



## IoT based mobile driver drowsiness detection using deep learning

Emre Şafak<sup>1\*</sup>, İbrahim Alper Dođru<sup>2</sup>, Necaattin Barışçı<sup>2</sup>, Sinan Toklu<sup>2</sup>

<sup>1</sup>HAVELSAN, R&D Technology and Product Management Department, 06530, Ankara, Turkey

<sup>2</sup>Department of Computer Engineering, Technology Faculty, Gazi University, 06560, Ankara, Turkey

### Highlights:

- Driver drowsiness detection was made from face images on mobile devices
- New convolutional neural network model developed for driver drowsiness detection
- Transfer learning technique using the pre-trained model for the training

### Keywords:

- Driver drowsiness detection
- Driver drowsiness detection on mobile devices,
- Convolutional neural networks
- IoT
- Deep learning

### Article Info:

Research Article  
Received: 23.09.2021  
Accepted: 06.11.2021

### DOI:

10.17341/gazimmfd.999527

### Correspondence:

Author: Emre Şafak  
e-mail:  
esafak@havelsan.com.tr  
phone: +90 541 266 2073

### Graphical/Tabular Abstract

In the study, Convolutional Neural Networks were used for driver drowsiness detection on mobile devices. The data received from the camera of the mobile device was sent to the server through the developed mobile application. According to the camera images coming from the mobile device, the results produced by the model are sent back to the mobile device via the mobile application and the drowsiness status is shown to the user. In order to increase the success rate of the model, the pre-trained model was reused with the transfer learning technique. The developed model achieved a success rate of 95,65% and achieved better results than previous studies. The architecture of the developed system is shown in Figure A.

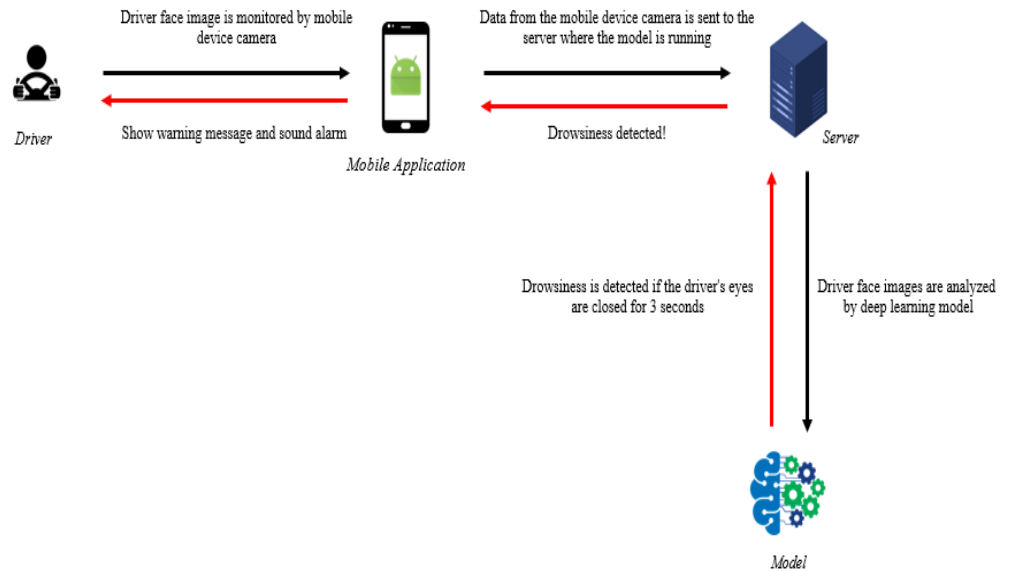


Figure A. The architecture of the developed system

**Purpose:** The aim of the study is to detect the drowsiness status of drivers on mobile devices by using convolutional neural networks. If the eyes of the drivers are closed for more than three seconds, the driver is warned with message and alarm sound. Mobile devices have been preferred due to their low power consumption and widespread use.

### Theory and Methods:

Convolutional neural networks are preferred for training because they show high performance especially in image recognition problems. In order to achieve a high accuracy rate, the pre-trained model was re-used with the transfer learning technique. In order to increase the processing speed, the training model was revised, and the number of parameters was reduced. Due to the limited processing capacity of mobile devices, the results are sent to the mobile device via the application while the model is running on the server.

### Results:

While the developed driver drowsiness detection model can detect instant from video, the accuracy rate of the model has been obtained as 95.65%.

### Conclusion:

By using a light model and transfer learning technique for driver drowsiness detection are made quickly on mobile devices. This application has the potential to prevent 40% of traffic accidents.



## Derin öğrenme kullanılarak nesnelerin interneti tabanlı mobil sürücü yorgunluk tespiti

Emre Şafak<sup>1\*</sup>, İbrahim Alper Doğru<sup>2</sup>, Necaattin Barışçı<sup>2</sup>, Sinan Toklu<sup>2</sup>

<sup>1</sup>HAVELSAN, ARGE Teknoloji ve Ürün Yönetimi Bölümü, 06530, Ankara, Türkiye

<sup>2</sup>Gazi Üniversitesi, Teknoloji Fakültesi, Bilgisayar Mühendisliği Bölümü, 06560, Ankara, Türkiye

### Ö N E Ç İ K A N L A R

- Mobil cihazlarda yüz görüntülerinden sürücü yorgunluk tespiti yapılmıştır
- Sürücü yorgunluk tespiti için yeni evrimsel sinir ağı modeli geliştirilmiştir
- Eğitim işlemi için ön eğitilmiş model kullanılarak transfer öğrenme tekniği uygulanmıştır

#### Makale Bilgileri

Araştırma Makalesi

Geliş: 23.09.2021

Kabul: 06.11.2021

#### DOI:

10.17341/gazimmfd.999527

#### Anahtar Kelimeler:

Sürücü yorgunluk tespiti,  
mobil cihazlarda sürücü  
yorgunluk tespiti,  
evrimsel sinir ağları,  
nesnelerin interneti,  
derin öğrenme

#### ÖZ

Sürücü yorgunluk tespiti trafik kazalarını önlemek için önemli bir konudur. Şiddetli trafik kazalarının %40'ı yorgunluk nedeniyle yaşanmaktadır. Sürücü yorgunluk tespiti için çeşitli yöntemler kullanılmaktadır. Sürücü yorgunluk tespiti yöntemlerinden biri EEG ve ECG gibi sinyallerin analiz edilmesine dayalı sürücü yorgunluk tespitidir. Bir başka sürücü yorgunluk tespiti yöntemi araç-sürücü etkileşimine dayalı sürücü yorgunluk tespitidir. Yapılan çalışmada kullanılan ve son sürücü yorgunluk tespiti yöntemi görüntülerden sürücü yorgunluk tespitidir. Bu yöntem diğer iki yönteme göre maliyet ve kullanılabilirliğin yanında sürücüye müdahale gerekmediğinden daha avantajlıdır. Görüntülerden sürücü yorgunluk tespiti çalışmalarında klasik görüntü işleme teknikleri ve derin öğrenme algoritmaları kullanılmaktadır. Son sürücü yorgunluk tespiti çalışmaları genellikle derin öğrenme modellerini temel almaktadır. Bunun yanında yaygın kullanımın sağlanabilmesi için geliştirilecek modelin mobil cihazlar üzerinde çalışabilmesi gerekecektir. Yapılan çalışmada mobil cihazlarda sürücü yorgunluk tespiti için Evrimsel Sinir Ağları kullanılmıştır. Modelin başarı oranını artırabilmek için önceden eğitilmiş model transfer öğrenme tekniğiyle tekrar kullanılmıştır. Eğitim işlemi için geliştirilen model 14 katmandan ve 1,236,217 parametreden oluşmaktadır. Modeli eğitmek için 2425 görüntüden oluşan veri seti kullanılmıştır. Veri seti açık göz ve kapalı göz görüntüleri olmak üzere iki kategoriden oluşmaktadır. Geliştirilen model %95,65 doğruluk oranına, %95,86 kesinlik oranına, %94,32 duyarlılık oranına ve %95,17 f1 skor oranına ulaşarak önceki çalışmalardan daha iyi sonuç elde etmiştir.

