



## Real-time fire and smoke detection for mobile devices using deep learning

Emre Şafak<sup>1\*</sup>, Necaattin Barışçı<sup>2</sup>

<sup>1</sup>R&D Technology and Innovation Department, HAVELSAN, 06530, Ankara, Türkiye

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

### Highlights:

- MobileNet convolutional neural network revised for fire and smoke detection
- Revised MobileNet comparison of existing lightweight convolutional neural networks
- Transfer learning technique was applied using the pre-trained model for the training process

### Keywords:

- Fire and smoke detection
- Fire and smoke detection for mobile devices
- Convolutional neural networks
- Internet of Things
- Deep Learning

### Graphical/Tabular Abstract

In the study, Convolutional Neural Networks were used for fire and smoke detection for mobile devices. The MobileNet convolutional neural network was revised, the last 3 layers were removed and replaced with a flattening layer and a dense layer consisting of two nodes. Fire and smoke detection model, the method with the highest accuracy was determined among the models developed using revised MobileNet, original MobileNet, MobileNetV2, EfficientNetB0 and ShuffleNet convolutional neural networks. According to test results, highest accuracy rate of 98.37% was achieved in the revised MobileNet. The architecture of the developed system is shown in Figure A.

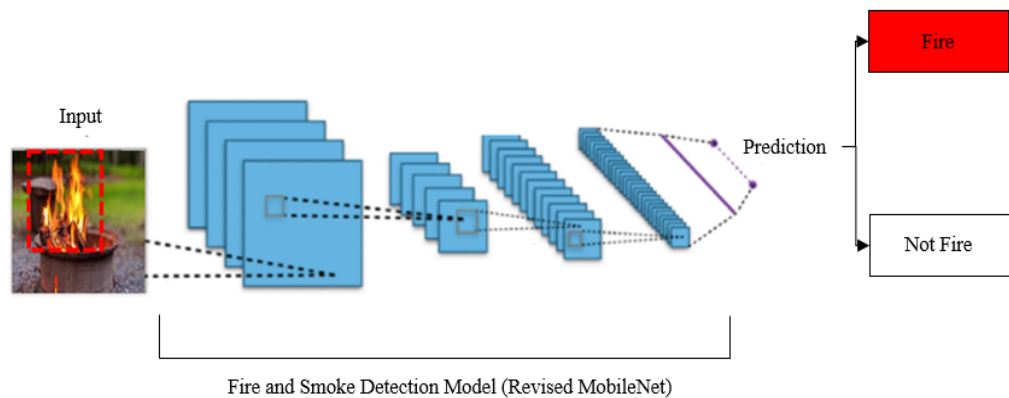


Figure A. Fire and smoke detection with convolutional neural networks

### Article Info:

Research Article

Received: 23.12.2021

Accepted: 13.10.2022

### DOI:

10.17341/gazimmfd.1041091

### Correspondence:

Author: Emre Şafak

e-mail:

esafak@havelsan.com.tr

phone: +90 541 266 2073

### Purpose:

The aim of the study is to provide fire and smoke detection on mobile devices using convolutional neural networks. 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. Light convolutional neural networks were used to enable the model to be developed to use on mobile devices. MobileNet convolutional neural network was revised with last 3 layers were removed and replaced with a flattening layer and a dense layer consisting of two nodes. The pre-trained model on ImageNet was reused with the transfer learning technique.

### Results:

While the developed fire and smoke detection model can detect instantaneously via video, the accuracy of the model has been achieved as 98.37%.

### Conclusion:

Fire and smoke detection is provided quickly on mobile devices by using a lightweight model and transfer learning technique. This study has the potential to prevent fires or reduce damage caused by fires.



## Derin öğrenme kullanılarak mobil cihazlar için gerçek zamanlı yangın ve duman tespiti

Emre Şafak<sup>1\*</sup>, Necaattin Barışcı<sup>2</sup>

<sup>1</sup>HAVELSAN, ARGE Teknoloji ve İnovasyon 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

- MobileNet evrişimsel sinir ağı yangın ve duman tespiti için revize edilmiştir
- Revize edilmiş MobileNet ile mevcut hafif evrişimsel sinir ağları karşılaştırılmıştır
- Eğitim işlemi için ön eğitilmiş model kullanılarak transfer öğrenme tekniği uygulanmıştır

#### Makale Bilgileri

Araştırma Makalesi

Geliş: 23.12.2021

Kabul: 13.10.2022

#### DOI:

10.17341/gazimmfd.1041091

#### Anahtar Kelimeler:

Yangın ve duman tespiti,  
mobil cihazlar için yangın ve  
duman tespiti,  
evrişimsel sinir ağları,  
transfer öğrenme,  
nesnelerin interneti,  
derin öğrenme

#### ÖZ

Yangın; ekolojik, sosyal ve ekonomik zararlara neden olan doğal afettir. Küresel ısınma ve patlayıcı/yanıcı kimyasalların kullanımının yaygınlaşması ile birlikte yangınlar insanlık için en önemli sorunlardan biri haline gelmiştir. Yangınların erken tespiti tahribatı en aza indirmek için kritik öneme sahiptir. Bu sebeple yangınların erken tespit edilebilmesi için görüntüler üzerinden yangın algılama üzerine çalışmalar yapılmaya başlamıştır. Görüntülerden yangın tespiti için yapılan son çalışmalarda genellikle derin öğrenme algoritmaları kullanılmaktadır. Bu çalışmalar kameralar üzerinden alınan görüntülerin güçlü sunucular üzerinde çalışan modeller ile analizine odaklanmaktadır. Mobil cihazlar ve nesnelerin internetindeki gelişmeler ile artık uç cihazlar üzerinde görüntüler analiz edilebilir. Yapılan çalışmada görüntülerin bir sunucuya aktarılmadan mobil cihaz üzerinde analiz edilmesini sağlayacak düşük işlem gücü gerektiren yangın ve duman tespit modeli geliştirilmiştir. MobileNet evrişimsel sinir ağı revize edilerek son 3 katman kaldırılmış ve yerine düzleştirme katmanı ile iki düğümden oluşan yoğun katman eklenmiştir. Yangın ve duman tespiti modeli için revize edilmiş MobileNet, orijinal MobileNet, MobileNetV2, EfficientNetB0, ShuffleNet, NASNetMobile ve PeleeNet evrişimsel sinir ağları kullanılarak geliştirilen modeller arasında en yüksek doğruluk oranına sahip yöntem belirlenmiştir. Modelleri eğitmek ve test etmek için 43,355 görüntüden oluşan veri setinin %80'i eğitim %20'si test işlemi kullanılmıştır. Yapılan test sonuçlarına göre revize edilmiş MobileNet ağı %98,37 ile en yüksek doğruluk oranına ulaşılmıştır.

## Real-time fire and smoke detection for mobile devices using deep learning

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

- MobileNet convolutional neural network revised for fire and smoke detection
- Revised MobileNet comparison of existing lightweight convolutional neural networks
- Transfer learning technique was applied using the pre-trained model for the training process

#### Article Info

Research Article

Received: 23.12.2021

Accepted: 13.10.2022

#### DOI:

10.17341/gazimmfd.1041091

#### Keywords:

Fire and smoke detection,  
fire and smoke detection for  
mobile devices,  
convolutional neural  
networks,  
transfer learning,  
internet of things,  
IoT, deep learning

#### ABSTRACT

Fire is a natural disaster that causes ecological, social and economic damage. With global warming and the widespread use of explosive/flammable chemicals, fires have become one of the most important problems for humanity. Early fire detection is critical to minimize destruction. For this reason, studies on fire detection through images have begun to be carried out in order to detect fires early. In recent studies for fire detection from images deep learning algorithms are generally used. These studies focus on the analysis of images taken from cameras with models running on powerful servers. With the developments in mobile devices and internet of things, images can analyzed on edge devices. In the study fire and smoke detection model which requires low processing power has been developed to enable the images to be analyzed on mobile device without transferring them to server. The MobileNet convolutional neural network was revised, the last 3 layers were removed and replaced with a flattening layer and a dense layer consisting of two nodes. Fire and smoke detection model, the method with the highest accuracy was determined among the models developed using revised MobileNet, original MobileNet, MobileNetV2, EfficientNetB0, ShuffleNet, NASNetMobile and PeleeNet convolutional neural networks. To train and test the models, 80% of the dataset consisting of 43,355 images was used for training and 20% for testing. According to test results, highest accuracy rate of 98.37% was achieved in the revised MobileNet.

