları yapılmıştır. Bu testlerin ardından, PCA yöntemi kullanılarak, sürücü yüz tanıma testleri yapılmıştır. Çalışmanın son kısmında ise nihai hedef olan, sürücü performans takip sistemi için, bu çalışmalar tek uygulama içinde birleştirilmiştir.

2. KAYNAK ÖZETLERİ

King ve ark. (1998) sürücü direksiyon hareketlerini izleyerek yorgun sürücü tespiti çalışması yapmışlardır. Sistem, sürücü direksiyon hareketinden kaynaklanan, zamana dayalı, frekansa dayalı ve faza dayalı, üç fonksiyondan oluşan bir algoritma içerir. Bu fonksiyonlar;

- 1- Zamana dayalı fonksiyon; direksiyonun hareketlerinin değişim zamanları,
- 2- Frekansa dayalı fonksiyon; direksiyonun açısal hız değişimlerinin güç spektrumları,
- 3- Faza dayalı fonksiyon; direksiyon açısı ve direksiyon açısal hızı faz çizimleri, ile ilgili verileri içerirler.

Bu sistem kapalı devre halinde 17 denekle test edilmiştir. Test sonuçlarında sistem % 70.5 oranında zamanında cevap vermiş, % 17.7 oranında geç cevap vermiş ve %11.8 oranında ise yorgun sürücü tespit edilememiştir (King ve ark., 1998).

Araç parametrelerine dayalı teknikler genel olarak kurulumu pahalı ve zor olarak bilinmektedir. Bu soruna karşılık olarak, 2015 yılında Samuel ve ark. (2015) yeni bir sistem kurulumu önermişlerdir. Bu sistemde sürücü direksiyon hareketlerini algılamak için direksiyona dik olacak şekilde bir ivmeölçer yerleştirmişlerdir. Sürücünün direksiyon hareketleriyle paralel olarak ivmeölçerin farklı direksiyon açılarındaki çıktıları alınmıştır. Çıktıların uykululuk durumuyla bağlantısı hakkında bir sonuca varılamamıştır (Lawoyin ve ark.2015).

Sürücü yorgunluğu, fizyolojik değişiklikler ölçülerek de tespit edilir. Bu fizyolojik değişiklikleri ölçen birçok fizyolojik gösterge (EKG, EOG, EEG) olmasına rağmen en güvenilir yöntem EEG olarak bilinir. Sürücüler yoruldukları zaman bilinç seviyesinde değişiklikler olur. Bu değişiklikler EEG ile ölçülerek sürücünün yorulma hali saptanabilir (Lal ve Craig, 2000).

Antoine ve arkadaşları tek EEG kanalını kullanarak sürücü yorgunluk hali tespiti çalışması yapmış, bu çalışmaların sonucunda %84.2 oranında başarılı sonuçlar elde etmişlerdir (Picot ve ark., 2008).

Fizyolojik parametrelere dayalı uyku tespit yöntemlerinden birisi de EOG sinyallerini kullanmaktır. 2005 yılında, 18-26 yaşları arasında 10 farklı denekten alınan 30 adet EOG veri seti ile bir uyku tespit etme çalışması yapılmıştır. Bu çalışmada deneklerin gözlerinin alt ve üst kısımlarına Alüminyum Klorürden oluşan birer elektrot takılmıştır. Ayrıca sol kulak üzerine de gümüş bir elektrot takılmıştır. Bu elektrotlardan alınan sinyal verileri ile uyku tespiti yapılmıştır. Çalışmanın sonucunda %87.96 oranında doğru tespit yapılmıştır (Chieh ve ark., 2005).

Fizyolojik parametrelere dayalı yöntemlerin sonuçları yüksek çıksa da farklı kişilerde farklı sinyaller alınması da olağandır. 2005 yılında yapay sinir ağları kullanılarak bu sorunu çözmeye yönelik bir çalışma yapılmıştır. Bu çalışmada, sempatik sinir aktivitesi, parasempatik sinir aktivitesi ve kalp atış hızı parametreleri ölçülerek nabız hızı takip edilmiştir. Nabız hızı yanında direksiyon hareketleri de takip edilerek, sürücü uykululuk/yorgunluk tespiti yapılmaya çalışılmıştır. Bu sistem 6 denek üzerinde denenmiş ve %98 doğru tespit oranına ulaşmıştır (Hayashi ve ark., 2005).

2016 yılında yapılan bir çalışmada, fizyolojik parametrelere dayalı uykululuk/yorgunluk tespit yöntemlerinin invaziv olmasından dolayı tercih edilmediği belirtilmiş ve bu soruna karşılık olarak da invaziv olmayacak bir fizyolojik parametrelere dayalı sistem üzerinde çalışma yapılmıştır. Yapılan çalışmada otonom sinir aktivitesi, invaziv olmayacak bir şekilde, kalp atış hızı değişkenliği sinyallerinden tahmin edilmeye çalışılmıştır. Ancak düşük frekanslarda sempatik ve parasempatik aktivitelerden etkilenerek, tespit yüzdesinin iyi olmadığı söylenmiştir. Çalışma sonunda ise bu tür sistemlerin tek başına kullanılamayacağı ve görüntü işleme benzeri bir sistemle bir arada kullanılabileceği söylenmiştir (Vicente ve ark., 2016).

Li ve ark. (2015) giyilebilir teknolojiyi kullanarak, EEG tabanlı bir uykululuk/yorgunluk tespit sistemi geliştirmişlerdir. Ticari bir kol saatine kuru elektrot sensörleri yerleştirilerek bu sensörlerden EEG sinyalleri okunup Sürücünün

uykululuk/yorgunluk hali saptanmaya çalışılmıştır. Yapılan yapay sürüş ortamı testlerinde deneklerin ellerini oynatmasından (saçlarıyla oynaması ve yüzünün herhangi bir bölgesiyle oynaması vb.) dolayı erken uyarı verme, ayrıca yüksek frekanslarda hatalı çıkışlar almışlardır. Ancak bu sorunlara rağmen %90'lık bir doğru tahmin oranına ulaşmışlardır.

Williamson ve Chamberlain (2005) sürücü yorgunluk tespiti üzerine yaptıkları araştırmada, sürücü yorgunluğunu tespit etmek için en tatmin edici sonuçları veren yöntemlerin, görüntü işleme yöntemleri ve EEG yöntemleri olduğunu belirtmişlerdir. Araştırma sonucunda, görüntü işleme yöntemlerinin non-invaziv olmasından dolayı, EEG yöntemlerine göre daha çok tercih edildiği söylenmiştir.

Fluetra ve Bosmiya (2013) var olan sürücü yorgunluk/uykululuk tespit teknikleri üzerine bir araştırma yapmışlardır. Bu araştırmada sürüş tekniğinin karmaşıklığından ve tespit oranının çok yüksek olmadığından dolayı, en az kullanılan yöntem olduğuna değinilmektedir. EEG yönteminin ise güzel sonuçlar vermesine rağmen invaziv olmasından dolayı gerçek bir proje veya sistemde kullanılmadığı belirtilmiştir. Bir diğer yöntem olan görüntü işleme yönteminin ise kullanıcıya yönelik olması ve sistem kurulumunun basit olmasından dolayı en çok tercih edilen sürücü yorgunluk/uykululuk tespit yöntemi olduğu sonucuna varmışlardır.

Davranışsal parametrelere dayalı sistemler yani görüntü işleme tabanlı olarak bildiğimiz sistemlerde yapılan çalışmalar, genel olarak düşük hızlardaki (30 fps) kameralar kullanılarak yapılır. Ancak yüksek hızlardaki (100fps-200fps) bir kameranın kullanılması ve bu hızdaki bir kamera ile uyumlu bir donanım ve algoritma geliştirilirse, görüntü işleme tabanlı yöntemler, Fizyolojik parametreye dayalı tekniklerde olan yüksek doğruluk oranlarını yakalayabilir (Antoine ve ark., 2009).

Yukarda anlatılan soruna karşılık Taner ve ark. (2010) ortalamanın üzerinde hızı olan 110 fps'lik bir web kamera kullanarak sürücünün göz hareketlerinden sürücü uykululuk/yorgunluk tespiti yapmışlardır. Sistemleri, gözün yatay konumu kullanılarak, kameranın gözdeki değişiklikleri takip etmesiyle çalıştığı açıklanmıştır. Laboratuvar

ortamında yapılan testlerde, kameranın ortalamanın üzerinde bir hızda olmasının da etkisiyle, %94 doğru tespit oranına ulaşıldığı belirtilmiştir.

Vural ve ark. (2007-2008) Davranışsal parametrelere dayalı ve Araç parametrelerine dayalı uykululuk/yorgunluk tespiti üzerine bir dizi çalışma yapmışlardır. 2007 yılındaki ilk çalışmada, sürücünün yüz hareketlerinden ve direksiyon hareketlerinden uykululuk/yorgunluk tespiti yapmışlardır. Bu çalışmada sürücünün yüz hareketlerini, sürücüyü karşıdan gören bir kameradan, Facial Action Coding System (FACS) olarak bilinen Yüz Hareketleri Kodlama Sistemini kullanmışlardır. Sürücünün direksiyon hareketlerini izlemek için ise direksiyon üzerine yerleştirilen bir ivmeölçer aracılığıyla takip etmişlerdir. Verilerinin %20 sini test, %80' ini ise eğitim için ayırmış, sonuç olarak ise gerçek olmayan sürüş ortamında yapılan testlerde, geliştirdikleri sistem %94 oranında doğru çıktı vermiştir. 2008 yılında ise yüz hareketlerinden 30 farklı veri seti alıp bunlarla makine öğrenmesi tekniğini kullanarak sürücü uykululuk/yorgunluk tespiti çalışması yapmışlardır. Bu çalışmada gerçek olmayan sürüş ortamında %96 doğruluk oranıyla, bu çalışmanın öncesinde yapılan çalışmalar arasında sürücü uykululuk/yorgunluk tespit oranı en yüksek çalışmadır.

Hong ve Qin (2007) daha önce yapılan çalışmaların, yüz şekilleri ve göz büyüklükleri değiştikçe ve sürücü yüzünü oynattıkça hata oranının arttığına dikkat çekip, bu soruna karşılık yüz takibi için güvenilir ve sağlam bir algoritma geliştirilmesi gerektiğini savunarak bu soruna karşılık bir çalışma yapmışlardır. Çalışmaları sonucu geliştirdikleri sistem uykululuk tespiti için;

- 1-Yüz tespiti,
- 2-Göz bölgesi tespiti,
- 3-Göz durumu tespiti,
- 4-PERCLOS hesaplanması,
- 5-Uykululuk hali belirlenmesi,

olmak üzere 5 aşamalı bir şekilde ilerlemektedir. Sistem tasarımı iyi olsa da araştırmacıların test için kullandıkları görüntülerin normalden fazla küçük olmasından dolayı, test sonuçlarından iyi sonuçlar alınamamıştır.

Rahman ve ark. (2015) görüntü işleme tabanlı sürücü uykululuk/yorgunluk tespiti çalışmalarında, iki farklı çözünürlükteki kamera arasındaki sonuç farklarını ortaya çıkarmışlardır. Bu çalışmada Viola-Jones algortimasını kullanarak yüz tespiti yapmış, tespit edilen yüzden ise Viola-jones Cascad sınıflandırıcısını kullanarak göz bölgesi çıkarımı yapmışlardır. Tespit edilen gözün, açık kapalılık durumu içinse Harris köşe dedektörü (Harris Corner Detection-HCD kullanılmıştır. Çalışmada dikkat çeken kısım, iki farklı çözünürlükteki kamerayla yapılan testlerin sonuçları Çizelge 2.1 ve Çizelge 2.2’de gösterilmiştir.

Çizelge 2.1. 16 MegaPiksel çözünürlüklü kamera ile yapılan testlerin sonucu

Aydınlatma	Doğruluk oranı
Normal	%94
Kötü	%12.5
Parlak	%87.5

Çizelge 2.2. 2 MegaPiksel çözünürlüklü kamera ile yapılan testlerin sonucu

Aydınlatma	Doğruluk oranı
Normal	%0
Kötü	%0
Parlak	%69

Test sonuçlarına göre, yüksek çözünürlüklü kamera ve normal aydınlatma altında yapılan testlerde, %95 ile yüksek bir doğruluk oranı yakalanmıştır. Yüksek çözünürlüklü kamera ve düşük aydınlatma altında yapılan testlerde, bu oranın sıfıra yaklaştığı görülmektedir. Düşük çözünürlüklü kamera ile yapılan testlerde, aydınlatma yüksek olmadığı sürece, algılama oranı 0’dır. Bu testlerde anlaşılmaktadır ki, kamera çözünürlüğünün, sonuçlara önemli bir etkisi vardır.

Ji ve Yang (2002), bir CCD kamera kullanarak geliştirdikleri Görüntü işleme tabanlı sürücü uykululuk/yorgunluk ve dikkatsizlik takibi sistemin, tatmin edilir düzeyde doğru sonuçlar verdiğini ve bu sistemin güvenli olduğunu savunmuşlardır. Sistem sürücünün yüz yönünü ve göz kapağı hareketini izleyerek sürücünün uykululuk/yorgunluk ve

dikkatsizlik durumunu tespit etmeye çalışır. Daha önce yapılan benzer çalışmalara farkla bu çalışmada sürücü dikkatsizliği için yüz takibinden dikkatsizlik tespiti eklenmiştir. Ek olarak sistemin gerçek zamanlı çalışması planlansa da sistem 15 fps ile 300 MHz hızında çalıştırılmıştır. Ayrıca her ne kadar sistemin yüksek doğruluk oranında çalıştığı ve güvenilir olduğu belirtilse de, çalışmanın çıktıları hakkında net bir bilgi verilmemiş, sistemin sayısal olarak, doğruluk hassasiyetiyle ilgili bir sonuç açıklanmamıştır.

Mandal ve ark. (2016) sürücü uykululuk/yorgunluk tespiti için spektral regresyona dayalı, göz açıklık seviyesini tahmin etmeye yönelik bir çalışma ve birden fazla modele uygulanabilecek göz durumunu tahmin etmeye yönelik bir füzyon algoritması önermişlerdir. Araştırmacılar bu sistemin, özellikle yüzü karşıdan net görünmeyen sürücünün eğik ve yandan görüntülerinde başarılı sonuçlar verdiğini belirtmişlerdir. Sistem otobüs sürücülerine yöneliktir ve test için dokuzar dakikalık 15 farklı video kullanılmıştır. Araştırmacılar bazı videolarda sınıflandırma hatalarının olduğunu söylemiş ve test sonuçlarını da kaynak belirtmeden diğer sistemlerle karşılaştırmalı olarak vermişlerdir. Araştırmacılar normal görüntülerde kendi sistemlerinin %85.02 diğer sistemlerin %95.18 olduğunu ve eğik görüntülerde ise kendi sistemlerinin tespit yüzdesinin %63.50, diğer sistemlerin ise %59.52 olduğunu belirtmişlerdir.