## IoT based mobile driver drowsiness detection using deep learning

### H I G H L I G H T S

- Driver drowsiness detection was made from face images on mobile devices
- New convolutional neural network model developed for driver drowsiness detection
- Transfer learning technique using the pre-trained model for the training

#### Article Info

Research Article

Received: 23.09.2021

Accepted: 06.11.2021

#### DOI:

10.17341/gazimmfd.999527

#### Keywords:

Driver drowsiness detection,  
driver drowsiness detection  
on mobile devices,  
convolutional neural  
networks,  
IoT,  
deep learning

#### ABSTRACT

Driver drowsiness detection is an important issue to prevent traffic accidents. 40% of severe traffic accidents are due to drowsiness. Various methods are used for driver drowsiness detection. One of the driver drowsiness detection method is driver drowsiness detection based on the analysis of signals such as EEG and ECG. Another driver drowsiness detection method is driver drowsiness detection based on vehicle-driver interaction. The last driver drowsiness detection method used in the study is driver drowsiness detection from images. This method is more advantageous than the other two methods in terms of cost and usability because no driver intervention required. Classical image processing techniques and deep learning algorithms are used for driver drowsiness detection from images. Recent driver drowsiness detection studies are based on deep learning models. In addition, the model to be developed will need to be able to work on mobile devices in order to ensure widespread use. In the study, Convolutional Neural Networks were used for driver drowsiness detection on mobile devices. In order to increase the success rate of the model, the pre-trained model was reused with the transfer learning technique. The model developed for the training consists of 14 layers and 1,236,217 parameters. The dataset consists of two categories, open-eye and closed-eye images. The developed model achieved 95.65% accuracy, 95.86% precision, 94.32% recall and 95.17% f1 score which achieved better results than previous studies. A dataset of 2425 images was used to train the model.

## 1. GİRİŞ (INTRODUCTION)

Sürücü yorgunluğu tespiti akıllı araçlarda kazaları önleme açısından önemli bir uygulamadır. Yorgun sürüş trafik kazalarının ana nedenlerinden biridir. Araştırmalar yorgun sürüşte trafik kazası olma olasılığının normal sürüşe göre beş kat daha fazla olduğunu göstermektedir. Yorgun sürüşten kaynaklanan kazalar toplam trafik kazalarının %20'sini, şiddetli trafik kazalarının ise %40'ını oluşturmaktadır [1]. Çalışmalar yorgunluk tespiti için üç ana yöntem olduğunu göstermektedir. İlk yorgunluk algılama yöntemi EEG ve ECG gibi fiziksel sinyallerin kullanılmasıdır. İkinci yorgunluk algılama yöntemi araç davranışına dayalı algılama yöntemidir. Sürücünün yorgunluk tespiti direksiyon, gaz pedalı ve tekerleklerdeki davranışlarından anlaşılabilir. Üçüncü yorgunluk algılama yöntemi ise bilgisayar görüntüdür. Bu yöntemde yüz görüntüsü analiz edilerek ağız ve göz açıklığı kontrol edilip göz kırpması ve esneme frekansı hesaplanarak sürücünün yorgunluk tespiti yapılır. Bu yöntemin avantajı basit ve sürücünün aracı kullanmasını etkilememesidir [2]. Görüntülerden sürücü yorgunluk tespiti için klasik görüntü işleme teknikleri ve derin öğrenme algoritmaları kullanılmaktadır. Klasik görüntü işleme teknikleri ile sürücü yorgunluk tespiti görüntülerin algoritmik analizine dayanır. Ancak bu yöntem daha düşük bir doğruluk sağlar, gecikmeli algılamaya neden olur ve büyük miktarda hesaplama gücü gerektirir. Yeni sürücü yorgunluk tespiti çalışmaları genellikle derin öğrenme ağı modellerini temel almaktadır [3]. Günümüzde kullanımı gittikçe yaygınlaşan ve gelişen mobil cihazlar destekledikleri multimedya iletişimi ve uygulamalar sayesinde cep bilgisayara dönüşmüşlerdir [4]. Gelişen mobil cihazlar ve sensör ağlarıyla nesnelere interneti fiziksel ve sanal varlıkları birbirine bağlayarak gerekli ağ altyapısının oluşturulmasını sağlayacaktır [5]. Bu nedenle geliştirilecek uygulamaların mobil cihazlara yönelik olması kullanılabilirliği artırırken diğer sistemlerle entegrasyonu kolaylaştıracaktır.

Zhongmin Liu vd. tarafından yüz ifadelerinden sürücü yorgunluk tespiti üzerine yapılan çalışmada derin öğrenme ve bulanık mantık kullanılmıştır. Ağız ve göz tespitinde eğitim için Caltech10k Web Faces veri seti kullanırken test için FDDB veri seti kullanılmıştır. Sürücünün yorgunluk durumunu belirlemek için esneme sıklığı ve göz kapağı kapanma sıklığı hesaplanır. Sürücünün esneme ve göz kapama sıklığı hesaplandıktan sonra bulanık çıkarım sistemi sürücü yorgunluk durumunu belirler. Geliştirilen ağız ve gözün birlikte analiz edildiği modelin başarı oranı esneme ve %85,9 iken göz kapanmasında %93,4 olarak tespit edilmiştir. Yorgunluk tespiti modelinin başarı oranı normal durumlarda %96,5, hafif yorgun durumlarda %94,7 ve şiddetli yorgunluk durumunda %100 olarak tespit edilmiştir. Yorgunluk tespiti modelinin algılama hızı ise 53 fps olarak tespit edilmiştir [6]. Caio Bezerra Souto Maior vd. tarafından göz açıklığı oranından gerçek zamanlı sürücü yorgunluk tespiti üzerine yapılan çalışmada çok katmanlı algılayıcı rastgele orman ve destek vektör makineleri algoritmaları

kullanılmıştır. Yapılan çalışmada düşük donanım gereksinimleri ve eğitim süresinin kısa olması gibi sebeplerle çok katmanlı algılayıcı rastgele orman ve destek vektör makineleri algoritmaları kullanılmıştır. Kullanılan algoritmalar arasından destek vektör makineleri algoritması %94,9 başarı oranı ile en iyi performansı göstermiştir. Yorgunluk tespiti için göz dışında yüzdeki diğer özelliklerin dikkate alınması gereksiz bilgiye ve hesaplama gücünün artmasına neden olacağı için yalnızca göz dikkate alınmıştır. Yapılan çalışmada DROZY gibi zorlayıcı test veri seti üzerinde %94,44 gibi bir başarı oranı elde etmiştir [7].

Abdelmalik Moujahid vd. tarafından yapılan çalışmada sürücü yorgunluk tespiti için kompakt yüz tanımlayıcısı kullanılmıştır. Yapılan çalışmada yüz görüntülerinin algılanmasında duyarlı ve etkili olduğu için regresyon ağacı topluluğu algoritması kullanılmıştır. Görüntülerdeki ayırt edici özellikleri tespit edebilmek için algılanan bakım seviyesi temelli bir tanımlayıcı kullanılmıştır. Görüntüleri sınıflandırabilmek için ise destek vektör makineleri algoritması kullanılmıştır. Kullanılan NTHU veri seti 36 farklı senaryo için video verileri içermektedir. Makalede sürücü durumu dört kategoride ele alınmıştır; uykulu olmayan, uykulu, esneyen ve başını salladı. Veri setindeki gereksiz alanların azaltılabilmesi için temel bileşen analizi yöntemi kullanılmıştır. Geliştirilen model temel bileşen analizi metodu kullanılmadan ortalama %76,77 doğruluk oranına ulaşmıştır. Temel bileşen analizi metodu kullanıldığında modelin doğruluk oranı %76,92 olmuştur [8]. Faisal Mohammad vd. tarafından yapılan çalışmada OpenCV kullanılarak yorgunluk tespiti için Java temelli bir mobil uygulama geliştirilmiştir. Yorgunluk tespiti için sadece sağ göze odaklanılmıştır. Bu sayede daha az görüntü analiz edilerek işlem gücü düşürülmüştür. Yapılan çalışmada geliştirilen uygulamanın doğruluğu üç farklı yöntem ile test edilmiştir. İlk yöntem fotoğraflar üzerinden yorgunluk tespitidir. Fotoğraflar Adobe Animate programı kullanılarak dinamik hale getirilmiş ve göz açılıp kapanarak test işlemi gerçekleştirilmiştir. İkinci yöntemde laboratuvar ortamında iki kişinin gözünü yavaşça kapattığı senaryo test edilmiştir. Telefon, laboratuvar ortamında telefon kamerası ile sürücü arasında 30 cm uzaklık olacak şekilde yerleştirilmiştir. Son test araç içerisinde direksiyona yerleştirilen telefon ile yapılmıştır. Uygulamada sınıflandırma işlemi için OpenCV kütüphanesi kullanılmıştır. Yüz ve gözlerin tespit edilebilmesi için OpenCV'de bulunan görüntü sınıflandırıcı algoritması Haar sınıflandırıcı kullanılmıştır. Yorgunluk beyaz piksel oranına göre hesaplanmaktadır. Beyaz piksel oranı %5 ve %50 limitlerinin altına düşerse yorgunluk algılanmaktadır. Uygulama göz kırpması gibi kısa süreli piksel değişimlerinden etkilenmemektedir. Uzun süreli göz kapağı kapanması durumunda alarm sürekli olarak çalar ve sürücüdün geri bildirim ister. Uygulamada göz kapağı 3 saniyeden fazla kapalı durursa alarm çalışmaktadır [9].

