

Akıllı Sürüş Güvenliği Sistemi (ASGÜS): İnsan Hatalarını Azaltmak için Sensör Tabanlı Sistemler ve Görüntü İşleme Yöntemlerinin Entegrasyonu

Faruk Özgür^{1*}, Özge Öztimür Karadağ¹

¹Bilgisayar Mühendisliği, Alanya Alaaddin Keykubat Üniversitesi, Antalya, Türkiye.

*farukozgur501@gmail.com

Özet

Bu çalışma, sürücü güvenliğini artırmayı amaçlayan yenilikçi bir sistemin geliştirilmesini hedeflemektedir. Trafik kazalarının büyük bir kısmı insan hatalarından kaynaklanmaktadır ve bu hataların azaltılmasına yönelik teknolojik çözümler hayati önem taşımaktadır. Bu amaçla, sürücü dikkat izleme, trafik işareti tanıma, kan ve kusmuk tespiti, nabız izleme ve alkol tespiti gibi birçok bileşenden oluşan kapsamlı bir güvenlik sistemi tasarlanmıştır. Çalışma, sistem bileşenlerinin yüksek doğruluk oranları ile çalıştığını ve sürücü davranışlarının güvenilir şekilde izlenebildiğini göstermektedir. Sonuç olarak, bu çalışma yalnızca tek bir unsura odaklanan literatürdeki çalışmalardan farklı olarak çoklu bileşenleri entegre etmekte ve araç içi güvenlik teknolojilerinde yenilikçi bir katkı sunmaktadır. Elde edilen bulgular, sistemin trafik kazalarının azaltılmasına yönelik önemli bir potansiyel taşıdığını ortaya koymaktadır. Sistemin temel bileşenlerinden biri, sürücünün dikkat durumunu analiz etmek için geliştirilen göz kırpma tespit modelidir. Bu model, gerçek zamanlı analiz yapabilmektedir. Trafik işareti tanıma sistemi için Evrişimsel Sinir Ağı (ESA) tabanlı bir model eğitilmiş ve modelin doğruluk oranı %96 olarak hesaplanmıştır. Ayrıca, kan ve kusmuk tespiti için oluşturulan özel veri seti etiketlenerek ESA modeli ile eğitilmiş ve doğruluk oranı kan tespiti için %95,65, kusmuk tespiti için %93 olarak elde edilmiştir. Nabız izleme sistemi, sürücünün kalp atışını anbean takip ederek ani sağlık sorunlarının tespit edilmesine olanak sağlamaktadır. Sensör teknolojisi olarak direksiyon simidine entegre edilen optik nabız sensörleri kullanılmıştır. Alkol tespit sisteminde ise MQ-3 gaz sensörleri ve nabız sensörlerinden gelen veriler birleştirilerek sürücünün alkol etkisi altında olup olmadığı belirlenmiştir.

Anahtar Kelimeler: Evrişimsel Sinir Ağı, Trafik işareti tanıma, Görüntü işleme, Nabız sensörleri, Alkol tespiti, Sürücü dikkat izleme

Smart Technologies in Driver Safety: Approaches to Reducing Human Errors with Sensor-Based Systems and Image Processing

Abstract

This study aims to develop an innovative system aimed at improving driver safety. A significant portion of traffic accidents are caused by human error, and technological solutions aimed at reducing these errors are crucial. To this end, a multi-component safety system was designed, including driver attention monitoring, traffic sign recognition, a blood and vomit detection system, heart rate monitoring, and alcohol detection. The study demonstrates that the system components operate with high accuracy and can reliably monitor driver behavior. Consequently, unlike studies in the literature that focus on a single element, this study integrates multiple components and offers an innovative contribution to in-vehicle safety technologies. The findings demonstrate that the system has significant potential for reducing traffic accidents. One of the system's key components is the blink detection model developed to analyze driver attention. This model is capable of performing real-time analysis. A Convolutional Neural Network (CNN)-based model was trained for the traffic sign recognition system, and the accuracy rate was calculated as 96%. Additionally, a custom dataset created for blood and vomit detection was labeled and trained with the CNN model, achieving an

accuracy rate of 95.65% for blood detection and 93% for vomit detection. The heart rate monitoring system monitors the driver's heart rate in real-time, allowing for the detection of sudden health problems. The sensor technology used optical heart rate sensors integrated into the steering wheel. The alcohol detection system combined data from MQ-3 gas sensors and heart rate sensors to determine whether the driver was under the influence of alcohol.

Keywords: Convolutional Neural Network, Traffic sign recognition, Image processing, Pulse sensors, Alcohol detection, Driver attention monitoring

1. GİRİŞ

Trafik kazalarındaki ölümlerin sayısı, 2000 yılında 1,15 milyondan 2018 yılında 1,35 milyona çıkarak istikrarlı bir şekilde artmaya devam etmektedir. Dünya çapındaki 56,9 milyon ölümden yaklaşık %2,37'sini trafik kazaları oluşturmaktadır ve küresel ölümlerin sekizinci nedenidir [1]. Bu artış, trafik kazalarının ciddi bir sorun olduğunu ve yaşam üzerindeki etkilerinin önemli bir risk oluşturduğunu göstermektedir. Türkiye'de yapılan araştırmalara göre, trafik kazalarının toplam maliyetinin sigorta sektöründe %16,37, finansal sistemde %0,36 ve gayri safi yurtiçi hasılda %0,55'lik bir paya sahip olduğu tespit edilmiştir. 2012 yılı itibarıyla, trafik kazalarının toplam maliyetinin 4,3 milyar ABD doları olduğu tahmin edilmektedir. Bu veriler, trafik kazalarının yalnızca can kayıplarına yol açmakla kalmayıp, aynı zamanda ekonomik sonuçlar doğurduğunu da ortaya koymaktadır [2].

Başka bir araştırmada, 2015 ile 2030 yılları arasında trafik kazalarının dünya ekonomisine toplam 1,8 trilyon dolarlık bir maliyet oluşturacağı öngörülmektedir [3]. Bu büyük ekonomik kayıp, trafik kazalarının yalnızca bireyler üzerinde değil, küresel ekonomik istikrar üzerinde de önemli bir tehdit oluşturduğunu göstermektedir. Bu nedenle, trafik güvenliğini artırmak ve kazaları önlemek amacıyla alınacak önlemler giderek daha fazla önem kazanmaktadır.

Trafik kazalarının oluşmasında insan faktörünün kritik bir rol oynadığı belirlenmiştir. Yapılan araştırmalar, eğitim seviyesinin yüksek olmasının bile trafik kazalarının tamamen önüne geçemeyeceğini ortaya koymaktadır [4]. Teknolojik gelişmeler, yol altyapısındaki iyileştirmeler ve otomotiv endüstrisindeki ilerlemelere rağmen, trafik kurallarına uyulmaması, işaret ve sinyallerin dikkate alınmaması ve riskli sürüş davranışlarının devam etmesi halinde, kazaların önlenmesinin mümkün olmadığı ifade edilmektedir.

Teknolojinin trafik kazalarının azaltılmasında önemli bir rol oynadığı görülmektedir [5]. Otomotiv endüstrisindeki gelişmeler sonucunda, sürücü güvenliğini artırmaya yönelik çeşitli sistemlerin kullanıma sunulduğu tespit edilmiştir. Acil fren sistemleri, şerit takip sistemleri ve yorgunluk tespit sistemleri gibi gelişmiş sürücü destek sistemleri, kazaların önlenmesine katkı sağlamaktadır. Ayrıca, otonom araç teknolojisinin insan hatalarından kaynaklanan kazaları azaltma potansiyeline sahip olduğu belirtilmektedir. Bu teknolojiler sayesinde, araçların çevresini izleyerek tehlikeleri algıladığı, gerektiğinde müdahale edebildiği ve sürücü hatalarından kaynaklanan riskleri en aza indirdiği görülmektedir.