Ji ve ark. (2004) gerçek zamanlı bir sürücü uykululuk/yorgunluk ve dikkatsizlik analizi çalışması yapmışlardır. Bu çalışmada, farklı etnik kökenlerden ve farklı yaş gruplarından oluşan 13620 görüntülük bir veri tabanı kullanmışlardır. Uykululuk durumu tespiti için PERCLOS yöntemi kullanılan çalışmada, test görüntülerindeki göz bölgelerinin elle girildiği belirtilmiştir. Bu çalışmanın test sonuçlarında doğruluk oranı %95.8 olduğu söylenmiştir.

Gözün kapalılık durumunu takip etmek için birçok algortima ve yöntem önerilmiştir. Liu ve ark. (2010) göz bölgesini takibi için iyi bir performans sergileyeceğini savunduğu yeni bir yöntem sunmuştur. Bu yöntemde yüz ve göz bölgelerinin tespiti ve takibi için, basamaklı sınıflandırıcılar algoritmasını ve elmas arama algoritmasını kullanarak, sürücü uykululuk/yorgunluk tespiti çalışması yapmıştır. Ayrıca alınan göz kapağı bilgilerinden, sürücünün uykululuk/yorgunluk durumuna karar vermek için;

- 1- Göz kapağının kapalı kalma süresi,
- 2- Üst üste göz açıp kapama sayısı,
- 3- Göz açma-kapama süresi,

olmak üzere 3 aşamalı bir yöntem önermiştir. 10 denek ile yapılan laboratuvar ortamı testlerinde tespit yüzdesinin %98 çıktığı söylenmiştir.

Görüntü işleme tabanlı yöntemlerde kameranın doğru görüş açısı için ilk kurulumda kalibre edilmesi gerekebilir. Bu soruna karşılık yapılan bir çalışmada IR kamera kullanarak kalibre ihtiyacının olmayacağı savunularak, bir IR kamera araç gösterge paneli bölgesine yerleştirilerek sürücü uykululuk hali tespiti çalışması yapılmıştır. Kamera aracın ön gösterge panel bölgesine yerleştirilir ve PERCLOS yöntemini kullanarak sürücünün uykululuk halini saptamaya çalışır. Gerçek sürüş ortamından alınan verilerle yapılan testlerde tespit yüzdesi %79.84 olarak ölçülmüştür. Araştırmacılar sistemin arabaya başlangıç tasarımı (üretim aşamasında) monte edilmesi gerektiğini belirtmişlerdir (Garcia ve ark.,2012).

Fan ve ark. (2007) davranışsal parametrelere dayalı (görüntü işleme tabanlı) sürücü uykululuk/yorgunluk sistemlerine, esneme takibi ile sürücü uykululuk/yorgunluk takibi adında yeni bir yöntem eklemişlerdir. Geliştirilen yöntemde, bir CCD kameradan alınan görüntülerden, Gravity-Center yöntemi ile yüz tespiti ardından ağız kenarları Gabor dalgacıklarını kullanarak doku analizi yapmaktadır. Buradan ağız bölgesi durumu takibi yapılırken sürücünün esneme durumu tespit edilmeye çalışılır. Esneme tespiti ile sürücü uykululuk tespitinde ilk olan bu çalışmanın testleri için 20 farklı videodan 400 görüntü, veri seti olarak kullanılmıştır. Test için 10 normal görüntü ve 10 esneme durumundaki görüntülerden kullanmışlardır. Test sonuçlarında ise normal durum tespitlerinde tanıma oranı % 74.5, esneme durumu tespitlerinde ise tanıma oranı ise %69.5'tir.

Omidyeganeh ve ark. (2011) davranışsal parametrelere dayalı uykululuk/yorgunluk tespiti sistemlerine, var olan iki yöntemi (esneme takibi ve göz takibi) birleştirerek, yeni bir çalışma eklediler. Bu sistemde, sürücünün esneme ve PERCLOS takibini yapan, füzyon tabanlı bir uygulamadır. Çalışmada test için 30fps hızla, 10 ayrı videodan 10.000 görüntü kullanılmıştır. Araştırmacılar, deneylerinin sonucunda, önerdikleri sistemin

yüksek verimlilik gösterdiğini savunsalar da, çalışma sonucuna dair sadece %98'lik yüz tespit yeteneğine dair bilgiler vardır.

Son yıllarda görüntü işleme tabanlı çalışmaların artmasıyla, çeşitli programlar, görüntü işlemeye yönelik uzun işlemleri kısaltan, geliştiricileri uzun kod yüklerinden kurtaran, çeşitli araç ve kütüphaneler sunmuşlardır. Bunlardan MATLAB en bilinenlerdendir. Ahmad ve Boroli (2015) MATLAB görüntü işleme araçlarını kullanarak bir sürücü uykululuk/yorgunluk tespiti çalışması yapmışlardır. Yüz, göz ve ağız tespiti için MATLAB'ın kaskad nesne tanımlayıcısını (Cascad Object Identifier) kullanarak, göz kapalılık durumunu ve esneme durumunu takip ederek uykululuk/yorgunluk tespiti çalışması yapmışlardır. Bu çalışmada 1000 görüntü ile iki ayrı donanımda testler yapılmıştır. Bu iki ayrı donanımın sonuçları Çizelge 2.3'te verilmiştir.

Çizelge 2.3. İki ayrı donanımdan (sistemden) elde edilen sonuçlar

Parametreler	Sistem-1	Sistem-2
Yüz yakalama oranı	%89	%96
Göz ve ağız yakalama oranı	%86	%96
Uykulu sürücü tespit yüzdesi	%89	%95
İşlem süresi	>10s	2s

Testlerde kullanılan ilk donanımda 4GB RAM'i olan bir kişisel bilgisayar ve görüntüleri almak için de, VGA girişli bir web kamera kullanılmıştır. İkinci donanımda ise 8 GB RAM'i olan 3MP USB girişli bir web kamera kullanılmıştır. Tablo-2 'de ki sonuçlara bakıldığında donanım farkı ile net sonuçlar elde edebilebileceği de açıkça görülmektedir.

Son yıllarda yapılan çalışmalar incelendiğinde, görüntü işleme tabanlı uykululuk/yorgunluk tespiti çalışmalarında, daha çok makine öğrenmesi teknikleri kullanılmıştır. Kumar ve Patra (2018), yaptıkları çalışmada, göz en-boy oranı, Ağız açıklık oranı ve burun uzunluk oranını ölçüp, bu ölçüm değerlerine uygun eşik noktaları belirleyerek uykululuk/yorgunluk tespiti yapmaya çalışmışlardır. Göz en-boy oranı belli bir eşiğin altında ise gözler kapalı sayılacak, ağız açıklık oranı belli bir eşiğin altında ise

sürücü esneme durumunda sayılacak ve burun da belli bir eşiğin altında ise sürücü yola bakmıyor sayılacak. Bu çalışmalarında web kamerası kullanan çalışmacılar, tespit işlemlerinde makine öğrenmesi uygulamışlardır. Destek Vektör Makinesi (Support Vektor Machine-SVM) kullanarak yaptıkları sınıflandırmanın %95.58'lik bir hassasiyet oranına sahip olduğunu belirtmişlerdir. Çalışmacılar veri tabanlarını, araç sürücülerinin yüz video ve resimlerinden oluşan, IVERDRIFAC veri seti diye bilinen veritabanından, 6 farklı sürücü videosu olarak oluşturmuşlardır. Aldıkları görüntülerin üçte ikisini eğitim için kullanmış, kalan üçte birlik kısmını ise algoritmalarını test etmek için kullanmışlardır. Sınıflandırma için, Bayesian sınıflandırıcısını, Fisher' in doğrusal ayırt edici analizi ve doğrusal çekirdekli destek vektör makinesini kullanmışlardır. En yüksek hassasiyete, Bayesian sınıflandırıcısı ile ulaştıklarını söyleseler de, bu sınıflandırıcının özgüllüğünün çok düşük (%57) olduğunu belirtmişlerdir. Fisher'in doğrusal ayırt edici analizi ile yapılan sınıflandırmada hassasiyetin %89.6 ve özgüllüğün %100 olduğunu belirtmişlerdir. Destek vektör makinesi ile yapılan sınıflandırmanın %100 özgüllük ve %95.6 hassasiyet oranı ile sistemleri için, en uygun sınıflandırıcı olduğunu belirtmişlerdir.

Akı (2017) doktora çalışmasını görüntü işleme tabanlı sürücü uykululuk/yorgunluk takibi üzerine yapmıştır. Bu çalışmada 4 gönüllü denekten 1077 görüntü alınarak bir veri tabanı oluşturulmuştur. Bu görüntülerden 548 inde gözler açık durumda, 529 unda ise gözler kapalı durumdadır. Veri tabanındaki bu görüntülere Gabor filtreleri uygulanarak 13 adet öznitelik çıkarılmıştır. Bu 13 adet öznitelikten, makine öğrenmesi uygulaması için veri setleri oluşturulmuştur. Bu çalışmada gözlerin kapalılık oranı olarak PERCLOS kullanılmış, ayrıca gözlerin kapalılık süresinin bir ölçüm değeri olarak CLOSDUR (Closed Duration: kapalılık zamanı) parametresi kullanılmıştır. Oluşturulan algoritmada ise Makine öğrenmesi uygulanarak görüntülerin 24 fps hızında işlendiği söylenmiştir. Çalışmada sınıflandırıcı olarak çeşitli sınıflandırıcılar (Naïve Bayes, IBk, J48, SVM, Voted Perceptron) kullanılmış, bu sınıflandırıcılar arasında uygulama için en iyi performansı J48 algoritmasının gösterdiğini belirtilmiştir. Sınıflandırma da %90 başarı elde edildiği belirtilmiştir. Ancak çalışmada ayrıca bu hızın, özniteliklerin 10 'unu kullanılarak elde edildiği, 20 öznitelik kullanımı durumunda ise 21 fps 'lik bir hıza düşüldüğü belirtilmiştir. Kolerasyon işlemi sonunda

ise 13 özniteliğin kullanıldığı belirtilmiştir. Araştırmacının, kendi çalışmasını, saniyede işlenen çerçeve (Frame per second-fps) hızı üzerinden, diğer uygulamalar ile karşılaştırdığı bir tablo aşağıda verilmiştir.

Çizelge 2.4. Real-Time bazında benzer çalışmalarla kıyaslanması (Akı, 2017)

Görüntü işleme yöntemi	Makine öğrenmesi algoritmaları	Ölçülen büyüklük	FPS
*Gabor Filtreleri	Naïve Bayes, IBk, J48, SVM, Voted Perceptron	PERCLOS CLOSDUR	24**
Gabor filtreleri	Temel bileşen analizi (PCA), Gizli Markov modelleri (HMM)	Esname	19
Viola Jones detektörü, Belirgin noktalar analizi (SPA)	-	PERCLOS BLINK Esname	16,5
Yerel ikili desenler (LBP)	Destek vektör makinaları (SVM)	PERCLOS	12
Ters perspektif eşleştirme (IPM)	-	PERCLOS BLINKFREQ Yol şeritleri	6
Temel bileşen analizi (PCA)	Temel bileşen analizi (PCA)	PERCLOS	6
Viola Jones detektörü, Blok yerel ikili desenler (LBP) histogram özellik çıkarımı	İstatistiksel öğrenme yöntemi (PLS), Destek vektör makinaları (SVM)	PERCLOS	3


(*) Çalışmada geliştirilen gerçek zamanlı uygulama. (**) FPS değeri, ekran çıktılarının gösterilmediği, normal çalışma durumunda ölçülmüştür.

3. MATERYAL ve YÖNTEM


Görüntü işleme tabanlı sistemler için sunduğu çeşitli kütüphane ve araçlardan dolayı, MATLAB ortamında çalışılmıştır. Veri tabanındaki görüntüleri, Viola-jones cascaded dedektörü kullanılarak sürücü yüz ve göz tespiti yapılmıştır. Tespit edilen yüz ve göz görüntülerine Gabor filtreleri uygulanarak öznitelikler çıkarıldı. Bu özniteliklerden oluşan veri setlerine çeşitli sınıflandırıcılar uygulanarak en uygun sınıflandırma algoritması belirlenmiştir. Sınıflandırma algoritmalarını uygulamak için, ücretsiz bir veri madenciliği çalışma ortamı olan Weka programı kullanılmıştır. Sürücü seyir süresi belirlemek için, ilk çalışma anında sürücünün kimlik tespiti (yüz tanıma) yapıldı. Bunun içinse PCA (PCA-Principal Component Analysis) yöntemi kullanılmıştır.

3.1. Viola-Jones Algoritması

Uzun zaman boyunca bilgisayarlı görü sistemlerinde nesne tespiti için bir çok çalışma yapılmıştır. Viola ve Jones, (2001) tarafından geliştirilen yüz yakalama dedektörü bu alanda ilk başarılı çalışmalardan sayılır. Literatürde Viola-Jones algoritması olarak da bilinir. Bu algoritma, büyük veri setlerinde, yavaş çalışma sorununa karşı, az sayıda özellik kullanarak hızlı sonuçlar almak için kullanılır (Bayrakdar ve ark. 2017). Viola-Jones dedektörü, Haar-cascade dedektörü fonksiyonlarının benzerini kullanır. Haar-cascade dedektöründen farklı olarak, görüntünün özelliklerini çıkaran 24x24 çözünürlüğünde, dört adet dikdörtgen kullanır. Şekil 3.1 'de Haar-benzeri özellikler ve şekil 3.2 'de ise viola-jones dedektöründe kullanılan dört adet dikdörtgen verilmiştir.




Şekil 3.1. Haar-benzeri özellikler (Ayvaz ve Gürüler, 2017)



Şekil 3.2. Viola-Jones dedektöründe kullanılan dikdörtgenlerin özellikleri (Viola ve Jones, 2001)

Şekil 3.2’ de A ve B ikili dikdörtgenlerinde, kendi içlerindeki dikdörtgenlerde bulunan pikselleri toplayarak, bu toplamların farkını alır. C dikdörtgeninde ise kenarda kalan iki dikdörtgen içindeki piksellerin toplamı ile ortadaki dikdörtgen içinde kalan piksellerin toplamının farkını alır. D dikdörtgeninde ise çaprazda kalan dikdörtgenlerdeki toplam piksellerin farkını alır. A, B, C ve D dikdörtgenleri, Şekil 3.3’te gösterildiği gibi görüntünün üzerinden kaydırılarak, görüntü özellikleri çıkarılır.




