

**(Araştırma Makalesi)****VGG16'da Araç Hasar Tespiti****Ayberk GEZER<sup>\*1</sup>, Muzaffer Tolga YILMAZ<sup>2</sup>, Durmuş ÖZDEMİR<sup>3</sup>**

<sup>1</sup>Kütahya Dumlupınar Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 43030, Kütahya, ORCID No : <https://orcid.org/0009-0000-8716-4697>

<sup>2</sup>Kütahya Dumlupınar Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 43030, Kütahya, ORCID No : <https://orcid.org/0009-0003-4735-1166>

<sup>3</sup>Kütahya Dumlupınar Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 43030, Kütahya, ORCID No : <https://orcid.org/0000-0002-9543-4076>

**Anahtar Kelimeler:**

Transfer Learning  
VGG16,  
CNN,  
Image Classification

**Özet:** Günümüzde oluşan trafik kazalarında hızlı bir şekilde hasar tespiti ve buna bağlı olarak hasar kayıtlarının tutulması gerekmektedir. Kazalarda oluşan trafik yoğunluğunu engellemek ve yolu hızlı bir şekilde trafiğe açmak için hasar tespit çalışmalarını hızlandırması önem arz etmektedir. Derin öğrenme teknolojileri hasarın büyüklüğünün hesaplanması, hasar durumunun gösterilmesi ve hasarın maddi boyutu hakkında çıkarımlar yapma konusunda çeşitli avantaj sağlamaktadır. Bu çalışmada sadece sigorta şirketlerinin ya da resmi kurumların sonuçları görmesi için değil, son kullanıcıya da hitap edecek ve oluşan kazaların hasar sınıfını ortaya çıkaracak bir karar destek sistemi amaçlanmıştır. Sunulan yazılım ile sadece kaza süreçlerinde değil, aynı zamanda araç alım-satımı yapılırken hızlı şekilde aracın maddi olarak değerinin belirlenmesinde objektif bir bakış açısı sunmayı amaçlar. Bu çalışmada, CNN alt modeli olan VGG16 tabanlı modelimizi kaggle platformu (5757 adet görüntü) üzerinden elde ettiğimiz veri seti üzerinde eğitim aşamasını geliştirilmiştir. VGG16 ile elde edilen araç nesne tespit oranımız %98, aracın hasarlı olup olmadığının doğruluk oranı %90, hasar oluşan bölgenin tespitini yaptığımız eğitimde elde edilen sonuçlar ise %70 ve son olarak hasarın seviyesini (düşük, orta ve yüksek) belirlediğimiz doğruluk oranı ise %66 olarak elde edilmiştir.

**(Research Article)****Car Damage Detection with VGG-16****Keywords:**

Transfer Learning  
VGG16,  
CNN,  
Image Classification

**Abstract:** In today's traffic accidents, assessing the damage and keeping damage records quickly is necessary. It is crucial to accelerate damage assessment studies to prevent traffic congestion caused by accidents and open the road to traffic quickly. Deep learning technologies provide various advantages in calculating the magnitude of the damage, displaying the damage situation, and making inferences about the material extent of the damage. In this study, a decision support system is aimed not only for insurance companies or official institutions to see the results but also for the end user and to reveal the damage class of the accidents. The software offered aims to provide an objective perspective not only in accident processes but also in quickly determining the financial value of the vehicle when buying and selling the vehicle. In this study, the training phase of our VGG16-based model, a CNN sub-model, was developed on the data set we obtained from the Kaggle platform (5757 images). With VGG16, our vehicle object detection rate is 98%, the accuracy rate of whether the vehicle is damaged is 90%, the results obtained in the training in which we detect the damaged area is 70%, and finally, the accuracy rate in determining the level of damage (low, medium and high) is 66% has been obtained.

## 1. GİRİŞ

Araç hasar tespit sistemleri gerek bireysel kullanım gerekse sigorta şirketleri gibi kurumsal alanlarda kullanımı oldukça önem arz etmektedir. Kaza durumlarında özellikle zaman ve pratiklik açısından önemli avantajlar sunmaktadır. Sigorta şirketleri eksper uzmanlarının raporları doğrultusunda hasar ödemeleri yapmaktadırlar. Ancak eksperin deneyimi ve mesleki tecrübesinin yetersiz olduğu durumlarda şirketi zarara uğratan durumlar söz konusu olabilmektedir. Çiğdem vd. önerdiği bulanık mantık ağ tabanlı modelleri ortaya çıkan kusur oranlarını eğittiğimiz model ile destekleyerek hasar tespit çalışmalarını hızlandırmayı ve dezenformasyon yaratılmasının önüne geçmesini amaçlamaktadır [1].