Bu çalışma, sürücülerin dikkat seviyesini artıracak, sağlık durumlarını takip edecek ve sürüş güvenliğini iyileştirecek bir sistem geliştirmeyi amaçlamaktadır. Bu hedef doğrultusunda, kamera sistemleri, görüntü işleme teknolojileri, alkol sensörleri ve nabız sensörleri gibi çeşitli bileşenlerin entegrasyonu planlanmaktadır. İlk aşamada, aracın içerisine yerleştirilen bir kamera aracılığıyla sürücünün göz hareketleri ve baş pozisyonu takip edilerek, dikkat dağınıklığı ve uyku hali tespit edilmektedir. Dikkatin uzun süre dağılması durumunda, araç otonom sürüş moduna geçerek kontrolü ele almaktadır. Bu yaklaşımın, sürücü kaynaklı hataların neden olduğu kazaları azaltma potansiyeline sahip olduğu değerlendirilmektedir.

Bununla birlikte, araca entegre edilen alkol ve nabız sensörleri aracılığıyla sürücünün sağlık durumu sürekli izlenmektedir. Alkol sensörü, sürücünün alkol seviyesini belirleyerek yasal sınırların aşılması durumunda aracı otonom sürüş moduna geçirip güvenli bir alana park etmektedir. Benzer şekilde, nabız sensörü

sayesinde kalp krizi gibi acil durumların tespit edilmesi halinde, aracın güvenli bir şekilde kendisini durdurması sağlanmaktadır.

Bu çalışmanın temel amacı, sürücü güvenliğini artırmaya yönelik yenilikçi teknolojilerin entegrasyonu ile bir otomobilin işlevselliğini geliştirmektir. Kamera sistemleri, görüntü işleme teknikleri, alkol sensörleri ve nabız sensörleri gibi teknolojilerin kullanılması ile, sürücünün dikkatini dağıtabilecek veya trafik güvenliğini riske atabilecek durumların tespit edilmesi sağlanmaktadır. Bu gibi durumların meydana gelmesi halinde, aracın otonom sürüş modu devreye girecektir. Böylece, daha güvenli bir sürüş deneyimi sunulacak ve trafik kazalarının önlenmesine katkıda bulunacaktır.

2. LİTERATÜR TARAMASI

Bu çalışma kapsamında, dikkat algılama ve sürücü güvenliği sistemleri ile ilgili daha önce yapılan çalışmalar incelenmiş, bu sistemlerin geliştirilmesi sürecinde kullanılan veri setleri, yöntemler ve temel gereksinimler detaylandırılmıştır. Literatür taraması sırasında hem otomotiv üreticileri hem de teknoloji firmaları tarafından geliştirilen sistemler analiz edilmiştir.

Mevcut çalışmalar incelendiğinde, dikkat algılama sistemlerinin genellikle gaz pedalı ve direksiyon kontrolüne uygulanan basınç, direksiyon hareketleri ve sürücü davranışlarını izleyerek dikkat seviyesini belirlemeye odaklandığı görülmüştür [6, 7, 8]. Bunun yanı sıra, göz hareketlerini ve göz açıklığını takip eden sistemlerin, yorgunluk tespiti konusunda daha etkin olduğu belirlenmiştir [9, 10].

Mercedes Benz firması tarafından 2009 yılında kullanılmaya başlayan Attention Assist sistemi, birkaç dakika boyunca hızlanma, pedal kullanımı, araç hızı direksiyon gibi verileri değerlendirerek sürücü profili oluşturur ve seyahatin devamı sırasında elde olan verileri karşılaştırarak herhangi bir anormallik tespit ettiğinde sürücüyü uyarmaktadır [11].

Ford firmasının yaptığı diğer çalışmada ise sürücünün direksiyon düzeltmeleri ele alınır. Araç içine yerleştirilen kamera ile yol çizgileri takip edilerek şeritlere uygun hareket edilip edilmediğine bakılır. Eğer sık sık şerit değişikliği yapıyor ise sürücünün dikkat bozukluğu olduğu anlamına gelip sürücüye uyarı vermektedir [12].

Trafik işareti tanıma sistemleri üzerine yapılan çalışmalar genellikle belirli trafik işaretlerine odaklanmış olup, mevcut sistemler genellikle hız sınırı, tek yön ve sollama yasakları gibi yaygın işaretleri algılamaktadır. Bu alandaki çalışmalar genellikle ESA tabanlı modellerle gerçekleştirilmiştir [13]. Mevcut çalışmadan farklı olarak, 43 farklı trafik işareti tanınabilecek şekilde genişletilmiş bir veri seti kullanılmıştır ve özelleştirilmiş bir ESA modeli olan Xception modeli kullanılmıştır.

Alkol tespit sistemleri incelendiğinde, Volvo tarafından geliştirilen sistemin, sürücüye nefes testi uygulayarak alkol tespiti yaptığı görülmektedir [14]. Ancak bu tür sistemlerin gaz sensörü kullanması nedeniyle kolayca yanıltılabildiği, yolcunun alkol alımı gibi durumlarda yanlış alarm verebildiği tespit edilmiştir. Bu eksikliği gidermek adına bu çalışma, direksiyon simidine entegre edilen nabız sensörü ile gaz sensörü verilerini birleştiren bir sistem önerilmektedir.

Literatürde giyilebilir sensörlere dayalı olarak sürücünün sağlık durumunu izlemeye yönelik bazı çalışmalar bulunmasına rağmen, araç içi entegre sensörlerle kalp krizi veya bilinç kaybı gibi acil durumları doğrudan algılayan kapsamlı bir sistem henüz geliştirilmemiştir. Bu çalışmada, sürücü sağlığını anlık olarak izleyebilen ve olası acil durumları tespit edebilen bütünlük bir yaklaşım sunulmaktadır.


Mevcut literatürde sürücünün sağlık durumunu ve olası acil durumlarını izlemeye yönelik çeşitli yaklaşımlar (ör. giyilebilir sensörler, kamera tabanlı izleme veya biyosinyal ölçümleri) bulunmaktadır. Ancak bu çalışmaların çoğu, sürücünün sürekli ek donanım kullanmasını gerektirmesi, gerçek zamanlı entegrasyonda sınırlı kalması veya araç içi kullanımda pratik zorluklar barındırması nedeniyle doğrudan

uygulanabilir görülmemektedir. Bu çalışmada ise, söz konusu eksiklikleri gidermek amacıyla araç içine entegre, sürücüden ek çaba gerektirmeyen ve gerçek zamanlı çalışabilen bütüncül bir sistem önerilmektedir.

Ayrıca, burun kanaması veya kusma gibi acil durumların tespitine yönelik literatürde herhangi bir çalışmaya rastlanmamıştır. Bu iki durumu kapsayan veri setleri sıfırdan oluşturulmuş ve etiketlenmiştir.

Sonuç olarak, bu çalışma mevcut sürücü güvenliği sistemlerini geliştirerek, literatürde bulunan boşlukları gidermeyi ve yeni çözümler sunmayı hedeflemektedir. Geliştirilen sistemler sayesinde, güvenlik teknolojilerinin daha geniş bir alanda gelişimine katkı sağlanması amaçlanmaktadır.

3. MATERYAL VE METOT



Şekil 1. Sistemin genel mimarisi

Bu çalışma, sürüş güvenliğini artırmak ve sürücünün sağlık durumunu anlık olarak izlemek amacıyla yazılım ve donanım olmak üzere iki ana modülden oluşmaktadır. Yazılım birimi, sürücü dikkat sistemi, trafik işareti tanıma sistemi ve kan/kusmuk tespit sistemi gibi önemli işlevleri içeren üç alt modülden meydana gelmektedir. Bu yazılımlar, sürücünün davranışlarını ve çevresel koşulları analiz ederek olası riskleri tespit etmekte ve aracın güvenli sürüşünü desteklemektedir. Donanım birimi ise nabız ölçme sistemi ve alkol tespiti sistemi ile sensör bazlı modüllerle oluşturulmuştur. Bu sistemler, sürücünün sağlık durumu

hakkında gerçek zamanlı veri sağlayarak, ani sağlık sorunlarının tespit edilmesine ve önlenmesine katkı sağlayacaktır.

ASGÜS genel mimarisi Şekil 1’de verilmiştir. Bu mimaride, sistemin bileşenleri ile bu bileşenler arasındaki veri akışı genel hatlarıyla sunulmuştur.