Şekil 3.3. Görüntünün özelliklerini çıkaran dikdörtgenlerin görüntü üzerine uygulanması (Viola ve Jones, 2001)

Viola-Jones dedektörü görüntü özelliklerini çıkarmadan önce, verimliliği arttırmak için, görüntüye integral imaj uygular. İntegral imaj, görüntü $\{x,y\}$ konumunda olması koşulu ile, $\{x,y\}$ koordinatlarının üzerinde ve solunda kalan piksellerin toplanması ile bulunur. Bunun için;

$$i(x, y) = \sum_{x' \leq x, y' \leq y} i(x', y') \quad (3.1)$$

eşitliği kullanılır. (3.1) eşitliğinde, $i(x,y)$ ifadesi, integral imajı temsil eder.

Görüntüye integral imaj uygulandıktan sonra, görüntünün özellikleri çıkarılır. Ancak, bu özelliklere ait veriler çok büyük boyutlara ulaşacaktır. Viola-jones algoritması bu soruna karşılık olarak, Adaboost öğrenme algoritmasını kullanır. Adaboost öğrenme modelinde, zayıf örnekler bulunur ve bu örnekler birleştirilerek, basit ve güçlü bir sınıflandırıcı oluşturulur. Algoritmada her örneğin bulunması bir iterasyona denk gelmektedir. İterasyon sayısı arttıkça süre uzar, doğruluk oranı artar. Bu algoritma, nesne bulmak için görüntüye uygulandığında, görüntünün arka planını hızlı bir biçimde atarak nesne benzeri bölgeleri kademeli olarak hesaplar. Şekil 3.4'te bunun bir modellenmesi gösterilmiştir.



Şekil 3.4. Viola-Jones Algoritmasının mantık şeması (Viola ve Jones, 2001)

Şekil 4 'te algoritmanın ilk üç iterasyonu modellenmiştir. Burada F, her iterasyondan sonra elenen negatif (nesne olmayan) bölgelerdir. T ise her iterasyondan sonra elde kalan bölgeye karşılık gelir. Algoritmada ilave iterasyonlar ve işlemler eklenerek, nesne tespit yüzdesi de arttırılabilir.

3.2. Gabor Dalgacık Dönüşümleri

Gabor filtrelerini, ilk olarak Denis Gabor ortaya koymuştur (Derpanis, 2007). Gabor dalgacık dönüşümü (GDD), farklı frekans ve açılarda görüntü çıkarımı için kullanılmaktadır. Bu özelliği ile insan görme sistemine benzetilen GDD, görüntü işleme uygulamalarında sıkça kullanılmaktadır (Çalışkan ve Ertuğrul, 2015). Gabor dalgacıkları ilk olarak ortaya konulduğunda tek boyutlu iken, daha sonra görüntü işleme alanında kullanılma amacıyla iki boyutlu Gabor dalgacıkları geliştirilmiştir. Örnek bir $M[x, y]$ matrisine sahip görüntü için gabor filtrelerinde ana fonksiyonu:

$$g(x, y; \lambda, \theta, \psi, \sigma, \gamma) = \exp\left(-\frac{x'^2 + \gamma^2 y'^2}{2\sigma^2}\right) \exp(i(2\pi \frac{x'}{\lambda} + \psi)) \quad (3.2)$$

denklemini ifade edilir. Denklem (3.2) ile hesaplama sonucu reel olmayacağından, elde edilen sayının reel ve sanal kısmı ayrı ayrı hesaplanabilir. Bunun için;

$$g(x, y; \lambda, \theta, \psi, \sigma, \gamma) = \exp \left(-\frac{x'^2 + \gamma^2 y'^2}{2\sigma^2} \right) \cos \left(2\pi \frac{x'}{\lambda} + \psi \right) \quad (3.3)$$

$$g(x, y; \lambda, \theta, \psi, \sigma, \gamma) = \exp \left(-\frac{x'^2 + \gamma^2 y'^2}{2\sigma^2} \right) \sin \left(2\pi \frac{x'}{\lambda} + \psi \right) \quad (3.4)$$

denklemleri kullanılabilir. Bu denklemlerde

ψ , faz açısını,

σ , standart sapmayı,

λ , görüntünün dalga boyunu,

γ , ana fonksiyonun oluşturduğu eğrinin en/boy oranı,


θ ise yönelim açısını temsil etmektedir.

Denklemlerde verilen x ve y değerlerinin hesaplamak içinse;

$$x' = x \cos \theta + y \sin \theta \quad (3.5)$$

$$y' = -x \sin \theta + y \cos \theta \quad (3.6)$$

denklemleri kullanılır. 8 farklı açı ve 5 farklı dalga boylarındaki gabor dalgacıklarının, genlik çıktıları şekil 3.5 'te görülmektedir.



Şekil 3.5. Farklı açı ve dalga boylarındaki Gabor dalgacık genlikleri

3.3. PCA (Principal Component Analysis) Yöntemi ile Yüz Tanıma

Temel bileşenler analizi, karmaşık ilişkili parametreler içeren, çok boyutlu verileri, küçük boyutlara indirgenerek kullanılmasına imkan veren bir yöntemdir (Yazar ve ark. 2009). Bu perspektiftan bakıldığında PCA, yüz tanımlamada kullanıldığında, hızlı kolay ve kabul edilebilir sonuçlar vermektedir.

PCA ile yüz tanımda özyüz (eigenface) metodolojisi kullanılır. Bu metodoloji ilk olarak Sirovic ve Kirby tarafından kullanılmıştır (Sirovich ve Kirby, 1987). Kullanılan temel bileşenler analizi, temelde bileşenlerin varyans - kovaryansının hesaplanmasına dayanır. Yüksek varyanslı değişkenler seçilip, temel bileşenler oluşturularak, bu bileşenler sayesinde daha az değişken ve değişkenler arasındaki ilişkiler kullanılarak boyutlar küçültülebilir (Kaufman ve Breeding, 1976).

Türk ve Pentland (1991), özyüz metodolojisini kullanarak, yüz tanımda en etkili yöntemlerden birisini geliştirmişlerdir. Veri tabanını çok çeşitli ve büyük tutan çalışmacılar, %96'ya kadar doğruluk oranları yakamışlardır. Özyüz metodolojisinde, ilk olarak veri matrisi hazırlanır. M adet resimden oluşan veri tabanında, bu her resmin de N vektörüne sahip olduğunu düşünersek, A veri matrisi;

$$A = [x^1, x^2, x^3, x^M] \quad N \times M \quad (3.7)$$

Eşitliği ile ifade edilir. Burada x^m her bir resmi ifade eder. Veri kümesinin matrisi hazırlandıktan sonra, veri tabanındaki resimlerinin ortalaması alınarak standardize edilir. Bunun için;

$$B = \frac{1}{M} \sum_{n=1}^M x^n = \begin{bmatrix} B^1 \\ \vdots \\ B^N \end{bmatrix} \quad (3.8)$$

eşitliği kullanılır. Burada B veri setinin ortalamasıdır. Yüz ortalaması bulunduğundan sonra her resim için, eşitlik 3.9 kullanılarak normalize edilir. Oluşan bu yeni sonuçlar, veri seti matrisinden çıkarılarak, veri seti matrisinin (A) ortalaması (A') bulunur. Bunun için eşitlik 3.10 kullanılır.

$$C^i = x^i - B \quad (3.9)$$

$$A' = \begin{bmatrix} C_1^1 - B^1 C_1^2 - B^1 \\ \vdots \\ C_N^1 - B^N C_N^2 - B^N \end{bmatrix} \quad (3.10)$$

A' matrisinin ortalaması sıfırdır. Bir sonraki adımda bu matrisin kovaryans değeri;

$$D = \frac{1}{M} \sum_{n=1}^M C_n C_n^T = A' A'^T \quad (3.11)$$

Eşitliği ile hesaplanır. Bu kovaryans matrisi kullanılarak öz değerler hesaplanabilir. Bu hesaplamayı yapmak içinse;

$$Dv = av \quad (3.12)$$

eşitliği kullanılır. Burada a , C matrisinin öz değeri, v ise öz değerle ilişkili olan öz vektördür. Bu özdeğerler hesaplandığında, bir Y sütun matrisi oluşturulur. Bu matris öz değerlerin büyükten küçüğe doğru dizilmesiyle oluşturulur. Bu öz değerlerden önemli olanları seçilerek, öznitelik matrisi oluşturulur. Öznitelik seçimi için, eşitlik 3.13 kullanılarak iz düşüm matrisi bulunur.

$$W = u^T x A' \quad (3.13)$$

W öznitelik matrisi, u ise öz değeri yüksek olan öznitelik matrislerinin transpozudur. Hesaplama ve tanımlama işlemi tamamlandıktan sonra özyüz metodolojisinde bir sonraki adım olan tanıma işlemine geçilir. Bunun için eşitlik 3.14 kullanılarak, test görüntüsü ile öz değerler aralarındaki farklar, W_t matrisi oluşturulur.

$$b_n = u_n^T (N - B) \quad (3.14)$$

$$T = ||W_t x W||^2 \quad (3.15)$$

Bu matrisin eşitlik 3.15 'teki öklid uzaklığı kullanılarak, yüz tanıma işlemi gerçekleşir.

3.4. Makine Öğrenmesi

Makine öğrenmesi; çeşitli verileri girdi olarak alan, bu girdileri sınıflandıran ve tahmine dayalı olarak, belirli aralıklarda kabul edilebilir çıktılar üreten algoritmalar. 1960’larda ortaya çıkan makine öğrenmesi yaklaşımı günümüzde, çoklukla yapay zeka çalışmalarında kullanılmaktadır. Makine öğrenmesi; Denetimli öğrenme, Denetimsiz öğrenme ve Pekiştirmeli öğrenme başlıkları altında incelenir (Bilgin, 2018).

Denetimli Öğrenme, girdileri ve çıktıları belli olan, makine öğrenmesi yöntemidir. Bu yöntemde girdi ve çıktılar arasındaki ilişkiyi programlayıcı tarafından hazırlanan bir program sağlar. Girdi veya çıktılarıdaki hatalara göre programlayıcı çeşitli değişiklikler yapabilir. Denetimli öğrenme kendi içinde sınıflandırma, regresyon ve tahmin bölümlerinden oluşur. Örneğin iki ayrı veriyi ayırtıracak bir algoritma oluşturulacağını varsayalım. Sınıflandırma, girdi verilerini kategorize eder. Regresyon ise değişkenler arasındaki ilişkiyi analiz eder. Son olarak tahmin ise önceki verileri, yeni verileri referans alarak, bu yeni verilerin eğilimlerini tahmin etmeye çalışır (Bilgin, 2018).

Denetimsiz Öğrenme; mevcut verileri analiz ederek ilişkileri ve çıktıları belirler. Veri çıktıları kontrol edecek veya çeşitli düzenlemeler yapacak bir programlayıcı (operatör) yoktur. Denetimsiz öğrenme zamanla verileri işledikçe, veri analiz yeteneği gelişen ve doğru çıktı üretme kabiliyeti artan makine öğrenmesi yöntemidir.

Pekiştirmeli öğrenme; etkisiz girdilerin ve parametrelerin yeniden değiştirilerek farklı varyasyonlarda en uygun algoritmayı ve girdi kümesini belirlemeye çalışır. Etkisiz veya düşük düzeylerde etki eden parametre veya girdiler belirlenerek, bunlar çıkarılır. Bu şekilde hızlı bir algoritma ile kabul edilebilir aralıklarda çıktılar üretilmesi hedeflenir (Bilgin, 2018).

3.6. Sınıflandırıcılar

Makine öğrenmesi için çeşitli makine öğrenmesi algoritmaları (sınıflandırıcılar) geliştirilmiştir. Bu algoritmaların uygunluğu, girdi ve çıktılarına göre değişebilirler. Önceden hangi algoritmanın en uygun olduğunu saptamak çok zordur. Genelde aynı

girdi ve çıktılar üzerinde çeşitli sınıflandırıcılar kullanılarak en uygun olanı seçilmeye çalışılır. Literatürde bir çok veri sınıflandırma algoritması olduğundan biz sadece en bilinenlerden ve görüntü işleme alanında da sık kullanılan sınıflandırmalardan bazılarını ele alacağız.

3.6.1. Bayes sınıflandırıcı

Bayes sınıflandırıcılar, Bayes teoremini kullanan istatistik tabanlı sınıflandırma yöntemidir. Bu sınıflandırıcılarda her bir özelliği diğer özelliklerden bağımsız olarak sınıflandırır ve olasılığa bağlı olarak tahmin yürütmeyi sağlar.

Bayes sınıflandırıcılar, diğer sınıflandırıcılara oranla daha az karamşık ve varsayımlar reel olmamasına rağmen, en başarılı ve en çok kullanılan sınıflandırıcılardan birisidir (Kaynar ve ark., 2017). Bayesi teoremi aşağıdaki denklem (3.4) ile ifade edilir.

$$P(A|B) = \frac{P(B|A).P(A)}{P(B)} \quad (3.16)$$

Burada;

$P(A)$; A durumunun olma olasılığı,

$P(A|B)$; B durumu gerçekleştiğinde, A olayının olma olasılığı,

$P(B)$; B durumunun olma olasılığı,

$P(B|A)$; A durumu gerçekleştiğinde, A olayının olma olasılığı olarak verilir.


Naif bayes sınıflandırmada tüm özellikler birbirinden bağımsızdır, dolayısıyla bu durum bayes teoremine uygulandığında bayes sınıflandırıcı;

$$P(C|F_1, \dots, F_n) = \frac{P(C)P(F_1, \dots, F_n|C)}{P(F_1, \dots, F_n)} \quad (3.17)$$

Şeklinde formülize edilebilir. Burada F durumları özelliklerdir. C ise sınıfı (hedefi) belirtir (Olgun ve Özdemir, 2012).

3.6.2. Destek vektör makineleri (Support Vektor Machines-SVM)

Destek vektör makineleri (DVM), istatistiksel tabanlı denetimli öğrenme çeşididir. İlk olarak lineer olan ikili sınıflarda kullanılan DVM 'ler daha sonra lineer olmayan ve çoklu sınıflara da uygulanacak şekilde geliştirilmiştir. DVM karar sınıfı belirleyerek, iki sınıf arasında birbirine en uygun veri örneklerinin bu karar sınırına dik uzaklığını belirleme prensibiyle çalışır. Bu sınıflandırıcı çeşidinde daha düşük frekanslarda daha iyi sonuçlar elde edilmesi hedeflenir. Bu sebeple çok boyutlu verilerde en çok kullanılan yöntemlerden birisidir (Sevli, 2019). DVM'lerde önemli olan en uygun karar doğrusunu seçebilmektir. Şekil 3.6'da de iki sınıf arasında kullanılan lineer ayırım doğrusu görülmektedir.