Geleneksel makine öğrenimleri eğitim verileri ve test verileri aynı özellik alanlarına sahiptir. Bir kez test verileri değişirse tahmin modelleri kullanılamaz ve yeniden oluşturulması gerekir. Bu sebeple yeniden eğitilmesi gerekir ve pratik değildir. Yeni eğitim verilerinin toplanması, hazırlanması gerekir ve uzun zaman almaktadır. Makine öğrenimi algoritmaları ve yarı denetimli algoritmalarından farklı olarak [2,3] farklı olan transfer öğrenimi eğitim verisi ile test verisinin farklı olabileceğini düşünmektedir [4]. Geleneksel makine öğrenimler toplanan veriler üzerinden matematiksel kullanarak tahminler yapar. Transfer öğrenimi eğitim verileri ve test verilerinin etki alanlarını kullanarak bir model oluşturur. Transfer öğrenimi bir insanın öğrenmesine benzer. Örnek olarak kiraz ile erik meyvelerini ayırt edebilen bir insan elma ve armut meyvelerini daha kolay ayırt etmeyi öğrenir. Transfer öğrenim bir alanda elde edilen bilgileri farklı bir görev ve alanda kullanmaktır. Örneğin bir nesne tanıma görevinde kullanılan model farklı bir nesne tanıma görevinde de kullanılabilir. Transfer öğrenim konsept ve becerilerin farklı alanlarda kullanılmasını sağlar. Böylelikle tekrar tekrar öğrenim yapılmasına gerek kalmaz ve kaynaktan tasarruf sağlar. Sınırlı veri sayısına sahip olunan durumlarda ise önceden öğrenilen bilgiler kullanılır. Bu süreç içinde model daha iyi bir başlangıç noktası elde eder. [5] Yani daha önceden öğrendiğimiz bir bilgiyi nasıl öğrendiğimizin yöntemini farklı bir şeyi ayırt etmekte kullanılır, öğrenme aktarımı yapar.

Transfer öğrenimin daha önceden eğitilmiş modellerin yeniden kullanılması ile daha az veri ile daha yüksek performans, daha az maliyet ve daha hızlı bir eğitim süreci sağlamaktadır. Bu sebeple transfer öğrenim maliyet ve verimlilik açısından geleneksel makine öğrenimi algoritmalarından daha yüksek bir performans sunar [6].

Araç hasar tespiti üzerine yapılan çalışmalar incelendiğinde yapay sinir ağlarının bu konuda yüksek performans verdiği gözlenmiştir [7-9]. Derin öğrenme modelleri de bu konuda nesne tespiti için kullanılmıştır [10-12].

Bunun bize yaratacağı fayda daha önceden kullandığımız modellerin özelliklerini ve ağırlıklarını başka görevler için kullanabiliriz. Yaptığımız çalışmada arabalardaki

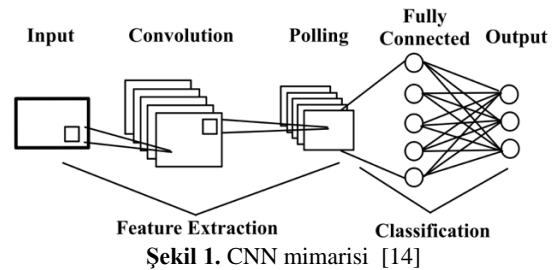
hasarları tespit etmek istedik. Bununla ilgili çeşitli çalışmalar mevcuttur. Bunlardan biri Vehicle Damage Detection segmentation algorithm based on improved mask RCNN [13] aracın hasarlarını Mask RCNN kullanarak segmentasyon maskeleye yapılmıştır. Bizim istediğimiz sadece hasar tespiti değil tespit edilen hasarın aracın hangi bölgesinde olduğu ve hasar seviyesinin belirlenmesidir. Projede evrişimli sinir ağlarından olan VGG16 modelini kullanarak bir hasar tespit mekanizması geliştirdik. Bu mekanizma hızlı sonuçlar çıkartması yanında bir standart getirerek maddi ve manevi kayıpları en aza düşürmeyi amaçlar.

