



T.C.
SELÇUK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



GÖRÜNTÜ İŞLEME YÖNTEMLERİ
KULLANARAK ARAÇ MARKA VE
MODELİNİN TESPİT EDİLMESİ

Mehmet Furkan KUNDURACI

YÜKSEK LİSANS

Bilişim Teknolojileri Mühendisliği Anabilim Dalı

Ağustos-2019
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Mehmet Furkan KUNDURACI tarafından hazırlanan ‘‘Görüntü İşleme Yöntemleri Kullanarak Araç Marka ve Modelinin Tespit Edilmesi’’ adlı tez çalışması 22/10/2019 tarihinde aşağıdaki jüri tarafından oy birliği ile Selçuk Üniversitesi Fen Bilimleri Enstitüsü Bilişim Teknolojileri Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

Başkan

Dr. Öğr. Üyesi Levent CİVCİK

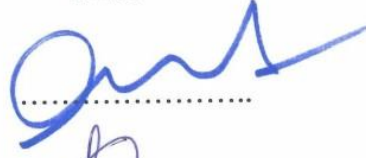
Danışman

Doç. Dr. Humar KAHRAMANLI ÖRNEK

Üye

Prof. Dr. Fatih BAŞÇİFTÇİ

İmza



Yukarıdaki sonucu onaylarım.


Prof. Dr. Mustafa YILMAZ
FBE Müdürü

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.



İmza

Mehmet Furkan KUNDURACI

Tarih:20.08.2019

ÖZET

YÜKSEK LİSANS TEZİ

GÖRÜNTÜ İŞLEME YÖNTEMLERİ KULLANARAK ARAÇ MARKA VE MODELİNİN TESPİT EDİLMESİ

Mehmet Furkan KUNDURACI

**Selçuk Üniversitesi Fen Bilimleri Enstitüsü
Bilişim Teknolojileri Mühendisliği Anabilim Dalı**

Danışman: Doç. Dr. Humar KAHRAMANLI ÖRNEK

2019, 51 Sayfa

Jüri

**Dr. Öğr. Üyesi Levent CİVCİK
Doç. Dr. Humar KAHRAMANLI ÖRNEK
Prof. Dr. Fatih BAŞÇİFTÇİ**

Görüntü işleme tabanlı uygulamalar son yıllarda yaygın bir biçimde pek çok alanda kullanılmaktadır. Sınıflandırma, sayım, ölçme, hedef takibi gibi görevleri yerine getiren pek çok uygulama geliştirilmiştir. Bu tez çalışmasının amacı, araçların marka ve modelinin tespitinde etkili ve düşük maliyetli bir yöntem kullanarak farklı uygulamalar için çözüm sunmaktır. Araçların marka ve modelinin tespitinde Faster-RCNN modeli kullanılarak yüksek doğrulukta bir algoritma ve sınıflandırma metodu önerilmiş ve gerçekleştirilmiştir.

Önerilen çözüm değişik açılardan çekilmiş ve farklı kaynaklardan edilen çeşitli resimler üzerinde test edilmiştir. Çalışmada marka tespitinde Faster-RCNN metodu kullanılmıştır. Marka tespitinde 20 marka 21 sınıf üzerinde çalışılmıştır. Çalışmada bu metod 10 sınıfta %90'ın üzerinde, 8 sınıfta %80 ile %90, 4 sınıfta ise %70-%80 arası doğru sonuç vermiştir. Genel başarıda bu metod %89,76 doğru sonuç vermiştir.

Çalışmada araç modelinin tespitinde Faster-RCNN metodu kullanılmıştır. Şekil temeli bir görüş benimsenmiştir. 20 markanın 51 modeli üzerinde çalışılmıştır. 51 modelin farklı açılardan çekilmiş 6160 resmi eğitim gerçekleştirilmiştir. 2639 resim üzerinde sınama yapılmıştır. Genel başarıda bu yöntem %69,72 oranda doğru sonuç vermiştir.

Anahtar Kelimeler: Araç marka tespiti, Araç model tespiti, Görüntü İşleme, Yapay Sinir Ağları, Faster RCNN

ABSTRACT

MS THESIS

**DETECTION VEHICLE BRAND AND MODEL USING IMAGE PROCESSING
METHODS**

Mehmet Furkan KUNDURACI

**THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCE OF SELÇUK
UNIVERSITY
THE DEGREE OF MASTER OF SCIENCE
IN INFORMATION TECHNOLOGY ENGINEERING**

Advisor: Assoc. Prof. Dr. Humar KAHRAMANLI ÖRNEK

2019, 51 Pages

Jury

Assist. Prof. Dr. Levent CİVCİK

Assoc. Prof. Dr. Humar KAHRAMANLI ÖRNEK

Prof. Dr. Fatih BAŞÇİFTÇİ

Image processing-based applications have been widely used in many areas in recent years. Many applications have been developed that perform tasks such as classification, counting, measuring and target tracking. The aim of this thesis is to provide solutions for different applications by using an effective and low cost method in determining the brand and model of vehicles. A high accuracy algorithm and classification method has been proposed and implemented by using Faster-RCNN model in determining brand and model of vehicles.

The proposed solution was taken from different angles and tested on various images from different sources. In the study, Faster-RCNN method was used for brand identification. In brand determination, 20 brands and 21 classes were studied. In this study, this method yielded over 90% accuracy in 10 classes, 80-90% in 8 classes, and 70-80% in 4 classes. In general success, this method gave 89.76% correct results.

In the study, Faster-RCNN method was used to detect the vehicle model. Shape-based vision was adopted. 51 models of 20 brands have been studied. 6160 training images of 51 models were taken from different angles. Tests were performed on 2639 images. In general success, this method yielded correct results at a rate of 69.72%.

Keywords: Vehicle Brand detection, vehicle model detection, Image Processing, Artificial neural networks, Faster RCNN

ÖNSÖZ

Yüksek lisans sürecinde bana destek olan hocalarımdan Dr. Nevzat ÖRNEK'e, Danışmanım Doç. Dr. Humar KAHRAMANLI ÖRNEK'e teşekkür ederim. Bunun yanı sıra bu süreçte bana destek olan arkadaşlarıma, aileme, ikizime, kardeşlerime ve eşime sonsuz teşekkürlerimi iletmek isterim.