Şekil 3.6. İki farklı sınıf arasında kalan karar doğrusu gösterimi (Sevli, 2019)

Yukardaki karar doğrusuna ait fonksiyon ;

$$f(x) = \sum_{i=1}^n w_i x_i + b \quad (3.18)$$

denklemini ile ifade edilir. Burada b karar doğrusunun orjine olan uzaklığı veya diğer bir deyişle karar doğrusunun eşik değeridir. W ağırlık vektörü, x ise girdilerdir. DVM'lerde

lineer olarak ayrılmayan verilere çeşitli çekirdek fonksiyonlar uygulanır. Bunlardan bazıları;

$x^T y + c$: Doğrusal çekirdek,


$(x^T y + 1)^d$: Polinomial (Polinomyal) çekirdek,

$\exp(-\gamma ||x - y||^2)$: Radyal Tabanlı (Radial Basis) Çekirdek,

ve $\tanh(ax^T y + b)$: Sinir ağı sigmoid (Neural network sigmoid) çekirdek fonksiyonlarıdır (Güran ve ark., 2014).

3.6.3. Karar ağaçları

Karar ağaçları öğrenmesi, kolay if-else yapılarından oluşur ve en çok kullanılan denetimli öğrenme algoritmalarındandır. Sınıflandırma ve regresyonun her ikisinde de kullanılan bu öğrenme çeşidi, hiyerarşik yapı itibariyle kök-düğüm-yaprak yapısına benzerliği sebebiyle karar ağaçları olarak isimlendirilir. Burada kök ilk if(eğer) başlangıcı olup ardından gelen her düğüm ise bir kararı(girdiyi) temsil eder. Yaprak kısmında ise, içinde if-else yapısı bulunmayan sonuç kısımlarıdır. Karar ağaçlarında her düğümünden sonra verilerin yarısı elendiğinden dolayı çok hızlı işler. Ayrıca karar ağaçları yapı itibariyle basit olduğundan dolayı en çok tercih edilen öğrenme türlerindendir (Kaya ve Yıldız, 2014). Örnek bir sürücünün sürüş performansı ile ilgili bir karar ağacı Şekil 3.7 'de verilmiştir.



Şekil 3.7. Örnek bir karar ağacı algoritması

Genellikle ağaç yapısını oluşturmak için Entropi kavramını da bilmek gerekir. Entropi karar ağaçlarında belirsizlik ölçüsü olarak kullanılır. Bir Alana ait belirsizlik ve düzensizlik arttıkça, artan Entropi değeri;

$$Entropy(D_1) = -\sum_{i=1}^m p_i \log_2 p_i \quad (3.19)$$

eşitliği ile bulunur. Burada D, sınıfa ait bir özellik ve m değeri durum sayısıdır. Pi ise i. durumun olasılığıdır. Her bir özellik için ortalama değer bulunmak istendiğinde, 3.19 denklemi;

$$E(T, X) = \sum_{c \in X} P(c) E(c) \quad (3.20)$$

halini alır. Burada T sınıfının tüm X özelliklerinin Entropisi hesaplanır. Ayrıca Entropi hesaplanırken, entropinin düşük oranda olması istenir. Bunun için Bilgi kazancı (Information Gain) kullanılır. Bilgi kazancı;


$$Gain(S, D) = H(S) - \sum_{V \in D} \frac{|V|}{|S|} H(V) \quad (3.21)$$

eşitliğiyle bulunur. Burada S girdi verileri, D ise niteliklerden birisidir. Sistemin kazancı olan Gain(S, D) 'i hesaplamak için; girdi verilerinin entropi değerinden, özniteliklerin

entropi değeri çıkarılarak bulunur. 3.21 denkleminde de anlaşıldığı üzere, özneliliklerin entropi değeri azaldıkça, sistemin kazancı artmaktadır (Aytekin ve Ark. 2018).

3.6.4. Yapay sinir ağları

Yapay sinir ağları, genelde karmaşık ve bulanık verilere uygulanmak için kullanılan sınıflandırma yöntemidir (Kılınç ve ark., 2015). Bu sınıflandırma yöntemi, biyolojik sinir hücrelerini modellediğinden, her bir elemanına da nöron veya yapay sinir denir. Yapay sinir ağları sınıflandırmasında tek bir nöron varsa, doğrusal sınıflandırma kullanılır. Ancak çoğunlukla karmaşık ve doğrusal olmayan verilerde kullanıldığından genelde birçok çeşidi olan çok katmanlı algılayıcılar olarak bilinen MLP algoritmaları (Multi-Layer Perceptron) kullanılır (Kaynar ve ark., 2017). MLP 'ler giriş katmanı, ara katmanlar ve çıkış katmanı olmak üzere üç bölümden oluşur. Giriş katmanında girdi verileri vardır. Girdi verileri ise giriş katmanından gizli katmanlar olarak da bilinen ara katmanlarda işlenir. Ara katmanda işlenen veriler çıkış katmanına iletilir ve bu katmandan çıktı olarak verilir. Şekil 3.8 'de örnek bir çok katmanlı yapay sinir ağı verilmiştir.



Şekil 3.8. Örnek bir MLP yapısı (Kazan ve Karakoca, 2019)


Giriş katmanı olarak x girdisi verilirken, 3 adet arak atman vardır ve bu ara katmanlar birden fazla nörondan oluşmaktadır. Yapay sinir ağının çıkış katmanı ise $Y=f(x)$ fonksiyonundan oluşmaktadır.

3.6.5. K-en yakın komşu

K-en yakın komşu (K-Nearest Neighborhood-KNN) algoritması, en kolay uygulanabilir ve anlaşılabilir denetimli öğrenme türlerinden birisidir (Karakoyun & Hacıbeyoğlu, 2014). Yeni bir örnek için, k kadar komşu noktalara olan uzaklıkların ölçülmesi ile sınıfının belirlenmesi mantığına dayanan bu yöntemin genel akış şeması;


- 1-K değerinin belirlenmesi,
- 2-Yeni örneğin diğer nesneler arasındaki uzaklığın hesabı,
- 3-Uzaklığı en az olan örneklerle göre en yakın komşuların belirlenmesi,
- 4-En yakın komşu sınıflarının toplanması
- 5- En uygun komşu sınıfının belirlenmesi, şeklindedir.

Yukarıda verilen akış şemasında dikkat edilmesi gereken nokta en yakın komşu nesnelerin uzaklığı belirlenirken, farklı uzaklık ölçüm yöntemlerinin kullanılmasıdır. Manhattan uzaklığı, Öklid uzaklığı, Minkovski uzaklığı ve Chebyshev uzaklığı gibi çeşitli uzaklık ölçüm yöntemleri kullanılsa da bunların en çok kullanılanı ve bilineni öklid uzaklığıdır (Taşçı ve Onan, 2016). Şekil 3.9 ‘da iki farklı sınıf elemanlarının iki boyutlu uzaydaki dağılımları gösterilmiştir.



Şekil 3.9. Örnek iki sınıfın elemanlarının iki boyutlu uzayda dağılımı

Bu örnek için, şekil 3.10’da ki gibi yeni bir eleman (girdi) geldiğini varsayalım.



Şekil 3.10. En yakın komşuların belirlenmesi

Şekil 3.10 incelendiğinde, gelen yeni veriye en yakın üç komşusundan ikisi kırmızı-yuvarlak şeklinde gösterilen sınıftandır. Dolayısıyla gelen yeni veri bu grubun içinde değerlendirilir. Burada uzaklığı hesaplamak için kullanılan yöntemlerden yukarıda saydığımız dört tanesinin formülleri aşağıda verilmiştir.

Öklid uzaklığını hesaplamak için;

$$\sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (3.22)$$

Formülü kullanılır. Burada n hesaplanan özellik sayısıdır.

Manhattan uzaklığı;

$$(\sum_{i=1}^n |x_i - y_i|) \quad (3.23)$$

Formülü ile hesaplanır. Manhattan uzaklığının öklid uzaklığından farkı noktalar arasındaki uzaklığın mutlak değerini almasıdır.

Minkowski uzaklığı içinse;

$$(\sum_{i=1}^n |x_i - y_i|^p)^{1/p} \quad (3.24)$$

eşitliği kullanılır. Minkowski uzaklığı, öklid ve manhattan uzaklığının genelleştirilmiş hali olarak bilinmektedir. Minkowski eşitliğinde, $n \rightarrow \infty$ olduğunda formül Chebyshev uzaklığını verir (Alfeilat ve ark., 2019).


Chebyshev uzaklığı;

$$\lim_{p \rightarrow \infty} (\sum_{i=1}^n |x_i - y_i|^p)^{1/p} = \max_{i=1}^n |x_i - y_i| \quad (3.25)$$

formülü ile hesaplanır (Alfeilat ve ark., 2019).

3.7. Görüntülerin Elde Edilmesi (Face Detection)

Görüntüler internet ortamından ve gönüllü kişilerden alınmak üzere, 50 ayrı kişinin video görüntüleri toplanarak hazırlanmıştır. Video görüntüleri, sürüş esnasında veya sürüş ortamına benzetilerek alınmıştır. Göz kapalılığı tespiti testleri için, görüntülerden göz bölgeleri 120x40 boyutlarında kırpılarak, 1000 adet açık durumdaki ve 1000 adet kapalı durumdaki göz görüntüsü oluşturulmuştur. Esneme tespiti testleri için görüntülerden, yüz bölgesi (ağız bölgesi kırpılan alanine içinde kalacak şekilde) 200x200 boyutlarında, 1000 adet esneme durumundaki ve 1000 adet esneme olmayan durumdaki yüz görüntüsü oluşturulmuştur. Bu test görüntülerinde, farklı yaş grupları, farklı ten renklerinde ve farklı ırklardan insanlar vardır. Ancak bu tez çalışmasının hedefi ve konusu itibarıyla, genel bir sürüş destek sistemi tasarımı olmasından dolayı, gözlük takan kişilerden ve karanlık ortamda bulunan kişilerden görüntüler alınmamıştır. Şekil 3.11 de bu görüntülerden örnekler verilmiştir.



(a)




(b)


Şekil 3.11. Hazırlanan görüntülerden iki örnek (a)-kapalı durumdaki göz görüntüsü, (b)-esneme durumundaki yüz görüntüsü

3.8. Öznitelik Çıkarımı

Veri setlerinin hazırlanması için, görüntülere Gabor dalgacıkları uygulanarak veri setleri oluşturulmuştur. Öznitelik çıkarımı için 0-157.5 derece arasında olmak üzere, sekiz farklı açı ve beş farklı dalga boyu seçilmiştir. Bu açı ve dalga boyları sonucunda 40 farklı öznitelik çıkarımı yapılmıştır. Bu öznitelikler her görüntü için toplanmıştır. Özniteliklerin toplanması sonucu, göz tespiti ve esneme tespiti için, 40 sütun ve 2000 satırdan (40x2000) oluşan iki veri seti oluşturulmuştur. Şekil 3.12 ‘de örnek bir kapalı göz görüntüsüne, şekil 3.13’te açık durumdaki bir göz görüntüsüne ait, 8 farklı açı ve 5 farklı dalga boyunda, gabor filtreleri uygulanmış görüntüler verilmiştir.




Şekil 3.12. Kapalı bir göz görüntüsüne ait GDD çıktıları




Şekil 3.13. Açık bir göz görüntüsüne ait GDD çıktıları

Şekillerde satırlar farklı dalga boylarına ve sütunlar farklı açılara aittir. Göz görüntülerine uygulanan filtrelerin sonuçları incelendiğinde, ikinci satırda görüntülerdeki doku yapısı görüntüsü bozulmaya başladığı görülmektedir. Burada aslında filtrenin etki oranı artık bu seviyeden sonra düşmeye başlar.

Esne ve esnemem durumlarına ait görüntülere uygulanmış 40 adet gabor filresinin çıktıları ise sırasıyla Şekil.9 ve Şekil.10’ da verilmiştir.



Şekil 3.14. Örnek bir esne durumdaki yüz görüntüsüne ait GDD çıktıları



Şekil 3.15. Örnek bir esneme olmayan yüz görüntüsüne ait GDD çıktıları

Esneme tespiti için kullanılacak görüntülerin filter uygulanmış çıktıları incelendiğinde, göz görüntülerinin çıktılarına oranla daha geç bozulmaya başladığı görülür. Özellikle üçüncü satırdan doku görüntülerinin bozulmaya başladığı söylenebilir.

3.9. Sınıflandırma

Veri setlerindeki öznitelikleri sınıflandırmak için Weka programı kullanılmıştır. Veri madenciliği uygulamaları için kullanılan bu program, sınıflandırma için sağladığı çeşitli destek ve kütüphaneleri sebebiyle bu çalışmada tercih edilmiştir. Ayrıca Matlab ve farklı programlar da kullanılarak sınıflandırma uygulamaları yapılabilir.

3.9.1. ARFF (Attribute Relation File Format) dosyası

Matlab uygulamasında Gabor filtreleri uygulanarak hazırlanan çıktı matrisi, csv dosyası olarak kaydedilmiştir. Kaydedilen bu dosya ise bazı düzenlemeler yapılarak, Weka programında kullanılacak, arff dosyasına dönüştürüldü. Bu düzenlemeler veri setinden oluşan dosyanın üst kısmına eklenen ve verileri tanıttak kodlardır. Şekil 3.16 'da çalışmada kullanılan arff dosyasının örnek bir görüntüsü verilmiştir.

```

@relation mouthClassifier
@attribute 'O0W0' real
@attribute 'O1W0' real
@attribute 'O2W0' real
@attribute 'O3W0' real
@attribute 'O4W0' real
@attribute 'O5W0' real
@attribute 'O6W0' real
@attribute 'O7W0' real
.
.
.
@attribute 'O0W4' real
@attribute 'O1W4' real
@attribute 'O2W4' real
@attribute 'O3W4' real
@attribute 'O4W4' real
@attribute 'O5W4' real
@attribute 'O6W4' real
@attribute 'O7W4' real
@attribute class {c,o}

@data
0.0069527,0.0064222,0.0062206,0.006249,0.0066708,0.0
0.0068701,0.0063323,0.0060811,0.0060281,0.0063896,0.
0.0041795,0.0035829,0.0035008,0.0035627,0.0041518,0.

```

Şekil 3.16. Arff dosyası içeriğinin görüntüsü

Şekil 3.16 de verilen örnek arff dosyası görüntüsünde, en üstte bulunan @relation komutu dosya ismini tanımlamak için kullanılıp devamındaki tanım dosya ismi olarak tanımlanmaktadır. Sonraki satırlarda ise öznelik ve sınıf (attributes) tanımlamaları yapılır. Son olarak verilerin başladığı kısmın başına @data komutu girilir. Bu şekilde arff dosyası hazırlarak veri setleri sınıflandırma için hazır hale getirilmiş olur. Veri setleri sınıflandırılırken, veri setindeki 2'şer bin verinin %10'u yani 200' ü test için kullanılmıştır.