Sónia Soares vd. tarafından yapılan çalışmada mobil telefonlardan toplanan verilerin analizi ile sürücü yorgunluk durumları tespit edilmiştir. Yorgunluk tespiti için kullanılan

parametreler; sürekli sürüş süresi, toplam sürüş süresi, mola sayıları ve mola süreleridir. Kullanılan veri seti kimlikleri kaldırılmış verilerden oluşmaktadır. Veri setinde 273 sürücünün 634 sürüş kaydı bulunmaktadır. Yapılan çalışmada sürücünün dikkat dağınıklığı ve uykulu durumunu izlemek ve uyararak için mobil uygulama geliştirilmiştir. Veri setindeki her bir sürüş kaydında zaman damgası, aracın hızı, sürücünün dikkat durumu, molalar arasındaki sürüş süresi, toplam sürüş süresi, ilk molaya kadar sürüş süresi, mola sayısı, mola süresi, sürücünün yaşı, sürücünün cinsiyeti ve GPS kayıtları yer alır. Sürücü yorgunluk tespiti bu değişkenlere göre yapılmaktadır. Mola sonrası yolculukların %13'ünde dikkat dağınıklığı tespit edilirken yeni seyahatlerde %52 oranında dikkat dağınıklığı yaşanmıştır. Erkek sürücülerde uykulu olma olasılığının daha fazla olduğu tespit edilmiştir. Sürüş sırasında dikkat dağınıklığı oranı erkeklerde %56 kadınlarda ise %44 olarak tespit edilmiştir. Sürücünün geri bildirimlerle uyarılması mola verilmesinde etkili olmaktadır. Sürücünün yaşının uyuklama durumunda etkisi olmadığı görülmüştür. Sürüş sırasında uyuklama durumu en çok genç sürücülerde tespit edilmiştir. Sürücü her ne sebeple durursa dursun dikkat dağınıklığı ve uyku durumu ortadan kalkmaktadır. Dikkat dağınıklığı ve uyuklama üzerindeki en etkili parametre mola sayısıdır. Yapılan çalışma sonucunda yorgunluğun temel olarak sürekli sürüş süresinin fazla olmasından kaynaklandığı tespit edilmiştir. Bu nedenle kısa süreli de olsa sık molalar verilmesi gerektiği sonucuna varılmıştır [10].

Rajamohana S.P. vd. tarafından yapılan çalışmada sürücü yorgunluk tespiti için evrişimsel sinir ağı ile çift yönlü uzun kısa süreli bellek yöntemi birleştirilerek kullanılmıştır.

Önerilen yöntem üç aşamada çalışır. İlk olarak sürücü yüz görüntüsü belirlenir. Ardından Öklidyen algoritması ile göz açılıp kapanması sıklığı takip edilir. Son aşamada kapalı veya açık göz tespiti yapılır. Sınıflandırma için evrişimsel sinir ağı ve çift yönlü uzun kısa süreli bellek yöntemi birlikte kullanılmıştır. Kullanılan veri seti toplamda 2208 görüntüden oluşur. Veri seti sürücünün gözlüklü ve gözlüksüz olma durumlarını da kapsamaktadır. Yapılan çalışmada InceptionV3 evrişimsel sinir ağı algoritması kullanılmıştır. Veri setinin %70'i eğitim %30'u test işlemi için kullanılmıştır. Evrişimsel sinir ağının doğruluk oranını iyileştirebilmek için çift yönlü uzun kısa süreli bellek yöntemi modeli kullanılmıştır. Model, Adam optimizasyon yöntemi ile geliştirilerek sürücü yorgunluk tespiti doğruluk oranı iyileştirilmeye çalışılmıştır. Evrişimsel sinir ağı modeli tek başına kullanıldığında doğruluk oranı %85 olarak elde edilmiştir. Evrişimsel sinir ağı modeli çift yönlü uzun kısa süreli bellek yöntemiyle birlikte kullanıldığında doğruluk oranı %94 olmuştur [11]. Sürücü yorgunluk tespiti ile ilgili yapılan çalışmaların özeti Tablo 1'de sunulmuştur.

Literatürdeki mevcut çalışmalarda mobil cihazlara yönelik derin öğrenme temelli çözümler bulunmamaktadır. Mobil cihazların yaygın olarak kullanılması ve düşük güç tüketimi sayesinde mobil cihazlar için geliştirilen model sürücü yorgunluk tespiti uygulamasının yaygın kullanımı açısından önemlidir. Bu çalışmada evrişimsel sinir ağları kullanılarak mobil cihaz üzerinden sürücü yorgunluk tespiti yapılmıştır. Sürücü yorgunluk tespiti için hafif bir evrişimsel sinir ağı modeli geliştirilirken AlexNet, VGG-16, ResNet-50, MobileNet algoritmaları da aynı veri seti üzerinde eğitilerek başarı oranları önerilen model ile karşılaştırılmıştır. Başarı

**Tablo 1.** Sürücü yorgunluk tespiti ile ilgili yapılan çalışmalar (Studies on driver drowsiness detection)

| Çalışma                         | Teknik                          | Algoritma   | Özellik                                   | Veri Seti               | Değerlendirme Metriği                  | Başarı Oranı    |
|---------------------------------|---------------------------------|---|---|-------------------------|--|-----------------|
| Zhongmin Liu ve ark. [6]        | Derin öğrenme                   | MB-LBP  | Sürücü yorgunluk tespiti                  | Caltech10k<br>Web Faces | Doğruluk ve FPS                        | %93,4<br>53 FPS |
| Caio Maior ve ark. [7]          | Derin Öğrenme, Makine Öğrenmesi | Çok Katmanlı Algılayıcı, Rastgele Orman ve Destek Vektör Makineleri | Sürücü yorgunluk tespiti                  | DROZY                   | Doğruluk                               | %94,44          |
| Abdelmalik Moujahid ve ark. [8] | Derin Öğrenme, Makine Öğrenmesi | Destek vektör makineleri  | Sürücü yorgunluk tespiti                  | THU                     | Doğruluk                               | %76,92          |
| Faisal Mohammad ve ark. [9]     | OpenCV                          | Haar Sınıflandırıcı   | Mobil Cihazlarda Sürücü yorgunluk tespiti | -                       | Laboratuvar, Fotoğraf ve araç testleri | -               |
| Sónia Soares ve ark. [10]       | Derin Öğrenme                   | -   | Sürücü yorgunluk tespiti                  | 634 sürüş kaydı         | Doğruluk                               | %78,04          |
| Rajamohana S.P. ve ark. [11]    | Derin Öğrenme                   | Evrişimsel Sinir Ağı ve BİLSTM                                      | Sürücü yorgunluk tespiti                  | 2208 görüntü            | Doğruluk                               | %94             |

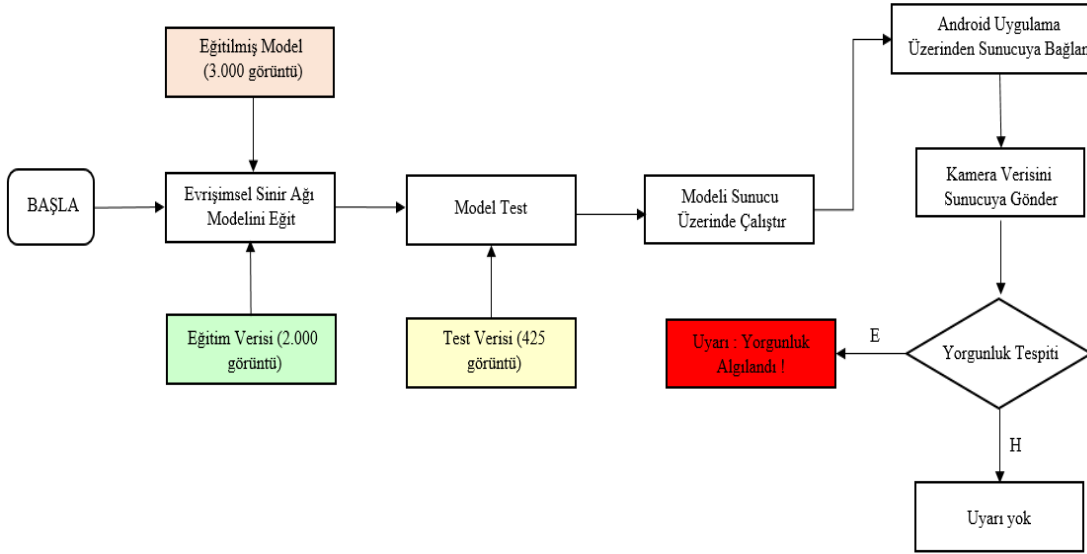
oranını artırabilmek için transfer öğrenme tekniği ile ön eğitilmiş model kullanılmıştır. Bu makalede yapılan çalışmada kullanılan materyal ve metod, araştırma bulguları ve sonuçlar anlatılmıştır. İkinci bölümde çalışmada kullanılan yöntem ve veri seti açıklanmıştır. Üçüncü bölümde önerilen yöntemin deneysel sonuçları ve diğer çalışmalarla karşılaştırılması yer almaktadır.