## 2. MATERYAL VE METOT

Bu çalışma kapsamında model olarak VGG16 modelini seçilmiştir. Literatür incelendiğinde CNN modellerinde VGG16 modelinin daha başarılı sonuçlar sunması ve aynı zamanda görüntü tabanlı veri setleri üzerinde daha başarılı olması VGG16 modelinin tercih edilmesindeki temel sebepler arasındadır. Python programlama dili ve Tensorflow, Keras ve Hype5 kütüphaneleri kullanılmıştır. Geliştirme ortamı olarak Jupyter Notebook tercih edilmiştir. Tensorflow ve Keras kütüphanesi modelin eğitilmesi aşamalarında kullanılırken, eğitilen modelin kayıt edilmesi için ise Hype5 kütüphanesi kullanılmıştır.

### 2.1. CNN (Evrişimli Sinir Ağları)

Evrişimli sinir ağları (CNN'ler), bir görüntü gibi ızgara benzeri bir topolojiye sahip verileri işlemek için özel olarak tasarlanmış bir tür sinir ağı mimarisidir. Her biri, verilerdeki farklı desenleri veya özellikleri algılayabilen bir dizi filtreyi öğrenmekten sorumlu olan, birbirine bağlı birden çok katmandan oluşur. CNN mimarisinin iç yapısı Şekil 1'de sunulmuştur.



CNN modeli beş katmandan oluşur. Bu katmanlar aşağıda açıklanan gibidir:

Giriş katmanı: Giriş katmanı, bu durumda bir görüntü olan ham verileri alır ve bir sonraki katmana iletir.

Evrişimli katmanlar (Convolutional Layer): Bu katmanlar, görüntüdeki belirli desenleri veya özellikleri algılamak için kullanılan girdi verilerine bir dizi filtre uygular. Bu filtreler tipik olarak küçüktür ve birbirleriyle örtüşerek tüm görüntüyü kaplamalarına izin verir.

Havuzlama katmanları (Pooling Layer): Bu katmanlar, evrişim katmanının çıktısındaki bir grup bitişik pikselin maksimum veya ortalama değerini alarak verilerin

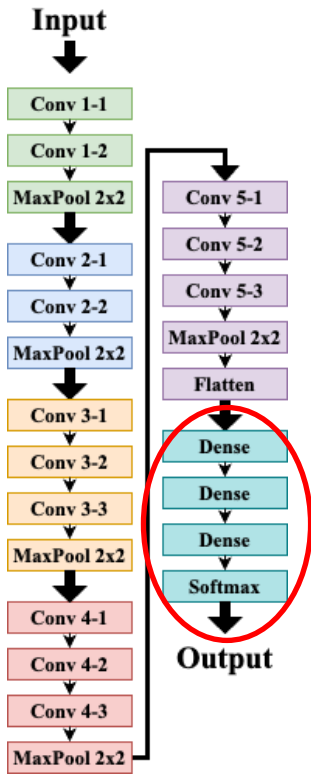
boyutunu azaltır. Bu, hesaplama yükünün azaltılmasına yardımcı olur ve ayrıca fazla uydurmanın önlenmesine yardımcı olur.

**Tamamen bağlı katmanlar (Fully Connected Layer):** Bu katmanlar, bir katmandaki her nöronu bir sonraki katmandaki her nörona bağlayarak yoğun, tamamen bağlı bir ağ oluşturur. Önceki katmanlar tarafından öğrenilen özelliklere dayalı tahminler yapmak için kullanılırlar.

**Çıktı katmanı (Output Layer):** Çıktı katmanı, girdi verilerine dayalı olarak nihai tahmini veya sınıflandırmayı üretir.

## 2.2. VGG-16 Modeli

VGG16, Oxford'daki Visual Geometry Group (VGG) tarafından geliştirilen bir evrişimli sinir ağı (CNN) mimarisidir. 2014 yılında Karen Simonyan ve Andrew Zisserman tarafından "Very Deep Convolutional Networks for Large-Scale Image Recognition" makalesinde tanıtıldı [15]. Önerilen VGG16 mimarisi Şekil 2'de sunulmuştur.