Mehmet Furkan KUNDURACI
KONYA-2019



İÇİNDEKİLER

ÖZET	v
ABSTRACT	vi
ÖNSÖZ	vii
İÇİNDEKİLER	viii
SİMGELER VE KISALTMALAR	ix
1. GİRİŞ	1
2. KAYNAK ARAŞTIRMASI	4
3. MATERYAL VE METOT	12
3.1 Metot.....	12
3.1.1 Tensorflow	12
3.1.2 OpenCV.....	12
3.1.3 Python.....	13
3.1.4 Faster-RCNN yapay sinir ağıları algoritması	14
3.2 Materyal.....	15
3.2.1 Markaların belirlenmesi	15
3.2.2 Araç modellerinin belirlenmesi	19
4. UYGULAMA	24
4.1 Marka Tespiti.....	24
4.1.1 Ön işlem aşaması.....	25
4.1.2 Uygulama aşaması.....	27
4.2 Model Tespiti.....	29
4.2.1 Ön işlem aşaması.....	30
4.2.2 Uygulama aşaması.....	32
5. SONUÇ VE TARTIŞMA	35
5.1 Değerlendirme	48
6. ÖZGEÇMİŞ	52

SİMGELER VE KISALTMALAR

AI	: Artificial Intelligence
API	: Application Programming Interface
BoF	: Bag of Features
BSD	: Berkeley Software Distribution
CCD	: Charge Coupled Device
CIE	: International Commission on Illumination
CNN	: Convolution Neural Network
CPU	: Central Processing Unit
EDS	: Elektronik Denetleme Sistemi
Fast RCNN	: Fast Region Convolution Neural Network
Faster RCNN	: Faster Region Convolution Neural Network
GB	: Gigabyte
Ghz	: Gigaheartz
GNU	: GNU's Not Unix
GPU	: Graphical Processing Unit
HOG	: Histograms of oriented gradient
HSV	: Hue, Saturation, Value
İHA	: İnsansız Hava Aracı
KB	: Kilobyte
LNPR	: License and Plate Recognition
LLC	: Local-constraint Linear Coding
LPR	: License Plate Recognition
MB	: Megabyte
MMR	: Araç marka ve model tanıma
M-SIFT	: Modified Scale Invariant Feature Transform
Ms	: Milisaniye
OCR	: Optical Character Recognition
OpenCV	: Open Source Computer Vision
RFID	: Radio frequency identification
RoI	: Reigon of Interest (İlgi Alanı)
RPN	: Region Proposal Network
SIFT	: Scale Invariant Feature Transform
SMG	: Square Mapped Gradient
SPM	: Spatial Pyramid Matching
SVM	: Support Vector Machine
TEDES	: Trafik Elektronik Denetleme Sistemi
TSU	: Tensor Processing Unit
XML	: Extensible Markup Language

1. GİRİŞ

Günümüzde elektronik ve bilişim teknolojileri pek çok alanda hayatı kolaylaştırmak için kullanılmaktadır. Bilgisayar ve elektronik teknolojisi de günümüzde birçok alana hizmet vermekte, birçok problem için çözüm bulmaya çalışmaktadır. Nitekim bu problemlerden biri de trafik güvenliğidir. Trafikteki araçların plakalarının kontrolü, trafiğin seyri, araçların takip edilmesi ve benzeri birçok işlem kameralar vasıtasıyla bilgisayarlar tarafından yapılmaktadır. Tabii ki bu kameraların kontrolü ve kameralardan alınan görüntülerden bilgi çıkarımı için görüntü işleme yöntemlerinden faydalanılmaktadır.

Trafik Kontrolünde ihtiyaç duyulan işlevlerden biri de araçların marka ve modellerinin tespit edilmesidir. Bu kontrolün birçok nedeni bulunmaktadır.

Bu nedenlerden biri trafiğin güvenliğidir. Kamyon ve Tır gibi ağır vasıtaların bazı yolları kullanmaları yasaktır. Ve şehir içinde bazı bölgelere girmeleri yasaktır. Marka, model ve araç tipi tespit edilen araçların ihlalleri tespit edilebilir.

Bir diğer neden ise araçların doğruluğudur. Yani aracın plakadaki marka ve modeli ile gerçekte olan marka ve modeli uyuşmayabilir. Buna benzer olarak daha sık karşılaşılabilecek olanı ise aracın gerçekteki rengi ile aracın plaka bilgilerine kayıtlı rengi arasında uyumsuzluk olabilmektedir. Özellikle çalıntı araçlarda veya illegal durumlarda bu gibi olaylarla daha sık karşılaşılmaktadır.

Aracın markasının ve modelinin tespit edilmesi özel sektörde de kullanılabilir. İlan sitelerinin, araç ilanlarında kullanıcı hatasının en aza indirgenmesi amacıyla aracın modelinin resim üzerinden otomatik tespiti ve sınıflandırması yapılabilir. Bu sayede ilanların doğru kategorilerde olması sağlanabilir. Bununla birlikte araç bakımı yapılan işletmelerde araç tanımlanması için kullanılabilir.

Akıllı şehirler ve trafik güvenliği kapsamında geliştirilen projeler araçların markasının ve modelinin tespit edilmesini de amaçlamaktadır. Hali hazırda birçok otomobil firması otonom araç geliştirmesi yapmaktadır. Geliştirilen bu araçların sınamaları da gerçekleşmektedir. Bu araçların gündelik hayatta kullanılmasıyla birlikte bir takım sorunların ortaya çıkması muhtemeldir. Bu araçların trafik güvenliğini tehdit etmeyecek şekilde hareket etmesi, en ufak aksaklıklarının kameralar vasıtasıyla denetlenmesi, araç marka ve modellerinin tespitinin yapılarak ilgili firmalara rapor edilmesi gerekmektedir. Bu sebeple marka ve modelin tespiti akıllı şehirler için de kullanılması gereken bir özelliktir.

Trafiğin denetlenmesini sağlayan emniyet müdürlüğünün kullandığı EDS ve TEDES gibi sistemlerde aracın plakasının tespitinin yanı sıra aracın doğrulanması açısından aracın markasının, modelinin ve renginin de tespit edilmesi gerekmektedir. Kural ihlallerinde aracın plakasının yanlış okunması durumunda bile bu bilgiler aracın doğruluğunu teyit etmede yardımcı olabilmektedir. Bu sayede yanlış araca ceza yazılmasının önüne geçilebilir.

Daha birçok neden veya sorun kurum ve kuruluşların istek ve ihtiyaçlarına göre artış ve değişkenlik gösterebilmektedir. Bu gibi sorunların daha aza indirilmesi için bu çalışmada görüntü işleme yöntemleri ile araçların marka ve modelleri tespit edilmeye çalışılmıştır.