## 2. MATERYAL VE METOT (MATERIAL AND METHOD)

Görüntülerden sürücü yorgunluk tespiti diğer sürücü yorgunluk tespiti yöntemlerine göre işlevsellik ve maliyet açısından daha avantajlıdır. Yapılan çalışmalarda görüntülerden sürücü yorgunluk tespitinde klasik görüntü işleme teknikleri yerine daha yüksek doğruluk sağlayan derin öğrenme algoritmaları kullanılmaktadır. Mobil cihazlar yaygın kullanıma sahip olduğu için sürücü yorgunluk tespiti işleminin mobil cihazlar üzerinden yapılması uygulamanın kullanılabilirliğini artıracaktır. Bu nedenle yapılan çalışmada evrişimsel sinir ağları kullanılarak geliştirilen sürücü yorgunluk tespiti modeli mobil cihaz üzerinde çalıştırılmıştır. Yapılan çalışmanın akış diyagramı Şekil 1’de görülmektedir.

Şekil 1’de mobil cihazlarda sürücü yorgunluk tespiti uygulamasının geliştirilmesi için yapılan işlemler görülmektedir. İlk olarak sürücü yorgunluk tespiti geliştirilmesi için kullanılacak veri seti belirlenmiştir. Sürücü yorgunluk tespiti modelini eğitmek toplam 2425 görüntüden oluşan veri seti kullanılmıştır. Veri setindeki 2000 görüntü eğitim ve geçerleme için kullanılırken geri kalan 425 görüntü test için kullanılmıştır. Eğitim işlemi için 3 evrişirme katmanı, 3 havuzlama katmanı, 1 düzleştirme katmanı, 1 bırakma katmanı, 3 tam bağlantılı katman ve 3 doğrusal katman olmak üzere toplam 14 katmanlı ve 1,236,217 parametreden oluşan model kullanılmıştır. Geliştirilen sürücü yorgunluk tespiti için tasarlanan evrişimsel sinir ağı modeli Tablo 2’de görülmektedir.

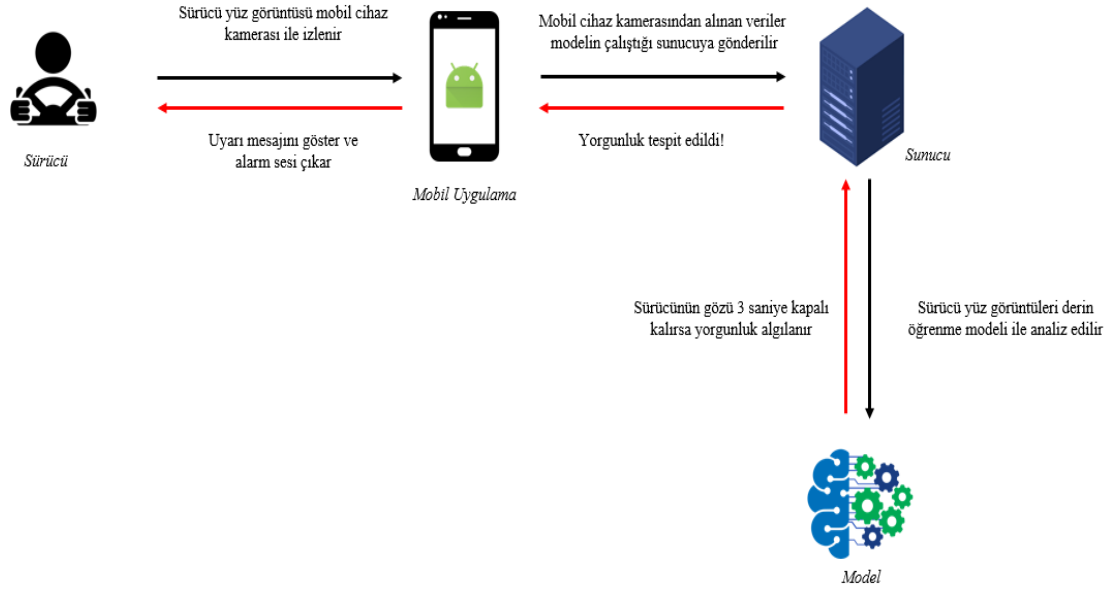
Tablo 2’de görüldüğü gibi 14 katmandan oluşan hafif bir evrişimsel sinir ağı modeli geliştirilmiştir. Ezberlemeyi engellemek için bırakma katmanı kullanılmıştır. Sürücü yorgunluk tespiti modeli geliştirildikten sonra sonucu üzerinde çalıştırılmıştır. Geliştirilen sistemin mimarisi Şekil 2’de sunulmuştur. Şekil 2’de görüldüğü gibi mobil cihazın kamerasından alınan veriler geliştirilen mobil uygulama aracılığıyla sunucuya gönderilmiştir. Mobil cihazdan gelen



Şekil 1. Akış diyagramı (Flowchart)

Tablo 2. Evrişimsel sinir ağı mimarisi (Convolutional neural network architecture)

| Katman (K)                            | Hiper Parametreler  |
|---------------------------------------|---|
| Evrişirme (K1, K3, K5)                | Filtre size: 3x3, Filtre number: (32 – 64 – 128), Kernel size: 3x3, Activation function: ReLU |
| Havuzlama (K2, K4, K6)                | Pooling region size: 2x2, Stride: 2x2, Pooling method: max-pooling                            |
| Bırakma Katmanı (K7)                  | Dropout probability: 0,5  |
| Düzleştirme Katmanı (K8)              |   |
| Yoğun Katman (K9, K11, K13)           | Neurons number: 512, Dropout probability: 0,5, Activation function: ReLU                      |
| Tam Bağlantılı Katman (K10, K12, K14) | Neurons number: 2, Dropout probability: 0,5, Activation function: None                        |



Şekil 2. Geliştirilen sistemin mimarisi (The architecture of the developed system)

kamera görüntülerine göre modelin ürettiği sonuçlar tekrar mobil uygulama aracılığıyla mobil cihaza gönderilerek yorgunluk durumu kullanıcıya gösterilmiştir.

### 2.1. Veri Seti (Dataset)

Modeli eğitmek için 2425 görüntüden oluşan veri seti kullanılmıştır [12]. Veri seti açık göz ve kapalı göz görüntüleri olmak üzere iki kategoride oluşturulmuştur. Veri setinin model eğitiminde daha iyi sonuçlar veren %80/%20 eğitim/test oranına göre bölünmesi önerilmektedir [13]. Ancak modeli eğitirken hiper parametre ayarlarının hassas bir şekilde yapılabilmesi için 250 görüntü geçerleme işlemi için kullanılmıştır. Veri setindeki görüntülerin %82,48'i eğitim ve geçerleme işlemi için kullanılırken %17,52'si test işlemi için kullanılmıştır. Sayısal olarak ifade edilirse veri setindeki 1750 görüntü eğitim, 250 görüntü geçerleme ve 425 görüntü test için kullanılmıştır.

### 2.2. Hiper Parametreler (Hyperparameters)

Modelin eğitilmesi için Tablo 3'te yer alan hiper parametreler kullanılmıştır;

**Tablo 3.** Eğitimde kullanılan hiper parametreler (Hyperparameters used in training)

| Hiper Parametre | Değer               |
|-----------------|---------------------|
| epoch           | 30                  |
| verbosity       | 1                   |
| learning rate   | 0,001               |
| loss_function   | binary_crossentropy |
| optimizer       | Adam                |
| threshold       | 0,5                 |

Tablo 3'de yer alan değerlerde model maksimum başarı oranına ulaşmıştır. Epoch değeri veri setinin tamamının kaç

defa evrişimsel sinir ağından geçirildiğini ifade etmektedir. Yapılan çalışmada veri setinin tamamı 30 defa eğitilmiştir. Verbose, modelin eğitim ilerleyişinin görüntülenebilmesi için 1 olarak ayarlanmıştır. Eğitim sırasında ağırlıkların güncellendiği miktar olan öğrenme oranı 0,001 olarak ayarlanmıştır. Tahmin edilen değer ile gerçek değer arasındaki kaybı hesaplamak için ikili çapraz entropi kayıp fonksiyonu kullanılmıştır. Öğrenme oranının eğitim içerisinde farklı parametrelere göre ayarlanabilmesi için Adam optimizasyon algoritması tercih edilmiştir. Modelin ikili sınıflandırma tahmini için eşik değeri 0,5 olarak belirlenmiştir. Modelin hesapladığı skor 0,5 eşik değerinden büyük ise göz kapalı olarak sınıflandırılırken 0,5 eşik değerinden düşük ise göz açık olarak sınıflandırılır.