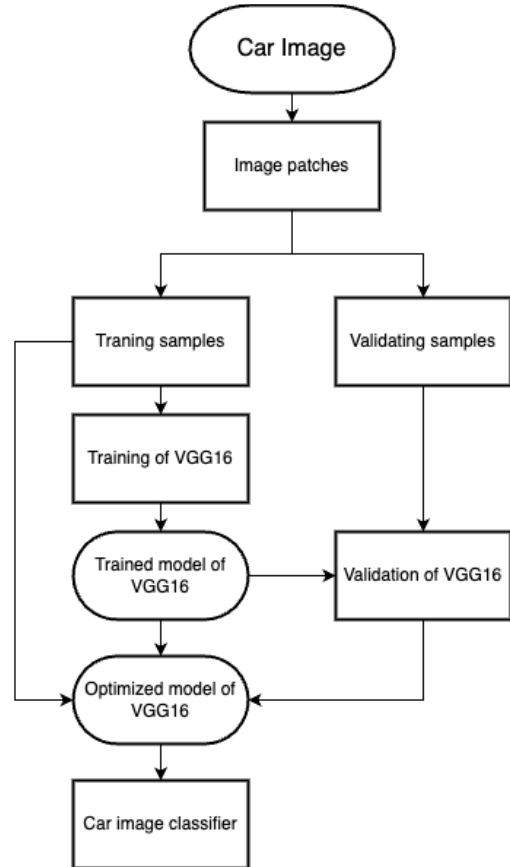
Şekil 2. Önerilen VGG16 mimarisi [16]

VGG16 modeli Şekil 2'de görüldüğü gibi 13 kıvrımlı katman ve 3 tam bağlantılı katman dahil olmak üzere 16 katmandan oluşur. Evrişimli katmanlar, giriş görüntülerinden öznelikleri çıkarmak için kullanılırken, tam bağlantılı katmanlar sınıflandırma için kullanılır. İlk blok 64 filtreye sahipken, kalan bloklar sırasıyla 128, 256, 512 ve 512 filtreye sahiptir. VGG16 mimarisinin en önemli özelliklerinden biri, evrişimli katmanlarda küçük 3x3 filtreler kullanmasıdır, bu da onun uzamsal bilgileri daha büyük filtrelerden daha etkili bir şekilde yakalamasına olanak tanır. Şekil 2'de kırmızı daire

içerisinde yer alan katmanlar modelin doğruluğunu arttırmak için kullanılmıştır. Bu katmanları eğiterek sonuçlarımızı daha iyi bir hale getirmeyi amaçladık. VGG16, 16 katman kullanan bir model olarak evrişimli sinir ağları içerisinde yüksek doğruluk oranı ve performansı sağlaması model seçiminde etkili olmuştur.

## 3. EĞİTİM VE BULGULAR

Çalışmamızda VGG16 modeli ile; araç nesne tespit oranı aracın hasarlı olup olmadığını belirlemesi, hasar oluşan bölgenin tespitini ve son olarak hasarın seviyesini (düşük, orta ve yüksek) belirlemek amaçlanmıştır. Önerilen VGG-16 eğitim akış şeması Şekil 3'de verilmiştir.



Şekil 3. Önerilen VGG-16 eğitim akış şeması

Bütün eğitimlerimizde Şekil 3'te olan akış şemasını takip ederek geliştirmesini yaptık. En son bütün eğitimleri tek bir yapıda topladık ve değerlendirme yapmasını sağladık. Bütün eğitimlerimizi ve çıkan sonuçlarını inceleyelim.

Ön işlem olarak görüntülerimizi sadece 224x224 formatında eğitime hazır hale getirilmiştir. Ardından PIL görüntü örnekleri Numpy dizisine dönüştürülmüştür, sonrasında bu dizinin şekli genişletilmiştir. Görüntüler RGB formatından BGR formatına dönüştürülüp, ardından her renk kanalını ölçeklendirme olmadan ImageNet veri kümesine göre sıfır olarak ortalanmıştır.