## 1. Giriş (Introduction)

Yangın, insan ve çevreye önemli ölçüde zarar veren ciddi bir doğal afettir. Küresel ısınma ve patlayıcı/yanıcı kimyasalların kullanımının yaygınlaşması ile birlikte yangın sayısında giderek artış yaşanmaktadır. 2019 yılında dünya genelinde toplam 3,082,565 yangın meydana gelmiştir. Bu yangınlarda toplam 19,187 kişi yaşamını kaybederken 68,217 kişi yaralanmıştır. Yaşanan yangınların %31,6'sı kapalı alanlarda, %13,4'ü araçlarda, %1,8'i ormanlarda, %20'si otluk alanlarda, %14'ü çöplerde ve %19,2'si diğer sebeplerle meydana gelmiştir [1]. Orman yangınları son yıllarda küresel ısınmanın etkisiyle önemli derecede artmıştır. Türkiye'de yanan orman alanı 2021 yılında 2020 yılına göre %94,97 oranında artış göstermiştir. Türkiye'de 2020 yılında orman yangınları nedeniyle 99,857 hektar 2021 yılında ise 194,709 hektar orman alanı yanmıştır [2]. Yangınlar ciddi ekonomik kayıplara yol açmakta ve ekolojik çevreyi tahrip etmektedir. Bunun yanında yangınlar insan yaşamının güvenliği için de büyük bir tehdit oluşturmaktadır. Yangın kaynaklı zararları en aza indirmek için yangınların erken tespiti ve otonom müdahale afet yönetim sistemleri için önemlidir. Erken yangın algılama ve yüksek doğrulukta hassasiyet yangın kayıplarının azaltılmasını sağlar. Yangınların erken tespiti için kapalı alanlarda ısı ve duman detektörleri kullanılmaktadır. Ancak ısı ve duman detektörleri gibi geleneksel yangın algılama teknolojileri geniş alanlar ile karmaşık binalar için uygun değildir. Görüntülerden yangın tespiti yüksek doğruluk, esnek sistem kurulumu, karmaşık binalar ve geniş alanlarda yangınları etkin bir şekilde algılama yeteneği sayesinde son yıllarda önemli bir araştırma konusu haline gelmiştir [3]. Görüntülerden yangın tespiti için yapılan çalışmalar derin öğrenme algoritmaları üzerinde yoğunlaşmaktadır. Evrişimsel sinir ağlarına dayanan derin öğrenme algoritmaları kendi kendine öğrenilme ve etkili özellik çıkarabilmesi sayesinde görüntü tanıma uygulamalarında iyi performans göstermektedir [4]. Yangın ve duman tespitinin yüksek doğrulukta yapılabilmesinin yanında kaynakların etkili kullanılması gerekmektedir. Geleneksel yaklaşımlarda veri kaynaklarından toplanan veriler merkezi sunucular üzerinde işlenmektedir. Veri miktarının giderek artması ve nesnelerin interneti ile milyarlarca cihazın internete bağlanmasıyla mevcut işlem kapasiteleri ve bant genişlikleri yeterli olmayacaktır [5]. Günümüzde kullanımı gittikçe yaygınlaşan ve gelişen mobil cihazlar destekledikleri özellikler ve uygulamalar sayesinde cep bilgisayara dönüşmüşlerdir [6]. Bu nedenle geliştirilecek yangın ve duman tespiti modelinin bir merkezi işlem sunucusu yerine düşük işlem gücüne sahip mobil cihazlar üzerinde maksimum performans ile çalışabilmesi gerekmektedir. Günümüzde mobil cihazlardaki gelişmeler düşük işlem gücü gerektiren evrişimsel sinir ağı modellerinin cihaz üzerinde çalışabilmesine olanak vermektedir. Cihaz kamerasından alınan veriler yine düşük işlem gücüne sahip mobil cihaz üzerinden analiz edilerek yangın tespit edildiğinde alarm üretilmesi sağlanacaktır. Bu sayede kaynakların verimli kullanılması sağlanırken diğer sistemlerle entegrasyon sağlanabilecektir [7].

Pu Li vd. tarafından yapılan çalışmada görüntülerden yangın tespiti için algılama doğruluğunda çok iyi performansa sahip Faster-RCNN, R-FCN, SSD ve Yolov3 algoritmaları yangın görüntüleri veri kümesi üzerinde eğitilerek maksimum performansa sahip model tespit edilmeye çalışılmıştır. Eğitim işlemi için 29,180 görüntüden oluşan veri seti kullanılmıştır. Veri setindeki yangın görüntülerinin sayısı 13,400'dür. Veri setinde yangın içermeyen görüntü sayısı 15,780'dir. Veri setinin %50'si eğitim/geçerleme işlemi, %50'si test işlemi için kullanılmıştır. Bu çalışmada Yolo V3 algoritması yangın algılamada %87,3 ortalama kesinlik ile en iyi performansı göstermiştir [8]. Chenghua Li vd. tarafından yapılan çalışmada duman algılama işleminde doğruluğu ve gerçek zamanlı performansı arttırabilmek için SCCNN (Skor Kümelemeli Evrişimsel Sinir Ağı) isimli yeni

evrişimsel sinir ağı modeli önerilmektedir. Şüpheli duman alanları tespit edebilmek için Gaussian Mixture Model tekniği kullanılmıştır. Ardından skor kümeleme tekniği ile yeniden revize edilen ağ duman bölgelerini tespit etmek için kullanılmıştır. Skor kümeleme ezberlemeyi azaltan ve tahmin doğruluğunu arttıran kayıp fonksiyonudur. Önerilen modelin eğitilmesi için 8805 duman görüntüleri ve 8511 duman olmayan görüntülerden oluşan veri seti kullanılmıştır. Geliştirilen skor kümeleme temelli evrişimsel sinir ağı modeli gerçek zamanlı duman tespitinde %97,17 doğruluk oranına ulaşmıştır [9].

Renjie Xu vd. tarafından yapılan çalışmada evrişimsel sinir ağlarının topluluk öğrenme ile birlikte kullanılarak orman yangınlarının tespit edilmesi önerilmektedir. Yapılan çalışmada 2976 orman yangını görüntüsü ve 7605 yangın dışı görüntü olmak üzere 10,581 görüntü içeren orman yangını veri seti kullanılmıştır. Yangın algılama süreci için Yolov5 ve EfficientDet modelleri entegre edilmiştir. Öğrenme ve sınıflandırma işlemi için ise EfficientNet modeli kullanılmıştır. Yolov5 ve EfficientDet algılama modelleri 2381 orman yangını görüntüsü ile eğitilmiş ve 476 orman yangını görüntüsü ile test edilmiştir. EfficientNet görüntü sınıflandırıcı modeli 2381 orman yangını görüntüsü ve 5804 yangın dışı görüntü ile eğitilmiş ve 476 orman yangını görüntüsü ve 1160 yangın dışı görüntü ile test edilmiştir. Orman yangınları tahmini üç modelin kararlarına dayalı olarak yapılmaktadır. Veri seti üzerinde yapılan deneyler önerilen yöntemin herhangi bir ekstra gecikme olmaksızın algılama performansını %2,5 ila %10,9 oranında iyileştirdiğini ve yanlış pozitifleri %51,3 oranında azalttığını göstermektedir [10].

Lijun He vd. tarafından yapılan çalışmada normal ve sisli hava koşullarında duman tespiti için dikkat mekanizmasını özellik ve karar seviyesinde birleştirilen bir model önerilmektedir. Küçük duman algılama sorununu çözmek için mekansal ve kanal dikkatinin birleştirilmesi önerilmektedir. Görüntülerdeki duman bölgelerine daha fazla ağırlık değerleri verilerek kanallara yeniden sunulur. Veri seti çeşitli pozitif ve sert negatif örnekler ile oluşturulmuştur. Veri seti normal hava, sisli hava, bulut, su buharı ve hareketli nesnelere gibi gerçek duruma olabildiğince yakın 560 video içermektedir. Küçük dumanların tespiti için kanal ve mekansal dikkatin birleştirildiği dikkat mekanizması VGG-16 ağına ikinci grup evrişirme katmanının temeline yerleştirilmiştir. Son olarak özellik ve karar düzeyinde füzyon modülü VGG-16 ağına üçüncü, dördüncü ve beşinci grup evrişirme katmanının temeline yerleştirilmiştir. Geliştirilen model sisli havalarda duman tespitinde %92,30 doğruluk oranına ulaşmıştır [11].

Khan Muhammad vd. tarafından yapılan çalışmada yangın tespiti için önceden eğitilmiş GoogleNet mimarisine ince ayar yapılarak uygun maliyetli evrişimsel sinir ağı mimarisi geliştirilmiştir. Evrişimsel sinir ağları sayesinde özellik mühendisliği süreci ortadan kaldırılmış ve yangın verilerinden özelliklerin otomatik olarak öğrenilmesi sağlanmıştır. Kullanılan veri seti farklı ortamlarda çekilen 31 video içermektedir. Bu veri kümesinde 14 adet yangın videosu ve 17 adet yangınsız normal video bulunmaktadır. Veri setinin %80'i eğitim ve kalan %20'si test için kullanılmıştır. Bu veri seti üzerinde %94,43 başarı oranına ulaşmıştır. Ayrıca geliştirilen model 119'u yangın sınıfına ve 107'si yangın dışı sınıfa ait 226 görüntü içeren başka bir veri seti üzerinde de test edilmiştir. Bu veri seti küçük ama kırmızı ve ateş renginde nesnelere, ateşe benzer güneş ışığı senaryoları ve farklı binalarda ateş renginde aydınlatmalar içerdiğinden oldukça zorlayıcıdır. Test için kullanılan bu veri setinde %86 kesinlik değerine ulaşılmıştır [12]. Saima Majid vd. tarafından yapılan çalışmada gerçek dünya yangın çıkış görüntüleri üzerinde eğitilmiş evrişimsel sinir ağları ve transfer öğrenme kullanılarak yangını tespit etmek için özel bir çerçeve sunulmaktadır. Önerilen çerçevede görüntülerde yangının

görselleştirilmesi ve yerinin belirlenmesi için Grad-CAM yöntemi kullanılır. Bunun yanında önerilen çerçevede ağı daha iyi performans elde etmesine önemli ölçüde yardımcı olan bir dikkat mekanizması yer alır. Yapılan çalışmada ResNet50, VGG16, GoogleNetV3 ve EfficientNetB0 evrimsel sinir ağı modelleri denenmiştir. Modeller, ağı daha iyi performans elde etmesine önemli ölçüde yardımcı olan bir dikkat mekanizması kullanır. Grad-CAM sonuçlarıyla önerilen dikkat kullanımının modelleri görüntülerdeki yangının konumuna daha yakın yönlendirdiği tespit edilmiştir. Kullanılan veri seti 3988 yangın ve 3989 yangın olmayan görüntü olmak üzere toplam 7977 görüntüden oluşmaktadır. Veri setinin %80'i eğitim ve kalan %20'si test için kullanılmıştır. EfficientNetB0 kullanılan veri seti üzerinde %95,40 doğruluk oranına ulaşarak en iyi performans gösteren evrimsel sinir ağı olmuştur [13].