Bilgisayar için görüntüler sadece sayısal bilgilerden oluştuğundan araçların üzerinde bulunan marka logoları klasik görüntü işleme yöntemleriyle tespit etmek hayli zordur.

Çalışmada markanın şu şekilde tespit edilmesi amaçlanmıştır;

Aracın marka logosunun bulunduğu resimler toplanıp bu resimler üzerinde marka logosunun bulunduğu bölgeler, marka isimlerine göre etiketlenecek, etiketlenen resimler yapay sinir ağıyla eğitildikten sonra, geliştirilen model resimler üzerinde sınanacaktır. Tanıma işlemi aracın tamamı üzerinden yapılacaktır. Plaka bölgesi veya ilgi alanı bölgesi gibi kesit alınarak ön işlem yapılmayacaktır.

Araç markası tespit edilirken bazı zorluklar vardır. Doğrudan resmin tamamı üzerinde tespit yapılacağından resim üzerinde birçok şekil tespit edilmek istenen araç logosuna benzetilebilir.

Öte yandan resimler üzerinde yer alan araçların üzerinde bulunan marka logoları farklı renklerde ya da ışığın yansımalarından dolayı bazı bölümleri açık bazı bölümleri koyu olabilir. Bu sebeple bütün bu durumlarda da aracın markası doğru tespit edilebilmelidir. Bununla birlikte marka logosu farklı renkte ve dokularda zeminlerin üzerinde bulunsalar bile yine doğru şekilde tespit edilmelidir.

Bu çalışmada aracın logosunun gözüktüğü resimler hangi açıdan ve hangi koşulda çekilmiş olursa olsun aracın markasının doğru şekilde tespit edilmesi amaçlanmaktadır.

Çalışmada araç modellerinin tespitinin şu şekilde yapılması amaçlanmıştır;

Belirlenen araç modellerine ait resimler toplanıp aracın bulunduğu bölgeler araç model ismine göre etiketlenecektir. Etiketleme işlemi aracın gelen tamamı seçilerek yapılacaktır. Aracın belli bir özelliğine odaklanılmayacaktır. Etiketlenen resimler yapay sinir ağıyla eğitildikten sonra, geliştirilen model resimler üzerinde sınanacaktır. Tanıma işlemi aracın tamamı üzerinden yapılacaktır. Plaka bölgesi veya ilgi alanı bölgesi gibi kesit alınarak ön işlem yapılmayacaktır.

Araç modeli tespit edilirken birçok zorluk vardır. Marka tespitinde odaklanılan kısım sadece marka logosu olduğundan model tespitine göre daha az özellik aranacaktır. Model tespitinde ise aracın farklı açıdan çekilmiş fotoğrafları üzerinden tespit yapılmaya çalışılacaktır. Bu da aracın marka logosundaki gibi basma kalıp görüntüden çok aracın dış görünüşünün eğitilmesi demektir. Bu görüntüde aracın farı, genişliği, yüksekliği, uzunluğu, stop lambaları, radyatör ızgarası gibi daha birçok özelliği de bu tespitte girmektedir. Görüntülerin sayısal değerlerden oluştuğu düşünülürse bu işlem çok daha karmaşık hale gelmeye başlayacaktır.

Bununla birlikte aynı marka ve model araçların farklı renklerinde de model doğru şekilde tespit edilmelidir. Aracın bulunduğu arka plan, koşul ne olursa olsun yine aracın modeli doğru şekilde tespit edilmelidir.

Bu çalışmada aracın hangi açıdan çekilmiş görüntüsü olursa olsun modelini doğru şekilde tespit etmek amaçlanmaktadır.

Bu çalışmada araçların markalarını ve modellerini tespit eden bir algoritma geliştirilmeye çalışılmıştır. Yapay sinir ağları metodlarından Faster-RCNN metodu benimsenerek model eğitimi yapılmıştır. Yazılımda bu eğitim modeli kullanılmıştır.

2. KAYNAK ARAŞTIRMASI

Özbay (2006) çalışmasında otomatik araç tespitinde bir algoritma önermiştir. Çalışmada önerilen algoritma üç temel bölümden oluşmaktadır; Plaka bölgesinin çıkartılması, plaka karakterlerinin ayrıştırılması ve plaka karakterlerinin tanınması bölümleridir. Plaka bölgesinin çıkartılmasında kenar belirleme ve lekeleme algoritmaları, Ayrıştırma bölümünde; lekeleme, filtreleme ve bazı morfolojik algoritmalar ve Plaka karakterinin tanınmasında; şablon temelli eşleştirme algoritmaları kullanılmıştır. Algoritma için gerekli kodlar matematik temelli bir yazılım üzerinde yapılmıştır. Sistemde kullanılan görüntüler farklı bölgelerde, değişik zaman periyotlarında ve farklı aydınlatma bölgelerinde çekilmiş ve sistem test edilmiştir. Sistemin genel başarı oranı ise %92.57'dir.

Eski (2008) çalışmasında araç tanıma işlemini araç görüntüleri üzerinden belirli bir kesit alarak yapmıştır. Bu kesite ilgi alanı bölgesi(*RoI*) denmektedir. İlgi alanının konumunu ve büyüklüğünü plaka bölgesine göre belirlemiştir. Plaka bölgesinin tespitini ise özel bir şirketin yazılımı ile gerçekleştirmiştir. Araç sınıflarının özniteliklerinin belirlenmesinde; *Square Mapped Gradient*(SMG), SIFT, *Modified SIFT*(M-SIFT) olmak üzere 3 yöntem kullanmıştır ve bu üç yöntemin karşılaştırmasını yapmıştır. Yaptığı karşılaştırmalar sonucunda SIFT yönteminin gerçek zamanlı uygulamalar için yavaş ve ayrıcılığının az olduğunu, SMG yönteminin %89 marka, %94 tür; M-SIFT yönteminin ise %93 üzerinde marka ve %96 üzerinde tür tanıma başarısı elde etmiştir. Eski çalışmasında yaygın olarak kullanılan markalara yer vermiş, çalışması araç modellerini kapsamamıştır.