Sistemin genel işleyişi, donanım ve yazılım alt modüllerinin entegrasyonu ile birleştirilmiştir. Donanım modülleri, sürücünün vücut durumu ve çevresel koşullar hakkında bilgi toplarken, yazılım modülleri görüntü işleme verilerini analiz ederek sürücünün güvenliğini tehlikeye sokabilecek durumları belirler.

Yazılım ve donanım modülleri aşağıda detaylandırılmıştır:

3.1 Yazılım Modülleri


Sürücü Dikkat Sistemi

Bu bölümde sürücü dikkat tespit sisteminin temel bileşeni olarak göz kırpma tespiti ele alınmıştır. Göz kırpma davranışının izlenmesi, sürücünün dikkat seviyesinin belirlenmesinde önemli bir göstergedir. Bu amaçla, görüntü işleme ve yüz tanıma tekniklerinden yararlanılmış, sistemin gerçekleştirilmesi için Python programlama dili kullanılmıştır. Uygulamanın geliştirilmesinde OpenCV, dlib ve imutils kütüphanelerinden faydalanılmıştır.

OpenCV, gerçek zamanlı görüntü işleme işlevlerini sağlarken; dlib, yüz algılama ve yüz üzerindeki belirli anatomik noktaların (facial landmarks) tespiti için kullanılmıştır. Imutils kütüphanesi ise görüntülerin yeniden boyutlandırılması, kanal dönüşümü gibi işlemleri kolaylaştırmak adına çalışmaya dâhil edilmiştir.

Uygulama, gerçek zamanlı olarak kameradan alınan görüntü akışı üzerinde çalışmaktadır. Her kare, daha verimli yüz algılama işlemi için gri tonlamaya dönüştürülmektedir. Dlib kütüphanesinin sağladığı 68 noktalı yüz yer işaretleme modeli (68-point facial landmark model) kullanılarak, yüz bölgesi üzerindeki sol ve sağ göz konumları tespit edilmektedir.

Gözlerin açık ya da kapalı olması durumu, Göz En-Boy Oranı (Eye Aspect Ratio - EAR) yöntemi ile belirlenmektedir. EAR değeri, göz çevresindeki belirli noktalar arasındaki mesafelere dayalı olarak hesaplanır. EAR değerinin belirlenen bir eşik değerinin altına düşmesi, gözlerin kapalı olduğunu; eşik değerin üzerinde olması ise gözlerin açık olduğunu ifade etmektedir. Bu hesaplama her bir görüntü karesi için sürekli olarak tekrarlanır ve elde edilen EAR değerleri üzerinden göz kırpma sayısı ve gözlerin kapalı kalma süresi analiz edilir. Göz kırpmalar, süresine bağlı olarak kısa ve uzun kırpma olarak sınıflandırılır. Kısa kırpma, normal dikkatin göstergesi iken; uzun süreli göz kapalı kalma (örneğin mikro uyku) dikkatin azaldığına işaret eder. Sistem, bu kırpma davranışlarının sıklığını ve süresini analiz ederek önceden belirlenmiş tehlike eşik değerine göre değerlendirme yapar. Bu eşik aşıldığında sürücüye uyarı gönderilir ve araçta otonom sürüş modunun devreye girmesi sağlanarak güvenlik artırılır. Şekil 2’de bu sisteme ait akış diyagramı sunulmuştur.



Şekil 2. Sürücü dikkat sistemi akış diyagramı

Trafik İşareti Tespiti

Trafik işareti tespiti, sürücü güvenliğini artırmak ve otonom araç sistemlerine katkı sağlamak amacıyla kullanılan önemli bir görsel tanıma problemidir. Bu bölümde, trafik işaretlerini doğru ve hızlı şekilde sınıflandırmak için literatürde yaygın kullanılan ve yüksek performansı ile öne çıkan Xception mimarisi tercih edilmiştir. Xception, derinlik bazında ayrılabilir evrişimler (depthwise separable convolutions) kullanan modern bir konvolüsyonel sinir ağıdır ve klasik mimariler olan AlexNet veya VGG'ye kıyasla daha az parametre ile daha yüksek doğruluk ve verimlilik sunmaktadır. AlexNet ve VGG gibi modeller, daha büyük parametre sayısı ve daha yavaş eğitim süreçleri nedeniyle özellikle sınırlı veri ve donanım koşullarında dezavantaj yaratmaktadır [15]. Bu nedenle, küçük ve orta büyüklükteki veri kümelerinde daha hızlı ve etkili sonuç veren Xception modeli, trafik işareti tespiti için uygun bir seçim olmuştur.

Model eğitimi için Kaggle'da yer alan German Traffic Sign Recognition Benchmark (GTSRB) veri seti kullanılmıştır [16]. Veri seti, 43 farklı trafik işareti kategorisinden oluşan 39.209 eğitim görseli ve 12.630 test görseli içermektedir. Şekil 3'te veri setinin görüntüleri bulunmaktadır. Tüm görüntüler, modelin kabul ettiği standart giriş boyutu olan 224x224 piksel ve 3 renk kanalı (RGB) formatına dönüştürülmüştür. Bu standartlaştırma, modelin giriş katmanına uygun ve homojen veri sağlayarak öğrenme sürecinin stabil ve verimli olmasına katkı sağlamıştır.



Şekil 3. Trafik veri seti örnek görüntüler

Modelin eğitimi için transfer öğrenme tekniği kullanılmıştır. Transfer öğrenme, önceden eğitilmiş bir modelin ağırlıklarını yeni bir görevde kullanma yöntemidir. Bu yaklaşım, büyük veri kümesinde eğitilmiş bir modelin özelliklerini, daha küçük veri kümesine sahip olan bir problemde kullanarak eğitim sürecini hızlandırır. Bu teknik sayesinde, model daha hızlı ve verimli bir şekilde eğitilmiş olur. Önceden ImageNet veri kümesi üzerinde eğitilmiş Xception modelinin ilk katmanları dondurulmuş, sadece son bloklardaki katmanlar ve son sınıflandırma katmanı eğitime açılmıştır. Böylece, model önceden öğrenilmiş genel görüntü özelliklerini korurken, trafik işaretlerine özgü sınıflandırma görevini adapte etmiştir. Modelin son katmanı, 43 sınıfı ayıracak şekilde yeniden düzenlenmiş ve eğitim 15 epoch boyunca gerçekleştirilmiştir. Model mimarisi Şekil 4'te gösterilmiştir.


Epoch sayısı, doğrulama kaybı ve doğruluk değerleri izlenerek yapılan ön denemeler sonucunda belirlenmiş; 15 epoch sonrasında modelin performansının plato yaptığı ve ek eğitimlerin anlamlı bir iyileşme sağlamadığı gözlemlenmiştir. Ayrıca, aşırı öğrenmeyi önlemek için erken durdurma (Early Stopping) stratejisi uygulanmış ve doğrulama kaybında 5 ardışık epoch boyunca iyileşme görülmediğinde eğitim süreci otomatik olarak sonlandırılmıştır. Bu parametrelerin seçimi, modelin genelleme kabiliyetini korurken eğitim süresini optimize etmeyi amaçlamaktadır.

Optimizasyon aşamasında, öğrenme oranı 0.0001 olan Adam optimizör ve çok sınıflı sınıflandırma problemi için uygun olan categorical cross-entropy kayıp fonksiyonu kullanılmıştır. Eğitim sürecinde aşırı öğrenmeyi engellemek amacıyla erken durdurma stratejisi uygulanmıştır. Doğrulama kaybında iyileşme gözlemlenmediğinde eğitim süreci sonlandırılmıştır. Bu yöntem, modelin genelleme yeteneğini artırarak aşırı uyum riskini azaltmıştır.

Modelin katman yapısı şu şekildedir: Giriş görüntüsü önce derinlik bazında ayrılabilir evrişimler içeren Xception taban modeli üzerinden geçirilir (7x7x2048 çıkış boyutu). Ardından, uzamsal boyutları küçülten global average pooling katmanı (2048 boyutlu vektör çıkışı) gelir. Modelin öğrenme kapasitesini artırmak için 1024 nöronlu ve ReLU aktivasyonlu tamamen bağlı (dense) katman takip eder. Son katman ise, 43 sınıf için softmax aktivasyon fonksiyonuna sahip çıkış katmanıdır. Bu yapı, hem modelin karmaşık özellikleri öğrenmesini sağlar hem de sınıflandırma performansını artırır.