Lida Huang vd. tarafından yapılan çalışmada yangın tespiti için evrimsel sinir ağı algoritmalarının farklı katmanlarına 2 boyutlu Haar dönüştürücü yerleştirilerek dalgacık temelli evrimsel sinir ağlarının kullanılması önerilmektedir. Önerilen yöntem iki temel evrimsel sinir ağı olan sunucu tarafını temsilen ResNet50 ve mobil uygulamalar için MobileNetV2 kullanılarak test edilmiştir. Eğitim ve test işlemi için Corsican ile Foggia ve Sharma yangın veri setleri birlikte kullanılarak çeşitli ve dengeli yeni bir veri seti hazırlanmıştır. Veri seti 2704 yangın ve 2737 yangın olmayan görüntü olmak üzere toplam 5441 görüntüden oluşmaktadır. Veri setinin %80'i eğitim işlemi için kullanılırken %20'si test işlemi için kullanılmıştır. Önerilen yöntem ile revize edilmiş ResNet50 %89 kesinlik değerine ulaşırken MobileNetV2 %85 kesinlik değerine ulaşmıştır [14].

Xin Zheng vd. tarafından yapılan çalışmada orman yangın dumanının tespit edilebilmesini sağlamak için EfficientDet, Faster R-CNN, YOLOv3, ve SSD evrimsel sinir ağları kullanılmıştır. Yapılan çalışmada 17,840 duman görüntüsünden oluşan veri seti hazırlanmıştır. Veri setini hazırlamak için akışkanlar dinamiğinin Navier-Stokes denklemine dayalı bir bilgisayar simülasyonu modeli kullanılmıştır. Bu sayede modellerin genelleme yapabildiğini

sağlayacak büyük miktarda veri içeren veri seti elde edilmiştir. Veri setinde yer alan 12,640 görüntü orman yangını dumanı görüntüsüdür. Geri kalan 5200 görüntü ise orman yangını olmayan duman görüntüsüdür. Veri setinin %70'i eğitim işlemi için kullanılırken %30'u test işlemi için kullanılmıştır. EfficientDet algoritması, değerlendirilmede kullanılan dört evrimsel sinir ağı algoritması arasında %95,7 ortalama doğruluk ile en yüksek doğruluk oranına ulaşmıştır [15].

Yangın ve duman tespiti ile ilgili yapılan çalışmaların özeti Tablo 1'de sunulmuştur.

Literatürdeki mevcut çalışmalarda mobil cihazlara yönelik derin öğrenme temelli çözümler üzerine yeterli çalışma bulunmamaktadır. Yangın ve duman tespitinin uç cihazlar üzerinde yapılabilmesi ve düşük güç tüketimi sayesinde mobil cihazlar için geliştirilen derin öğrenme modeli maliyet ve yaygın kullanım açısından önemlidir. Yangın ve duman tespiti için hafif evrimsel sinir ağı modelleri ve MobileNet algoritması revize edilerek kullanılmıştır. Yapılan çalışmada kullanılan evrimsel sinir ağları MobileNet, MobileNetV2, EfficientNetB0, ShuffleNet, NASNetMobile, PeleeNet ve revize edilmiş MobileNet algoritmasıdır. Yapılan çalışmalarda karşılaşılan en önemli problem ateş veya duman görüntülerinin başka nesnelere karıştırılmasıdır. Bu durumu engellemek için transfer öğrenme kullanılarak daha önceden ImageNet veri seti üzerinde eğitilmiş model kullanılmıştır. Bu sayede modelin nesnelere birbirinden daha iyi ayırt edilebilmesi sağlanabilmiştir. Seçilen modelleri eğitmek ve test etmek için 43,355 görüntüden oluşan veri seti kullanılmıştır. Veri setinin %80'i eğitim %20'si test işlemi için kullanılmıştır. Yapılan test sonuçlarına göre revize edilmiş MobileNet ağı %98,37 ile diğer modeller arasında en yüksek doğruluk oranına ulaşmıştır. 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.

**Tablo 1.** Yangın ve duman tespiti ile ilgili yapılan çalışmalar (Studies on fire and smoke detection)

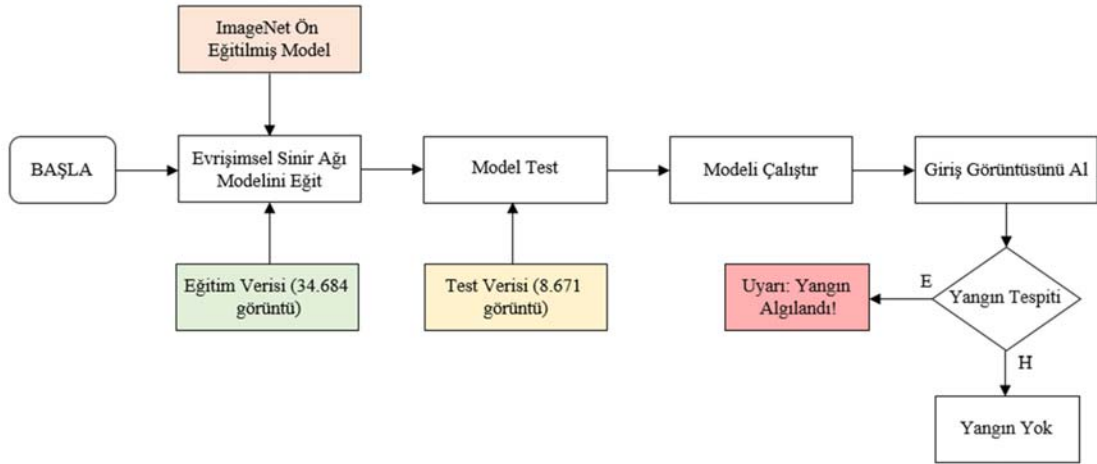
Çalışma	Teknik	Algoritma	Özellik	Veri Seti	Değerlendirme Metriği	Başarı Oranı
Pu Li vd. [8]	Derin öğrenme	Faster-RCNN, R-FCN, SSD ve Yolov3	Yangın ve Duman tespiti	29,180	Kesinlik	%87,3
Chenghua Li vd. [9]	Derin Öğrenme	Skor Kümelemeli Evrimsel Sinir Ağı, Gaussian Mixture Model	Duman Tespiti	17,316 duman ve dumsuz görüntü	Doğruluk	%97,17
Renjie Xu vd. [10]	Derin Öğrenme	EfficientDet ve Yolov5	Orman Yangını ve Duman Tespiti	10,581 görüntü içeren orman yangını veri seti	Algılama Hızı	%2,5 - %10,9 artırılmıştır
Lijun He vd. [11]	Derin Öğrenme	VGG-16, Dikkat Mekanizması	Duman Tespiti	560 dumanlı ve sisli dumanlı video	Doğruluk	%92,30
Khan Muhammad vd. [12]	Derin Öğrenme	GoogleNet	Yangın ve Duman Tespiti	31 yangın ve yangın olmayan video	Kesinlik	%94,43
Saima Majid vd. [13]	Derin Öğrenme	ResNet50, VGG16, GoogleNetV3, EfficientNetB0	Yangın ve Duman Tespiti	7977 yangın ve yangın olmayan görüntü	Doğruluk	%95,40
Lida Huang vd. [14]	Derin Öğrenme ve Haar Dönüştürücü	ResNet50 ve MobileNetv2	Yangın Tespiti	5441 yangın ve yangın olmayan görüntü	Kesinlik	%89 ve %85
Xin Zheng vd. [15]	Derin Öğrenme	EfficientDet Faster R-CNN YOLOv3 SSD	Duman Tespiti	17,840 orman yangını ve yangın olmayan duman görüntüsü	Doğruluk	%95,7

## 2. Materyal ve Metot (Material and Method)

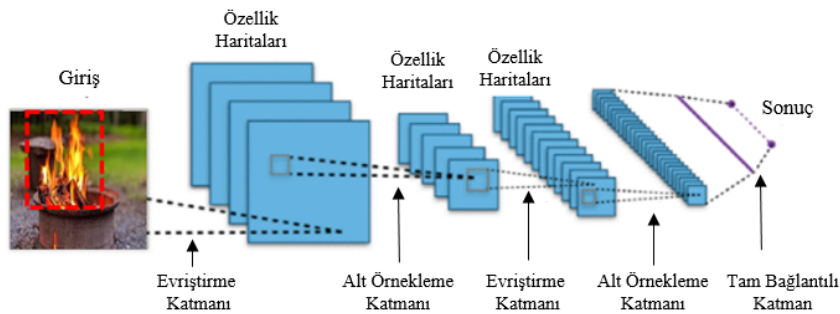
Görüntülerde yangın ve duman tespiti geleneksel yangın algılama teknolojilerinden kullanılabilirlik ve maliyet açısından daha avantajlıdır. Literatürde yapılan çalışmalarda yangın ve duman tespitinde klasik görüntü işleme teknikleri yerine daha yüksek doğruluk oranı sağlayan derin öğrenme algoritmaları kullanılmaktadır. Yangın ve duman tespitinin yüksek doğrulukta yapılabilmesinin yanında kaynakların verimli kullanılması gerekmektedir. Nesnelerin interneti milyarlarca cihazın birbirine bağlanması işlemlerin merkezi sunucular üzerinde yapılabilmesini giderek zorlaştıracaktır. Bunun için geliştirilecek yangın ve duman tespiti modeli mobil cihazlarda çalışabilmelidir. Bu nedenle yapılan çalışmada mobil cihazlarda maksimum performansta çalışabilecek hafif evrişimsel sinir ağı modelleri kullanılmıştır. Yapılan çalışmanın akış diyagramı Şekil 1'de görülmektedir. Şekil 1'de hafif yangın ve duman tespiti modelinin geliştirilmesi için yapılan çalışmalar görülmektedir. Öncelikle yangın ve duman tespiti modelinin geliştirilmesi için geniş kapsamlı veri seti hazırlanmıştır. Yangın ve duman tespiti modelini eğitmek için toplam 43,355 görüntüden oluşan veri seti kullanılmıştır. Veri setinde yer alan 34,684 görüntü eğitim ve 8,671 görüntü test işlemi için kullanılmıştır. Eğitim işlemi için MobileNet, MobileNetV2, EfficientNetB0, ShuffleNet, NASNetMobile, PeleeNet ve revize edilmiş MobileNet algoritmaları kullanılmıştır. 28 katmanlı orijinal MobileNet modelinden son 3 katman silinerek yerine ReLU aktivasyon fonksiyonuna sahip düzleştirme katmanı ve iki düğümden oluşan (yangın ve yangın değil) softmax aktivasyon fonksiyonuna sahip bir yoğun katman eklenmiştir. Yapılan değişiklik ile MobileNet algoritmasının parametre sayısı 4,253,864'den 3,230,914'e düşürülmüştür. Bu

sayede model daha uygun maliyetli olarak çalışarak gerçek zamanlı olarak yangın ve duman tespiti yapabilir. Bu sayede model gerçek zamanlı olarak yangın ve duman tespiti yapabilir. Yangın ve duman tespitinin yapılmasını sağlayan evrişimsel sinir ağı mimarisinin çalışması Şekil 2'de sunulmuştur.