Bingöl ve Kuşçu (2008) çalışmalarında araç plaka tanıma sistemi gerçekleştirmişlerdir. Tasarlanan plaka tanıma sistemi üç önemli aşamadan oluşmaktadır. Bunlar: plaka bölgesinin bulunması işlemi, karakter ayrıştırma işlemi ve karakter tanıma işlemidir. Plaka bölgesinin bulunması işlemi için kenar bulma algoritmaları, karakter ayrıştırma işlemi için blob coloring algoritması, karakter tanıma işlemi için ise şablon eşleştirme algoritması kullanılmıştır. Sistem 100 ayrı araç resmi işlenerek test edilmiştir.

Placzek, çalışmasında (Placzek, 2011) vizyon temelli araçların tanınması konusunda bir yöntem önermektedir. Önerilen yöntem, görüntü verilerinde kayıtlı araçların otomatik tanınması için görüntü bölümlerinin bulanık tanımını kullanır. Tanım, referans görüntünün bölümleri (araç modeli) için belirlenen seçilmiş geometrik özellikleri ve şekil katsayılarını dikkate alır. Önerilen yöntem bulanık kurallara sahip muhakeme sistemi kullanılarak uygulanmıştır. Bir aracın görünür kısımlarına karşılık gelen görüntü bölümlerinin şeklini ve

düzenini açıklayan bulanık kurallara dayanarak bir araç tanıma algoritması geliştirilmiştir. Algoritmanın, farklı referans görüntüleri (ve çeşitli araç şekilleri) için tanımlanan bulanık kurallar kümesiyle uzatılması, trafik sahnelerinde araçların sınıflandırılmasını sağlar. Geliştirilen yöntem, yol trafik kontrolü ve gözetim sistemleri için video sensörlerinde uygulama için uygundur.

Çevik ve Çakır (2011) çalışmalarında bir giriş kapısına gelen aracın plakasını kamera görüntüsü alınarak görüntü işleme algoritmaları kullanarak tespit etmişlerdir. Yazılım tarafından okunan plaka; veri tabanından kontrol edilmekte ve plaka veri tabanında kayıtlı ise kapı açılmakta, kayıtlı değilse uyarı verilmektedir. Çalışmada plakadaki karakterleri ayırmak için Blob Coloring (İkili Renklendirme) algoritması kullanılmıştır. Geliştirilen yazılım ile plakaların yerinin bulunmasında %98, plakaların doğru olarak okunmasında ise % 88,1 başarı elde edilmiştir.

Tuna (2011), çalışmasında Çok markalı servis istasyonları için Görüntü tabanlı araç marka ve modeli tanıma sistemi geliştirmiştir. Tuna'nın çalışması önceki çalışmalardan farklı olarak yazılımın; düşük donanımlı ve farklı sistemlerde de etkili bir biçimde çalışmasını amaçlamıştır. Çalışmada 7 markanın 33 modeli kullanılmış. Test sonuçlarından elde edilen verilere göre %99'un üstünde başarı elde ettiğini belirtmiştir fakat kaç adet görüntü üzerinde bu sonuçlara ulaştığını belirtmemiştir.

Ülker (2015) çalışmasında araç tespiti, arka plan modeli oluşturularak sahnedeki hareketli objelerin tespiti ile başlamıştır. Elde edilen ikili imgenin isabeti, gölge tespit metodu kullanılarak yükseltilmiştir. Kapanma durumu, ikili büyük objelerin geometrik özelliklerinden ve objelerin ardışık kesmelerde birbirleri ile olan ilişkilerinden elde edilen bilgilerle tespit edilmektedir. Kapanma durumundaki objelerin geometrik özelliklerine ait varsayımlara dayanan ve bu objelerin doğrulukla tespitini amaçlayan bir kesimleme algoritması önermiş ve gerçeklemiştir.

Karaimer (2015) çalışmasında tüm yönlü videolarda araç tespiti ve sınıflandırması için, hareketli nesnenin arka plan ayırması sonucu elde edilen şekline dayanan bir yöntem önermiştir. Diğer şekil tabanlı sınıflandırma yöntemlerinden farklı olarak, ardışık video karelerinden elde edilen bilgidan yararlanılmıştır. Sınıflandırılan araç tipleri; motosiklet, binek araç ve dolmuştur.

Kısa ve Borsalı (2015) bildirimlerinde bir aracın önünde seyreden aracın uzaklığının tek kamera kullanarak tahminini yapan bir çalışma yaptıklarını belirtmişlerdir. Yaptıkları çalışmada trafikte seyreden bir binek aracın konsoluna bağlanmış tek bir CCD kamera ile

alınan sayısal görüntülerden, aracın önünde seyreden diğer araçlardan en yakın olanının araca olan uzaklığını tahmin etmeyi sağlayan bir yöntem sunulmuştur. Uzaklığı öndeki aracın plaka bölgesinin büyüklüğüne göre tespit etmeye çalışmışlardır. Çalışmada 100cm'de %0.4, 2500cm'de %4.96'lık bir hata payı ile doğru tespit yapmışlardır. Araç olma olasılığı olan görüntüleri elde etmek üzere görüntüye gaussian algoritması ile gürültü giderme işlemi uygulanmakta, eşikleme ve canny algoritması uygulanarak kenarlar belirlenmekte, Hough algoritması ve Harris ve Stephens köşe bulma algoritması kullanılarak görüntüdeki araç olma olasılığı olan aday dikdörtgenler belirlenmektedir. Aday dikdörtgenlerin araç olup olmadığı konusundaki karar görüntünün her hangi bir plaka görüntüsü içerip içermediğine bakılarak verilmektedir. Plaka olma potansiyeli taşıyan aday dikdörtgenler ise, aday dikdörtgen görüntülerinin en boy oranı esas alınarak sınıflandırılmaktadır. Aday görüntülerin belirlenmesinde açık kaynak lisanslı bir görüntü işleme kütüphanesine ait fonksiyonlar kullanılmıştır.

Araç renk bilgisi, ITS (Intelligent Traffic System)'de önemli unsurlardan biridir. Fuad Rachmadi ve Ketut Eddy Purnama tarafından yapılan çalışmada (Fuad Rachmadi ve Ketut Eddy Purnama, 2015) konveksiyonel sinir ağlarını(CNN) (Krizhevsky ve ark., 2012) kullanarak araç renk tanıma metodu sunulmuştur. Elbette CNN şekil bilgisine dayalı sınıflandırma yöntemini öğrenmek için tasarlanmıştır. Fakat Onlar CNN'in renk tanımına dayalı sınıflandırmayı öğrendiğini de kanıtlamışlardır. Metotlarında giriş resmini HSV ve CIE Lab olmak üzere 2 farklı renk uzayına dönüştürmektedirler ve bunu bazı CNN metotlarından çalıştırmışlardır. Eğitim süreci Krizhevsky tarafından başlatılan prosedürü takip etmekte, öğrenme oranının bazı yinelemelerden sonra 10 kat azaldığını göstermektedir. Yöntemlerini test etmek için Chen tarafından sağlanan kamuya açık renk tanıma veri kümesi kullanılmaktadır. Sonuçlar, modellerinde, Chen tarafından sağlanan orijinal sistemden % 2'lik daha yüksek toplam hassasiyetle performans sergilediğini göstermektedir.