### 3.1. Araba mıdır?

İlk olarak görüntüde bir araç olup olmadığını kontrol etmek gerekir. Çünkü buradan doğru bir sonuç çıkmazsa

diğer aşamalara geçmek vakit kaybı ve sistemde yoğunluk verir. Araba mı? veri seti Tablo 1'de sunulmuştur.

**Tablo 1.** Araba mı? veri seti

Veri seti	Eğitim	Doğrulama
Araba	920	230

Tablo 1'de veri setinde yazdığı gibi ilk eğitimizde yukardaki sayılarda yazdığı gibi eğitimi tamamladık. Ve çıkan eğitim verimizi kaydettik. Burada alacağımız sonuç sadece araba olup olmadığı sorgusunu yapmaktadır.


### 3.2. Arabada hasar var mı?

Bu aşamada benzer şekilde bir hasarın olup olmadığını tespit ederek diğer aşamalara bundan çıkan sonuca göre devam etmesi için bu eğitimi yaptık. Arabada hasar var mı? veri seti Tablo 2'de, Arabada hasar var mı? doğruluk matrisi ise Şekil 4'te sunulmuştur.

**Tablo 2.** Arabada hasar var mı? veri seti

Veri seti	Eğitim	Doğrulama
Hasarlı	920	230
Hasarsız	920	230

Tablo 2'de veri setinde bulunan görüntü sayıları mevcuttur. Yaptığımız eğitim ve doğrulama çalışmasında %90 doğruluk payına ulaşılmıştır.



**Şekil 4.** Arabada hasar var mı? doğruluk matrisi

### 3.3. Hasar arabanın hangi bölgesindedir?


Artık daha ciddi bir sorgulama içerisindeyiz burada amacımız görüntüdeki hasar alan bölgenin arabanın hangi bölgesine sahip olduğunu tespit etmektir. Parametrelerimiz aracın ön tarafı, yan tarafı ve arka tarafını algılayabilecek şekilde eğitilmiştir. Hasar arabanın hangi bölgesindedir? veri seti Tablo 3'te, Hasar arabanın hangi bölgesindedir? ise Şekil 5'te verilmiştir.

**Tablo 3.** Hasar arabanın hangi bölgesindedir? veri seti

Veri seti	Eğitim	Doğrulama
Ön	418	73
Arka	287	50
Yan	271	48

Tablo 3'te veri setimizde eğitim ve doğrulama için kullandığımız görüntü adetleri görülmektedir. Yaptığımız

eğitim ve doğrulamadan sonra %70 doğruluk payına ulaşılmıştır.



**Şekil 5.** Hasar arabanın hangi bölgesindedir?


### 3.4. Hasarın seviyesi nedir?

Son eğitimimize geldik. Artık hasarın olduğunu ve nerede olduğunu öğrendik, son olarak hasarın kendi belirlediğimiz seviyesini ayırmak kaldı. Hasarın seviyesi nedir? veri seti Tablo 4'te, Hasarın seviyesi nedir? doğruluk matrisi ise Şekil 6'da sunulmuştur.

**Tablo 4.** Hasarın seviyesi nedir? veri seti

Veri seti	Eğitim	Doğrulama
Düşük	278	48
Orta	315	55
Yüksek	386	68

Tablo 4'te veri setinde bulunan araç görüntü sayıları yazmaktadır. Burada 3 dereceye ayırarak eğittik. Veri setinde hasarları sınıflandırırken hasarların maddi boyutunu baz aldık. Düşük seviye hasarda aracın kozmetik (boya hasarları, çatlak kırılma) ve plastik aksamlarında olan hasarları, orta seviye hasar durumunda araç üzerindeki tek bir bölgede yoğunlaşan ve aracın hasar gören bölgesinin şiddetli bir şekilde meydana gelen yapısal zararları ve son olarak yüksek seviye hasar durumunda ise aracın yürüyen aksamında veya hasarın birden fazla bölgede yüksek seviyede etkili olması durumunda verilecek çıktı olarak sınıflandırdık. Yaptığımız eğitim ve doğrulama çalışmasında %66 doğruluk payı elde edilmiştir.