### 2.3. Evrişimsel Sinir Ağları (Convolutional Neural Networks)

Evrişimsel sinir ağları girdi görüntüsünü alabilen, görüntüdeki çeşitli bölgelere öğrenilebilir ağırlıklar atayabilen ve sınıflandırma yapabilen ileri beslemeli yapay sinir ağıdır. Evrişimsel sinir ağlarında gereken ön işleme diğer algoritmalar göre daha azdır. Evrişimsel sinir ağları genellikle görüntülerde kullanılan kalıpları tanımak için kullanılmaktadır ancak bilgisayarlı görü, veri analizi, doğal dil işleme ve sinyal işleme için de kullanılır. Evrişimsel sinir ağı 4 temel katmandan oluşur. Bunlar; evrişim katmanı, havuzlama veya alt örnekleme katmanı, tam bağlantılı katman ve bırakma katmanıdır [14].

Evrişim katmanı evrişimsel sinir ağının ilk katmanıdır. Evrişim işlemi alınan görüntüdeki bölgesel tüm piksellerin tek bir değere dönüştürülerek görüntü boyutunun düşürülmesidir. Evrişim katmanı giriş görüntüsüne evrişim işlemi uygulayarak sonucu bir sonraki katmana aktarır. Giriş bilgisini filtrelemek ve özellik haritası çıkarmak için çeşitli boyutlarda filtreler kullanılır. Filtreler, evrişim işlemi

gerçekleştirmek için girdi görüntüsü üzerinden geçerek matris çarpımı işlemi yapar. Evrişimin gerçekleştiği her bir alan için sonuç özellik haritasına yazılır. Özellik haritası oluşana kadar filtre kaydırılmaya devam edilir. Bir evrişim katmanında genellikle birden fazla filtre olduğu için bu katmanın çıktısında birden fazla özellik haritası oluşmaktadır. Evrişimsel sinir ağları genellikle birden fazla evrişim katmanına sahiptir [15].

Havuzlama katmanının temel amacı hesaplama maliyetlerini azaltmak için kıvrımlı özellik haritasının boyutunu küçültmektir. Bunun için katmanlar arasındaki bağlantılar azaltılır ve her bir özellik haritasında bağımsız olarak çalışılır. Maksimum, ortalama ve toplam havuzlama olmak üzere üç tür yöntem vardır. Maksimum havuzlama yönteminde en büyük eleman özellik haritasından alınır. Ortalama havuzlama yönteminde önceden tanımlanmış bölümündeki elemanların ortalaması hesaplanır. Toplam havuzlama yönteminde önceden tanımlanmış bölümdeki öğelerin toplamı hesaplanır. Havuzlama katmanı genellikle evrişim katmanı ve tam bağlantılı katmanı arasında bir köprü görevi görür [16]. Tam bağlantılı katman nöronlarla birlikte ağırlıklar ile önyargılardan oluşur ve nöronları iki farklı katman arasında bağlamak için kullanılır. Bu katmanlar genellikle çıktı katmanından önce yerleştirilir ve bir evrişimsel sinir ağı mimarisinin son birkaç katmanını oluşturur. Önceki katmanlardan gelen girdi görüntüsü düzleştirilir ve tam bağlantılı katmana beslenir. Düzleştirilmiş vektör daha sonra matematiksel fonksiyon işlemlerinin genellikle gerçekleştiği birkaç tam bağlantılı katmandan daha geçer. Bu aşamada sınıflandırma işlemi gerçekleşmeye başlar [17].

Bırakma katmanı modelin veri setine fazla uyum göstermesini engellemek için kullanılır. Belirli bir model eğitim veri setine fazla uyum sağlarsa eğitim verileri üzerinde çok iyi çalışırken yeni bir veri üzerinde kullanıldığında aynı performansı gösteremeyebilir. Bu sorunun üstesinden gelmek için eğitim işlemi sırasında sinir ağından birkaç nöronun düştüğü ve modelin boyutunun küçüldüğü bir bırakma katmanı kullanılır [18]. Aktivasyon fonksiyonları evrişimsel sinir ağı modelinin en önemli parametrelerinden biridir. Aktivasyon fonksiyonları ağın değişkenleri arasındaki her türlü sürekli ve karmaşık ilişkiyi

öğrenmek ve tahmin etmek için kullanılırlar. Modelin hangi bilgilerinin ileri yönde tetiklenmesi ve hangilerinin ağı sonunda olmaması gerektiğine karar verilir. Aktivasyon fonksiyonları ağı doğrusal olmama özelliği ekler. ReLU, Softmax, tanH ve Sigmoid fonksiyonları yaygın olarak kullanılan aktivasyon fonksiyonlarıdır [14].

#### 2.4. Evrişimsel Sinir Ağı Modelleri (Convolutional Neural Network Models)

##### 2.4.1. AlexNet (AlexNet)


AlexNet, Alex Krizhevsky tarafından 2012 yılında geliştirilmiştir. AlexNet 2012 yılında gerçekleştirilen ImageNet yarışmasını %15,3 hata oranı ile kazanmıştır [19]. AlexNet mimarisi beş evrişimsel katman ve üç tam bağlantılı katman olmak üzere sekiz katmandan oluşmaktadır. AlexNet, önceki sinir ağlarında standart olarak kullanılan tanh işlevi yerine ReLU aktivasyon fonksiyonunu kullanmıştır. Bu sayede tanh kullanan bir evrişimsel sinir ağından altı kat daha hızlı eğitim yapılabilmektedir. AlexNet eğitim işleminin çoklu ekran kartları üzerinde aynı anda yapılmasına izin vererek daha büyük modellerin eğitime izin verirken eğitim süresini de kısaltmaktadır. AlexNet ağına 61 milyon parametreye sahip olması nedeniyle fazla uyumu engellemek amacıyla pikseller üzerinde temel bileşen analizi ve bırakma katmanları kullanılmıştır [20]. AlexNet mimarisinin çizimi Şekil 3'te sunulmuştur.

##### 2.4.2. VGG-16 (VGG-16)

VGG-16, 2014 yılında K. Simonyan ve A. Zisserman tarafından geliştirilmiştir. VGG-16 2014 yılında gerçekleştirilen ImageNet yarışmasını %7,3 hata oranı ile kazanmıştır. VGG-16 yalnızca evrişirme ve havuzlama katmanlarının yer aldığı toplam 16 katmandan oluşmaktadır. VGG-16 toplam 138 milyon parametreye sahiptir [21]. VGG-16 konfigürasyonu ana hatlarıyla Tablo 4'te sunulmuştur.

##### 2.4.3. ResNet-50 (ResNet-50)

ResNet, 2015 yılında Kaiming He, Xiangyu Zhang, Shaoqing Ren ve Jian Sun tarafından geliştirilmiştir. Resnet-




Şekil 3. AlexNet mimarisi (AlexNet architecture) [20]



**Tablo 4.** VGG-16 konfigürasyonu (VGG-16 configuration) [21]

| Evrişim Ağı Konfigürasyonu                 |                     |                     |                               |                               |   |
|--|---------------------|---------------------|-------------------------------|-------------------------------|---|
| A  | A-LRN               | B                   | C                             | D                             | E                                       |
| 11 ağırlık katmanı giriş (224x224 görüntü) | 11 ağırlık katmanı  | 13 ağırlık katmanı  | 16 ağırlık katmanı            | 16 ağırlık katmanı            | 19 ağırlık katmanı                      |
| konv3-64 maksimum havuzlama                | konv3-64 LRN        | konv3-64 konv3-64   | konv3-64 konv3-64             | konv3-64 konv3-64             | konv3-64 konv3-64                       |
| konv3-128 maksimum havuzlama               | konv3-128           | konv3-128 konv3-128 | konv3-128 konv3-128           | konv3-128 konv3-128           | konv3-128 konv3-128                     |
| konv3-256 maksimum havuzlama               | konv3-256 konv3-256 | konv3-256 konv3-256 | konv3-256 konv3-256 konv3-256 | konv3-256 konv3-256 konv3-256 | konv3-256 konv3-256 konv3-256 konv3-256 |
| konv3-512 maksimum havuzlama               | konv3-512 konv3-512 | konv3-512 konv3-512 | konv3-512 konv3-512 konv3-512 | konv3-512 konv3-512 konv3-512 | konv3-512 konv3-512 konv3-512 konv3-512 |
| konv3-512 maksimum havuzlama               | konv3-512 konv3-512 | konv3-512 konv3-512 | konv3-512 konv3-512 konv3-512 | konv3-512 konv3-512 konv3-512 | konv3-512 konv3-512 konv3-512 konv3-512 |
| konv3-512 maksimum havuzlama               | konv3-512 konv3-512 | konv3-512 konv3-512 | konv3-512 konv3-512 konv3-512 | konv3-512 konv3-512 konv3-512 | konv3-512 konv3-512 konv3-512 konv3-512 |
| softmax fonksiyonu                         |                     |                     |                               |                               |   |

50, 50 katman ve 25,6 milyon parametreden oluşan evrişimsel sinir ağıdır. ResNet 2015 yılında gerçekleştirilen ImageNet yarışmasını %3,57 hata oranı ile kazanmıştır. ResNet çok derin ağları eğitme sorununu gidermek için artık bloklar kullanmaktadır. Artık bloklar ile bazı katmanların üzerinden atlamak için kısayollar kullanır [22]. Artık blok yapısı Şekil 4'te sunulmuştur.