Şekil 2'de görüldüğü gibi alınan görüntü evrişimsel sinir ağı katmanlarından geçirilerek özellik haritası çıkarılır. Evrişimsel sinir ağı çoklu dizilerden/matrislerden oluşan verileri işlemek için özel olarak tasarlanmış derin öğrenme algoritmasıdır. Evrişimsel siniri ağı evrişim işlemleri sayesinde normal sinir ağlarına göre hesaplama açısından daha verimlidir [16]. Evrişimsel sinir ağı evrişim katmanı, havuzlama katmanı, düzleştirme katmanı, bırakma katmanı ve tam bağlantılı katman olmak üzere 5 tür katman içerir. Bu beş katmana ek olarak aktivasyon fonksiyonu olarak adlandırılan önemli parametreye sahiptir [17]. Evrişim katmanı, girdi görüntüsünden özellik çıkaran ilk katmandır. Evrişim katmanı görüntünün özelliklerini algulamak için görüntüye evrişim filtresi uygular. Evrişim katmanı bir dizi ağırlıkları alır ve bu ağırlıkları sinir ağından gelen girdiler ile çarpar. Girdileri evrişim sürecinden geçirmek sinir ağını eğitmeyi zorlaştıran büyük miktarda veri üretilmesine neden olur. Bu nedenle verileri sıkıştırmak için girdi havuzlama katmanından geçirilir [18]. Havuzlama katmanının temel amacı hesaplama maliyetini azaltmak için kıvrımlı özellik haritasının boyutunu küçültmektir. Her bir özellik haritasının boyutu azaltılırken önemli bilgiler korunmaktadır. Özellik haritalarının boyutunu azaltmak için katmanlar arasındaki bağlantılar azaltılır ve her bir özellik haritasında bu işlem bağımsız olarak gerçekleşir. Havuzlama katmanı genellikle evrişim katmanı ve tam bağlantılı katman arasında köprü görevi görür [19]. Bırakma katmanı, evrişimsel sinir ağı



Şekil 1. Akış diyagramı (Flowchart)



Şekil 2. Evrişimsel sinir ağının çalışması (Working of convolutional neural network) [12]

ezberleme yapmasını engellemek amacıyla rastgele seçilen belirli nöron setlerinin eğitim aşaması sırasında dikkate alınmamasını sağlar. Bırakma katmanı kullanılmayan evrişimsel sinir ağlarında tüm ağırlıklar birlikte öğrenilmektedir. Bu durumda özelliklerin bir kısmı öğrenilirken diğer özellikler öğrenilmez ve ağ ezberlemeye başlar. Bırakma katmanı sayesinde ağıdaki tüm ağırlıklar yerine bazı ağırlıkların öğrenilmesi sağlanır [20]. Düzleştirme katmanı, verilerin son katmana girmek için bir boyutlu diziyeye dönüştürülmesini sağlar. Tek bir özellik vektörü oluşturmak için evrişimli katmanların çıktılarını düzleştirir. Tüm piksel verileri tek bir satıra koyularak son katmanla bağlantı kurulur [21]. Tam bağlantılı katman, nöronlarla birlikte ağırlıklar ve önyargılardan oluşur. Tam bağlantılı katman, nöronları iki farklı katman arasında bağlamak için kullanılır. Bu katmanlar genellikle çıktı katmanından önce yerleştirilir ve bir evrişimsel sinir ağı mimarisinin son katmanlarını oluşturur. Önceki katmanlarda düzleştirilen girdi görüntüsü tam bağlantılı katmana gelerek sınıflandırma işlemi gerçekleştirilir [22]. Aktivasyon fonksiyonu doğrusal bir işlem olan evrişim işleminden sonra özellik haritasına doğrusal olmama özelliği eklenmesini sağlar ve genellikle evrişim katmanından sonra yerleştirilir. Sigmoid, tanh ve ReLU yaygın kullanılan aktivasyon fonksiyonudur [23]. Model giriş görüntüsünü ilgili tüm evrişimsel sinir ağı katmanlarından geçtikten sonra özellik haritasına göre Yangın Tespit Edildi veya Yangın Yok olarak sınıflandırır.

### 2.1. Veri Seti (Dataset)

Modeli eğitmek için 43,355 görüntüden oluşan veri seti hazırlanmıştır. Mevcuttaki veri setleri Fire Detection Dataset [24], FIRESENSE [25] ve Fire Detection Image Dataset [26] kullanılarak yeni bir veri seti hazırlanmıştır. Veri seti yangın ve yangın olmayan görüntüler olmak üzere iki kategoride oluşturulmuştur. Veri setindeki görüntülerin %80'i eğitim ve değerlendirme işlemi için kullanılırken %20'si test işlemi için kullanılmıştır [27]. Sayısal olarak ifade edilirse veri setindeki 34,684 (16,773 yangın ve 17,911 yangın olmayan) görüntü eğitim için kullanılırken 8,671 (4,159 yangın ve 4,512 yangın olmayan) görüntü test için kullanılmıştır. Veri seti 2,1 GB dosya büyüklüğüne sahiptir.

### 2.2. Hiper Parametreler (Hyperparameters)

Evrişimsel sinir ağlarında evrişimli katman sayısı, katmanlarda kullanılan filtre sayısı, filtre boyutu, aralık ve dolgu değeri, tam bağlantılı katman sayısı ve her katmandaki nöron sayısı hiper parametreleri ağı başarısını doğrudan etkilemektedir. Evrişimsel sinir ağlarının performansında en etkili hiper parametreler; filtre sayısı, filtre boyutu, katman sayısı, seyreltme (dropout) oranı, öğrenme oranı ve yığın boyutudur. Seyreltme oranı nöron sayısı ile doğru orantılı olarak seçilmelidir. Çok fazla nöron sayısına sahip katmanlarda daha yüksek seyreltme değerleri seçilirken, düşük nöron sayısına sahip katmanlarda düşük seyreltme değerleri seçilmelidir. Evrişimsel sinir ağlarının derinliği arttıkça girdi boyutlarının küçültüldüğü ve özellik haritalarının artırıldığı görülmektedir [28]. Modelin eğitilmesi için Tablo 2'de yer alan hiper parametreler kullanılmıştır;

**Tablo 2.** Eğitimde kullanılan hiper parametreler (Hyperparameters used in training)

Hiper Parametre	Değer
devir (epoch)	9
devir için adım sayısı (steps_per_epoch)	32
öğrenme oranı (learning rate)	0,001
kayıp fonksiyonu (loss_function)	categorical_crossentropy
iyileştirici (optimizer)	Adam

Tablo 2'de yer alan değerlerde önerilen model maksimum başarı oranına ulaşmıştır. Devir değeri veri setinin kaç kez önerilen evrişimsel sinir ağında eğitildiğinin göstermektedir. Yapılan çalışmada veri seti 9 defa önerilen evrişimsel sinir ağında eğitildiğinde maksimum değere ulaşılmıştır. Yığın boyutu değerinin çok büyük seçilmesi (1024, 2048 vb.) sınıflandırma başarısını düşürürken çok küçük seçilmesi eğitim adımlarını yavaşlatmaktadır. Bu nedenle 32, 64, 128, 256 gibi orta değerler seçilmelidir [28]. Veri seti sayısı yüksek olduğu için devir için adım sayısı değeri 32 olarak ayarlanmış ve veri seti her bir adımda 32 parça halinde alınarak eğitilmiştir. Transfer öğrenme gibi adaptif yöntemler kullanılmadığı durumlarda öğrenme oranı için başlangıçta daha büyük değerler sonlara doğru küçük değerler seçilmektedir. Büyük öğrenme oranlarının seçilmesi eğitimi hızlandırırken, öğrenme oranının küçültülmesi sınıflandırma başarısını artırmaktadır [28]. Model eğitiminde öğrenilen ağırlıkların güncellenme oranı olan öğrenme oranı 0,001 olarak ayarlanmıştır. Modelin tahmini ile gerçek değer arasındaki kaybı hesaplayabilmek için kategorik çapraz entropi fonksiyonu kullanılmıştır. Kategorik çapraz entropi kayıp fonksiyonu büyük veri kümelerinin eğitim tahminlerindeki gürültülü verilerden kaynaklı hataları engellemede kendini kanıtlamıştır [29]. Belirlenen öğrenme oranının farklı parametrelere göre güncellenebilmesi için Adam optimizasyon algoritması kullanılmıştır. Adam optimizasyon algoritması hesaplama açısından verimli olması, düşük bellek gereksinimine ihtiyaç duyması ve veri seti büyük problemler için uygun olması nedeniyle tercih edilmiştir [30].