**Şekil 6.** Hasarın seviyesi nedir? doğruluk matrisi

#### 4. SONUÇ

Tüm eğitim ve doğrulamalarımızı yaptık ve eğittiğimiz modelleri kayıt altına aldık. Veri setleri Tablo 5'te verilmiştir.

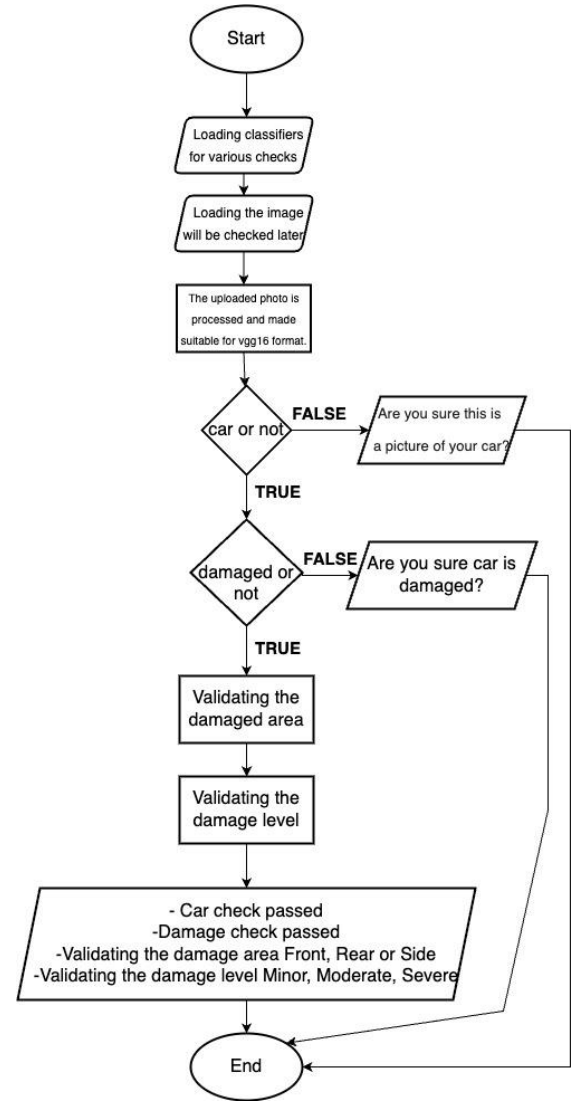
**Tablo 5.** Veri setleri

Veri seti	Eğitim	Doğrulama
Araba mıdır?	920	230
Arabada hasar var mı?	1840	460
Hasar arabanın hangi bölgesindedir?	976	171
Hasarın seviyesi nedir?	979	171

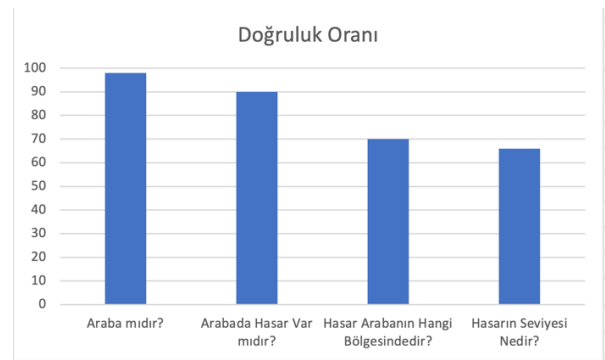
Toplam 5.757 görüntüden oluşan veri setimizi kullandık. İncelediğimiz farklı modeller kullanılarak yapılan diğer çalışmalarda kullanılan modellerin doğruluk oranlarının bizim modelimize yakın fakat daha düşük doğruluk oranları verdiğini gözlemledik. Ayrıca aynı modeli kullanan ama farklı veri setleri ve farklı sayıda veri seti kullanan çalışmalarda da doğruluk olarak öne çıkabildiğimizi gözlemledik. Bu gözlemlerimiz sayesinde kullandığımız modelin, veri setinin ve veri seti sayısının bize genel olarak doğru bir sonuç verdiğine ve yeterli olduğuna kanaat getirdik. Transfer öğrenimin nispeten daha düşük görüntü sayısına sahip bir veri setiyle de yüksek bir doğruluk oranına ulaşabileceğini gözlemledik. Şimdi bu modelleri tek tek sorgulayarak görüntüden bir sonuç alınmıştır. Sorgulama akış şeması Şekil 7'de verilmiştir.