Sonuç olarak, Xception mimarisinin derinlik bazında ayrılabilir evrişim teknolojisi, trafik işaretlerindeki renk ve şekil varyasyonlarını etkin bir şekilde öğrenirken, model boyutunu küçültüp eğitim süresini azaltır. Transfer öğrenmede ilk katmanların dondurulması ise genel özellik çıkarımının korunmasını sağlarken,

sınıflandırmaya özgü katmanların eğitilmesiyle görev başarısı optimize edilir. Bu sayede hem hesaplama kaynakları verimli kullanılmış hem de %98'in üzerinde doğrulukla trafik işareti tespiti gerçekleştirilmiştir.



Şekil 4. Trafik işareti tespiti modelinin mimarisi

Kan/Kusmuk Tespit Sistemi

Bu bölümde, burun kanaması ve kusmayı tespit etmek amacıyla bir sistem geliştirilmiştir. Bu bağlamda, önceki bir çalışmada oluşturulmuş burun kanaması ve kusma içeren acil durum yüz veri kümesi kullanılmıştır [17]. Veri kümesi, modelin genelleme yeteneğini artırmak ve modelin farklı senaryolarda başarımını değerlendirmek amacıyla %70 eğitim, %15 test ve %15 doğrulama olmak üzere rastgele bölümlendirilmiştir. Bu oranların seçilmesinde, eğitim sürecinde modelin yeterince öğrenmesini sağlamak ve aşırı uyum riskini minimize etmek hedeflenmiştir.



Şekil 5. Kusma, burun kanaması ve normal insan yüzlerinden oluşturulan veri seti örnek görüntüleri

Veri setinde toplam 514 burun kanaması ve 27 kusmuk resmi bulunmaktadır. Şekil 5'te veri setinde var olan resimlerden bazıları gösterilmiştir. Bu görüntüler üzerinde çeşitli ön işleme adımları gerçekleştirilmiştir. Öncelikle, tüm görüntüler modelin giriş boyutuna uygun hale getirilmesi için 128x128 piksele ölçeklendirilmiştir. Ayrıca, modelin renk bilgisinden ne kadar yararlanması gerektiği test edilerek, bazı deneylerde görüntüler gri tonlamaya çevrilmiştir. Daha sonra, görüntü detaylarını vurgulamak ve kenar belirginleştirme yapmak amacıyla "Blur", "Contour", "Detail", "Edge Enhance" ve "Emboss" filtreleri uygulanmış ve bu işlem sonucunda 1245 adet filtrelenmiş burun kanaması görüntüsü ve 135 adet filtrelenmiş kusmuk görüntüsü elde edilmiştir. Görsellerin etiketlenmesi için "LabelImg" programı kullanılmış ve etiketli veriler XML, CSV ve JSON formatlarında kaydedilmiştir. Etiketleme işlemi, modelin doğru sınıflandırma yapabilmesi için kritik bir aşama olup, nesnelerin doğru sınır kutularıyla belirlenmesini sağlamıştır [18].


Burun kanaması ve kusmayı tespit etmek için geliştirilen iki ayrı modelde ESA mimarisi kullanılmıştır. ESA'lar, özellikle görüntü işleme ve tanıma konularında oldukça başarılıdır. Evrişimli katmanlar, görüntüdeki önemli özellikleri otomatik olarak çıkararak modelin öğrenme sürecini iyileştirmekte; havuzlama (pooling) katmanları ise boyutu küçülterek hesaplama maliyetini düşürmektedir. Bunun sonucunda, model hem daha hızlı çalışmakta hem de aşırı uyum riskini azaltmaktadır [19].

Model eğitimi sürecinde, modelin en iyi performansı göstermesi için çeşitli hiper parametre ayarları belirlenmiştir. Modelin kayıp fonksiyonu olarak ikili sınıflandırma problemleri için yaygın olarak kullanılan "binary_crossentropy" tercih edilmiştir. Bu fonksiyon, modelin çıktısını olasılık değerleri olarak üreterek, hangi sınıfa daha yakın olduğunu ölçmektedir. Modelin ağırlıklarını güncellemek için "rmsprop" optimizasyon algoritması kullanılmıştır. RMSprop, özellikle düzensiz veri dağılımlarına sahip veri kümelerinde stabil öğrenmeyi sağladığı için tercih edilmiştir. Modelin başarısını değerlendirmek amacıyla "accuracy" metriği kullanılmıştır. Eğitim sürecinin aşırı uyum riskini azaltarak genel performansı artırmak için eğitim epoch sayısı 10 olarak belirlenmiştir. Bu seçim, eğitim sürecinin gereksiz uzamasını engellemek ve modelin verimli bir şekilde öğrenmesini sağlamak için yapılmıştır.

Modelin mimari yapısı, veri setinin büyüklüğü ve problem türüne uygun olarak yapılandırılmıştır. Küçük bir veri seti ile çalışıldığından, derin ve karmaşık bir model yerine daha hafif ve hesaplama açısından verimli bir ESA mimarisi tercih edilmiştir. Bu doğrultuda, modelde toplam üç evrişim katmanı (convolutional layers) kullanılmıştır. İlk evrişim katmanı 32 filtre içermekte ve 3x3 çekirdek boyutuna sahiptir. İkinci evrişim katmanı 64 filtre içerirken, üçüncü katmanda ise 128 filtre bulunmaktadır. Her evrişim katmanında ReLU (Rectified Linear Unit) aktivasyon fonksiyonu kullanılarak doğrusal olmayan ilişkilerin modellenmesi sağlanmıştır.

Evrişim katmanlarını takip eden iki adet 2x2 boyutunda maksimum havuzlama (max-pooling) katmanı eklenmiştir. Bu katmanlar, görüntü boyutunu küçültüp en belirgin özellikleri koruyarak, modelin işlem gücünü daha verimli kullanmasını sağlamıştır. Daha sonra, özellik haritalarını tam bağlantılı katmanlara aktarabilmek için birleştirme (flatten) katmanı eklenmiştir. Tam bağlantılı katmanlarda 128 ve 64 nöron içeren iki gizli katman bulunmakta olup, her ikisinde de ReLU aktivasyon fonksiyonu kullanılmıştır. Modelin çıktısı ise sigmoid aktivasyon fonksiyonu ile hesaplanarak, modelin olasılık değerleri üretmesi sağlanmıştır.

Bu mimari, veri setinin görece küçük olması nedeniyle fazla parametre içermeyen, ancak derin öğrenme modellerinin avantajlarından faydalanan bir yapı olarak belirlenmiştir. Daha derin bir model kullanılması durumunda aşırı uyum riski artabilir iken, daha yüzeysel bir model kullanılması öğrenme kapasitesini sınırlayacaktır. Bu nedenle hem hesaplama maliyetini düşük tutacak hem de yeterli öğrenme kapasitesine sahip olacak şekilde optimize edilmiş bir ESA modeli tercih edilmiştir. Gelecek çalışmalar için daha büyük veri setleri ile transfer öğrenme tekniklerinin kullanılması ve modelin farklı senaryolarda test edilmesi önerilmektedir. Şekil 6'da bu sisteme ait akış diyagramının adımları verilmiştir.



Şekil 6. Kan/Kusmuk tespit sistemi akış diyagramı

3.2 Donanım Modülleri

Nabız Ölçme Sistemi

Donanım biriminin ilk adımı olarak, direksiyona entegre edilmiş nabız sensörleri kullanılarak sürücünün kalp atış hızının izlenmesi ve olası anormal durumların tespiti hedeflenmiştir. Bu sistem, sürücünün kalp atış hızında bir anormallik tespit ettiğinde, aracı otonom sürüş moduna geçirerek güvenli bir şekilde park edilmesini sağlar. Bu yaklaşım, sürücünün ani sağlık sorunları yaşaması durumunda meydana gelebilecek kazaları önlemeyi amaçlamaktadır.

Sürücünün nabız verileri, genel sağlık durumu hakkında kritik bilgiler sunmaktadır. Nabız takibi sayesinde ani kalp krizi, aritmi veya tansiyon değişiklikleri gibi sağlık sorunları tespit edilebilir. Nabızdaki ani yükselmeler ya da düşüşler kalp krizine işaret edebilirken, uykuya dalma veya bayılma gibi durumlar sırasında nabız hızındaki değişimler, anormalliklerin tespitine yardımcı olur.