**Şekil 4.** Artık öğrenme blok yapısı (Residual learning block structure) [19]

#### 2.4.4. MobileNet (MobileNet)

MobileNet, mobil ve gömülü görüntü uygulamaları için tasarlanmış 28 katman ve 4,2 milyon parametreden oluşan

evrişimsel sinir ağıdır. MobileNet, mobil ve gömülü cihazlar için düşük gecikme süresine sahip olan hafif derin sinir ağların geliştirilmesini sağlayan derinlemesine ayrılabilir evrişimler kullanan modern bir mimariye dayanır [23]. MobileNet'te derinlemesine ayrılabilir evrişim her bir giriş kanalına tek bir filtre uygular. Noktasal evrişim daha sonra derinlik yönündeki evrişim çıktılarını birleştirmek için  $1 \times 1 \times 1$  evrişim uygular. Gecikme ve doğruluk arasında verimli bir şekilde değiş tokuş yapan iki basit küresel hiper parametre sunulmaktadır. Bu hiper parametreler model oluşturucunun problemin kısıtlamalarına dayalı olarak uygulamaları için doğru boyutlu modeli oluşturmasına izin verir. Transfer öğrenimini çalıştırmak veya uygulamak için çok daha az hesaplama gücü gerektirir [24]. MobileNet mimarisi Tablo 5'de sunulmuştur.

#### 2.5. Tensorflow (Tensorflow)

Tensorflow makine öğrenimi için kullanılan açık kaynak yazılım kütüphanesidir. Tensorflow Google tarafından 2015 yılında kullanıma sunulmuştur. Tensorflow, veri akışına ve türevlenebilir programlamaya dayalı bir matematik kitaplığıdır. 2017 yılında yayımlanan ikinci sürümde hem CPU hem de GPU üzerinde işlem yapılabilmesi sağlanmıştır. Tensorflow; 64 bit Linux, macOS, Windows, Android ve iOS dahil olmak üzere birçok platformda kullanılabilir. Esnek mimarisi çeşitli platformlarda (CPU'lar, GPU'lar, TPU'lar) hesaplamaların kolay dağıtımına olanak tanır [25].



Tensorflow adı sinir ağlarının tensörler olarak adlandırılan çok boyutlu veri dizileri üzerinde gerçekleştirdiği işlemlerden türemiştir. Tensör, potansiyel olarak daha yüksek boyutlardaki vektörlerin ve matrislerin genellemesidir. Sinir ağına girdi olarak beslenen değişen boyutlara ve sıralara sahip veri dizilerine tensör denir. Derin öğrenme için özellikle eğitim sürecinde çok karmaşık bir formatta büyük miktarda veri kullanılmaktadır. Tensorflow hesaplamaları durum bilgisi olan veri akışı grafikleri olarak ifade edilebilir [26]. Tensorflow; Tensorflow Çerçeve, TensorBoard ve TensorFlow Servis olmak üzere 3 ana bileşenden oluşur. Tensorflow, akademik araştırma ve endüstriyel uygulamalarda yaygın olarak kullanılmaktadır [27]. Tensorflow, görüntü tanıma ve sınıflandırma problemlerinde başarılı sonuçlar vermesinden ve yaygın kullanılmasından dolayı yapılan çalışmada tercih edilmiştir.

**Tablo 5.** MobileNet mimarisi (MobileNet architecture) [21]

| Katman                     | Filtre         | Giriş Boyutu |
|----------------------------|----------------|--------------|
| Evriştirme / s2            | 3x3x3x32       | 224x224x3    |
| Evriştirme dw / s2         | 3x3x3x32 dw    | 112x112x32   |
| Evriştirme / s1            | 1x1x32x64      | 112x112x32   |
| Evriştirme dw / s2         | 3x3x3x64 dw    | 112x112x64   |
| Evriştirme / s1            | 1x1x64x128     | 56x56x64     |
| Evriştirme dw / s1         | 3x3x128 dw     | 56x56x128    |
| Evriştirme / s1            | 1x1x128x128    | 56x56x128    |
| Evriştirme dw / s2         | 3x3x128 dw     | 56x56x128    |
| Evriştirme / s1            | 1x1x128x256    | 28x28x128    |
| Evriştirme dw / s1         | 3x3x256 dw     | 28x28x256    |
| Evriştirme / s1            | 1x1x256x256    | 28x28x256    |
| Evriştirme dw / s2         | 3x3x256 dw     | 28x28x256    |
| Evriştirme / s1            | 1x1x256x512    | 14x14x256    |
| 5x (Evriştirme dw / s1     | 3x3x512 dw     | 14x14x512    |
| Evriştirme / s1)           | 1x1x512x512    | 14x14x512    |
| Evriştirme dw / s2         | 3x3x512 dw     | 14x14x512    |
| Evriştirme / s1            | 1x1x512x1024   | 7x7x512      |
| Evriştirme dw / s2         | 3x3x1024 dw    | 7x7x1024     |
| Evriştirme / s1            | 1x1x1024x1024  | 7x7x1024     |
| Ortalama Havuzlama / s1    | Havuzlama 7x7  | 7x7x1024     |
| Tam Bağlantılı Katman / s1 | 1024x1000      | 1x1x1024     |
| Softmax Fonksiyonu / s1    | Sınıflandırıcı | 1x1x1000     |

### 2.6. Transfer Öğrenme (Transfer Learning)

Transfer öğrenme, bir görev için geliştirilen bir modelin ikinci bir görevdeki bir model için başlangıç noktası olarak yeniden kullanıldığı derin öğrenme yöntemidir. Transfer öğrenme önceden eğitilmiş modellerin derin öğrenme problemleri üzerinde başlangıç noktası olarak kullanılmasıdır. Transfer öğrenme, ikinci görevi modellerken hızlı ilerleme veya gelişmiş performans sağlayan bir optimizasyondur [28]. Derin öğrenme modellerinin eğitildiği büyük ve zorlu veri kümelerini eğitmek için gerekli olan büyük miktardaki kaynaklar göz önünde bulundurulduğunda transfer öğrenme eğitim işlemlerinde önemli fayda sağlamaktadır. Derin öğrenme modelinde birincil amaç eğitim verisinden öğrenilen kalıplara dayanan veriyi ortaya çıkarmaktır. Transfer öğrenmeyle farklı bir görev için öğrenilen kalıplardan bu

genelleme süreci başlatılmaya çalışılır. Esasen öğrenme sürecini boş bir sayfadan başlatmak yerine farklı bir görevi yerine getirmek için öğrenilmiş olan kalıplardan başlatmak daha etkin sonuçlar verebilir [29]. Transfer öğrenmede temel fikir bir modelde öğrenilen bilgiyi almak ve onu başka bir göreve uygulamaktır. Önceden eğitilmiş bir model benzer bir sorunu çözmek için bir başka çalışmada kullanılabilir. Benzer bir problemi çözmek için sınıftan bir model oluşturmak yerine, başka bir konuda eğitilen model bir başlangıç noktası olarak kullanılabilir. Daha önce büyük veri setlerinde eğitilmiş olan önceden eğitilmiş modeller kullanılarak elde edilen ağırlık ve mimari doğrudan tekrar kullanılabilir. Transfer öğrenme yönteminde hangi eğitimli modelin kullanılması gerektiğini seçerken dikkatli olunmalıdır. Problem önceden eğitilmiş modelin eğitim gördüğü konudan çok farklıysa çıktı tahmini yanlış olur. Önceden eğitilmiş ağırlık çok iyi eğitildiği varsayıldığından ağırlıkları çok fazla değiştirilmez. Model revize edilirken genellikle modeli eğitmek için kullanılan daha küçük bir öğrenme oranı kullanılır. Transfer öğrenme, zamandan tasarruf etmeyi ve daha iyi bir performans elde etmeyi sağlar. Transfer öğrenme veri kümesinin yetersiz olduğu durumlarda da kullanılabilir [30]. Yapılan çalışmada sürücü yorgunluk tespiti modelini eğitmek için 3.000 görüntü üzerinde ön eğitilmiş model transfer öğrenme tekniği ile tekrar kullanılmıştır.