Şekil 7'de gösterilen akış şemasına bağlı kalarak son eğitim dosyalarımızı yüklüyor ve sorgularımızı yaptık. Burada modellerimizi bu akış şemasından yola çıkan algoritma ile modellerimizi kullandık. Daha önceden bahsettiğimiz gibi bu çalışmayı 4 farklı soruya ayırmıştık. "Araç mı?" ve "Araçta hasar var mı?" sorularında araç tespiti ve hasar tespiti yaptığımız için tespit edilmemesi durumunda diğer modellerde sorgulama yapmayarak performans kaybını önledik. Kendi yaptığımız testlerde online alım-satım yapan web sayfalarından alınan hasarlı araçlarla, sokakta kendimiz çektiğimiz hasarlı çizik araç görüntülerini yüklediğimizde isabetli sonuçlar aldık. Zaten hasar tespit konusunda çok yüksek doğruluk değerine sahibiz. Spesifik alanlar hariç hasar bölgesi tespiti ve hasar seviyesi tespitinde de beklediğimizden daha tutarlı sonuçlar elde edilmiştir.

Yapılan 4 eğitimdeki doğruluk oranı Şekil 8'de verilmiştir.



**Şekil 7.** Sorgulama akış şeması



**Şekil 8.** Doğrululuk Oranı

Şekil 8'de görüldüğü gibi yaptığımız 4 eğitimde en düşük %66 doğruluk payını gördük. Bu da hasarın seviyesini tespit için yaptığımız eğitimdeydi. Hasarın bölgesini tespit etmekte %70, Arabada bir hasarın olup olmadığını ise %90 oranında doğruluk payı ile eğitimi tamamladık. Görüntüde olan araçlarda bir hasarın olup olmadığını yüksek bir seviyede doğru bir şekilde tespit edebiliyoruz. Örnek olarak aşağıdaki görüntüyü yüklediğimizde, ilk aşamada araba olup olmadığı sorgusu yapılarak, araba olduğunun sonucu elde edilmiştir. İkinci aşamada arabanın hasarlı olup olmadığı sorgusu yapılarak, hasarlı

olduğunun sonucu elde edilmiştir. Üçüncü aşamada arabanın hasarının hangi bölgesinde olduğunu sorgusu yapılarak, aracın hasarının ön bölgesinde olduğu sonucu elde edilmiştir. Dördüncü aşamada ise tespit edilen hasarın seviyesini saptamak için bir sorgu yapılarak, tespit edilen hasarın yüksek bir seviyede olduğu sonucu elde edilmiştir. Sonuç çıktısı Şekil 9'da verilmiştir.



```
Validating that this is a picture of your car...
1/1 [=====] - 0s 454ms/step
Car Check Passed!!!

Validating that damage exists...
1/1 [=====] - 0s 351ms/step
Validation complete - proceeding to location and severity determination

Validating the damage area - Front, Rear or Side
1/1 [=====] - 0s 419ms/step
Your Car is damaged at - Front Damage
Location assesment complete

Validating the Severity...
1/1 [=====] - 0s 389ms/step
Your Car damage impact is - Severe Damage
Severity assesment complete
```

Şekil 9. Sonuç çıktısı

Şekil 9'da görüldüğü gibi benzer görüntülerin yüklenmesi haline bize gelen sonuçlar çıktı olarak gösterilmektedir. Görüldüğü gibi hasarın aracın hangi bölgesinde olduğu ve öğretilen hasar derecesine göre çıktı vermektedir. Böylelikle hasarın maddi olarak hesaplanmasında ve kazalardaki hasar tespit çalışmalarının hızlanmasını sağlamaktadır. Bu modeller sigorta şirketlerinde kullanılarak eksper raporlarında ortaya çıkacak olan insan bazlı hataları minimum seviyeye indirmeyi ve belirli kurallar çerçevesinde bir standart getirmeyi amaçlar. Aynı zamanda modeller eş zamanlı hasar tespit sistemlerinde kullanılabilir, modelleri sabit trafik kameralarına entegre ederek olası bir kaza olması durumunda hızlı bir şekilde reaksiyon veren erken müdahale sistemleri yapılmasını sağlayabilir. Buna ek olarak trafiğin olmadığı durumlarda yapılan kazanın yolcular ve sürücünün yardım isteyememe durumunda yine hızlı bir şekilde reaksiyon verilip sürücü ve yolcuların can güvenliğinin en hızlı şekilde sağlanması amaçlanabilir. Bu sayede oluşan kazalarda trafiğin en az etkilenmesi ve her bir vatandaşımızın güvenli ve hızlı bir şekilde yardım alabilmesi amaçlanmaktadır.