Direksiyon simidi, sürücünün sürekli temas halinde olması nedeniyle nabız sensörlerini yerleştirmek için ideal bir nokta olarak seçilmiştir. Bu yöntem, doğru ve sürekli veri sağlarken sürücü tarafından ek bir işlem yapılmasını gerektirmemekte ve aracın iç tasarımında herhangi bir değişikliğe neden olmamaktadır. Böylece sürüş güvenliği sağlanırken, kullanıcı konforu ve araç estetiği korunmuş olur.

Nabız sensörü, optik sensör teknolojisini kullanarak kalp atış hızını ölçmektedir. Sensör, bir LED ve bir fotodiyot içerir. LED, kan damarlarındaki kan akışını takip ederek deriye ışık gönderir. Fotodiyot ise yansıyan ışığı algılayarak her kalp atışında değişen ışık miktarını ölçer. Bu veriler, bir mikrodenetleyici (örneğin Arduino) aracılığıyla işlenir ve sürücünün kalp atış hızı hesaplanır.

Çalışmada, sensörlerden her beş saniyede bir ölçüm yapılacak şekilde sistem tasarlanmıştır. Bu sayede, anlık dalgalanmaların etkisi en aza indirgenir. Beş dakikalık bir süre boyunca toplanan veriler, ortalama nabız hızını hesaplamak için kullanılır.

Tıbbi açıdan, bu tür kısa aralıklarla yapılan ölçümler, sürücünün nabzının daha doğru ve güvenilir bir şekilde değerlendirilmesini sağlar. Ortalama nabız hızı, belirli bir eşiğin üstünde ya da altında olduğunda sistem devreye girer. Araç otonom sürüş moduna geçer ve güvenli bir şekilde durdurulup park edilir. Otonom sürüş modu, araç içindeki sensörler ve yazılım tarafından tetiklenen bir dizi işlemi içerir. Nabız verisi, belirlenen eşiğin dışına çıktığında, mikrodenetleyici bu durumu tespit eder ve otonom sürüş modunun aktif hale gelmesi için aracın sürüş kontrol sistemine sinyal gönderir. Bu sinyal, aracın direksiyon, hız ve fren sistemlerini kontrol eden yazılımlar aracılığıyla, sürücünün müdahalesine gerek kalmadan güvenli bir şekilde aracın durmasını ve park edilmesini sağlar. Ayrıca, aracın çevresini algılayan diğer sensörler de park işlemi sırasında herhangi bir engel olmadığından emin olmak için aktif hale gelir.

Alkol Tespit Sistemi

Bu çalışmanın bir diğer önemli modülü, sürücünün alkol tüketimini ve fizyolojik durumunu izleyerek güvenliği artırmayı hedefleyen bir sistemin geliştirilmesidir. Alkol tüketiminin sürücü üzerindeki etkileri merkezi sinir sistemini baskılayarak, reflekslerin yavaşlaması, dikkat dağılması ve karar verme yetisinin azalması gibi sonuçlara yol açmakta ve bu durum trafik güvenliğini tehlikeye sokmaktadır. Bu bağlamda, araç içine yerleştirilen alkol sensörleri ile sürücünün alkol alıp almadığı tespit edilecektir. Alkol sensörleri, aracın içine stratejik olarak yerleştirilecektir; genellikle sürücünün nefesini algılayabileceği bölgelerde, yani araç içindeki hava akımının iyi olduğu alanlarda konumlandırılacaktır. Bu sensörler, araç içindeki alkol buharlarını tespit etmek amacıyla, belirli bir yükseklikte ve açık hava akışına yakın yerlerde yerleştirilir. Sensörlerin doğru veri sağlayabilmesi için, araç içindeki hava akışının sensörlere etkisi göz önünde bulundurulmuş ve araçtaki diğer hava kaynaklarından (örneğin havalandırma sisteminden) gelen havayla karışmaması için hassas yerleştirme yapılacaktır.

Alkol buharlarının varlığını algılamak için MQ-3 tipi gaz sensörleri kullanılmaktadır. MQ-3 sensörleri, alkol buharlarına maruz kaldığında elektriksel direncini değiştiren bir kimyasal katman içermektedir. Bu direnç değişikliği bir voltaj sinyali olarak algılanmakta ve Arduino mikrodenetleyicisi tarafından işlenerek, sensör çıkışındaki voltaj değişiklikleri alkol varlığını ve konsantrasyonunu göstermektedir. Alkol tespiti ardından, sürücünün fizyolojik durumunu anlamak için ek bir doğrulama yöntemi olarak direksiyona entegre edilmiş nabız sensörlerinden gelen veriler kullanılmaktadır.

Nabız Sensörünün Kullanımı ve Entegrasyonu

Nabız sensörü, sürücünün kalp atış hızını takip ederek fizyolojik durumunu değerlendirmektedir. Alkol tüketimi genellikle kan basıncını düşürüp kalp atış hızını artırdığı için sürücünün nabzında belirgin bir artış gözlemlenebilir. Nabız sensörü, optik sensör teknolojisine dayanmaktadır. Bu sensör, bir LED ışık kaynağı ve bir fotodiyot içerir; LED ışığı kan damarlarına gönderir ve fotodiyot yansıyan ışığı algılayarak, kalp atışlarını takip eder. Alkol tüketimine bağlı olarak nabızda hızlanma ve düzensizlik gözlenmesi durumunda, sistem sürücünün alkollü olabileceği varsayımıyla otonom sürüş modunu devreye sokar.

Veri İşleme ve Sistem Entegrasyonu

Sensörlerden elde edilen veriler, Raspberry Pi ve Arduino mikrodenetleyicileri aracılığıyla işlenmektedir. Başlangıçta analog sinyalleri dijital forma dönüştürmek için MCP3008 ADC modülü kullanılmıştır. Ancak MCP3008, her sensör için ayrı bir ADC kanalı gerektirdiğinden, çoklu sensörlerle çalışırken yetersiz kalmıştır. Bu sorunu aşmak amacıyla Arduino mikrodenetleyicisi tercih edilmiştir. Arduino, birden fazla analog sensörü destekleyebilme kapasitesine sahiptir ve analog sinyalleri dijital verilere dönüştürdükten sonra Raspberry Pi'ye seri iletişim yoluyla iletmektedir. Böylelikle alkol ve nabız sensörlerinden gelen veriler birleştirilerek sürücünün durumu değerlendirilmekte ve sistem, sürüş güvenliğini artırmak amacıyla otonom sürüş moduna geçmektedir.

Alkol ve Nabız Tespitinin Entegre Kullanımı

Sistemin doğruluğunu artırmak ve olası yanlış pozitifleri önlemek için, alkol tespiti ile nabız verilerinin birlikte değerlendirilmesi önem taşımaktadır. Araç içerisinde yer alan alkol sensörleri sadece sürücünün değil, araçtaki diğer yolcuların da alkol varlığını algılayabileceğinden, bu durum bazen yanlış sonuçlara yol açabilmektedir. Bu sorunu çözmek için, sürücünün direksiyondan alınan nabız verileri de kullanılarak nihai karar verilmektedir. Nabızdaki düzensizlikler ve artışlar, alkolün merkezi sinir sistemi üzerindeki baskılayıcı etkilerini doğrulamak amacıyla kullanılmaktadır. Bu iki veri kaynağı birlikte değerlendirildiğinde, sürücünün alkollü olup olmadığı daha güvenilir bir şekilde belirlenmektedir.

Sistem, sürücünün alkollü olduğu doğrulandığında aracı otonom sürüş moduna geçirerek güvenli bir şekilde park etmektedir. Bu entegre yaklaşım, yalnızca sürücünün değil, araçtaki diğer yolcuların güvenliğini de sağlamayı hedeflemekte ve alkol tüketimine bağlı kazaların önlenmesine katkı sunmaktadır.