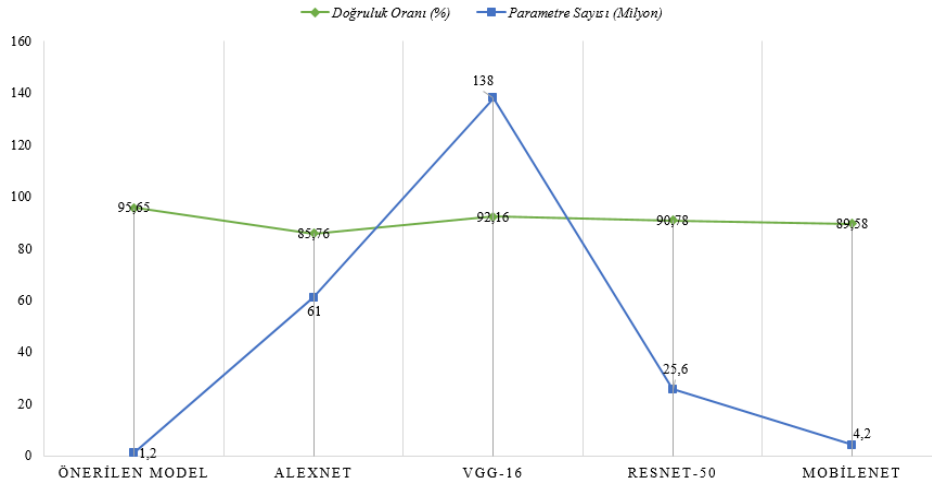
### 3. DENEYSEL SONUÇLAR (EXPERIMENTAL RESULTS)

Yapılan çalışmada Python 3.6 ve Tensorflow kütüphanesi kullanılmıştır. Eğitim ve geçirme işlemi için 2000 görüntü ve test işlemi için 425 görüntü kullanılmıştır. Transfer öğrenme yöntemi ile önceden 3000 görüntü üzerinde eğitilmiş model üzerine geliştirme yapılmıştır. Eğitim işlemi için 3 evriştirme katmanı, 3 havuzlama katmanı, 1 düzleştirme katmanı, 1 bırakma katmanı, 3 yoğun katman ve 3 tam bağlantılı katman olmak üzere toplam 14 katmanlı model geliştirilmiştir. Mobil cihazlarda yüksek performansta çalışabilmesi için model geliştirilirken parametre sayısının minimum seviyede tutulmasına dikkat edilmiştir. Geliştirilen model 1,236,217 parametreden oluşmaktadır ve bu sayı modelin mobil cihazda anlık tespit yapabilmesini sağlamaktadır. Aynı veri seti AlexNet, VGG-16, ResNet-50 ve MobileNet algoritmaları ile eğitilerek başarı oranları elde edilmiştir. Eğitilen modelin test işlemi sonucu elde edilen performans metrikleri ve diğer algoritmalar ile karşılaştırılması Tablo 6'da yer almaktadır.

Tablo 6'da görüldüğü gibi önerilen model diğer algoritmalara göre daha az parametre ile daha yüksek doğruluk oranına ulaşmıştır. Modellerin parametre sayıları ile doğruluk oranları arasındaki ilişki Şekil 5'te sunulmuştur. Geliştirilen modelin önceki çalışmalar ile karşılaştırılması Tablo 7'de görülmektedir. Tablo 7'de görüldüğü gibi yapılan çalışma derin öğrenme algoritması kullanılarak sürücü yorgunluk tespiti konusunda yapılan ilk çalışmadır. Bunun yanında elde edilen başarı oranı önceki yapılan çalışmalara göre daha yüksektir. Geliştirilen model düşük parametre sayısı ile yüksek doğruluk oranına ulaşması sayesinde mobil cihazdan gelen verileri anlık olarak işleyerek sonuçları anlık

**Tablo 6.** Sürücü yorgunluk tespiti modelinin performans metrikleri  
(Performance metrics of the driver drowsiness detection model)

| Algoritma      | Doğruluk (%) | Kesinlik (%) | Duyarlılık (%) | F1 SKOR (%) | Parametre Sayısı |
|----------------|--------------|--------------|----------------|-------------|------------------|
| Önerilen Model | 95,65        | 95,86        | 94,32          | 95,17       | 1,236,217        |
| AlexNet        | 85,76        | 86,43        | 85,76          | 85,27       | 61,000,000       |
| VGG-16         | 92,16        | 85,71        | 92,16          | 89,85       | 138,000,000      |
| ResNet-50      | 90,78        | 89,53        | 90,24          | 89,12       | 25,600,000       |
| MobileNet      | 89,58        | 89,63        | 89,25          | 89,29       | 4,200,000        |

**Şekil 5.** Doğruluk oranı ile parametre sayısı arasındaki ilişki (The relationship between the accuracy and the number of parameters)**Tablo 7.** Önerilen modelin önceki çalışmalarla karşılaştırılması (Comparison of the proposed model with previous studies)

| Çalışma                     | Teknik                          | Algoritma   | Özellik                                   | Veri Seti            | Değerlendirme Metriği                  | Başarı Oranı |
|-----------------------------|---------------------------------|---|---|----------------------|--|--------------|
| Önerilen Model              | Derin Öğrenme                   | Evrişimsel Sinir Ağı  | Mobil Cihazlarda Sürücü Yorgunluk Tespiti | 2425 görüntü         | Doğruluk                               | %95,65       |
| Zhongmin Liu vd. [4]        | Derin öğrenme                   | MB-LBP  | Sürücü yorgunluk tespiti                  | Caltech10k Web Faces | Doğruluk ve FPS                        | %93,4 53 FPS |
| Caio Maior vd. [5]          | Derin Öğrenme, Makine Öğrenmesi | Çok Katmanlı Algılayıcı, Rastgele Orman ve Destek Vektör Makineleri | Sürücü yorgunluk tespiti                  | DROZY                | Doğruluk                               | %94,44       |
| Abdelmalik Moujahid vd. [6] | Derin Öğrenme, Makine Öğrenmesi | Destek vektör makineleri  | Sürücü yorgunluk tespiti                  | NTHU                 | Doğruluk                               | %76,92       |
| Faisal Mohammad vd. [7]     | OpenCV                          | Haar Sınıflandırıcı   | Mobil Cihazlarda Sürücü yorgunluk tespiti | -                    | Laboratuvar, Fotoğraf ve araç testleri | -            |
| Sónia Soares vd. [8]        | Derin Öğrenme                   | -   | Sürücü yorgunluk tespiti                  | 634 sürüş kaydı      | Doğruluk                               | %78,04       |
| Rajamohana S.P. vd. [9]     | Derin Öğrenme                   | Evrişimsel Sinir Ağı ve BİLSTM                                      | Sürücü yorgunluk tespiti                  | 2208 görüntü         | Doğruluk                               | %94          |

olarak göstermektedir. Model sunucu üzerinde çalışırken mobil cihazdan alınan kamera verileri geliştirilen mobil uygulama üzerinden sunucuya gönderilmektedir. Sunucunun çalışması ve üretilen sonuçlar Şekil 6'da görülmektedir.

Şekil 6'da görüldüğü gibi Android uygulama üzerinden gelen veriler analiz edilerek sonuçlar ekrana yansıtılmakta ve mobil uygulamaya gönderilmektedir. Sürücü yorgunluk tespiti mobil uygulamasının ana sayfası Şekil 7'de

```

C:\WINDOWS\py.exe
num faces: 1
0.3197208288629785
False
current consecutive drowsy frames: 0
num faces: 1
0.34711590190415786
False
current consecutive drowsy frames: 0
num faces: 1
0.22958760570049191
True
current consecutive drowsy frames: 1
num faces: 1
0.1887932061239217
True
current consecutive drowsy frames: 2
num faces: 1
0.19762751918038146
True
current consecutive drowsy frames: 3
num faces: 1
0.1637456080305194
True
current consecutive drowsy frames: 4
50
192.168.1.3 - - [13/Jun/2021 17:17:04] "POST / HTTP/1.1" 200 -
{'drowsy': True}
Constructor called
Post!

```

Şekil 6. Sunucu ekranı (Server screen)

görülmektedir. Kullanıcılar uygulamayı çalıştırdıklarında Şekil 7'de yer alan Uygulamayı Başlat butonuna tıklayarak kameranın açılmasını ve sunucuya görüntülerin gönderilmesini başlatmaktadır. Mobil cihaz kamerasından sürücü yorgunluk tespiti Şekil 8'de görülmektedir.