## Etik Hususlar

### Etik kurallara uyum

Bu çalışmanın, özgün bir çalışma olduğunu; çalışmanın hazırlık, veri toplama, eğitim ve bilgilerin sunumu üzere tüm aşamalarından bilimsel etik ilke ve kurallara uygun davrandığımızı beyan ederiz.

### Çıkar çatışması

Yazarlar tarafından herhangi bir çıkar çatışması bildirilmemiştir.

## KAYNAKÇA

- [1] Çiğdem, A. C. I., Yılmaz, A. C. 2017. Maddi hasarlı trafik kazaları için sinirsel-bulanık ağ tabanlı bir kusur tespit modeli. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 29(2), 241-250.
- [2] Zhu, X. J. 2005. Semi-supervised learning literature survey.
- [3] Nigam, K., McCallum, A. K., Thrun, S., Mitchell, T. 2000. Text classification from labeled and unlabeled documents using EM. *Machine learning*, 39, 103-134.
- [4] Fung, G. P. C., Yu, J. X., Lu, H., Yu, P. S. 2005. Text classification without negative examples revisit. *IEEE transactions on Knowledge and Data Engineering*, 18(1), 6-20.
- [5] Torrey, L., Shavlik, J. 2010. Transfer learning. In *Handbook of research on machine learning applications and trends: algorithms, methods, and techniques*, IGI global, 242-264.
- [6] Weiss, K. R., Khoshgoftaar, T. M. 2016. An investigation of transfer learning and traditional machine learning algorithms. In *2016 IEEE 28th International Conference on Tools with Artificial Intelligence (ICTAI)*, IEEE, 283-290.
- [7] Kyu, P. M., Woraratpanya, K. 2020. Car damage detection and classification. In *Proceedings of the 11th international conference on advances in information technology*, 1-6.
- [8] Wang, X., Li, W., Wu, Z. 2023. Cardd: A new dataset for vision-based car damage detection. *IEEE Transactions on Intelligent Transportation Systems*.
- [9] Shirode, A., Rathod, T., Wanjari, P., Halbe, A. 2022. Car damage detection and assessment using CNN. In *2022 IEEE Delhi Section Conference (DELCON)*, IEEE, 1-5.
- [10] Kyu, P. M., Woraratpanya, K. 2020. Car damage detection and classification. In *Proceedings of the 11th international conference on advances in information technology*, 1-6.
- [11] Dhieb, N., Ghazzai, H., Besbes, H., Massoud, Y. 2019. A very deep transfer learning model for vehicle damage detection and localization. In *2019 31st international conference on microelectronics (ICM)*, IEEE, 158-161.
- [12] Dwivedi, M., Malik, H. S., Omkar, S. N., Monis, E. B., Khanna, B., Samal, S. R., vd. 2021. Deep learning-based car damage classification and detection. In *Advances in artificial intelligence and data engineering: Select proceedings of AIDE 2019*, Springer Singapore, 207-221.

- [13] Zhang, Q., Chang, X., Bian, S. B. 2020. Vehicle-damage-detection segmentation algorithm based on improved mask RCNN. *IEEE Access*, 8, 6997-7004.
- [14] Ozdemir, D., Kunduraci, M. S. 2022. Comparison of deep learning techniques for classification of the insects in order level with mobile software application. *IEEE Access*, 10, 35675-35684.
- [15] Simonyan, K., Zisserman, A. 2014. Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
- [16] Qassim, H., Verma, A., Feinzimer, D. 2018. Compressed residual-VGG16 CNN model for big data places image recognition. In *2018 IEEE 8th annual computing and communication workshop and conference (CCWC)*, IEEE, 169-175.