Donanım ve Yazılım Bileşenlerinin Entegrasyonu

Yazılım ve donanımın entegre edilmesi süreci, her iki birimin uyumlu bir şekilde çalışmasını sağlamak için kritik öneme sahiptir. Bu süreçte, Raspberry Pi 3 B+ kartı ve Arduino Uno, sensörlerden gelen verilerin doğru ve hızlı bir şekilde işlenmesi için birbirine bağlanmıştır. Arduino Uno, analog sensörlerden alınan sinyalleri dijital verilere dönüştürüp Raspberry Pi'ye iletirken, Raspberry Pi, Python tabanlı modelleri çalıştırarak bu verilerin analizini gerçekleştirmiştir.

Özellikle alkol ve nabız tespit sisteminde, sensörlerin ürettiği verilerin entegrasyonu hayati önem taşımaktadır. Alkol sensöründen alınan verilerle nabız sensörünün verileri birleştirilerek, sürücünün alkol alıp almadığı daha güvenilir bir şekilde tespit edilmektedir. Veri akışının sağlanması ve analizlerin kesintisiz bir şekilde yapılması için mikrodenetleyiciler arası seri iletişim protokolleri kullanılmıştır.

Sensör Verilerinin Toplanması ve İşlenmesi


Sistem, alkol ve nabız sensörlerinden gelen verileri toplamak ve analiz etmek için Arduino kartını kullanmaktadır. Arduino, analog sinyalleri dijital verilere dönüştürmekte ve bu verileri Raspberry Pi'ye seri haberleşme yoluyla iletmektedir. Raspberry Pi, Python tabanlı makine öğrenimi modellerini çalıştırarak dikkat tespiti, trafik işareti tanıma ve kan/kusuk verilerinin analizini gerçekleştirmektedir. Bu analizler sonucunda, sürücünün durumu hakkında karar verilip gerekirse otonom sürüş moduna geçilmesi sağlanmaktadır. Bu sayede, sürücü dikkat sistemi ve diğer güvenlik sistemleri entegre bir şekilde çalışmakta ve sürüş güvenliği artırılmaktadır.

4. DENEYSEL SONUÇLAR

Bu çalışma, sürücü dikkatinin izlenmesi, trafik işaretlerinin tanınması, kan/kusma algılama, nabız izleme ve alkol tespit sistemlerinin geliştirilmesi yoluyla araç içi güvenliğin artırılmasını ve trafik güvenliğinin sağlanmasını amaçlamaktadır. Bu amaç doğrultusunda, görüntü işleme, makine öğrenmesi ve çeşitli sensörlerden (IR kamera, nabız sensörü, gaz sensörü) gelen veriler kullanılarak, sürücü davranışları ve fiziksel durumlar izlenecek, olası tehlikeler tespit edilecektir.

Gerçekleştirilen deneylerde, her bir sistem bireysel olarak test edilmiş ve belirlenen senaryolar altında performansları değerlendirilmiştir. Örneğin, burun kanaması tespitinde %95,65 doğruluk oranına ulaşırken, kusuk sistemi %93 başarı oranı ile çalışmıştır. Ancak, bu sistemlerin gerçek dünya koşullarında daha geniş çaplı testlere tabi tutulması ve optimize edilmesi gerekmektedir. Gelecekte, daha büyük ve çeşitlendirilmiş veri kümeleri ile eğitilmesi, farklı çevresel koşullar altında test edilmesi sistemin genel performansını ve güvenilirliğini artıracaktır.

Bu proje, araç içi güvenlik teknolojilerinin geliştirilmesi ve uygulanması yönünde önemli bir adım olarak değerlendirilmektedir. Şekil 7, geliştirilen sistemlerin entegre edildiği prototipin nihai durumunu göstermektedir.



Şekil 7. Sistemin prototip olarak meydana getirilmesi

4.1 Sürücü Dikkat Sistemi

Bu bölümde geliştirilen sürücü dikkat tespit sistemi, Python programlama dili ile gerçekleştirilmiş olup, temel olarak göz kırpmaya davranışına dayalıdır. Uygulamanın geliştirilmesinde OpenCV, dlib ve imutils kütüphaneleri kullanılmıştır. Sistem, sürücünün göz kırpmaya sıklığı ve süresini gerçek zamanlı olarak izlemekte ve bu verilere dayanarak dikkat düzeyini değerlendirmektedir.

Deneyisel uygulamada, kameradan alınan görüntüler üzerinde dlib ile göz çevreleri işaretlenmiş, her karede gözün açık veya kapalı durumu hesaplanmıştır. Şekil 8’de örnek bir karede sistemin çalışma anı gösterilmekte olup, göz çevrelerinin doğru şekilde algılandığı ve sistemin eşik değerlere göre durumu analiz ettiği görülmektedir.

Göz kırpmaya davranışlarının izlenmesi, sürücünün yorgunluk ya da dikkat dağınıklığı gibi durumlarının belirlenmesinde önemli bir belirteç olarak kullanılmıştır. Elde edilen veriler ışığında, sistemin uzun süreli dikkat kayıplarını erken safhada tespit edebildiği gözlemlenmiştir. Sistem performansını artırmak amacıyla, Göz En-Boy Oranı (EAR) için kullanılan eşik değeri sabit bir değer yerine kişiye özel olarak belirlenmiştir. Uygulama başlatıldığında, sürücünün gözleri açık durumdayken elde edilen ortalama EAR değeri referans alınmakta ve bu değer %40’ı eşik değeri olarak kullanılmaktadır. Böylece sistem, farklı yüz yapısına ve göz açıklığına sahip bireyler için daha hassas ve uyarlanabilir bir değerlendirme yapabilmektedir. Belirlenen bu eşik değerinin altında, dakikada 5’ten az veya 30’dan fazla göz kırpmaya tespit edilmesi, dikkat dağınıklığı ya da stres durumu olarak yorumlanmakta ve bu durumlar da sistem tarafından riskli olarak sınıflandırılmaktadır. Bu gibi durumlarda, sistemin otonom sürüş moduna geçiş için tetikleme sinyali üreterek sürüş güvenliğini artırmayı hedeflediği planlanmıştır.




Şekil 8. Gözlerin tespiti ve sistemin çalışır durumu

4.2 Trafik İşareti Tespiti

Geliştirilen trafik işareti tespit sistemi, GTSRB- German Traffic Sign Recognition Benchmark veri kümesi kullanılarak eğitildi. Modelin eğitimi için Google Colaboratory platformu tercih edilmiştir ve başarı oranını artırmak amacıyla veri artırma ve transfer öğrenme teknikleri kullanılmıştır. Eğitim sürecinde, trafik işaretlerini doğru bir şekilde tanıyabilmek için F1 skoru, kesinlik (precision), duyarlılık (recall) ve doğruluk (accuracy) gibi değerlendirme kriterleri göz önünde bulundurulmuştur.

Modelin değerlendirilmesinin ardından elde edilen sonuçlar Tablo 1'de özetlenmiştir. Modelin doğruluk oranı %96 olarak belirlenmiş ve test verisi üzerinde yapılan analizlerde precision ve recall değerleri sırasıyla %92 ve %89 olarak hesaplanmıştır. Bu sonuçlar, trafik işaretlerinin doğru bir şekilde tespit edilebildiğini ve modelin genel olarak başarılı olduğunu göstermektedir. Modelin F1 skoru ölçümü ise %90.5 olarak elde edilmiştir, bu da modelin doğru tahminler yapmada oldukça etkili olduğunu ifade etmektedir. Şekil 9'da Modelin her bir adımda train-test-val değerlerinin grafiği gösterilmiştir.



Şekil 9. Modelin Train- Test- Val doğruluk grafiği

Ayrıca, modelin genel hataları değerlendirilirken, Ortalama Mutlak Hata (MAE) değeri 0.010987 olarak hesaplanmıştır. Bu düşük hata oranı, modelin trafik işaretlerini tespit etme konusunda oldukça hassas olduğunu ve tahminlerinde yüksek bir doğruluk sergilediğini göstermektedir. Ortalama MAE, modelin

tahminlerinde ne kadar doğru olduğunu gösteren önemli bir ölçüttür ve bu değer modelin çeşitli koşullarda da güvenilir bir performans sergileyeceğini işaret etmektedir.