Saghaei'nin çalışmasında (Saghaei, 2016), görüntü işleme algoritmaları kullanarak belirli bir yerden geçen araçların plaka sayısını çıkarabilen otomatik ve mekanize bir lisans ve plaka tanıma sistemi (LNPR) sistemi önermektedir. Önerilen sistemin uygulanması için GPS veya radyo frekansı tanımlama (RFID) gibi ek cihazların kurulması gerekmez. Özel kameralar kullanarak, sistem her geçen araçtan fotoğraf çeker ve görüntüyü LPR yazılımı tarafından işlenmesi için bilgisayara iletir. Plaka tanıma yazılımı, yerelleştirme, yönlendirme, normalleştirme, segmentasyon ve son olarak optik karakter tanıma (OCR) gibi farklı algoritmalar kullanır. Elde edilen veriler bir veri tabanındaki kayıtlarla karşılaştırılır.

Deneysel sonuçlar, sunulan sistemin, araç plakalarını gerçek görüntüler üzerinde başarıyla tespit edip tanıdığını ortaya koymaktadır. Bu sistem güvenlik ve trafik kontrolü için de kullanılabilir.

Araç plakası tanıma (VLPR) genellikle sürgülü pencere yaklaşımıyla yapılsa da değişken genişlikte karakterlere sahip veri kümelerinde sınırlı performans gösterebilir. Bu karakterleri önceden belirlemek için el yapımı algoritmalarıyla çözülebilir. Bu yaklaşım oldukça iyi çalışsa da, tanıyıcı yalnızca her dedektör penceresindeki piksellerin farkındadır ve görüntünün diğer bölümlerinde bulunabilecek diğer bağlamsal bilgileri dikkate almaz. Sürgülü pencere yaklaşımı ayrıca önceden elde edilmiş karakterler şeklinde eğitim verilmesini gerektirir; bu da elde edilmesi daha zor olabilir. Kook Cheand ve ark. (Koon Cheang ve ark., 2017) çalışması, gerçek dünyada yakalanan plaka fotoğraflarını tanımak için birleşik bir CNN modeli önerdiler. Özellik çıkarımı yapmak için bir CNN kullanarak ve sıralama için bir Tekrarlayan Sinir Ağı (RNN) kullanarak, tüm görüntüyü ConvNet'e girdi olarak besleyerek, tüm görüntünün içeriğine erişemeyen kayan pencere yaklaşımları sorununu ele alırlar. Bu, etiketli, tam plaka görüntülerinde tüm modelin uçtan uca eğitimini yapabileme avantajına sahiptir. ConvNet-RNN mimarisini kayan bir pencere-temelli yaklaşımla karşılaştıran deneysel sonuçlar ConvNet-RNN mimarisinin belirgin şekilde daha iyi performans gösterdiğini göstermektedir

Sochor ve ark. (Sochor ve ark., 2017), özellikle trafik izleme uygulamalarında araçların ayrıntılı olarak tanınmasına odaklanmaktadır. İnce taneli tanıma (otomatik parça keşfi, bilinear havuzlama) alanındaki son gelişmelere ortogonal bir yaklaşım önermektedirler. İnce taneli tanıma (Fine-grained) ortak türdeki nesnelere ince ayrıntılarına bakarak alt türlerinin tespit edilmesine odaklanan bir yaklaşımdır. Ayrıca, araçların ince taneli olarak tanınmasına odaklanan diğer yöntemlerin aksine, kendimizi ön / arka bakış açısıyla sınırlandırmıyorlar, ancak araçların herhangi bir bakış açısından görülmesine izin veriyorlar. Yaklaşımları, araçların etrafına yerleştirilmiş 3B sınırlayıcı kutulara dayanıyor. Sınırlama kutusu, trafik gözetleme verilerinden otomatik olarak oluşturulabilir. Kesin yapı kullanmanın mümkün olmadığı senaryolar için, 3D sınırlama kutusunun tahmini için bir yöntem önermektedirler. 3B sınırlama kutusu, görüntüyü bir düzlem içine “açarak” görüntünün bakış açısını normalleştirmek için kullanılır. Ayrıca, Konvolüsyonel Sinir Ağlarının eğitimi sırasında görüntünün rengini rastgele değiştirmeyi ve görüntüdeki rastgele bir konuma rastgele gürültülü bir dikdörtgen eklemeyi önerirler. Çok sayıda gözetleme kamerası tarafından alınan çeşitli bakış açılarından 116 bin araç görüntüsü ile büyük bir “*fine-grained*”

araç veri setini BoxCars116k'yı topladılar. Önerilen yöntemin CNN sınıflandırma doğruluğunu önemli ölçüde iyileştirdiğini gösteren bir takım deneyler yaptılar (doğruluk yüzde 12'ye kadar artırıldı ve hata, önerilen değişiklikler olmadan CNN'lere kıyasla% 50'ye kadar azaltıldı). Ayrıca, metotlarının “iyi-taneli tanıma” için modern metotlardan daha iyi performans gösterdiğini gösterdiler.

Dehghan ve ark. (Dehghan ve ark., 2017) tam otomatik araç yapım, model ve renk tanıma sistemi için bir yöntem önermektedirler Çalışmaları, Sighthound'un tam otomatik araç yapım, model ve renk tanıma sisteminin detaylarını anlatmaktadır. Sistemlerinin bel kemiği, yalnızca hesaplama açısından ucuz olmayan, aynı zamanda birçok rekabetçi kriterde en son teknoloji sonuçları sağlayan derin bir evrimsel sinir ağıdır. Ek olarak, derin ağları yarı otomatik bir işlemle etiketlenen birkaç milyon görüntünün büyük bir veri kümesi üzerinde eğitilmiştir. Sonunda, sistemlerini birkaç kamu veri setinde ve kendi iç test veri setinde test etmişlerdir. Elde ettikleri sonuçlar, tüm ölçütlerdeki diğer yöntemleri, önemli marjlar ile geride bıraktıklarını göstermektedir.