Şekil 7. Sürücü yorgunluk tespiti mobil uygulaması anasayfa ekranı  
(Driver drowsiness detection mobile app homepage screen)

Şekil 8'de görüldüğü gibi kullanıcının gözleri 3 saniye boyunca kapalı duruma geçerse uygulama Yorgunluk Tespiti Algılandı mesajını ekranda göstermekte ve uyarı için alarm sesi çıkarmaktadır.

#### 4. SONUÇLAR (CONCLUSIONS)

Trafik kazalarının %20'si, şiddetli trafik kazalarının %40'ı sürücü yorgunluğu nedeniyle yaşanmaktadır. Sürücü yorgunluk tespiti yorgunluktan kaynaklı trafik kazalarını engelleme potansiyeline sahip olduğu için önemli bir konudur. Görüntülerden sürücü yorgunluk tespiti diğer yöntemlere göre daha avantajlı olduğu için son dönemlerde yapılan çalışmalar bu alanda yoğunlaşmaya başlamıştır. Yapılan çalışmalarda da genellikle evrimsel sinir ağları ve tekrarlayan sinir ağları kullanılmaktadır. Ancak yapılan çalışmalar mobil veya daha az işlem gücüne sahip cihazlara yönelik değildir. Bu nedenle yapılan çalışmada evrimsel sinir ağları kullanılarak geliştirilen model mobil cihazlara uygun olarak tasarlanmıştır. Geliştirilen model 14 katmandan ve 1,236,217 parametreden oluşmaktadır. Modeli eğitme işlemine sıfırdan başlanmamış daha önce yüz görüntüleri üzerinde eğitilen model transfer öğrenme tekniği ile yeniden kullanılmıştır. Bu sayede geliştirilen model düşük parametre sayısına sahip olmasına rağmen %95,65 başarı oranı ile önceki çalışmalardan daha yüksek başarı oranı elde edilmiştir. Mobil cihaz kamerasından gelen görüntüler anlık olarak işlenerek sürücü yorgunluk tespiti yapılabilmektedir. Model tarafından sürücü yorgunluk tespiti yapılırsa kullanıcı hem mesaj hem de ses ile uyarılmaktadır. Geliştirilen uygulama havacılık ve demiryolu gibi farklı sektörlerde de kullanılma potansiyeline sahiptir. Sonraki çalışmalarda sürücü yorgunluk tespiti modeli esneme sıklığı, mola sıklığı, toplam sürüş süresi gibi sürüşü etkileyen parametrelere göre sürücülerini uyarılabilir.



**Şekil 8.** Mobil cihaz kamerası ile sürücü yorgunluk tespiti (Driver drowsiness detection with mobile device camera)

Bunun yanında sürücünün davranışsal tüm hareketleri analiz edilerek sürüşü olumsuz etkileyebilecek cep telefonu ile ilgilenme, içecek veya yiyecek tüketimi, yolcular ile sohbet gibi davranışların tespit edilmesi sağlanabilir.

#### KAYNAKLAR (REFERENCES)

1. Abílio Ramos M., Drogue E. L., Mosleh A., das Chagas Moura M., Ramos Martins M., Revisiting past refinery accidents from a human reliability analysis perspective: The BP Texas City and the Chevron Richmond accidents, *Canadian Journal of Chemical Engineering*, 95, 2293-2305, 2017.
2. Dementyev A., Holz C., DualBlink: A wearable device to continuously detect, track, and actuate blinking for alleviating dry eyes and computer vision syndrome, In *Proceedings of the ACM on interactive, mobile, wearable and ubiquitous technologies*, 1 (1), 1-19, 2017.
3. Jacobé de Naurois C., Bourdin C., Stratulat A., Diaz E., Vercher J.-L., Detection and prediction of driver drowsiness using artificial neural network models, *Accident Analysis & Prevention*, 126, 95-104, 2019.
4. Utku A., Doğru İ.A., Permission based detection system for android malware, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 32 (4), 1015-1024, 2017.
5. Öcal, H., Doğru, İ. A., Barışçı, N., Akıllı ve Geleneksel Giyilebilir Sağlık Cihazlarında Nesnelerin İnterneti, *Politeknik Dergisi*, 22 (3), 695-714, 2019.
6. Liu Z., Peng Y., Hu W., Driver fatigue detection based on deeply-learned facial expression representation, *Journal of Visual Communication and Image Representation*, 71, 102723, 2020.
7. Maior, C., Moura M., Santana J., Lins I., Real-time classification for autonomous drowsiness detection using eye aspect ratio, *Expert Systems with Applications*, 158, 113505, 2020.
8. Moujahid A., Dornaika F., Arganda-Carreras I., Reta J., Efficient and compact face descriptor for driver drowsiness detection, *Expert Systems With Applications*, 168, 114334, 2021.
9. Mohammad F., Mahadas K., Hung G.K., Drowsy driver mobile application: Development of a novel scleral-area detection method, *Computers in Biology and Medicine*, 89, 76-83, 2017.
10. Soares S., Ferreira S., Couto A., Drowsiness and distraction while driving: A study based on smartphone app data, *Journal of Safety Research*, 72, 279-285, 2020.
11. Rajamohana S.P., Radhika E.G., Priya S., Sangeetha S., Driver drowsiness detection system using hybrid approach of convolutional neural network and bidirectional long short term memory (CNN\_BILSTM), *Materials Today: Proceedings*, 45 (2), 2897-2901, 2021.
12. Eyes Dataset, [https://github.com/aayushrai/Driver\\_safety/tree/master/eyes](https://github.com/aayushrai/Driver_safety/tree/master/eyes). Erişim tarihi Eylül 5, 2021.
13. Rácz, A., Bajusz, D., Héberger, K., Effect of Dataset Size and Train/Test Split Ratios in QSAR/QSPR Multiclass Classification, *Molecules*, 26 (4), 1111, 2021.
14. Şafak E., Barışçı N., Age and Gender Prediction Using Convolutional Neural Networks, 2018 2nd International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT), Ankara-Türkiye, 19-21 Ekim, 2018.
15. Albawi S., Mohammed T. A., Al-Zawi S., Understanding of a convolutional neural network, *International Conference on Engineering and Technology (ICET)*, Antalya-Türkiye, 21-23 Ağustos, 2017.
16. Arı A., Hanbay D., Tumor detection in MR images of regional convolutional neural networks, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 34 (3), 1395-1408, 2019.
17. Yilmaz, S., Toklu, S., A deep learning analysis on question classification task using Word2vec representations, *Neural Computing and Applications*, 32, 2909-2928, 2020.
18. Elmas B., Identifying species of trees through bark images by convolutional neural networks with transfer learning method, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 36 (3), 1253-1270, 2021.
19. İnik, Ö., Ülker, E., Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri,

- Gaziosmanpaşa Bilimsel Araştırma Dergisi (GBAD), 6 (3), 85-104, 2017.
20. Krizhevsky A., Sutskever I., Hinton G., ImageNet classification with deep convolutional neural networks, In *Advances in Neural Information Processing Systems 2012*, Nevada-ABD, 1097-1105, 2012.
  21. Simonyan K., Zisserman A., Very deep convolutional neural networks for large-scale image recognition, arXiv preprint arXiv:1409.1556, 2015.
  22. He K. M., Zhang X. Y., Ren S. Q., Sun J., Deep Residual Learning for Image Recognition, 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas-ABD, 770-778, 27-30 Haziran, 2016.
  23. Uçar M., Glokom Hastalığının Evrişimli Sinir Ağı Mimarileri ile Tespiti, DEÜ FMD, 23 (68), 521-529, 2021.
  24. Howard A. G., Zhu M., Chen B., Kalenichenko D., Wang W., Weyand T., Andreetto M., Adam H., MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications, CoRR, abs/1704.04861, 2017.
  25. Şeker A., Diri B., Balık H.H., Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme, Gazi Mühendislik Bilimleri Dergisi, 3 (3), 47-64, 2017.
  26. Janardhanan P., Project repositories for machine learning with TensorFlow, Procedia Computer Science, 171, 188-196, 2020.
  27. Tensorflow. Tensorflow. <https://www.tensorflow.org/>. Erişim tarihi Ağustos 15, 2021.
  28. Bozinovski S., Fulgosi A., The influence of pattern similarity and transfer of learning upon training of a base perceptron B2, Proc. Symp. Informatica 3-121-5, Bled, 1976.
  29. Fırıldak K., Talu M.F., Evrişimsel Sinir Ağlarında Kullanılan Transfer Öğrenme Yaklaşımlarının İncelenmesi, 4 (2), 88-95, 2019.
  30. Singh S. P., Transfer of Learning by Composing Solutions of Elemental Sequential Tasks, Machine Learning, 8, 323-339, 1992.