### 2.3. Evrişimsel Sinir Ağı Modelleri (Convolutional Neural Networks)

Hafif evrişimsel sinir ağı modelleri düşük işlem gücünde çalışabilir, mobil/gömülü cihazlarda çalışabilir ve düşük parametre sayısına sahiptir [31]. Yapılan çalışmada kendini hafif olarak tanımlayan, düşük işlem gücünde çalışabilen, düşük parametre sayısına sahip olan (10 milyondan daha az parametre) veya mobil ve gömülü cihazlara yönelik geliştirilen MobileNet, MobileNetV2, EfficientNetB0, ShuffleNet, NASNetMobile ve PeleeNet evrişimsel sinir ağı modelleri tercih edilmiştir. Modellerin seçilme nedenleri Tablo 3'de açıklanmıştır.

#### 2.3.1. MobileNet (MobileNet)

MobileNet, mobil ve gömülü görüntü tanıma uygulamaları için kullanılan verimli evrişimsel sinir ağı modelidir. MobileNet evrişimsel sinir ağı 28 katman ve 4,253,864 parametreden oluşmaktadır. MobileNet, derinlemesine ayrılabilir evrişimler kullanır. Bu sayede aynı derinliğe sahip düzenli evrişimlerden oluşan ağlar ile karşılaştırıldığında parametre sayısı önemli ölçüde azaltılmıştır. Derinlemesine ayrılabilir evrişim bir filtrenin derinliğinin ve uzamsal boyutunun ayrılabilmesini sağlamaktadır. Derinlemesine evrişim her bir giriş kanalına tek bir filtre uygular. MobileNet gecikme ve doğruluk arasında verimli bir şekilde değiş tokuş yapan iki basit global hiper parametre sunar. MobileNet ağı yapısı performansı artıran başka bir faktördür. MobileNet ağı genişlik ile çözünürlük ve gecikme ile doğruluk arasında değiş tokuş yapmak için ayarlanabilir. MobileNet, transfer öğrenmeyi çalıştırmak veya uygulamak için daha az hesaplama gücüne sahiptir [32]. MobileNet mimarisi Tablo 4'de sunulmuştur.

#### 2.3.2. MobileNetV2 (MobileNetV2)

MobileNetV2, mobil cihazlarda daha iyi performans göstermeyi amaçlayan evrişimsel sinir ağı mimarisidir. MobileNetV2 53 katman derinliğine sahiptir ve 3,4 milyon parametreden oluşan evrişimsel sinir ağıdır. MobileNetV2, artık bağlantıların darboğaz katmanları arasında olduğu bir yapıya dayanmaktadır. Yeni darboğaz katmanları MobileNet evrişimsel sinir ağına tanıtılan derinlemesine ayrılabilir

**Tablo 3.** Evrişimsel sinir ağı modellerinin seçilme nedeni (Reason for choosing convolutional neural network models)

Model	Seçilme Nedeni
MobileNet	Mobil ve gömülü cihazlara yönelik geliştirilmesi, 4,253,864 parametre sayısına sahip olması ve düşük hesaplama gücü gerektirmesi nedeniyle kullanılmıştır [32].
MobileNetV2	Mobil ve gömülü cihazlara yönelik geliştirilmesi, 3,4 milyon parametreden oluşması ve düşük hesaplama gücü gerektirmesi nedeniyle kullanılmıştır [33].
EfficientNet B0	MobileNetV2 mimarisini temel alması, 5,3 milyon parametreden oluşması ve düşük hesaplama gücü gerektirmesi nedeniyle kullanılmıştır [34].
ShuffleNet	Mobil ve gömülü cihazlara yönelik geliştirilmesi, 5,4 milyon parametreden oluşması, hafif ve verimli bir tasarıma sahip olması, düşük hesaplama gücü gerektirmesi nedeniyle kullanılmıştır [35].
NASNetMobile	Mobil ve gömülü cihazlara yönelik geliştirilmesi, 5,6 milyon parametreden oluşması ve düşük hesaplama gücü gerektirmesi nedeniyle kullanılmıştır [36].
PeleeNet	Mobil ve gömülü cihazlara yönelik olması, 2,8 milyon parametreden oluşması ve düşük hesaplama gücü gerektirmesi nedeniyle kullanılmıştır [37].

evrişimler üzerine kuruludur. MobileNetV2 ağı bu yeni darboğaz katmanı ve artık bağlantıların üzerine inşa edilmiştir. MobileNetV2 mimarisi 32 filtrelili evrişim ve 19 artık darboğaz katmanı içerir [33]. MobileNetV2 genel mimarisi ana hatlarıyla Tablo 5’de sunulmuştur.

**Tablo 4.** 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

**Tablo 5.** MobileNetV2 mimarisi (MobileNetV2 architecture) [33]

Giriş	Operatör	t	c	n	s
224 <sup>2</sup> x3	konv2d	-	32	1	2
112 <sup>2</sup> x32	darboğaz	1	16	1	1
112 <sup>2</sup> x16	darboğaz	6	24	2	2
56 <sup>2</sup> x24	darboğaz	6	32	3	2
28 <sup>2</sup> x32	darboğaz	6	64	4	2
14 <sup>2</sup> x64	darboğaz	6	96	3	1
14 <sup>2</sup> x96	darboğaz	6	160	3	2
7 <sup>2</sup> x160	darboğaz	6	320	1	1
7 <sup>2</sup> x320	konv2d 1x1	-	1280	1	1
7 <sup>2</sup> x1280	orthvz 7x7	-	-	1	-
1x1x1280	konv2d 1x1	-	k	-	-


### 2.3.3. EfficientNetB0 (EfficientNetB0)

EfficientNet, 2019 yılında yayımlanan makalede önerilmiştir ve model ölçeklendirme üzerine odaklanmaktadır. Bu kapsamda ağı

derinliğini, genişliğini ve çözünürlüğünü dikkatli bir şekilde dengelemenin daha iyi performans sağlayacağı sonucuna ulaşılmıştır. EfficientNet, ağı boyutlarını ölçeklendirmek için bileşik ölçekleme yöntemini kullanır. Bileşik ölçekleme yöntemi giriş görüntüsü daha büyükse ağı daha fazla katmana ve görüntü üzerinde daha detaylı desenler yakalamak için daha fazla kanala ihtiyaç olduğunu belirler. EfficientNetB0 5,3 milyon parametreden oluşmaktadır ve MobileNetV2 darboğaz artık bloklarını temel alır [34]. EfficientNetB0 mimarisi ana hatlarıyla Şekil 3’de sunulmuştur.

### 2.3.4. ShuffleNet (ShuffleNet)

ShuffleNet, mobil cihazlar için tasarlanmış hesaplama açısından son derece verimli evrişimsel sinir ağıdır. ShuffleNet 50 katman ve 5,4 milyon parametreden oluşmaktadır. ShuffleNet, doğruluğu korurken hesaplama maliyetini azaltmak için noktasal grup evrişimini ve kanal karıştırma yöntemini kullanır. Grup evrişimi ile her evrişimin ilgili giriş kanalı ile çalışması sağlanmaktadır. Bu sayede aynı anda birden fazla girdinin işlenebilmesi sağlanmaktadır. Kanal karıştırma özelliği ile özellik haritaları gruplara ayrılarak daha iyi organize edilir ve özellik haritaları arasında bilgi akışı olmasını sağlar. ShuffleNet grup evrişimi ve kanal karıştırma sayesinde daha verimli ve hafif bir tasarıma sahip olduğundan daha iyi performans göstermektedir [35]. ShuffleNet mimarisi ana hatlarıyla Tablo 6’da sunulmuştur.

**Şekil 3.** EfficientNetB0 mimarisi (EfficientNetB0 architecture) [34]

### 2.3.5. NASNetMobile (NASNetMobile)

NASNet, pekiştirmeli öğrenme yöntemini kullanarak en uygun evrimsel sinir ağı mimarisinin oluşturulmasını sağlar. NASNet ağına kullanılan pekiştirmeli öğrenmede her arama işlemi sonucu ödül aranan mimarinin eğitilen veri seti üzerinde elde edilen doğruluktur. Farklı veri setleri üzerinde genellikle iyi sonuçlar veren evrişim katmanları pekiştirmeli öğrenme sayesinde yoğun olarak kullanılabilir. NASNet ağına genel mimari tanımlanmış olsa da evrişimli hücreler belli değildir. NASNet ağına yer alan normal ve indirgeme hücrelerinin yapıları denetleyici tekrarlayan sinir ağları tarafından aranır. NASNet ağına yer alan evrişimli hücrelerin tekrar sayısı ve ilk evrişim filtrelerinin sayısı ayarlanabilir parametrelerdir. Ayarlanabilir parametreler ölçeklendirme için kullanılır. Evrişimli hücreler normal ve indirgeme hücresi olmak üzere iki türdür. Normal hücre aynı boyutta özellik haritası döndüren evrişimli hücrelerdir. İndirgeme hücresi özellik haritasının yükseklik ve genişliğinin iki kat azaltıldığı hücrelerdir. NASNet Mobile, NASNet ağına mobil ve gömülü cihazlar için revize edilerek parametre sayısının düşürülmüş halidir. Orijinal NASNet ağı 88,9 milyon parametreden oluşurken NASNet Mobile 12 hücre ve 5,6 milyon parametre içermektedir [36].

### 2.3.6. PeleeNet (PeleeNet)

PeleeNet, sınırlı işlem gücü ve bellek kaynağına sahip mobil cihazlara yönelik geliştirilmiş verimli çalışabilen evrimsel sinir ağı modelidir. DenseNet mimarisi temel alınarak geliştirilmiştir. PeleeNet 2,8 milyon parametreden oluşmaktadır. PeleeNet evrimsel sinir ağı MobileNet, ShuffleNet ve MobileNetV2'de kullanılan derinlemesine ayrılabılır evrişimler yerine geleneksel evrişimleri kullanmaktadır.