Vaquero ve ark. (Vaquero ve ark., 2017), yalnızca 3D lidar bilgileriyle çalışan tam bir araç algılama ve izleme sistemi sunar. Tespit adımı, bir Velodyne HDL-64 sensörü tarafından sağlanan 3B bilginin özellikli bir sunumunu girdi olarak alan ve bir araca ait olup olmadığına ilişkin bir nokta başına sınıflandırma döndüren bir Konvolüsyonel Sinir Ağı (CNN) kullanır. Sınıflandırılmış nokta bulutu daha sonra, çevresindeki araçların konumunu ve hızını tahmin eden bir dizi Çok Hipotez Genişletilmiş Kalman Filtresi (MH-EKF) aracılığıyla uygulanan çok nesneli bir izleme sistemi için gözlemler üretmek üzere geometrik olarak işlenir. Sistem, KITTI izleme veri seti üzerinde kapsamlı bir şekilde değerlendirilmiştir ve çalışma, CNN tabanlı araç dedektörleri tarafından standart bir geometrik yaklaşım üzerine sağlanan performans artışını göstermektedir. Lidar tabanlı yaklaşımları, benzer şekilde rekabetçi sonuçlara sahip görüntü tabanlı bir dedektör için ihtiyaç duyulan verilerin yaklaşık % 4'ünü kullanır.

Sheng ve ark. tarafından sunulan çalışmada (Sheng ve ark., 2018) sinir ağları kullanılarak araç tespiti önerilmiştir. Bu çalışma evrimsel sinir ağına dayanan ve iki adımdan oluşan bir yöntem sunmaktadır: araç alanı tespiti ve araç markası sınıflandırması. RCNN (Konvolüsyonel Sinir Ağı özellikli Bölgeler), Faster RCNN, AlexNet, Vggnet, GoogLenet ve Resnet gibi detaylı karşıtlık analizi için eğitim ve sınıflandırma deneylerinde çeşitli tipik ağ modelleri uygulanmıştır. Önerilen yöntem, araç modellerini, markalarını ve diğer bilgileri doğru bir şekilde tanımlayabilir, orijinal veri seti ve zenginleştirilmiş veri seti ile, algoritma,

sonuçları altı tür araç modelinin sınıflandırılmasında ortalama % 93,32 civarında bir doğrulukla elde edebilir.

Ogier du Terrail ve Jurie (Ogier du Terrail ve Jurie, 2018) , Faster RER-CNN hakkında bir çalışma önermektedir. Bu çalışma hava görüntülerinden araçların tespitinin yapılmasıdır. Çalışmaları, Faster R-CNN yaklaşımı üzerine kurulur ve bunu, herhangi bir havadan imge görevine özgü rotasyon denkliği ile uygun şekilde ilgilenen bir algılama çerçevesine dönüştürür. Bu yeni boru hattı (Faster RER-CNN), : VeDAI (Razakarivony ve Jurie, 2015) gibi en zorlu hava görüntüleri veri kümelerinde cazip yanlarını söylemeye gerek duymadan, teknoloji harikası sonuçlar verir. Bu veri kümesi Faster R-CNN temellidir ve diğer iki veri kümesini de kapsamaktadır; Münih(Leitloff ve ark., 2014) ve GoogleEarth(Heitz ve Koller, 2008).

Watkins ve ark. (Watkins ve ark., 2018) çalışmalarında, ResNet mimarilerinin ince taneli araç sınıflandırma görevinde daha geleneksel CNN'den daha iyi performans gösterip gösteremediğini araştırmışlardır. Diğer veri kümelerinde ön eğitim yapmadan ResNet-18, ResNet-34 ve ResNet-50'yi Kapsamlı Arabalar veri kümesi üzerinde eğitmişler ve test etmişlerdir. Daha sonra, Mekansal Ağırlıklı Havuzlamayı (SWP) kullanmak için ağırları deęitirmişlerdir. Son olarak, ResNet-50 tabanlı bir ağı kullanarak, sınıflandırma işleminden önce bir yerelleştirme adımı eklemişlerdir. SWP ve yerelleştirmeyi kullanmanın ResNet50'nin sınıflandırma doğruluğunu artırdığını tespit etmişlerdir. SWP, doğruluęu yüzde 1,5 puan artırırken, yerelleştirme de doğruluęu yüzde 3,4 puan artırmaktadır. Her ikisini de kullanarak, doğruluęu yüzde 3,7 puan artırırken, Kapsamlı Arabalar veri setinde ilk 96% 'lık doğruluk oranı elde edilmiştir. Metodları, geleneksel CNN'leri kullananlar dahil bir dizi metottan daha yüksek doğruluk sağlamaktadır. Ancak, yöntemleri SWP kullanan önceden eğitilmiş ağırlar kadar iyi performans göstermemiştir.

Otopilot araç görüş sistemleri, son derece geniş ve zorlu sahnelerle başa çıkmak zorundadır. Alandaki araçlardan toplanan muazzam miktarda eğitim verisinden faydalanabilirler, ancak miktarlar çevrimdışı olarak eğitilemeyecek kadar büyüktür. Ancak tüm eğitim örnekleri aynı derecede deęerli deęildir ve hangi örneklerin toplanacağına öncelik vermek için örnekleme kullanılabilir. Bu yaklaşım, görüntülerdeki nesnelerin yüksek doğrulukta etiketlendiğini varsayar. Bu alanda doğru etiketler üretmek için araç videosunun mekansal-zamansal tutarlılığından yararlanılmaktadır. Pan ve ark. Çalışmada yakından uzaęa etiketleme stratejisi kullanmış olup olup ilk önce videodaki büyük ve yakın nesneleri etiketlemiş ardından bu nesnelerin uzaktaki görünümünü videoda zamanda geri giderek

takip etmişlerdir. Çalışmalarında, bu yaklaşımın uygulanabilirliğini birkaç adımda göstermişlerdir. İlk olarak, görüntülerdeki etiketli nesnelere optimal bir alt kümesinin (karşılaşılan ve etiketlenen tüm nesnelere göre) tanıma ağının gradyanlarını kullanarak önemle örnekleme yoluyla elde edilebileceğini not ederler. Daha sonra, bu gradyanlara, CNN çıkarımı yaparken zaten mevcut olan kayıp fonksiyonu kullanılarak çok düşük bir hata ile yaklaşılabileceğini gösterirler. Ardından, bu sonuçları, bir nesne algılama sistemi kullanarak daha büyük bir sahnedeki nesnelere genelleştirirler. Son olarak, nesne izlemeyi kullanarak kendi kendini etiketleyen bir şema tarif ederler. Nesnelere zaman içinde geriye doğru izlenir (uzak mesafeye) ve uzaktaki nesnelere doğruluğunu kontrol etmek için yakın nesnelere etiketleri kullanılır. Daha sonra, örneklemeli verilerin önemine göre eğitilmiş modellerin doğruluğu, tam verilerde eğitilen modellerin doğruluğu değerlendirilir.