3.9.2. Sınıflandırma algoritmalarının uygulanması

Sınıflandırma yöntemleri genelde kendi içlerinde farklı algoritmalara ayrılırlar. Bu çalışmada ise daha önceki başlıklarda anlatılan sınıflandırma yöntemlerinin en çok

kullanılan ve bilinen uygulamalarından oluşan algoritmalar kullanılmıştır. Farklı algoritmalarından oluşan bu yöntemlerden,

- 1- Bayes yöntemi için NaiveBayes algoritması,
- 2- K- En yakın komşu yöntemi için IbK algoritması ve Kstar algoritması,
- 3- Karar ağaçları yöntemi için J48 algoritması,
- 4- SVM yöntemi için Sequential Minimal Optimization (SMO) algoritması,
- 5- Yapay sinir ağları için Multilayerperceptron (MLP) algoritması kullanıldı.

Bu tez çalışmasının devamında, anlatımda kolaylık sağlaması açısından, kullanılan sınıflandırma algoritmalarının tam isimleri yerine, kısaltılmış parametrik isimleri kullanılacaktır. Kullanılan algoritmalar ve kısaltılmış parametrik isimleri Çizelge 3.1 'de gösterilmiştir.

Çizelge 3.1. Veri setlerini sınıflandırmak için kullanılan algoritmalar

Sınıflandırma yöntemi	Algoritma	Değişen parameter	Kısaltılmış parametrik isim
Bayes yöntemi	NaviBayes algoritması	Değişen parmetre	B1
Karar ağaçları yöntemi	J48 algoritması	Budanmış ağaç	DT1
Karar ağaçları yöntemi	J48 algoritması	Budanmamış ağaç	DT2
K-en yakın komşu yöntemi	IBk algoritması	1 en yakın komşu	KNN1
K-en yakın komşu yöntemi	IBk algoritması	4 en yakın komşu	KNN2
K-en yakın komşu yöntemi	IBk algoritması	8 en yakın komşu	KNN3
K-en yakın komşu yöntemi	KStar algoritması	1 komşu	KNN4
Yapay sinir ağları yöntemi	MLP algoritması	-	YSA1
SVM yöntemi	SMO algoritması	-	SVM1

3.9.3. Sınıflandırma sonuçlarının karşılaştırılması

Uygulanan sınıflandırma algoritmaları hız ve doğruluk bakımından karşılaştırılmıştır. bu karşılaştırmalar göz tespiti verileri ve esneme tespiti verileri üzerinde ayrıntılı incelenmiştir. Göz kapalılığı tespitinde çıkan sonuçlar Çizelge 3.2 ‘de verilmiştir.

Çizelge 3.2. Göz kapalılık tespiti verilerinde, sınıflandırma sonuçları

Algoritma	Hatalı tespit (open)	Doğru tespit (open)	Hatalı tespit (close)	Doğru tespit (close)	Doğrulu k oranı
B1	322	678	127	873	%77.55
DT1	56	944	46	954	%94.9
DT2	58	942	45	955	%94.85
KNN1	20	980	4	996	%98.8
KNN2	19	981	19	981	%98.1
KNN3	28	972	20	980	%97.6
KNN4	18	982	6	994	%98
YSA1	29	971	17	983	%97.7
SVM1	98	902	43	957	%92.95

Çizelge 3.2 incelendiğinde en doğru sonuçları veren algoritma K-en yakın komşu yönteminin IBk algoritmasıdır. Hata oranı en yüksek sonuçlar ise bayes yönteminin NiveBayes algoritmasından alınmıştır. Yapay sinir ağlarının MLP algoritması ile de doğruluk oranı yüksek olsa da sınıflandırma işlemleri daha uzun sürmektedir.

Göz tespiti verileri sınıflandırmada model oluşturmak için harcanan süreler de sistemin real-time çalışması için göz önünde bulundurulması gerekir. Çizelge 3.3 ‘te göz tespiti veri setinde sınıflandırmalarda model oluşturmak için harcanan süreler saniye cinsinden verilmiştir. Weka programında sınıflandırma yapılırken, model oluşturma sürelerinde, 10 milisaniyeden kısa süreler ölçülmez. Ölçülen süreler 10 milisaniye hassasiyetle ölçülür. Çizelge 3.3’te de KNN algoritmalarında model oluşturma süreleri, ‘<0.01s’ olarak verilmiştir. Weka programı 10 ms altındaki süreleri 0 olarak gösterdiğinden, KNN

algoritmalarının model oluşturma sürelerini 0 olarak verir. Ancak model oluşturmak için kesinlikle bir süre harcandığından, KNN algoritmalarının model oluşturma süreleri 0 ile 0.01s aralığında olduğunu belirtmek için, bu süre tabloda ‘<0.01s’ yazılmıştır.

Çizelge 3.3. Göz kapallık tespiti veri setinde model oluşturma süreleri

Algoritma	Model Oluşturma Süresi
B1	0.02s
DT1	0.08s
DT2	0.07s
KNN1	<0.01s
KNN2	<0.01s
KNN3	<0.01s
KNN4	<0.01 s
YSA1	19.88s
SVM1	0.18 s

Çizelge 3.4 ‘te esneme verilerinin sınıflandırılmasında elde edilen sonuçlar verilmiştir.

Çizelge 3.4 Esneme tespiti verilerinde sınıflandırma sonuçları

Algoritma	Hatalı (yawning)	Doğru (yawning)	Hatalı (not yawning)	Doğru (not yawning)	Doğruluk oranı
B1	273	727	526	474	%60.05
DT1	84	916	87	913	%91.45
DT2	82	918	84	916	%91.7
KNN1	15	985	11	989	%98.7
KNN2	42	958	22	978	%96.8
KNN3	65	935	28	972	%95.35
KNN4	24	976	7	993	%98.45
YSA1	31	969	35	965	%96.7
SVM1	151	849	252	748	%79.85

Çizelge 3.4 incelendiğinde algoritmaların sınıflandırma performansları, göz kapalılığı tespiti verilerini sınıflandırma sonuçlarına benzer sonuçlar görülmektedir. Burada her iki tabloda da dikkat çeken en yüksek doğruluk oranlarını veren en yakın komşu yöntemidir. Bu yöntemde komşu sayısı arttıkça, değişkenlik arttığından, doğruluk oranı bakımından bir azalma görülmektedir. Çizelge 3.5 ‘te ise bu veriler için sınıflandırma algoritmalarının model oluşturma süreleri verilmektedir.

Çizelge 3.5. Esneme tespiti verileri için algoritmaların model oluşturma süreleri

Algoritma	Model Oluşturma Süresi
B1	0.01s
DT1	0.21s
DT2	0.18s
KNN1	<0.01s
KNN2	<0.01s
KNN3	<0.01s
KNN4	<0.01 s
YSA1	20.3s
SVM1	0.49 s

3.9.4. Öznitelik seçimi

Veri setleri sınıflandırılırken 40 öznitelik kullanılmıştır, ancak sonuca etkisi bakımından zayıf olan öznitelikler Weka programı yardımı ile tespit edilmiştir. 40 öznitelikten 28’inin sonuca %(-) 1-9 aralığında etki edebildiği görülmüştür. 40 öznitelik için yapılan testlerde en yüksek doğruluk oranlarını veren K-en yakın komşuluk (KNN) yönteminin IBk algoritması içinse bu etki maksimum %1.7 oranındadır. Sistem bir bütün olarak düşünüldüğü zaman, algoritmanın daha hızlı çalışarak gerçek bir sistemde çalışması açısından, bu oran göz ardı edilebilir. Bu şekilde algoritmanın daha hızlı çalışması amaçlanır.

Göz tespiti veri setlerinde 12 adet öznitelikle yapılan sınıflandırmaların sonucu Çizelge 3.6 ‘da görülmektedir.

Çizelge 3.6. Göz kapalılığı tespiti verilerinde 12 adet öznitelik ile yapılan sınıflandırmaların sonuçları

Algoritma	Hatalı tespit (open)	Doğru tespit (open)	Hatalı tespit (close)	Doğru tespit (close)	Doğruluk oranı
B1	162	838	468	532	%68.5
DT1	63	937	57	943	%94
DT2	60	940	57	943	%94.15
KNN1	28	972	16	984	%97.8
KNN2	28	972	42	858	%96.5
KNN3	46	954	40	960	%95.7
KNN4	41	959	12	988	%97.35
YSA1	87	913	34	966	%93.95
SVM1	192	808	103	897	%85.25

12 adet öznitelikle elde edilen doğruluk oranlarında bir düşüş görülmektedir. Ancak bu düşüş ile beraber model oluşturma sürelerinde de bir düşüş görülmektedir. Göz tespiti veri setinde sınıflandırma algoritmalarının model oluşturma süreleri Çizelge 3.7’de verilmiştir.

Çizelge 3.7. Göz kapalılık tespiti verilerinde 12 adet öznitelikle yapılan sınıflandırmaların model oluşturma süreleri

Algoritma	Model Oluşturma Süresi
B1	0.01s
DT1	0.07s
DT2	0.07s
KNN1	<0.01s
KNN2	<0.01s
KNN3	<0.01s
KNN4	<0.01 s
YSA1	19.67s
SVM1	0.17s

Esname tespiti veri setinde de benzer şekilde 40 adet öznitelikten 28'i düşük etki oranı sebebiyle çıkarılmıştır. 12 adet öznitelik ile elde edilen sonuçlar Çizelge 3.8'de görülmektedir.

Çizelge 3.8. Esname tespiti verilerinde 12 adet öznitelik ile yapılan sınıflandırmaların sonuçları

Algoritma	Hatalı (yawning)	Doğru (yawning)	Hatalı (not yawning)	Doğru (not yawning)	Doğruluk oranı
B1	318	682	467	533	%57.45
DT1	116	884	101	899	%89.15
DT2	119	881	104	896	%88.85
KNN1	35	965	23	977	%97.1
KNN2	76	924	36	964	%94.4
KNN3	84	916	63	937	%92.65
KNN4	44	956	32	968	%96.2
YSA1	104	896	137	863	%87.95
SVM1	264	736	460	540	%63.8

Esname verilerini sınıflandırmada, model oluşturma süreleri Çizelge 3.9'da verilmiştir.

Çizelge 3.9. Esname tespiti verilerinde 12 adet öznitelik ile yapılan sınıflandırmaların model oluşturma süreleri

Algoritma	Model Oluşturma Süresi
B1	<0.01s
DT1	0.05s
DT2	0.05s
KNN1	<0.01s
KNN2	<0.01s
KNN3	<0.01s
KNN4	<0.01 s
YSA1	2.83s
SVM1	0.08 s

Esname tespiti veri setinde 12 adet öznitelikle yapılan sınıflandırmaların doğruluk oranlarında, göz kapalılık tespiti veri setine oranla daha yüksek düşüşler gözlenmiştir. Bunun sebebi olarak esneme tespitinde görüntülerin yüzün tamamını almasıdır. Ancak paralel olarak esneme tespiti veri setlerinde sınıflandırma algoritmalarının model oluşturma süreleri de daha yüksek oranlarda azalmıştır.

Hem göz tespiti verilerinin sınıflandırmasında, hem de esneme tespiti verilerinin sınıflandırmasında, ilk iki dalga boyunda uygulanan filtrelerin, sınıflandırma sonucuna en büyük etkiyi yaptığı, sonraki üç dalga boylarına ait filtrelerin daha düşük oranlarda etki ettiği görülmüştür.

Başlık 3.5' te verilen filtrelerin uygulandığı görüntülerin çıktılarında, ilk iki dalga boyundan sonra görüntü yapılarının iyice bozulduğu görülmüştü. Öznitelik azaltma işleminde, özniteliklerin sonuca etkisi incelendiğinde, bu görüntülerle uyduğu ve birbirini destekler nitelikte olduğu da görülmüştür.

Nihai olarak sınıflandırma sonucunda KNN yönteminin IBk algoritması için en uygun sonuçlar elde edildiği görülmüştür. Aynı zamanda özniteliklerden 28'i sınıflandırma sonucuna etkikisinin az olduğu görülmüştür. Bu sonuçlar her iki veri seti için de geçerlidir.

Uygulama kısmında Matlab kullanılacaktır. Ancak Weka programı Java tabanlı olduğundan, Weka'dan alınan eğitilmiş model çıktısı Matlab'da kullanılamamaktadır. Bu sebeple uygulamayı yapmadan önce, aynı sınıflandırma algoritmaları kullanılarak, daha önce seçilmiş 12 adet öznitelik ile Matlab'ta sınıflandırma işlemi yapılmıştır.

Çizelge 3.10 ve Çizelge 3.11 sınıflandırma sonuçlarının Matlab ve Weka için karşılaştırmasına dair bilgiler içermektedir. Bu karşılaştırmalar 12 adet öznitelik kullanılarak yapılmıştır. Çizelge 3.10 göz verilerinin, Çizelge 3.11 ise esneme tespiti verilerinin sınıflandırma sonuçlarına aittir.

Çizelge 3.10. Göz kapalılık tespiti verilerinde, Matlab ile yapılan sınıflandırma sonuçlarının Weka'da alınan sonuçlar ile karşılaştırılması

Algoritma	Matlab	Weka
B1	%77.2	%68.5
DT1	%92.2	%94
DT2	%93.4	%94.15
KNN1	%97.5	%97.8
KNN2	%95.8	%96.5
KNN3	%94.5	%95.7
KNN4	%96.5	%97.35
YSA1	%93.8	%93.95
SVM1	%89.5	%85.25

Çizelge 3.11. Göz kapalılık tespiti verilerinde, Matlab ile yapılan sınıflandırma sonuçlarının Weka'da alınan sonuçlar ile karşılaştırılması

Algoritma	Matlab	Weka
B1	%65.9	%57.45
DT1	%86.1	%89.15
DT2	%87.3	%88.85
KNN1	%96.5	%97.1
KNN2	%94.1	%94.4
KNN3	%92.1	%92.65
KNN4	%95.6	%96.2
YSA1	%86.2	%87.95
SVM1	%84.2	%87.95

Çizelge 3.10 ve Çizelge 3.11'e göre Matlab'da yapılan sınıflandırmalarda, doğru sınıflandırma oranlarında düşüş gözlenmiştir. Bu azalmalar bazı sınıflandırma algoritmaları için dikkate alınması gereken büyüklüktedir. Bu uygulama için seçilen KNN1 (IBk algoritması) algoritması için bu azalma değerleri, göz verilerini sınıflandırmada %0.3, esneme verilerini sınıflandırmada %0.6 'dır. Sonuç olarak, Weka

tarafında ve Matlab tarafında yapılan sınıflandırma çalışmalarında, en yüksek doğruluk oranlarını IBk algoritması vermiş ve bu doğruluk oranları her iki tarafta da birbirine çok yakın çıkmıştır. Dolayısıyla bu sonuçlara dayanarak uygulamada IBk algoritması kullanılacaktır.