NVIDIA TX2 üzerinde yapılan testlerde MobileNet ve MobileNetV2'den daha yüksek hız ve doğruluk oranına ulaşmıştır. PeleeNet, tahmin için 19x19, 10x10, 5x5, 3x3 ve 1x1 ölçekli 5 özellik haritası kullanır. PeleeNet, özellik haritalarının tümünü sınıflandırma ve regresyon gerçekleştirmek için artık bloktan geçirir [37]. PeleeNet mimarisi Tablo 7'de sunulmuştur.

### 2.4. Tensorflow (Tensorflow)

Tensorflow, makine öğrenmesi ve yapay zeka işlemleri için ücretsiz ve açık kaynak yazılım kütüphanesidir. C++ programlama dili kullanılarak geliştirilmiştir. Tensorflow, Google tarafından geliştirilmiş ve 2015 yılında açık kaynak olarak yayınlanmıştır. Google, Eylül 2019'da Tensorflow 2.0 güncel sürümünü yayınlamıştır. Tensorflow Javascript, C++, Java ve Python programlama dillerini desteklemektedir. Tensorflow Linux, macOS, Windows, Android ve iOS işletim sistemlerini desteklemektedir. Tensorflow ile bir model dağıtılırken uygulamaya bağlı olarak Tensorflow Serving ve Tensorflow Lite kullanılmaktadır. Tensorflow Serving, modeli sunucular ve bulut üzerinde dağıtmak için kullanılmaktadır. Tensorflow Lite, modeli mobil veya gömülü cihazlar üzerinde dağıtırken kullanılmaktadır [38]. Tensorflow hesaplama ile ilgili işlemler tensorları kullanır. Tensor, veri türlerini temsil eden n boyutlu bir vektör/matristir. Vektör tek boyutlu bir tensorken matris iki boyutlu tensordur. Tensorflow'da tüm işlemler graflar içerisinde gerçekleşir. Graf, modeldeki işlemleri temsil eden düğüm ve art arda gerçekleşen bir hesaplama kümesidir. Graf içerisinde tüm hesaplamalar tensorların birbirine bağlanmasıyla yapılır [39]. Tensorflow merkezi işlem birimi (CPU), grafik işlem birimi (GPU) ve tensor işlem birimi (TPU) üzerinde çalışabilir. Tensorflow

**Tablo 6.** ShuffleNet mimarisi (ShuffleNet architecture) [35]

Katman	Çıkış Boyutu	K Boyut	Adım	Tekrar	Çıkış Kanalları (g : gruplar)				
					g=1	g=2	g=3	g=4	g=8
Görüntü	224x224				3	3	3	3	3
Konv1 Maksimum Havuzlama	112x112	3x3	2						
	56x56	3x3	2	1	24	24	24	24	24
Aşama 2	28x28		2	1	144	200	240	272	384
	28x28		1	3	144	200	240	272	384
Aşama 3	14x14		2	1	288	400	480	544	768
	14x14		1	7	288	400	480	544	768
Aşama 4	7x7		2	1	576	800	960	1088	1536
	7x7		1	3	576	800	960	1088	1536
Küresel Havuzlama	1x1	7x7							
Tam Bağlantılı Katman					1000	1000	1000	1000	1000
Karmaşıklık					143M	140M	137M	133M	137M

**Tablo 7.** PeleeNet mimarisi (PeleeNet architecture) [37]

Aşama	Blok	Katman	Çıktı Şekli
Giriş			224x224x3
Aşama 0	Kök Blok		56x56x32
Aşama 1	Yoğun Blok	Yoğun Katman x 3	
	Geçiş Katmanı	1x1 evrişim, adım 1	28x28x128
Aşama 2	Yoğun Blok	2x2 ortalama havuzlama, adım 2	
	Geçiş Katmanı	Yoğun Katman x 4	14x14x256
Aşama 3	Yoğun Blok	1x1 evrişim, adım 1	
	Geçiş Katmanı	2x2 ortalama havuzlama, adım 2	7x7x512
Aşama 4	Yoğun Blok	Yoğun Katman x 8	
	Geçiş Katmanı	1x1 evrişim, adım 1	7x7x704
Sınıflandırma Katmanı	Yoğun Blok	Yoğun Katman x 6	
	Geçiş Katmanı	1x1 evrişim, adım 1	1x1x704
		2x2 küresel ortalama havuzlama	
		100D tam bağlantılı katman, softmax	



kullanılarak yapılan çalışmaları görselleştirmek için Tensorboard uygulaması kullanılmaktadır [40]. Tensorflow kütüphanesi görüntü tanıma ve sınıflandırma problemlerinde daha iyi sonuçlar vermesinden ve literatürde yaygın olarak kullanılmasından dolayı yapılan çalışmada tercih edilmiştir.

### 2.5. Transfer Öğrenme (Transfer Learning)

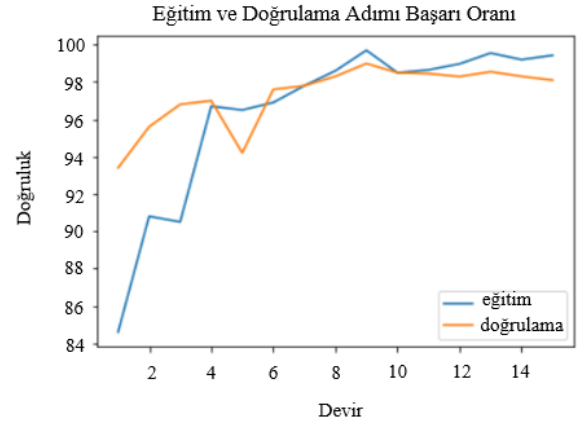
Transfer öğrenme önceden eğitilmiş model bilgisinin tekrar kullanılabilmesidir. Transfer öğrenme yeni modeller eğitebilmek için önceden eğitilmiş modellerin özelliklerinden ve ağırlıklarından yararlanır [41]. Özellikler modelin öğrenme sürecini kolaylaştırmak için veri setinden çıkarılan bilgilerdir. Ağırlıklar ise girdi verisinin çıktı verisini nasıl etkileyeceğini belirler. Transfer öğrenmenin çıkış sebeplerinden birisi çok sayıda etiketli eğitim verisi ile eğitilen modelin daha az veriye sahip bir görevde tekrar kullanılabilmesidir [42]. Transfer öğrenme ile model daha önceden eğitilmiş olduğundan daha az eğitim verisi ve hesaplama gücü ile daha güçlü modeller geliştirilebilir. Veri kümesi çok küçükse tüm ağ önceden eğitilmiş başlangıç ağırlıklarıyla yeniden eğitilir. Ön eğitilmiş modeller özellik mühendisliği ve eğitim süresini önemli ölçüde azaltır. Bunun yanında yeterli etiketli veri bulunmaması durumunda model öncelikle etiketli veriler üzerinden eğitilebilir ve etiketsiz veriler modelin tahminine göre etiketlenerek kullanılabilir. Transfer öğrenme görüntü tanıma, ses tanımanın ve doğal dil işleme alanlarında yaygın kullanıma sahiptir [44]. Yapılan çalışmada yangın ve duman tespiti modelini eğitmek için ImageNet 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 işlemi için 34,684 görüntü ve test işlemi için 8,671 görüntü kullanılmıştır. Transfer öğrenme yöntemi ile önceden ImageNet üzerinde eğitilmiş model üzerine geliştirme yapılmıştır. Mevcut çalışmalarda yangın tespiti için transfer öğrenme tekniği kullanılmadığı için farklı nesnelere ateş veya duman görüntüsüne benzetilmektedir. Bu nedenle geliştirilen modeller özellikle zorlayıcı görüntülerde yanlış tahminler yapmaktadır. Yangın ve duman tespitinde maksimum doğruluk oranına ulaşabilmek ve gerçek zamanlı tespit yapabilmek için MobileNet evrimsel sinir ağı revize edilmiştir. 28 katmanlı orijinal MobileNet modelinden son 3 katman silinerek yerine ReLU aktivasyon fonksiyonuna sahip düzleştirme katmanı ve iki düğümden oluşan (yangın ve yangın değil) softmax aktivasyon fonksiyonuna sahip bir yoğun katman eklenmiştir. Yapılan değişiklik ile MobileNet algoritmasının parametre sayısı

4,253,864'den 3,230,914'e düşürülmüştür. Aynı veri seti MobileNet, MobileNetV2, EfficientNetB0, ShuffleNet, NASNetMobile ve PeleeNet evrimsel sinir ağları ile eğitilerek başarı oranları elde edilmiştir. Eğitilen modelin test işlemi sonucu elde edilen performans metrikleri ve diğer algoritmalar ile karşılaştırılması Tablo 8'de yer almaktadır.

Tablo 8'de yapılan çalışma sonucu modellerin doğruluk, kesinlik, duyarlılık ve f1 skor performans metrikleri yer almaktadır. Doğruluk, modelin doğru tahminlerinin sayısının yapılan tüm tahmin sayısına oranıdır. Kesinlik, modellerin yangınları doğru tespit ettiği tahmin sayısının yanlış veya doğru olan tüm yangın tahmini sayısına olan oranıdır. Duyarlılık, modellerin yangınları doğru tespit ettiği tahmin sayısının yanlış veya doğru bilinen toplam yangın içeren test verisi sayısına oranıdır. F1 skor modelin doğruluğunu hesaplamak için kesinlik ve duyarlılığı hesaba katan performans metriğidir. Parametre sayısı eğitim sırasında öğrenilen ağırlıkların sayısıdır. Önerilen model doğruluk, kesinlik, duyarlılık ve f1 skor performans metriklerinde diğer algoritmalara göre daha az parametre ile daha iyi sonuçlar vermiştir. Önerilen modelin doğruluk-devir grafiği Şekil 4'de sunulmuştur.