Soleimani ve ark. (Soleimani ve ark., 2018) metin destekli derin bir CNN sınıfı kullanarak hava aracı tanıma problemini araştırmışlardır. CNN, havadan bir görüntü ve istenen bir sınıfı alır ve görüntü ile istenen sınıfın metinsel tanımını eşleştirerek evet veya hayır çıktısı yapar. Modellerini sentetik bir hava veri kümesi üzerinde eğitip, test etmişlerdir. İstenen sınıflar; araçların tipleri ve renklerinin kombinasyonundan oluşmaktadır. Bu strateji, testte eğitimden daha fazla sınıf olduğu düşünüldüğünde yardımcı olmaktadır.

Yüksek hareket kabiliyetinin avantajıyla, İnsansız Hava Araçları (İHA), bilgisayarlı görmede sayısız önemli uygulamayı beslemek için kullanılmaktadır; bu, kamera açısı, ölçek ve görüşe sahip gözetleme kameralarından daha fazla verimlilik ve kolaylık sağlar. Bununla birlikte, çok sınırlı İHA veri setleri önerilmektedir ve bunlar nispeten sınırlı senaryolarda yalnızca görsel izleme veya nesne tespiti gibi belirli bir göreve odaklanmaktadır. Sonuç olarak, ilgili araştırmaları artırmak için sınırsız bir İHA kriterinin geliştirilmesi büyük önem taşımaktadır. Du ve ark.'nın (Du ve ark., 2018) makalesinde, yeni zorluklarla birlikte karmaşık senaryolara odaklanan yeni bir İHA kıyaslaması oluşturmuşlardır. 10 saatlik ham videolardan seçilen, sınırlayıcı kutularıyla birlikte 14 farklı nitelikte (örn. Hava durumu, yangın yüksekliği, kamera görüntüsü, araç kategorisi ve tıkanma) yaklaşık 80.000 temsili görüntü üç temel bilgisayar görüşü görevi için hazırlanmıştır. Bunlar Nesne algılama, tek nesne izleme ve çoklu nesne izlemedir. Ardından, her görev için en son teknolojiye sahip algoritmalar kullanılarak detaylı bir nicel çalışma gerçekleştirilmiştir. Deneysel sonuçlar, mevcut son teknoloji yöntemlerin, İHA tabanlı gerçek sahnelerde, örneğin yüksek yoğunluklu, küçük nesnede ve kamera hareketinde ortaya çıkan yeni zorluklar nedeniyle, veri setlerinde daha kötü performans gösterdiğini göstermektedir. Çalışmalarında bildiği

çalışmalara göre şu ana kadar, çalışmaları sınırsız sahnelerde bu tür konuları kapsamlı bir şekilde araştırma ilk kez yapılmıştır.

Araç marka ve model tanıma (MMR) sistemleri, farklı araç modellerini tanımak ve sınıflandırmak için tam otomatik bir çerçeve sunmaktadır. Bu zorluğun üstesinden gelmek için çeşitli yaklaşımlar önerilmiştir, ancak bunlar sınırlı koşullarda gerçekleştirilebilirler. Nazemi ve ark. (Nazemi ve ark., 2018), yoldaki araçların markasının ve modelini iyi tanımlanmış bir sınıflandırma problemi olarak formüle eder ve yeni bir yapılandırılabilir tanıma sistemi önerir. Denetimsiz özellik öğrenme yöntemlerinden yararlanırlar ve daha ayrıntılı olarak, Giriş SIFT özelliklerini kodlamak için hızlı bir özellik kodlayıcısı olarak Locality kısıtlama Linear Coding (LLC) yöntemini kullanırlar. Önerilen yöntem, farklı koşulların gerçek ortamlarında gerçekleştirilebilir. Bu sistem, elli araç modellerini tanıyabilir ve belirtilen tüm sınıflardan birine ait olmayan diğer tüm araçları bilinmeyen bir araç olarak sınıflandırma avantajına sahiptir. Önerilen MMR çerçevesi, uygulama alanına bağlı olarak daha hızlı veya daha doğru olması için yapılandırılabilir. Önerilen yaklaşım, İran karayolu taşıt veri kümesi ve CompuCar veri kümesi dahil olmak üzere iki veri kümesi üzerinde incelenmiştir. İran karayolu taşıt veri kümesi, farklı hava ve ışık koşullarında trafik kameraları tarafından gerçek durumlarda yakalanan 50 araç modelinin görüntüsünü içerir. Deneysel sonuçlar, önerilen sistemin, İran karayolu taşıt veri kümesindeki son teknoloji yöntemlere göre üstünlüğünü ve CompuCar veri kümesinde sırasıyla % 97,5 ve % 98,4 doğrulukla karşılaştırılabilir sonuçların üstünlüğünü göstermektedir.

3. MATERYAL VE METOT

Bu bölümde çalışma için kullanılan materyallerden ve metotlardan bahsedilecektir.

3.1 Metot

Bu bölümde çalışma için kullanılan metotlardan bahsedilecektir. Çalışmada Tensorflow, OpenCV kütüphaneleri, Faster RCNN metodu ve Python kullanılmıştır.

3.1.1 Tensorflow

TensorFlow, yüksek performanslı sayısal hesaplama için açık kaynaklı bir yazılım kütüphanesidir. Esnek mimarisi, çeşitli platformlarda (CPU'lar, GPU'lar, TPU'lar) çalışma imkanı sağlamaktadır. Masaüstü bilgisayarlardan; sunucu kümelerine; mobil cihazlardan; kenar aygıtlarına kadar hesaplamanın kolayca yapılmasını sağlar. Aslen Google'ın AI organizasyonu içindeki Google beyin ekibinden araştırmacılar ve mühendisler tarafından geliştirilen, makine öğrenimi ve derin öğrenme için güçlü bir destekle birlikte gelen ve diğer birçok bilimsel alanda esnek sayısal hesaplama çekirdeği kullanan bir yazılım kütüphanesidir.