Tablo 1. Trafik işareti tespiti için eğitilen modelin değerlendirme kriterleri skorları

Doğruluk	96%
Duyarlılık	92%
Geri Çağırma	89%
F1-Ölçümü	90,5%

4.3 Kan/Kusmuk Tespit Sistemi

Kan/kusmuk tespiti sistemi için etik kurallara uygun bir şekilde iki adet veri seti oluşturulmuştur. Oluşturulan veri setleri özelleştirilmiş bir ESA modeli ile eğitilmiştir. Kusmuk veri setinin sınırlı olması ve örneklerin yetersiz olmasından dolayı modelin performansını etkilemiştir. Şekil 10'da sistemin yüzleri tespit edip burun kanaması olup olmadığını belirlediği çıktı gösterilmektedir.




Şekil 10. Burun kanaması tespit sisteminin çıktısı

Burun kanaması tespiti için eğitilen modelin değerlendirme kriterleri skorlarına bakılmıştır. Ortaya çıkan değerler Tablo 2'de verilmiştir.

Tablo 2. Burun kanaması için eğitilen modelin değerlendirme kriterleri skorları

Doğruluk	95,65%
Duyarlılık	94%
Geri Çağırma	90%
F1-Ölçümü	91,96%



Şekil 11. Burun kanaması modelinin confusion matrixi

Şekil 11’de ise confusion matrix bulunmaktadır. Burun kanaması tespiti için geliştirilen modelin başarısı, 0.0464 gibi düşük bir Ortalama Mutlak Hata (MAE) değeriyle ölçülmüştür. Bu sonuç, modelin tahminlerinin gerçek değerlere oldukça yakın olduğunu ve düşük hata payı ile yüksek doğruluk sağladığını göstermektedir.

Şekil 12’de ise kusma durumlarının tespit edilmesini göstermektedir.




Şekil 12. Kusma durumlarında sistemin çıktısı

Kusma tespiti için eğitilen modelin değerlendirme kriterleri skorlarına bakılmıştır. Ortaya çıkan değerler Tablo 3’te verilmiştir. Yapılan hesaplama sonucu, modelin MAE değeri 0.0963 olarak bulunmuştur, bu da modelin her tahminde ortalama olarak %9.63'lük bir hata payına sahip olduğunu göstermektedir. Bu sonuçlar, modelin genel doğruluğu hakkında önemli bir bilgi sunarak, yapılan sınıflandırmanın güvenilirliğini değerlendirmeye olanak tanımaktadır. Şekil 13’te ise modelin confusion matrisi verilmiştir.

Tablo 3. Burun kanaması için eğitilen modelin değerlendirme kriterleri skorları

Doğruluk	93%
Duyarlılık	92%
Geri Çağırma	88%
F1-Ölçümü	89,95%



Şekil 13. Kasma modelinin confusion matrixi

4.4 Nabız Ölçme Sistemi

Direksiyona entegre edilen nabız sensörleri ile sürücünün gerçek zamanlı kalp atış hızını takip eden sistem, ani sağlık sorunları tespit edildiğinde otonom sürüş moduna geçmektedir ve aracı güvenli bir şekilde durdurmaktadır. Nabız sensörlerinin doğruluğu ve güvenilirliği sistemin başarısı için kritik öneme sahiptir. Ancak farklı faktörlerin ve dış faktörlerin fizyolojik farklılıkları nedeniyle nabız ölçümlerinde farklılıklar meydana gelebilir. Bu nedenle sistemin daha fazla test edilmesi ve optimize edilmesi gerekmektedir. Şekil 14'te Nabız ölçme sisteminin adımları görülmektedir.

```
Kalp atışı tespit edildi: 130  
Kalp atışı tespit edildi: 144  
Ortalama nabız: 167.00  
Kalp krizi uyarısı: Ortalama nabız çok yüksek!  
Kalp atışı tespit edildi: 153
```

Şekil 14. Nabız ölçme sistemi

4.5 Alkol Tespit Sistemi

Araç içerisindeki alkol buharını tespit edip durumu doğrulamak için şoförün nabzını kontrol etmektedir. Bu sayede alkol sensörlerin doğruluğu nabız sensörleri ile de artırılmış olmaktadır. Alkol kullanımı tespit edildiğinde araç otonom sürüş moduna geçerek güvenli bir şekilde park işlemi gerçekleştirilmektedir. Şekil 15'te alkol kullanımında sistemin verdiği uyarı görülmektedir.

```
Alkol Seviyesi: 158.00 ppm  
UYARI: Alkol seviyesi yüksek! (150 ppm'den fazla)  
UYARI: Sürücü alkollü olabilir, nabız ortalamanın altında!
```

Şekil 15. Alkol durumunda sistemin çalışması

5. TARTIŞMA VE SONUÇ

Bu çalışma, sürücü dikkatinin izlenmesi, trafik işaretlerinin tanınması, kan ve kusma algılama, nabız izleme ve alkol tespit sistemleri gibi bir dizi bileşeni entegre ederek araç içi güvenliği artırmayı hedeflemektedir. Geliştirilen sistemler, sürüş güvenliğini sağlamak adına kritik işlevler sunmaktadır. Her bir sistemin doğruluğu ve güvenilirliği, trafik kazalarını önleme potansiyelini artırırken, aynı zamanda sürücülerin fiziksel durumlarını izleyebilme yeteneği sunmaktadır.

Literatürde sürücü güvenliği üzerine yapılan çalışmalara bakıldığında, genellikle tek bir sistem üzerine odaklanıldığı görülmektedir. Örneğin, "Driver Eye Blink Rate Detection and Alert System" çalışmasında göz kırpması oranı kullanılarak sürücü dikkatinin izlenmesi sağlanmış ve %78,66 doğruluk oranı elde edilmiştir [20]. Bununla birlikte, gerçekleştirilen "Design and Implementation of an Alcohol Detection Driver System" çalışmasında alkol tespiti için sensörler ve algoritmalar kullanılarak, sürücünün alkol düzeyine göre araç başlatma engellenmiştir [21]. Bu sistem, alkollü araç kullanımını engellemeye yönelik önemli bir çözüm sunmakta olup, alkolün trafikteki ölümcül kazalara etkisini azaltmayı amaçlamaktadır. Ancak, bu çalışmalarda yalnızca göz kırpması ve alkol tespiti verilerine dayanılırken, bu çalışmada nabız ve göz kırpması gibi ek sistemlerle sürücünün fiziksel ve zihinsel durumu daha kapsamlı bir şekilde izlenebilmektedir. Çalışmada, sürücünün yalnızca dikkatsizlik seviyesini değil, aynı zamanda fizyolojik durumunu da değerlendirilerek daha güvenilir bir sürüş güvenliği analizi sağlanmaktadır.

Bu çalışmada geliştirilen sistemlerin bir arada kullanılması, sürücü güvenliğini artırma amacı doğrultusunda önemli bir adım olmuştur. Alkol tespit sistemi, sürücünün alkol tüketimini izlerken, nabız sensörleri de sürücünün fizyolojik durumunu değerlendirmek için kritik bir rol oynamaktadır. Bu iki sistemin bir arada çalışması, alkol tüketimiyle birlikte ortaya çıkabilecek potansiyel sağlık sorunlarını daha güvenilir bir şekilde tespit etmeyi mümkün kılar. Özellikle, alkolün merkezi sinir sistemi üzerindeki etkileri nedeniyle reflekslerin yavaşlaması ve karar verme yetisinin azalması gibi durumlar, trafik güvenliğini ciddi şekilde tehlikeye atmaktadır. Alkol ve nabız verilerinin entegre analizi, bu riskleri minimize etmede etkili bir strateji sunmaktadır.

Ayrıca, kan ve kusma tespit sistemlerinin veri setlerinin oluşturulması süreci de oldukça önemlidir. Oluşturulan veri setlerinin sınırlı olması, modelin genel performansını olumsuz etkileyebilir. Kan ve kusma tespit sistemleri için yeterli çeşitlilikte veri sağlamak, bu durumların tespitinde başarıyı artırmak açısından kritik bir adımdır. Özellikle kusma durumu için daha geniş bir veri setine sahip olmak, modelin doğruluğunu ve güvenilirliğini artıracaktır. Literatürde benzer çalışmalarda kullanılan veri setlerinin büyüklüğü incelendiğinde, geniş ve çeşitlendirilmiş veri kümesine sahip olmanın model başarısını artırdığı görülmektedir [22]. Bu nedenle, gelecekte daha büyük ve çeşitli veri kümeleriyle sistemin test edilmesi planlanmaktadır.