Şekil 4. Önerilen modelin doğruluk-devir grafiği  
(The accuracy-epoch graph of the proposed model)

Şekil 4'de görüldüğü gibi önerilen model 9. devirde maksimum eğitim ve doğrulama başarı oranına ulaşmıştır. 14. devirden sonra modelin eğitim başarı oranı artarken doğrulamadaki başarı oranının düşmeye başladığı görülmüştür.

Önerilen modelin literatürdeki çalışmalarla karşılaştırılmasını sağlamak için 43,355 görüntüden oluşan ve yapılan çalışmada

Tablo 8. Yangın ve duman tespiti modelinin performans metrikleri (Performance metrics of the fire and smoke detection model)

Algoritma	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	F1 SKOR (%)	Parametre Sayısı
Önerilen Model	98,37	97,70	96,60	97,15	3,230,914
MobileNet	92,26	90,50	89,98	90,24	4,253,864
MobileNetV2	93,69	91,70	90,47	91,08	3,500,000
EfficientNetB0	96,30	93,80	93,20	93,50	5,300,000
ShuffleNet	95,40	95,32	94,50	94,91	5,200,000
NASNetMobile	87,22	86,47	87,10	86,78	5,600,000
PeleeNet	95,71	96,26	95,51	95,88	2,800,000

kullanılan aynı veri seti ile diğer çalışmalarda kullanılan modeller tekrar eğitilmiştir. Literatürdeki çalışmalarda mobil cihazlara yönelik kullanılan modeller varsa o modeller seçilirken yoksa en yüksek doğruluk oranına ulaşan model tercih edilmiştir. Literatürdeki çalışmalardan özelleştirilmiş modeller aynı veri seti ile tekrar eğitilemediği için karşılaştırmaya dahil edilmemiştir. Önerilen modelin literatürdeki çalışmalarıyla karşılaştırılması Tablo 9'da yer almaktadır.

Tablo 9'da görüldüğü gibi önerilen model mobil cihazlara yönelik geliştirilen EfficientNetB0 ve MobileNetv2 modelleri arasında %98,37 ile en yüksek doğruluk oranına ulaşmıştır. Veri seti üzerinde ise GoogleNet tüm modeller arasında %98,52 ile en yüksek doğruluk oranına ulaşmıştır.

Modellerin parametre sayıları ile doğruluk oranları arasındaki ilişki Şekil 5'de sunulmuştur.

Bir modelin performansını değerlendirmek için model karmaşıklığı, hesaplama karmaşıklığı, bellek kullanımı ve çıkarım süresi dikkate alınır. Önerilen modelde kullanılan MobileNet algoritması maksimum 630 MB bellek kullanımı, düşük karmaşıklığa sahip 17 MB model boyutuna, 2,4 milisaniye çıkarım süresine ve düşük parametre sayısı ile birlikte düşük hesaplama karmaşıklığına sahip olması sebebiyle

mobil cihazlar üzerinde anlık yangın ve duman tespiti yapabilir [41]. Geliştirilen model farklı hava koşulları ve ortamlarda tahmin yapabilmektedir. Önceki çalışmalarda yanlış tahmin yapılan görüntüler geliştirilen model üzerinde test edilmiştir. Bu görüntülerden ilki sisli hava koşullarında modelin yanlış tahmin yapmasıdır. Sis görüntüsünün model tarafından duman olarak algılanması yanlış tahminler yapılmasına neden olabilmektedir. Sisli havayı içeren görüntünün model üzerinde test edilmesi sonucu Şekil 6'da yer almaktadır.

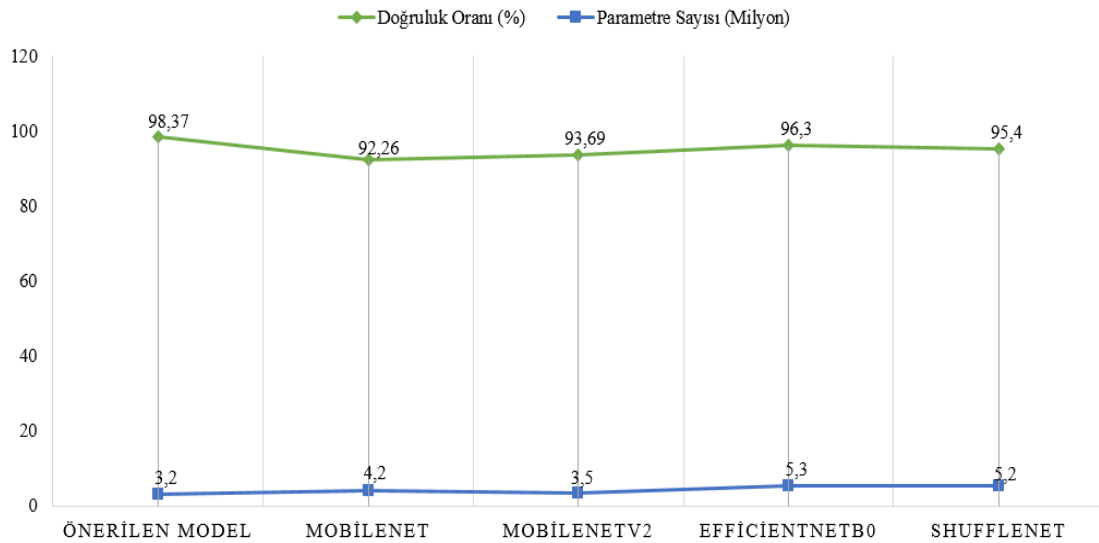
Şekil 6'da görüldüğü gibi model yoğun sisin yer aldığı görüntü için doğru tahmin yaparak yangın olmadığını tespit etmiştir.

Pu Li vd. tarafından yapılan çalışmada [8] modellerin yanlış tahmin yapmasına neden olan aleve benzeyen renklerin yoğun olarak bulunduğu görüntü geliştirilen model üzerinde test edilmiştir. Modelin ürettiği sonuç Şekil 7'de görülmektedir.

Şekil 7'de görüldüğü gibi yoğun ateş renginin bulunduğu görüntü için model tarafından doğru tahmin yapılarak yangın olmadığı tespit edilmiştir. Görüntülerden yangın tahmin çalışmalarında karşılaşılan bir diğer problem dumanın çok zayıf olarak belli olduğu görüntülerde yangın tespitidir. Modeli değerlendirmek için dumanın oldukça zayıf olduğu görüntüye model tarafından yapılan tahmin Şekil 8'de görülmektedir. Şekil 8'de görüldüğü gibi dumanın çok zayıf olduğu

**Tablo 9.** Önerilen modelin önceki çalışmalarla karşılaştırılması (Comparison of the proposed model with previous studies)

Çalışma	Teknik	Algoritma	Özellik	Değerlendirme Metriği	Başarı Oranı
Önerilen Model	Derin Öğrenme	Revize Edilmiş MobileNet	Mobil cihazlara yönelik geliştirilmiştir	Doğruluk	%98,37
Saima Majid vd. [13]	Derin Öğrenme	EfficientNetB0	Mobil cihazlara yönelik geliştirilmiştir	Doğruluk	%96,30
Lida Huang vd. [14]	Derin Öğrenme	MobileNetv2	Mobil cihazlara yönelik geliştirilmiştir	Doğruluk	%93,69
Pu Li vd. [8]	Derin öğrenme	Yolov3	Mobil cihazlara yönelik değildir	Kesinlik	%90,44
Khan Muhammad vd. [12]	Derin Öğrenme	GoogleNet	Mobil cihazlara yönelik değildir	Doğruluk	%98,52
Xin Zheng vd. [15]	Derin Öğrenme	EfficientDet	Mobil cihazlara yönelik değildir	Kesinlik	%97,02



**Şekil 5.** Doğruluk oranı ile parametre sayısı arasındaki ilişki (The relationship between the accuracy and the number of parameters)

görüntü için model tarafından doğru tahmin yapılarak yangın olduğu tespit edilmiştir. Yangın ve duman tespiti modelinin duman olmayan görüntülerdeki yangın tespiti Şekil 9'da görülmektedir.

Şekil 9'da görüldüğü gibi duman olmayan ateş görüntüsü için model tarafından doğru tahmin yapılarak yangın olduğu tespit edilmiştir.



Şekil 6. Sisli hava koşulunda model tarafından yapılan tahmin  
(Prediction made by the model in foggy weather)



Şekil 7. Yoğun ateş renginin bulunduğu görüntüde model tarafından yapılan tahmin  
(Prediction made by the model in the image with intense fire color)



Şekil 8. Dumanın çok zayıf olduğu görüntüde model tarafından yapılan tahmin  
(Prediction made by the model in the image which the smoke is very weak)



Şekil 9. Dumansız ateşlerden yangın tespiti  
(Fire detection from smokeless fires)