4. BULGULAR

Sınıflandırma çalışmalarında, veri setlerimizi sınıflandırmak için, en uygun sınıflandırma algoritması olarak K-en yakın komşuluk yönteminin IBk algoritması seçilmiştir. Bu algoritmanın komşu sayısı 1 olarak alınmıştır. Uzaklık hesabı için öklid uzaklığı alınmıştır. Bu sınıflandırma algoritması kullanılarak göz kapalılık ve esneme durumu için testler yapılmıştır. Buna ek olarak, Viola-Jones cascade dedektörü kullanılarak dikkatsizlik tespiti ve PCA yöntemi yüz tanıma testleri yapılmıştır. Bu uygulamalar tek bir uygulamada birleştirilerek, sürücü performans tespiti için bir program hazırlanmıştır. Bu program temel olarak;

- 1- Yüz tanıma ile seyir süresi tespiti,
- 2- Dikkatsizlik (PERCAR) tespiti,
- 3- Sürücü esneme (PERYAWN) tespiti ,
- 4- Sürücü göz kapalılık oranı (PERCLOS) tespiti,

adımlarından oluşmaktadır. Bu program MatLab ortamında hazırlanmıştır. Başlık 4.5 'te bu programa ait algoritma açıklamaları ile birlikte verilmiştir. Başlık 4.1, 4.2, 4.3, 4.4 ve 4.6' da ise yapılan testler ve sonuçları açıklanmıştır. Bu testlerde, Intel i5 8300H 3.30 GHz işlemcili ve 8 GB DDR4 RAM'li dizüstü tipi bir bilgisayar kullanılmıştır. Bu bilgisayarın üzerinde Windows 10 işletim sistemi koşturmaktadır.

4.1. Yüz Tanıma

SPTS sisteminde, sürücü yüz tanıma işlemi için, PCA yöntemi kullanılmıştır. Sürücü yüz tanıma testlerinde, 10 saniye uzunluğunda 248 çerçeveden oluşan bir video kullanılmıştır. Bu video içerisinde iki farklı kişi vardır. Yüz tanıma testlerinde, bu iki kişiye ait 10 yüz görüntüsünden oluşan bir veri tabanı kullanılmıştır. Veritabanındaki bu görüntüler, 200x180 boyutlarında ve videodaki her kişi için beşer tanedir. Test çalışmalarında elde edilen sonuçlar ise Çizelge 4.1'de verilmiştir.

Çizelge 4.1. Yüz tanıma testleri sonuçları

Parametreler	1.kişi	2. kişi
Doğru	124	124
Hatalı	0	0
Toplam	124	124
Doğru Tespit	%100	%100
Genel toplam	248	

Test sonuçlarında kullanılan videoya ait 248 çerçevenin hepsi doğru tespit edilmiştir.

4.2. Dikkatsizlik Tespiti

Dikkatsizlik testlerinde, 12 saniye uzunluğunda, 300 çerçeveden oluşan bir video kullanılmıştır. Bu video içerisinde 116 dikkatsiz, 166 dikkatli ve 18 belirsiz durumdaki çerçeveden oluşmaktadır. Test sonuçlarına göre, belirsiz durumdaki çerçevelerin yanlış algılandığı varsayıldığında, %87 doğruluk oranı çıkmaktadır. Bu belirsiz çerçeveler doğru tespit edildiği varsayıldığında ise, %93 doğruluk oranı çıkmaktadır. Bu sonuçlara ait veriler, Çizelge 4.2’te verilmiştir.

Çizelge 4.2. Test videosunun dikkatsizlik durumu sonuçları

Parametre	Dikkatsiz	Dikkatli	Toplam Yüzde (%)
Doğru	97	166	%87
Hatalı	0	19	%6.33
Belirsiz	5	13	%6
Toplam	102	198	%100

Sürücünün dikkatsizlik tespiti için hesaplanacak PERCAR oranı, son iki saniye için ele alınacaktır. Yapılan çalışma, sürücünün birinci dereceden dikkatsizlik durumunu (çok dikkatsiz) tespit etmeye yönelik olduğundan, bu sürenin yeterli olacağı düşünülmektedir.

4.3. Esneme Tespiti

Test çalışmalarında, sürücü esneme durumundaki çerçevelerin saptanmasında, hata oranı yüksek çıkmıştır. Bu sebeple uygulamanın, hatalı esneme uyarısı vermemesi için, PEEYAWN oranı %60 seçilmiştir. PERYAWN oranı hesaplanırken, son 2 saniye dikkate alınmaktadır. Bu sürenin, bir esnemenin tespit edilmesi için yeterli olduğu düşünülmektedir.

Esneme tespiti testlerinde, 10 saniye uzunluğunda içinde iki defa esneme durumu geçen offline bir video kullanılmıştır. Bu videoda ilk 300 frame için testler yapılmıştır. Elde edilen sonuçlar Çizelge 4.3'te verilmiştir.

Çizelge 4.3. Esneme tespiti testi sonuçları

Parametre	Esneme Var 1	Esneme Yok	Toplam Yüzde (%)
Doğru	70	158	%76
Hatalı	16	18	%11.33
Belirsiz	11	27	%12.66
Toplam	86	176	%100

Doğruluk oranı belirsiz durumda olan görüntüler hesaba katıldığında, %88.66 olmaktadır. Her ne kadar düşük bir oran olmasa da, PERCLOS testlerine oranla daha düşük başarımlar elde edilmiştir. Bunun sebebi olarak, esneme tespiti için yüzün tamamının kullanılmasıdır. Göz tespiti testlerinde yalnız göz bölgesi ele alınırken, esneme tespiti testlerinde yüz bölgesi tamamen ele alındığı için, esneme testlerinde başarımlar oranı daha düşük çıkmıştır.

4.4. Göz Kapalılık Tespiti

PERCLOS oranı ise, son sekiz saniye için hesaplanmaktadır. İnsanlarda ortalama göz kırpması sayısının 10-20 arasında (Büyükbaş, 2011) ve göz kırpması süresi 400 milisaniyeden uzun değildir (Kleven ve Koek, 1996). Bu durumda, normal bir insanda, her 2-4 saniyede bir göz kırpması gerçekleşmekte ve bu göz kırpması olayı en fazla 400


ms olmaktadır. Bu bilgilere dayanarak, normal bir insanda, 8 saniye içerisindeki gözün kapalı kalma zamanı, en fazla 1.6 saniye olabilir. Bizim seçtiğimiz PERCLOS eşik değeri ise %20'dir. Bu değer son sekiz saniyenin, toplamda 1.8 saniyesine denk gelmektedir.

Göz kapalılık testleri için iki adet offline video kullanılmıştır. Bu videolardan, birisi ağırlıklı olarak gözlerin açık olduğu durumları, diğeri ise ağırlıklı olarak gözlerin kapalı olduğu durumları içermektedir. Yaklaşık 10 saniyelik videolardan 300 frame kullanılarak testler yapılmıştır. İlk videonun test sonuçları ise Çizelge 4.4 'de verilmiştir.

Çizelge 4.4. Gözlerin açık olduğu durumunun yoğun olduğu videonun test sonuçları

Parametre	Gözler açık	Gözler kapalı	Toplam Yüzde	PERCLOS
Doğru	283	12	%99.77	-
Hatalı	0	1	%0.33	-
Belirsiz	0	2	%0.66	
Toplam	283	17	%100	%5.33


İlk video için yapılan test sonuçlarında 300 adet çerçeveden 17'si gözlerin kapalı olduğu, 283 adet de gözlerin açık olduğu tespit edilmiştir. Gözlerin açık olarak tespit edildiği çerçevelerde hata yokken, gözlerin kapalı olduğu 17 adet çerçeveden 5'ü hatalı tespit edilmiştir. Ancak hatalı olarak tespit edilen bu beş çerçeveden üçü, yarı açık durumdadır. Bu çerçeveler için kapalı veya açık olması hakkında net bir karar da verilemeyeceğinden bunlar tabloda parantez içinde 'belirsiz' olarak yazılmıştır. Bu çerçevelere ait örnek bir görüntü ise şekil 4.1'de verilmiştir. Şekil 4.2'de ise doğru şekilde tespit edilen açık ve kapalı göz durumlarından birer örnek verilmiştir.



Şekil 4.1. Gözlerin yarı açık durumu (belirsizlik durumu)



(a)



(b)

Şekil 4.2. Kapalı durumdaki (a) ve açık durumdaki (b) gözlerin tespiti

Şekil.12 de verilen açık ve kapalı göz örneklerinin kapalılık ve açıklık durumları net bir şekilde belirlenebilir durumdadır. Genellikle gözlerin açık olduğu bu videoda, PERCLOS oranı %5.33'tir ve uykululuk eşik değeri olan %20 'in altındadır.

Yoğun olarak gözün kapalı olduğu durumları içeren videonun test sonuçları ise Çizelge 4.5' te verilmiştir. Elde edilen sonuçlarda her ne kadar doğruluk oranı %94.66 olsa da, göz kapaklarının yarı açık yani belirsiz olduğu durumlar doğru tespit edilmiş sayıldığında, doğruluk oranı %97.33 oranında olmaktadır.

Çizelge 4.5. Gözlerin kapalı durumunun yoğun olduğu videonun test sonuçları

Parametre	Gözler açık	Gözler kapalı	Toplam Yüzde (%)	PERCLOS
Doğru	168	116	%94.66	-
Hatalı	0	8	%2.66	-
Belirsiz	2	6	%2.66	-
Toplam	170	130	%100	%43.33

4.5. Sürücü Performans Takip Sistemi Algoritması


Sürücü performans takibi için yazılan programın algoritması iki ana adımdan oluşmaktadır. İlk adım sürücü yüz tanıma işlemi yapılır. Sürücü yüz tanıma işlemi ilk start anında, bir kez için yapılacaktır ve diğer işlemler için döngü içerisine girecektir. Şekil 4.3 'te yüz tanımaya ait ve Şekil 4.4 'te SPTS döngüsüne ait algoritma verilmiştir. Aslında tek olan bu algoritmaların, iki şekil içinde verilmesinin sebebi, algoritmayı anlaşılır kılmaktır.

Sürücü yüz tanıma işlemi için, ilk önce veri girişi olarak, kameradan görüntü alınır. Bu görüntüde viola-jones cascade dedektörü ile yüz tespiti yapılır. Tespit edilen ilk 5 yüz görüntüsü (a) için, PCA yöntemi kullanılarak yüz tanıma işlemi yapılır. Algılanan bu 5 görüntüden, eşleşen görüntü sayısı (b) 3'ten az olması durumunda, seyir süresi sıfırdan başlayacaktır. Eşleşen görüntü sayısı 3'ten büyük olması durumunda yeni seyir süresi (T1), en son seyir süresinden (T2) devam edecektir.


Algoritma sonraki adım olarak döngü içine girmektedir. Döngü içinde ilk olarak kameradan veri girişi sağlanır ve Viola-Jones dedektörü ile yüz tespit edilir. Eğer herhangi bir yüz tespit edilmezse, dikkatsiz durumundaki çerçevelerin sayısı (d) bir arttırılır. Burada kolaylık olması açısından, dikkatsizlik durumu içeren çerçevelerin oranı PERCAR ile adlandırılacaktır. PERCAR, belli bir süre içinde, dikkatsizlik durumu içeren çerçevelerin, toplam çerçeve sayısına oranı olarak tanımlıyoruz. Bu uygulamada son 2 saniye (50 çerçeve) içinde PERCAR oranının %60 'ı (30 çerçeve) geçmesi durumunda, dikkatsizlik uyarısı verilecektir. Dikkatsizlik olmaması ve yüz algılanması durumunda ise program sonraki adım olan esneme kontrolüne geçecektir.

Sürücü esneme tespitinde, kolaylık olması açısından esneme durumunun olduğu, yani ağzın açık olduğu durumların oranı PERYAWN olarak adlandırılacaktır. PERYAWN, sürücünün esneme durumundaki çerçevelerin, toplam çerçeve sayısına oranı olarak alınacaktır. Programda esneme durumunun tespit edilmesi, son 2 saniye (50 çerçeve) için, PERYAWN oranının %60'ı (30 çerçeve) geçip geçmediği kontrol edilecektir. PERYAWN oranının %60 geçtiğinde, sürücü uykulu uyarısı verilecektir. Sağlanmaması durumunda ise bu adımı geçerek, PERCLOS'u kontrol etmektedir.

PERCLOS oranının son 8 saniye (200 çerçeve) içinde %20'den büyük olup olmadığını kontrol edilir. Bu şartın sağlanması durumunda, program bunu, sürücü uykulu/yorgun olarak değerlendirir. Bu durumda, sürücü uykulu/yorgun uyarısı verilir. Sağlanmaması durumunda ise program başa dönüp, kameradan görüntü alarak, aynı işlemleri tekrar etmektedir. Ayrıca program sonlandırılırsa, sürücü seyir süresi ve son 5 yüz görüntüsü kayıt edilerek çıkış yapılır.



Şekil 4.3. Algoritma – 1 (Yüz tanıma)



Şekil 4.4. Algoritma – 2 (SPTS döngü)

4.6. Sürücü Performans Takip Sistemi Testi

Sürücü performans takip sistemi için, 60 saniyelik ve 1500 çerçeve (25 fps hızında) içeren çevrimdışı bir video kullanılmıştır. Bu video tez konusuna uygun olarak, dikkatsizlik durumunu, uykululuk durumunu, esneme durumunu ve bunların hiç birisinin olmadığı normal durumları içermektedir. Videonun 0-10 saniyeleri arasında herşey normaldir. 10-20 saniyeleri arasında ise yoğun olarak gözün kapalı olduğu durumları içeren 10 saniyelik bir kısım barındırmaktadır. 20-30 saniyeleri arasında esneme durumu içermektedir. 30-40 saniyeleri arasında ise başka tarafa dönen (dikkatsizlik) durumu içermektedir. Son olarak 40-50 saniyeleri arasında tekrar, gözlerin yoğun olarak kapalı olduğu durumları içermektedir. Videonun geri kalan kısmında ise normal durumları içermektedir. Bu video için yapılan testlerde ise, aşağıdaki sonuçlar elde edilmiştir (normal bir ortamdan alınan videoda ki kişi sürücü olarak adlandırılacaktır).