Sürücü dikkat sistemi, göz kırpması verileri ile sürücünün yorgunluk seviyesini değerlendirebilen bir yapıdadır. Bu, dikkat dağınıklığı durumlarını erken tespit ederek, otonom sürüş moduna geçiş yapma yeteneği sunar. Ancak bu sistemlerin etkili bir şekilde çalışabilmesi için farklı ortamlarda, farklı ışık açıları ile sistemin güvenliği test edilmelidir. Başka bir çalışmada bu tür sistemlerin aydınlatma koşullarından etkilendiği belirtilmiş olup, geliştirilen sistemin benzer sorunlarla karşılaşma olasılığı değerlendirilmiştir [23]. Bu bağlamda, gelecekte sistemin daha farklı ortam koşullarında test edilerek doğruluk oranının optimize edilmesi gerekmektedir.

Sonuç olarak, bu çalışma sürücü güvenliğini artırma konusunda katkı sağlamaktadır. Ancak, her bir sistemin gerçek dünya koşullarında daha geniş çaplı testlere tabi tutulması, veri setlerinin zenginleştirilmesi ve optimizasyon süreçlerinin gerçekleştirilmesi gerekmektedir. Bu tür gelişmeler sistemlerin genel performansını ve güvenilirliğini artırarak trafik kazalarını önleme potansiyelini yükseltecektir.

6. TEŞEKKÜR BÖLÜMÜ

Bu çalışma 1139B412301078 başvuru numaralı TÜBİTAK 2209-B Üniversite Öğrencileri Sanayiye Yönelik Araştırma Projeleri Destekleme Programı tarafından hibelandirilip başarı ile sonuçlandırılmıştır.

Yazarlar arasında herhangi bir çıkar çatışması bulunmamaktadır.

Çalışma boyunca yardımlarını esirgemeyen Gürkan Çelik'e ve kan/kusmuk veri setinin etiketlenmesinde emeği geçen Melih Yıldız'a teşekkür ederiz.

REFERANSLAR

- [1] World Health Organization, Global Status Report on Road Safety 2018. Geneva, Switzerland: World Health Organization, 2019.
- [2] F. Kaplanhan, "An examination on the economic costs of traffic accidents in Turkey," The Journal of International Civilization Studies, vol. 6, no. 2, 2021.
- [3] S. Chen, M. Kuhn, K. Prettnner, and D. E. Bloom, "The global macroeconomic burden of road injuries: estimates and projections for 166 countries," The Lancet Planetary Health, vol. 3, no. 9, pp. e390–e398, 2019.
- [4] Ü. Çodur, Sis kaynaklı trafik kazalarının azaltılmasında görüntü işleme teknikleri, Yüksek Lisans Tezi, Fen Bilimleri Enstitüsü, Erzurum Teknik Üniversitesi, Erzurum, 2019.
- [5] L. Hamiti and A. Krasniqi, "The impact of technology on the prevention of road traffic accidents," Pakistan Journal of Life & Social Sciences, vol. 22, no. 2, p. 22318, 2024, doi: 10.57239/PJLSS-2024-22.2.001584.
- [6] A. El Khatib, C. Ou, and F. Karray, "Driver inattention detection in the context of next-generation autonomous vehicles design: A survey," IEEE Trans. Intell. Transp. Syst., vol. 21, no. 11, pp. 4483–4496, 2020, doi: 10.1109/TITS.2019.2940874.
- [7] M. Q. Khan and S. Lee, "A comprehensive survey of driving monitoring and assistance systems," Sensors, vol. 19, art. no. 2574, 2019, doi: 10.3390/s19112574.
- [8] A. Soultana, F. Benabbou, N. Sael, and S. Ouahabi, "A systematic literature review of driver inattention monitoring systems for smart cars," Int. J. Interact. Mob. Technol., vol. 16, no. 16, pp. 160–189, 2022, doi: 10.3991/ijim.v16i16.33075.
- [9] Cipia, [Online]. Available: <https://cipia.com/>. [Erişim: Kasım. 5, 2024].
- [10] Sorax Teknoloji, [Online]. Available: <https://www.soraxteknoloji.com/en/iot-2/>. [Erişim: Kasım. 5, 2024].
- [11] Car Magazine, "Mercedes launches Attention Assist," [Online]. Available: <http://www.carmagazine.co.uk/News/Search-Results/Industry-News/Mercedeslaunches-Attention-Assist/>. [Erişim: Ekim. 1, 2024].
- [12] Ford Media, [Online]. Available: <http://technology.fordmedia.eu/>. [Erişim: Ekim. 1, 2024].
- [13] A. Kashevnik, R. Shchedrin, C. Kaiser, and A. Stocker, "Driver distraction detection methods: A literature review and framework," IEEE Access, vol. 9, pp. 60063–60076, 2021, doi: 10.1109/ACCESS.2021.3073599.

- [14] Volvo Cars, "Driver alert and attention assist systems," [Online]. Available: https://www.volvocars.com/tr/support/car/s60/article/f1df148bc7f01a62c0a81f6f0b6b960e_59b320dbc7f05c55c0a81f6f1d425d1f_1b124e7d95b6d7b9c0a8015139b2bb2b. [Erişim: Ekim. 2, 2024].
- [15] T. N. Abu-Jamie and S. S. Abu-Naser, "Classification of Sign-Language Using Deep Learning – A Comparison between Inception and Xception Models," *Int. J. Acad. Eng. Res. (IJAER)*, vol. 6, no. 8, pp. 9–19, 2022.
- [16] GTSRB-German Traffic Sign Recognition Benchmark, [Online]. Available: <https://www.kaggle.com/datasets/meowmeowmeowmeowmeow/gtsrb-german-traffic-sign/>. [Erişim: Kasım. 5, 2024].
- [17] F. Özgür, N. Arıkan, and Ö. Öztimur Karadağ, "Comparison of a deep learning and a hybrid model for classification of an unbalanced urgent cases dataset for human faces," presented at UBMK 2024, Antalya, Türkiye, 2024.
- [18] F. Wang and J. Su, "Based on the improved YOLOV3 small target detection algorithm," in *Proc. 2021 IEEE 4th Adv. Inf. Manage., Communicates, Electron. Autom. Control Conf. (IMCEC)*, Chongqing, China, 2021, pp. 2155–2159, doi: 10.1109/IMCEC51613.2021.9482076.
- [19] Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner, "Gradient-based learning applied to document recognition," *Proc. IEEE*, vol. 86, no. 11, pp. 2278–2324, 1998.
- [20] A. R. Raipurkar and M. B. Chandak, "Driver Eye Blink Rate Detection and Alert System," *International Journal of Innovative Technology and Exploring Engineering*, vol. 9, no. 4, pp. 489–492, Feb. 2020, doi: 10.35940/ijitee.D1207.029420.
- [21] O. O. Alabi, O. A. Adeaga, S. A. Ajagbe, E. O. Adekunle, and M. O. Adigun, "Design and implementation of an alcohol detection driver system," *Int. J. Reconfigurable Embedded Syst.*, vol. 13, no. 2, pp. 278–285, Jul. 2024, doi: 10.11591/ijres.v13.i2.pp278-285.
- [22] R. S. Olson, W. La Cava, P. Orzechowski, R. J. Urbanowicz, and J. H. Moore, "PMLB: a large benchmark suite for machine learning evaluation and comparison," *BioData Mining*, vol. 10, art. no. 36, Dec. 2017, doi: 10.1186/s13040-017-0154-4
- [23] A. Koesdwiady, S. M. Bedawi, C. Ou, and F. Karray, "End-to-End Deep Learning for Driver Distraction Recognition," in *Image Analysis and Recognition (ICIAR 2017)*, F. Karray, A. Campilho, and F. Cheriet, Eds., vol. 10317, *Lecture Notes in Computer Science*. Cham, Switzerland: Springer, 2017, pp. 3–12, doi: 10.1007/978-3-319-59876-5_2.