#### 4. Sonuçlar (Conclusions)

Yangın, insan ve çevreye önemli ölçüde zarar veren doğal afettir. Yangınların önceden tespit edilmesi tahribatı en aza indirmek için önemli bir konudur. Yangınların erken tespiti için binalarda ısı ve duman dedektörleri kullanılmaya başlanmıştır. Ancak bu dedektörler maliyetli ve geniş alanlarda kullanılabilir değildir. Bu nedenle görüntülerden yangın tespiti üzerine çalışmalar yapılmaya başlanmıştır. Görüntülerden yangın tespiti için yapılan çalışmalarda genellikle derin öğrenme algoritmaları kullanılmaktadır. Ancak mobil cihazlar veya düşük işlem gücüne sahip diğer cihazlara yönelik yeterli çalışma bulunmamaktadır. Bu nedenle yapılan çalışmada mobil cihazlar üzerinde çalışabilecek modeller geliştirilmiştir. Yangın ve duman tespiti için MobileNet evrişimsel sinir ağı revize edilmiş ve mobil cihazlar için geliştirilen diğer evrişimsel sinir ağları ile karşılaştırılmıştır. Orijinal MobileNet evrişimsel sinir ağından son 3 katman silinerek yerine düzleştirme katmanı ve iki düğümünden oluşan (yangın ve yangın değil) bir yoğun katman eklenmiştir. Yapılan değişiklik ile MobileNet algoritmasının parametre sayısı 4,253,864'den 3,230,914'e düşürülmüştür. Transfer öğrenme tekniği ile ImageNet üzerinde ön eğitilmiş model tekrar kullanılmıştır. Bu sayede diğer nesnelerin ateş ve duman görüntülerinden daha iyi bir şekilde ayırt edilebilmesi sağlanmıştır. Yapılan test sonuçlarına göre önerilen model %98,37 doğruluk oranına ulaşarak önceki çalışmalardan daha yüksek başarı oranı elde edilmiştir. Geliştirilen

model geniş alanlarda yangınların mobil cihaz üzerinde daha düşük güç tüketimi ve anlık olarak yapılabilmesini sağlamaktadır. Yapılan çalışmanın literatüre katkısı önceki çalışmalarda ulaşılan doğruluk oranının artırılması, üç farklı yangın veri setinin birlikte kullanılması, mobil ve gömülü cihazlara yönelik hafif yangın tespiti modelinin geliştirilmesidir. Önerilen model üç farklı yangın veri setinin birlikte kullanılması ve transfer öğrenme ile önceden eğitilmiş ağırlıkları kullanması sayesinde önceki çalışmalardan daha yüksek doğruluk oranına ulaşmıştır. Gelecekte modelin ortam koşullarına göre (sıcaklık, nem vb.) yangın başlamadan da tahminler yapılabilmesi sağlanarak özellikleri genişletilebilir. Ayrıca insansız hava aracı, uydu vb. uzaklığın fazla olduğu durumlar için uygun yangın ve duman tespiti modelinin geliştirilmesi sağlanabilir.

#### Kaynaklar (References)

- Brushlinsky N. N., Ahrens M., Sokolov S. V., Wagner P. (2021), World Fire Statistics, CTIF World Fire Statistics Center, <https://www.statista.com/statistics/1264713/area-burned-by-wildfire-in-turkey/>, Erişim tarihi Nisan 24, 2022.
- N. Sönnichsen, Land burned by wildfires in Turkey 2009-2021, <https://www.statista.com/statistics/1264713/area-burned-by-wildfire-in-turkey/>, Erişim tarihi Nisan 24, 2022.
- Bu F., Gharajeh M.S., Intelligent and vision-based fire detection systems: A survey, *Image and Vision Computing*, 91, 2019.
- Geetha S., Abhishek C.S., Akshayanat C.S., Machine Vision Based Fire Detection Techniques: A Survey, *Fire Technol*, 57, 591-623, 2021.
- Şafak E., Arslan Ç., Gözütok M., Köprülü T., Dağıtık Defter Teknolojileri ve Uygulama Alanları Üzerine Bir İnceleme, *Avrupa Bilim ve Teknoloji Dergisi*, 29, 36-45, 2021.
- Utku, A., Doğru, İ.A., Barışçı, N., Akıllı ve Geleneksel Giyilebilir Sağlık Cihazlarında Nesnelerin İnterneti, *Politeknik Dergisi*, (3), 695-714, 2019.
- Öcal, H., Doğru, İ.A., Barışçı, N., Akıllı ve Geleneksel Giyilebilir Sağlık Cihazlarında Nesnelerin İnterneti, *Politeknik Dergisi*, (3), 695-714, 2019.
- Li P., Zhao W., Image fire detection algorithms based on convolutional neural networks, *Case Studies in Thermal Engineering*, 19, 2020.
- Li C., Yang B., Ding H., Shi H., Jiang X., Sun J., Real-time video-based smoke detection with high accuracy and efficiency, *Fire Safety Journal*, 117, 2020.
- Xu R., Lin H., Lu K., Cao L., Liu Y., A Forest Fire Detection System Based on Ensemble Learning, 12 (2), 2021.
- He L., Gong X., Zhang S., Wang L., Li F., Efficient attention based deep fusion CNN for smoke detection in fog environment, *Neurocomputing*, 434, 224-238, 2021.
- Muhammad K., Ahmad J., Mehmood I., Rho S., Baik S.W., Convolutional Neural Networks Based Fire Detection in Surveillance Videos, *IEEE*, 6, 18174-18183, 2018.
- Majid S., Alenezi F., Masood S., Ahmad M., Gündüz E.S., Polat K., Attention based CNN model for fire detection and localization in real-world images, *Expert Systems with Applications*, 189, 2022.
- Huang L., Liu G., Wang Y., Yuan H., Chen T., Fire detection in video surveillances using convolutional neural networks and wavelet transform, *Engineering Applications of Artificial Intelligence*, 110, 2022.
- Zheng X., Chen F., Lou L., Cheng P., Huang Y., Real-Time Detection of Full-Scale Forest Fire Smoke Based on Deep Convolution Neural Network, *Remote Sensing*, 14 (3), 536, 2022.
- Şafak E., Barışçı N., Age and Gender Prediction Using Convolutional Neural Networks, 2018 2nd International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT), Ankara, 2018.
- Albawi S., Mohammed T. A., Al-Zawi S., Understanding of a convolutional neural network, *International Conference on Engineering and Technology (ICET)*, 2017.
- Ari 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.
- İnik, Ö., Ülker, E., Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri, *Gaziosmanpaşa Bilimsel Araştırma Dergisi (GBAD)*, 6 (3), 85-104, 2017.
- Cai S., Shu Y., Chen G., Ooi B.C., Wang W., Zhang M., Effective and Efficient Dropout for Deep Convolutional Neural Networks, *CoRR*, abs/1904.03392, 2020.
- Zhang X., Lin T., Xu J., Luo X., Ying Y., ADeepSpectra: An end-to-end deep learning approach for quantitative spectral analysis, *Analytica Chimica Acta*, 48-57, 2019.
- Krizhevsky A., Sutskever I., Hinton G., ImageNet classification with deep convolutional neural networks, *NIPS'2012*, 2012.
- Khan A., Sohail A., Zahoor U., Qureshi A.S., A survey of the recent architectures of deep convolutional neural networks, 53, 5455-5516, 2020.
- Fire Detection Dataset, <https://mivia.unisa.it/datasets/video-analysis-datasets/fire-detection-dataset/>, Erişim tarihi Aralık 20, 2021.
- FIRESENSE, <https://zenodo.org/record/836749#YcDXMWhBzIV>, Erişim tarihi Aralık 20, 2021.
- Fire-Detection-Image-Dataset, <https://github.com/cair/Fire-Detection-Image-Dataset>, Erişim tarihi Aralık 20, 2021.
- Rác, A., Bajusz, D., Héberger, K., Effect of Dataset Size and Train/Test Split Ratios in QSAR/QSPR Multiclass Classification, *Molecules*, 26 (4), 2021.
- Gülüçü A., Kuş Z., Konvölüsyonel Sinir Ağlarında Hiper-Parametre Optimizasyonu Yöntemlerinin İncelenmesi, *Gazi University Journal of Science Part C: Design and Technology*, 7 (2), 503-522, 2019.
- Zhang Z., Sabuncu M.R., Generalized Cross Entropy Loss for Training Deep Neural Networks with Noisy Labels, *CoRR*, abs/1805.07836v4, 2018.
- Kingma D.P., Ba J.L., Adam: A Method for Stochastic Optimization, *CoRR*, abs/1412.6980v9, 2017.
- Chen W., Gao L., Li X., Shen W., Lightweight convolutional neural network with knowledge distillation for cervical cells classification, *Biomedical Signal Processing and Control*, 71 (A), 103177, 2022.
- 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.
- Sandler M., Howard A., Zhu M., Zhmoginov A., Chen L.C., MobileNetV2: Inverted Residuals and Linear Bottlenecks, *CoRR*, abs/1801.04381, 2019.
- Tan M., Le Q.V., EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks, *CoRR*, abs/1905.11946, 2019.
- Zhang X., Zhou X., Lin M., Sun J., ShuffleNet: An Extremely Efficient Convolutional Neural Network for Mobile Devices, *CoRR*, abs/1707.01083, 2017.
- F. Saxen, P. Werner, S. Handrich, E. Othman, L. Dinges and A. Al-Hamadi, "Face Attribute Detection with MobileNetV2 and NasNet-Mobile," 2019 11th International Symposium on Image and Signal Processing and Analysis (ISPA), 176-180, 2019.
- Wang R. J., Li X., Ling C. X., Pelee: A Real-Time Object Detection System on Mobile Devices, *CoRR*, abs/1804.06882v3, 2018.
- Tensorflow. Tensorflow. <https://www.tensorflow.org/>, Erişim tarihi Aralık 20, 2021.
- Janardhanan P., Project repositories for machine learning with TensorFlow, *Procedia Computer Science*, 188-196, 2020.
- Şeker A., Diri B., Balık H.H., Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme, *Gazi Mühendislik Bilimleri Dergisi*, 3 (3), 47-64, 2017.
- 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.
- 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.
- Zhuang F., Qi Z., Duan K., Xi D., Zhu Y., Zhu H., Xiong H., He Q., A Comprehensive Survey on Transfer Learning, *IEEE*, 109 (1), 43-76, 2021.
- Fırlıdak K., Talu M.F., Evrişimsel Sinir Ağlarında Kullanılan Transfer Öğrenme Yaklaşımlarının İncelenmesi, *Journal of Computer Science*, 4 (2), 88-95, 2019.
- Bianco S., Cadene R., Celona L., Napoletano P., Benchmark Analysis of Representative Deep Neural Network Architectures, *CoRR*, abs/1810.00736v2, 2018.