0-10. saniyeler arası; program başlatıldığında, videonun ilk beş çerçevesinde yüz tespiti yapılmıştır. Bu yüz görüntüleri, veri tabanındaki en son sürücüye ait olan yüz görüntüleri ile karşılaştırıldı. Burada örnek sürücünden daha önce beş yüz görüntüsü alınarak veri tabanına kaydedilmiştir. Bu veri tabanında ise başarı durumunu ölçmek için beş farklı kişiden olmak üzere 25 farklı yüz görüntüsü de içermektedir.

Eğer videodan alınan ilk beş yüz görüntüsünden 3'ü veri tabanındaki en son sürücünün, yüz görüntüleri ile eşleşirse, sürücünün değişmediği kabul edilmiştir. Program için yapılan bu test denemesinde ise, videodan alınan bu ilk 5 yüz görüntüsünün beşinde de eşleşme sağlanmıştır. Sonuç itibarıyla, programın ilk adımı olarak hedeflenen, seyir süresi tespiti için sürücü yüz tanıma işlemi başarılı sonuç elde edilmiştir. Sürücü seyir süresine test amaçlı 100 saniyelik bir ekleme yapılmıştır. Ayrıca bu saniyeler arasında dikkatsizlik ve uykululuk (esneme ve PERCLOS) uyarısı alınmamıştır.


10-20. saniyeler arası; Bu saniyeler arasında, gözün kapalı olma durumu yoğun durumdadır. Yani sürücünün uykululuk durumu vardır. Daha önce algoritmada sürücünün son 8 saniye (200 çerçeve) PERCLOS oranı ölçüleceğini söylemiştik. Yapılan testlerde, videonun 455.'i çerçevesinde (18. saniye), PERCLOS oranı %20.5

olarak ölçülmüş ve sürücü uykulu uyarısı alınmıştır. Bu uyarının alındığı andaki örnek görüntü Şekil.14 'te verilmiştir.




Şekil 4.5. Uygulamanın sürücü uykululuğunu tespiti, PERCLOS=%20.5

20-30. saniyeler arası; Bu kısımda sürücü bir defa esnemektedir. Program genel olarak diğer bölümlerde PERYAWN oranını yüksek çıkartsa da, bu oran %60 üzerine çıkmamıştır. Esneme durumu esnasında, 629. çerçevede (26.saniyede) PERYAWN oranı %60'ı geçmiş ve sürücü uykulu uyarısı vermiştir. Bu çıktının alındığı ana ait görüntü Şekil 4.5'te verilmiştir.




Şekil 4.6. Esneme durumunda uykululuk uyarısı, PERYAWN=%62.

30-40. saniyeler arası; Bu saniyeler arasında ise sürücü birer defa sağ tarafına ve sol tarafına bakmaktadır. Yani bu saniyeler arasında iki kez dikkatsizlik durumu vardır. Uygulama başlatıldığında, PERCAR oranı dikkatsizlik içeren kısma kadar sıfır ortalama devam etmiştir. Dikkatsizlik içeren kısma geldiğinde ise ilk uyarısını 805. Çerçeve (33. saniye) vermiştir. İkinci uyarısını ise 924. Çerçeve vermiştir. Bu şekilde her iki dikkatsizlik içeren durum da tespit edilmiştir. Her iki durumu için, dikkatsizlik uyarısının alındığı ana ait örnek görüntüler şekil 4.6 ve şekil 4.7’da verilmiştir.



Şekil 4.7. Sola bakarken dikkatsizlik durumu, PERCAR=%62.



Şekil 4.8. Sağa bakarken dikkatsizlik durumu, PERCAR=%62.

40-50. saniyeler arası; Bu kısımda bir kez daha, gözlerin kapalı olduğu durumlar yoğunluktadır. Videonun 1107. Çerçevesinde (45. saniye) bir kez daha sürücü uykulu uyarısı verilmiştir.

50-60. saniyeler arası; Bu aralıkta videoda, uyarı verilmesi için herhangi bir durum yoktur. Program bu aralıkta herhangi bir uyarı vermeden normal sürüş şeklinde devam etmiştir.

Test videosunda esneme, dikkatsizlik durumlarının, programın verdiği uyarılar ile karşılaştırılması Çizelge 4.6' da verilmiştir.

Çizelge 4.6. Test çalışmasının sonuç karşılaştırması

Parametreler	Esneme	PERCLOS	Dikkatsizlik	Sürücü
Video	1	2	2	Aynı sürücü
Program	1	2	2	Aynı sürücü

Test sonuçlarında elde edilen sonuçlar videonun içeriği ile uyushmaktadır. Burada iki kez PERCLOS aşımı tespit edilmiştir. Videoda da son 200 çerçeve için hesaplandığında yalnız iki defa için PERCLOS aşımı olmaktadır. Burada PERCLOS uyarısı verildiğinde, durum tekrar normale dönene kadar ki süre için, tek uyarı olarak sayılmıştır. Bu durumda videonun tamamında iki adet PERCLOS oranının aşımından kaynaklı sürücü uykulu uyarısı alınmıştır. Bu iki uyarı videonun içeriği ile uyushmaktadır. Test sonuçlarında tespiti hedeflenen durumlar birebir doğru çıksa da, bütün çerçeveler hesaplandığında, Çizelge 4.7, Çizelge 4.8 ve Çizelge 4.9 ortaya çıkmaktadır.

Çizelge 4.7'de ele alınan test videosunda, ayrı ayrı iki adet dikkatsizlik durumu vardır. Program bu iki dikkatsizlik durumunu da tespit etmiştir. Test videosunda toplam dikkatsizlik durumundaki çerçeve sayısı ise 141 adettir. Ancak bu çerçevelerden 29 'u belirsiz durumdadır. Bu durumlar için hem dikkatli hem de dikkatsiz de denilebilir. Bu yüzden tabloda bu durum parantez içerisinde gösterilmiştir. Belirsiz görüntülerin tamamı dikkatli sayılırsa videonun toplam PERCAR oranı %7.46 olacaktır. Eğer bu

belirsiz görüntülerin hepsi dikkatsiz olarak kabul edilirse, videonun PERCAR oranı %9.4 olacaktır. Uygulamanın bize verdiği oran %7.93 ile bu aralığa denk gelmektedir.

Çizelge 4.7. Test videosunun dikkatsizlik durumu sonuçları

Parametreler	Video	Program
Dikkatsiz çerçeve	141(29 belirsiz)	119
Dikkatli çerçeve	1359	1381
Toplam PERCAR oranı	%7.46 -9.4	%7.93
Toplam dikkatsizlik durumu	2	2
Toplam çerçeve	1500	1500

Çizelge 4.8. Test videosunun esneme durumu sonuçları

Parametreler	Video	Program
Esneme olan çerçeve sayısı	55 (10 belirsiz)	186
Esneme olmayan çerçeve sayısı	1326	1173
Toplam PERYAWN oranı	%3.3 - 4	%13.5
Toplam Esneme durumu	1	1
Toplam çerçeve	1381	1381

Çizelge 4.8’de ele alınan test videosunda 45 esneme olan ve 10 tane belirsiz olan çerçeve vardır. Kesinlikle esneme yok denilebilecek 1304 çerçeve vardır. Videonun toplam PERYAWN oranı %3.3 - 4 arasındadır. Uygulamada elde edilen PERYAWN oranı ise %13.5 dir. Başlık 4.2 altında incelenen esneme tespitinde benzer oranlar elde edilmişti. Buradaki hata oranının fazla olması ise o başlık altında daha detaylı olarak açıklanmıştı. Ancak sonuç itibariyle, videoda 1 olan esneme sayısını, uygulama da 1 olarak tespit etmiştir. Bu sonuç açısından esneme tespitinin de kabul edilebilir ve uygulama içerisinde kullanılabilir olduğu görülmüştür. Videoda toplam 1500 çerçeve olmasına rağmen tabloda toplam çerçeve sayısı 1381 olarak verilmiştir. Bunun sebebi yüzün algılanmadığı 119 çerçevede yüz ve göz tespiti hiç yapılamamıştır. Bu çerçeveler toplam çerçeve sayısından çıkarılmıştır.

Sonuçlar, göz kapalılığını tespit etmede kabul edilebilir oranlar vermiştir. Uygulama, 1500 çerçeveden 248 tanesini kapalı olarak algılamıştır. Videoda, 273 kapalı göz görüntüsü vardır. Ancak bu çerçevelerden 33 tanesi belirsiz, 240 tanesi kesinlikle kapalı denilebilecek durumdadır. Programın tespit ettiği, kapalı göz çerçeve sayısı ise bu aralıktadır (240-273).

Çizelge 4.9. Test videosunun göz kapalılık tespiti sonuçları

Parametreler	Video	Program
Gözler kapalı	273(33 belirsiz)	248
Gözler açık	1227	1381
Toplam PERYAWN oranı	%17.3-19.7	%18
Toplam PERCLOS aşım durumu	2	2
Toplam çerçeve	1381	1381

5. SONUÇ

5.1. Sonuç

Yapılan arařtırmalar ve bu arařtırmalar sonucu bir SPTS oluřturulmuřtur. Bu sistem iin, bařlangıta hedeflenen, src seyir sresi tespiti, dikkatsizlik tespiti esneme tespiti ve gz kapalılık tespiti bařarılı řekilde gerekleřtirilmiřtir. alıřmada, sınıflandırma algoritmalarının bařarımını lmek iin, Weka programı kullanılmıřtır. Uygulama ise MatLab ortamında gerekleřtirilmiřtir. Yz tespiti iin Viola-Jones dedektr kullanılmıřtır.

Sınıflandırma alıřmaları iin 4000 grnt kullanılmıřtır. Bu grntler izelge 5.1’de gsterilmiřtir.

izelge 5.1. Tez alıřmasında, Sınıflandırma iřlemlerinde kullanılan veri tabanı dağılımı

	Gz kaplılık	Ağız (esneme)
Aık	1000	1000
Kapalı	1000	1000
Boyut (piksel)	120x40	200x200
Toplam	2000	2000
Genel toplam	4000	

Bu grntlere Gabor filtreleri uygulanarak 40 adet znitelik ıkarılmıřtır. Bunun sonucunda her iki set iin 2000x40 boyutunda bir veri seti matrisi elde edilmiřtir. Bu znitelikler kullanılarak yapılan sınıflandırma iřlemlerinde, en yksek oranı KNN sınıflandırma ynteminin IBk algoritması vermiřtir. Ancak algoritmanın hızı aısından znitelik seimi yapılmıřtır. Tm zniteliklerin sınıflandırma sonucuna etkisine bakılarak, her iki veri setindeki znitelik sayısı 40’tan 12’ye dřrlmřtir. znitelik azaltılması sonucu, gz kapalılık verilerinin sınıflandırma bařarımı, %98.8 ‘den %97.2 ye dřmřtir. Benzer řekilde esneme tespiti veri setlerinde sınıflandırma bařarımı %97.7 den %97.1 e dřmřtir. Ancak hızın arttırılması aısından bu dřřler gz ardı edilmiřtir.

Sınıflandırma sonrası uygulamanın başarımlarını ölçümü için farklı testler yapılmıştır. MatLab ortamında eğitilen modeller ile yapılam göz kapalılık ve esneme tespiti testlerinde; göz kapalılık için %0.33-2.66 arasında, esneme tespiti testlerinde ise %11.33 hata oranına ulaşılmıştır.

Uygulamada sürücü tanıma işlemi için PCA ile yüz tanıma yöntemi kullanılmıştır. Sürücü tanıma işlemi için, sürücü yüz görüntülerinin içinde bulunduğu bir veritabanı oluşturulmuştur. Bu veri tabanında son sürücüye ait 5 adet fotoğraf bulunmaktadır.

Hedeflenen genel SPTS sistemi içinde birleştirilecek uygulamalardan, uygulanabilir oranlar yakalandığı görülmüştür. Bu sonuçla hedeflenen uygulamanın gerçekleştirimi için, bu sistemler birleştirilerek bir algoritma oluşturulmuş ve bu algoritma uygulanarak test çalışması yapılmıştır. Yapılan test çalışmasında 60 saniye uzunluğunda, 1500 çerçeveden oluşan bir video kullanılmıştır. Bu videonun içeriğinde bulunan 1 esneme durumu, 2 dikkatsizlik durumu ve 2 PERCLOS oranının aşımı durumu başarılı bir şekilde tespit edilmiştir. Uygulama kısmında çalışma kolaylığı ve anlaşılabilirlik açısından PERYAWN ve PERCAR parametreleri kullanılmıştır. Burada ;

PERYAWN, belirli bir süre içerisinde, esneme durumundaki çerçevelerin toplam çerçeve sayısına oranı,

PERCAR, belirli bir süre içerisinde, dikkatsiz durumundaki çerçevelerin -çerçeve yerine süre de alınabilir- toplam çerçeve sayısına oranı, olarak tanımlanmıştır.

5.2. Tartışma

Yapılan SPTS çalışmasında, dört ayrı uygulamanın tek sistemde birleştirilmesi hedefi gerçekleştirilse de, bu uygulamalardan esneme tespitinde bir dizi sebepten dolayı, istenilen düzeyde sonuçlar alınamamıştır. Yapılan test videosunda bulunan bir adet esneme durumu tespit etse de, genel çerçeve hesabına (Çizelge 4.8) bakıldığında, hata oranı yüksek çıkmaktadır. Bu durum, esneme tespitinde kullanılan veritabanının, tüm yüz görüntüsünden oluşmasıdır. Ayrıca veri seti oluşturulurken, görüntülere GDD filtreleri dışında, herhangi bir filtre uygulanmamıştır. Yapılan çalışmanın 4 ayrı uygulamayı içinde bulundurduğundan ve hedeflenen çıktının, sürücülerin genel

performansını ilgilendiren bir sistem tasarımı olduğundan, bu durumlar göz ardı edilmiştir.

5.3. Öneriler

Yapılan bu çalışma, kişisel bir bilgisayar üzerinde test edilmiştir. Ancak yapılacak ek çalışmalar ile gömülü bir sisteme dönüştürülebilir ve gerçek zamanlı çalışması da sağlanabilir. Bu sistem kullanım itibari ile sadece hedef kişiyi karşıdan görecektir bir kamera ve bu kameradan alınacak görüntüleri işleyecek bir donanıma ihtiyaç duyar. Bu ihtiyaçlar göz önüne alındığında, sistem hemen her alanda kullanılabilir.

Bu sistem için hedeflenen ve düşünülen ek çalışmalardan birisi de, bu sisteme ek parametreler ekleyerek, sürücü sürüş performansının puanlamasını yapmaktır. Bu çalışma özellikle, toplu taşıma araçlarında ve yük taşıma araçlarında kullanılmaya yönelik olabilir. Karayollarındaki ağır kazaların önemli oranda, bu tür araçlara ait olduğu düşünüldüğünde, bu ek çalışma sayesinde olumlu yönde etki edebileceği düşünülmektedir. Ayrıca bünyesinde filolar barındıran şirketler için de, sürücü performansı kolaylıkla takip edilebilir olacağı düşünülmektedir.

Yapılan uygulamada, PERYAWN oranından dikkatsizlik tespiti ve PERCLOS oranından uykululuk/yorgunluk tespiti için, birer eşik değeri kullanılmıştır. İleriki çalışmalarda bu oranlar değiştirilerek farklı kademelerde uyarılar tanımlanabilir. Örneğin bu çalışmada, uykululuk/yorgunluk uyarısı için, PERCLOS eşik değeri %20 seçilmiştir. Bu eşik değeri farklı oranlarda tanımlanarak, sürücünün uykululuk/yorgunluk uyarıları farklı kademelerde tanımlanabilir.

6. KAYNAKLAR

- Ahmad, R. ve Borole, J., 2015. Drowsy Driver Identification Using Eye Blinkdetection. (IJCSIT) International Journal of Computer Science and Information Technologies, Vol.6, No.1, pp. 270-274.
- Akerstedt, T., Bassetti, C., Cirignotta, F., Borreguero, G. D., Gonçalves, M., Horne, J., Leger, D., Partinen, M., Penzel, T., Philip, P. ve Verster, J. C., 2013. Sleepiness at the Wheel. Paris, ASFA, INSV.
- Aki, M. O., 2017. Sürücü Uykululuğunun Gerçek Zamanlı Görüntü İşleme ve Makine Öğrenmesi Teknikleri ile Tespitine Yönelik Bir Sistem Tasarımı ve Uygulaması. Doktora Tezi, Trakya Üniversitesi, Fen Bilimleri Enstitüsü, Edirne.
- Alfeilat, H.A.A., Hassanat, A.B.A., Lassameh, O., Tarawneh, A.S., Alhasanat, M.B., Salman, H.S.E. ve Prasath, S., 2019. Effects of Distance Measure Choice on K-Nearest Neighbor Classifier Performance: A Review. Big Data. Vol.7, No.4, pp.1-28
- Antoine, P., Alice, C. ve Charbonnier, S., 2009. Comparison Between EOG And High Frame Rate Camera For Drowsiness Detection. Applications of Computer Vision (WACV) Snowbird, USA, IEEE, pp. 1-6.
- Aytekin, Ç., Sütcü, C.S. ve Özfidan, U., 2018. Text Classification Via Decision Trees Algorithm: Customer Comments Case. The Journal International Social Research. Vol.11, No.55, pp.782-792.
- Bayrakdar, S., Akgün, D. ve Yücedağ, İ., 2017. Video Dosyaları Üzerinde Yüz İfade Analizi İçin Hızlandırılmış Bir Yaklaşım. Pamukkale Üniversitesi Mühendislik Dergisi. Vol.23, no.5, pp. 602-613.
- Bilgin, M., 2017. Gerçek Veri Setlerinde Klasik Makine Öğrenmesi Yöntemlerinin Performans Analizi, Breast, Vol.2, No.9, pp.683-688.
- Büyükbay, Z., 2011. Bilgisayar Kullanıcılarında Görülen Oküler Yüzey Değişikliklerinin Değerlendirilmesi, Uzamanlık Tezi, Selçuk Üniversitesi Fen Bilimleri Enstitüsü, Konya.
- Chieh, T. C., 2005. Development of Vehicle Driver Drowsiness Detection System Using Electrooculogram (EOG). Computers, Communications, & Signal Processing with Special Track on Biomedical Engineering, IEEE 2005, pp. 165–168.
- Çalışkan, A. ve Ertuğrul, Ö. F., 2015. Wavelet Transform Based Fingerprint Recognition. 3rd Signal Processing and Communications Applications Conference (SIU), Malatya, IEEE, pp. 1481-1484.
- Danisman, T., Bilasco, I. M., Djeraba, C. ve Ihaddadene, N., 2010. Drowsy Driver Detection System Using Eye Blink Patterns. 2010 International Conference on Machine and Web Intelligence, Algiers, Algeria, pp. 230-233.
- Derpanis, K. G., 2007. Gabor Filters. York University.
- Fan, X., Yin, B.C. ve Sun, Y.-F., 2007. Yawning Detection For Monitoring Driver Fatigue. International Conference on Machine Learning and Cybernetics, Hong Kong, IEEE, pp. 664-668.
- Fuletra, J. D. ve Bosamiya, D., 2013. A Survey on Driver's Drowsiness Detection Techniques. International Journal on Recent and Innovation Trends In Computing and Communication, Vol.1, No.11, pp. 816 – 819.

- Garcia, S., Bronte, S., Bergasa, L. M., Almazan, J. ve Yebes, J., 2012. Vision-Based Drowsiness Detector For Real Driving Conditions. IEEE Intelligent Vehicles Symposium, Alcalá De Henares, Spain, IEEE, pp. 618-623.
- Güran, A., Uysal, M. ve Doğrusöz, Ö., 2014. Destek Vektör Makineleri Parametre Optimizasyonunun Duygu Analizi Üzerindeki Etkisi. DEÜ Mühendislik Fakültesi Mühendislik Bilimleri Dergisi. Vol.16, No.48, pp.86-93.
- Hayashi, K., Ishihara, K., Hashimoto, H. ve Oguri, K., 2005. Individualized Drowsiness Detection During Driving by Pulse Wave Analysis With Neural Network. Intelligent Transportation Systems, Vienna, IEEE, pp. 901-906.
- Hong, T. ve Qin, H., 2007. Drivers Drowsiness Detection in Embedded System. IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), Guangzhou, China, IEEE, pp. 1-5.
- Ji, Q. ve Yang, X., 2002. Real-Time Eye, Gaze And Face Pose Tracking For Monitoring Driver Vigilance. Real-Time Imaging, Vol.8, No.5, pp. 357-377.
- Ji, Q., Zhu, Z. ve Lan, P., 2004. Real-Time Nonintrusive Monitoring and Prediction of Driver Fatigue. Transactions on Vehicular Technology, Vol.53, No.4, pp. 1052-1068.
- Karakoyun, M. ve Hacibeyoğlu, M., 2014. Biyomedikal Veri Kümeleri ile Makine Öğrenmesi. Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi, Vol.16, No.48, pp. 30-41.
- Kaufman, G. J. ve Breeding, K. J., 1976. The Automatic Recognition of Human Faces From Profile Silhouettes. IEEE Transactions on Systems, Man, and Cybernetics, Vol.SMC-6, No.2, pp.113-121.
- Kaya, Ç. ve Yıldız, O., 2014. Makine Öğrenmesi Teknikleriyle Saldırı Tespiti: Karşılaştırmalı Analiz. Marmara Fen Bilimleri Dergisi, Vol.3, pp. 89-104.
- Kaynar, O., Tuna, M. F., Görmez, Y. ve Deveci, M. A., 2017. Makine Öğrenmesi Yöntemleriyle Müşteri Kaybı. C.Ü. İktisadi ve İdari Bilimler Dergisi, Vol.18, No. 1, pp. 1-14.
- Kazan, S. ve Karakoca, H., 2019. Makine Öğrenmesi İle Ürün Kategorisi Sınıflandırma. Sakarya University Journal of Computer and Information Sciences, Vol.2, No.1, pp. 18-27.
- Kiliç, D., Borandağ, E., Yücalar, F., Özçift, A. ve Bozyiğit, F., 2015. Yazılım Hata Kestiriminde Kolektif Sınıflandırma. Ulusal Yazılım Mühendisliği Sempozyumu (UYMS), İzmir, pp. 113-121.
- King, D. J., Mumford, D. K. ve Siegmund, G. P., 1998. An Algorithm For Detecting Heavy-Truck Driver Fatigue From Steering Wheel Motion. Kanada, ESV, pp. 873-882.
- Kleven, M. S. ve Koek, W., 1996. Differential Effects of Direct and Indirect Dopamine Agonists on Eye Blink Rate in Cynomolgus Monkeys. The Journal of Pharmacology and Experimental Therapeutics, Vol.279, No.3, pp. 1211-1219.
- Kumar, A. ve Patra, R., 2018. Driver Drowsiness Monitoring System Using Visual Behaviour and Machine Learning. Guwahati, India, IEEE Symposium on Computer Applications & Industrial Electronics (ISCAIE), pp. 339-344.
- Lal, S. K. ve Craig, A., 2000. Physiological Indicators of Driver Fatigue, Traffic Injury Prevention, Vol.18, No.2, pp. 1-6.
- Lawoyin, S., Fei, D.Y. ve Bai, O., 2015. Accelerometer-Based Steering-Wheel Movement Monitoring For Drowsydriving Detection. Journal of Automobile Engineering, Vol.229, No. 2, pp. 163-173.

- Li, G., Lee, B.L. ve Chung, W.-Y., 2015. Smartwatch-Based Wearable EEG System For Driver Drowsiness Detection. *IEEE Sensors Journal*, Vol.15, No.12, pp. 7169-7180.
- Mandal, B., Li, L., Wang, G. S. ve Lin, J., 2016. Towards Detection of Bus Driver Fatigue Based on Robust Visual Analysis of Eye State. *IEEE Transactions on Intelligent Transportation Systems*, Vol.18, No.3 pp. 545-557.
- Pal, N.R., Chuang, C.Y., Ko, L.W., Chao, C.F., Jung, T.P., Liang, S.F., ve Lin, C.T., 2008. EEG-Based Subject- and Session-independent Drowsiness Detection: An Unsupervised Approach. *EURASIP Journal on Advances in Signal Processing*, Vol.2008, ID.519480, pp.1-11
- Olgun, M.O. ve Özdemir, G., 2012. İstatistiksel Özellik Temelli Bayes Sınıflandırıcı Kullanarak Kontrol Grafiklerinde Örüntü Tanıma. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*. Vol.27, No.2, pp.303-311.
- Omidyeganeh, M., Javadtalab, A. ve Shirmohammadi, S., 2011. Intelligent Driver Drowsiness Detection Through Fusion of Yawning and Eye Closure. *IEEE Conference on Virtual Environments, Human-Computer Interfaces, and Measurement Systems (VECIMS)*, At Ottawa, Canada, pp. 1-6.
- Picot, A., Charbonnier, S. ve Caplier, A., 2008. On-Line Automatic Detection of Driver Drowsiness Using a Single Electroencephalographic Channel. *30th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, , Vancouver, BC, Canada, pp. 3864-3867.
- Rahman, A., Sirshar, M. ve Khan, A., 2015. Real Time Drowsiness Detection Using Eye Blink Monitoring. *Software Engineering Conference (NSEC)*, pp. 1-7.
- Ramazan, M., Awan, S. M., Khan, H. U., İlyas, M. ve Mahmood, A., 2019. A Survey on State-Of-The-Art Drowsiness Detection Techniques. *IEEE Access*, Vol.7, pp. 61904-61919.
- Sevli, O., 2019. Göğüs Kanseri Teşhisinde Farklı Makine Öğrenmesi Tekniklerinin Performans Karşılaştırması. *European Journal of Science and Technology*, No. 16, pp. 176-185.
- Sirovich, L. ve Kirby, M., 1987. Low-Dimensional Procedure for the Characterization of Human Faces. Reprinted From *Journal Of The Optical Society of America*, Vol.4, No.3, pp. 519-524.
- Takei, Y. ve Furukawa Y., 2005. Estimate of Driver's Fatigue Through Steering Motion. *International Conference on Systems, Man and Cybernetics*.
- Taşçi, E. ve Onan, A., 2016. K-En Yakın Komşu Algoritması Parametrelerinin Sınıflandırma Performansı Üzerine Etkisinin İncelenmesi. *Akademik Bilişim, Aydın, Türkiye*. pp.1-8.
- Tefft, B. C., 2012. Prevalence of Motor Vehicle Crashes Involving Drowsy Drivers. pp. 180-186.
- Turk, M. ve Pentland, A., 1991. Eigedces for Recognition. *Journal of Cognitive Neuroscience*, V.3, No. 1, pp. 71-86.
- Vicente, J., Laguna, P., Bartra, A. ve Bailon, R., 2016. Drowsiness Detection Using Heart Rate Variability. *Medical and Biological Engineering & Computing*, Vol.54, No. 6, pp. 927-937.
- Viola, P. Ve Jones, M., 2001. Rapid Object Detection Using a Boosted Cascade of Simple. *Accepted Conference On Computer Vision And Pattern Recognition*, Vancouver. pp.1-9.

- Vural, E., Çetin, M., Erçil, A., Littlewort, G., Movellan, J. ve Bartlett, S., 2007. Drowsy Driver Detection Through Facial Movement Analysis. Human-Computer Interaction, pp. 6–18.
- Vural, E., Çetin, M., Erçil, A., Littlewort, G., Movellan, J. ve Bartlett, 2008. Automated Drowsiness Detection For Improved Driver Safety. International Conference on Automotive Technologies. Istanbul, pp. 96-105.
- Williamson, A. ve Chamberlain, T., 2005. Review of On-Road Driver Fatigue Monitoring Devices, New South Wales: University Of New South Wales.
- Yan, J.-J., Kuo, H.-H., Lin, Y.F. ve Liao, T.-L., 2016. Real-Time Driver Drowsiness Detection System Based On Perclos and Grayscale Image Processing. 2016 International Symposium on Computer, Consumer and Control (IS3C), pp. 243-246.
- Yazar, I., Yavuz, H. S. ve Çay, M. A., 2009. Temel Bileşen Analizi Yönteminin ve Bazı Klasik ve Robust Uyarlamalarının Yüz Tanıma Uygulamaları. Eskişehir Osmangazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi, Vol.XXII, No.1, pp.49-63.

8. ÖZGEÇMİŞ

Kişisel Bilgiler

Soyadı, adı : Aktaş, Selman
Uyruğu : T.C.
Doğum tarihi ve yeri : 25/02/1992 Nusaybin/Merdin
Telefon : 0(541)-789-45-07
E-posta : selman.gop@gmail.com

Eğitim

Derece	Eğitim Bilgisi	Mezuniyet Yılı
Lisans	Gaziosmanpaşa Üni. Mekatronik Müh.	2017
Lise	Nusaybin Emire Gözü Lisesi	2012

İş Deneyimi

Yıl	Şirket	Görev
2017-2018	Park Kent Mob. A.Ş.	Ar-ge Müh.
2019-	S.G.M.S. Ltd. Şti.	Mekatronik Müh.

Yabancı Dil

Dil	Sınav	Puan
İngilizce	Yökdil	60