Dünya çapındaki firmalar tarafından da tercih edilen bu kütüphane, derin öğrenme konusuna yeni başlayan geliştiriciler için de kolay kullanıma sahiptir. (Tensorflow, 2018)

3.1.2 OpenCV

OpenCV (Açık Kaynak Bilgisayarlı Görme Kitaplığı) açık kaynaklı bir bilgisayarlı görme ve makine öğrenimi yazılım kütüphanesidir. OpenCV, bilgisayarlı görme uygulamaları için ortak bir altyapı sağlamak ve ticari ürünlerde makine algısının kullanımını hızlandırmak için inşa edildi. BSD lisanslı bir ürün olan OpenCV, işletmelerin kodu kullanmasını ve değiştirmesini kolaylaştırır.

Kütüphane, hem klasik hem de son teknoloji bilgisayarlı görme ve makine öğrenimi algoritmalarından oluşan kapsamlı bir dizi içeren 2500'den fazla optimize edilmiş algoritmaya sahiptir. Bu algoritmalar, yüzleri algılamak ve tanımlamak, nesnelere tanımlamak, videolarda insani eylemleri sınıflandırmak, kamera hareketlerini izlemek, hareketli nesnelere izlemek, nesnelere 3 boyutlu modellerini ayıklamak, stereo kameralardan 3B nokta bulutları üretmek,

görüntüleri yüksek çözünürlükte birleştirmek için kullanılabilir. Tüm bir sahnenin görüntüsü, bir resim veri tabanından benzer görüntüleri bulmak, flaş kullanarak çekilen görüntülerden kırmızı gözleri kaldırmak, göz hareketlerini takip etmek, manzarayı tanımak ve artırılmış gerçeklikle kaplamak için işaretleyiciler oluşturmak, vb. OpenCV'nin 47 binden fazla kullanıcı topluluğu vardır ve tahminen 14 milyondan fazla indirilmiştir. Kütüphane şirketler, araştırma grupları ve hükümet organları tarafından yaygın olarak kullanılmaktadır.

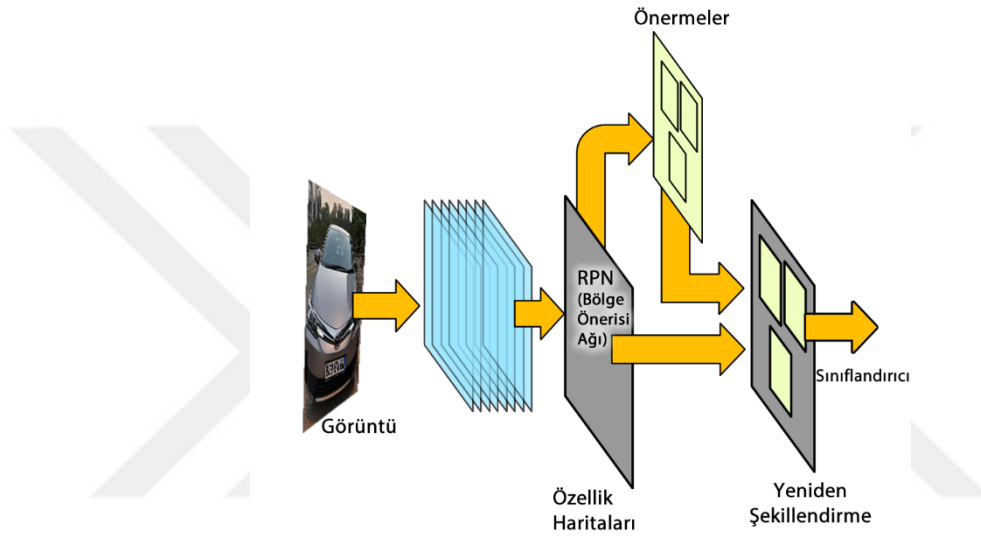
C ++, Python, Java ve MATLAB arayüzlerine sahiptir ve Windows, Linux, Android ve Mac OS'yi destekler. OpenCV çoğunlukla gerçek zamanlı görüş uygulamalarına yönelir ve mevcut olduğunda MMX ve SSE talimatlarından yararlanır. Tam özellikli bir CUDA ve OpenCL arayüzleri şu anda aktif olarak geliştirilmektedir. 500'den fazla algoritma ve bu algoritmaları oluşturan veya destekleyen yaklaşık 10 kat fazla fonksiyon vardır. OpenCV, C ++ dilinde doğal olarak yazılmıştır ve STL kapsayıcılarla sorunsuz çalışan bir şablona sahiptir. (OpenCV, 2019)

3.1.3 Python

Python, yorumlanmış, etkileşimli, nesne yönelimli bir programlama dilidir. Liste ve ilişkilendirme dizileri (sözlükler adı verilen), dinamik yazma ve dinamik bağlama, modüller, sınıflar, istisnalar, otomatik bellek yönetimi vb. Gibi üst düzey veri yapıları sağlar. Çok basit ve zarif bir sözdizimine sahiptir ve güçlüdür. Genel amaçlı programlama dili olarak 1990 yılında Guido van Rossum tarafından tasarlanmıştır. Diğer birçok betik dili gibi, ticari amaçlar için bile ücretsizdir ve pratik olarak herhangi bir modern bilgisayarda çalıştırılabilir. Bir python programı derleyici tarafından otomatik olarak platform bağımsız bayt koduna derlenir ve daha sonra yorumlanır. Python'da Linux, Windows NT, 98, 95, IRIX, SunOS, OSF altında yazılmış değiştirilmemiş bileşenler kullanılmaktadır. Python doğası gereği modülerdir. Çekirdek çok küçüktür ve uzatma modülleri içe aktarılarak uzatılabilir. Python dağıtımı, dize işlemlerinden Perl benzeri normal ifadelerden Grafik Kullanıcı Arabirimi (GUI) üreticilerine ve web ile ilgili yardımcı programları da içeren işlemler için çeşitli standart uzantı kitaplıklarını (bazıları Python'da, bazıları C veya C ++ ile yazılmış) içerir işletim sistemi hizmetleri, hata ayıklama ve profil oluşturma araçları vb. dili yeni veya eski kodla genişletmek için yeni uzantı modülleri oluşturulabilir. Python kullanıcı topluluğu üyeleri tarafından geliştirilmiş ve dağıtılmış çok sayıda genişletme modülü vardır. Python (2010)

3.1.4 Faster-RCNN yapay sinir ağı algoritması

Faster RCNN, RPN (Bölge Önerisi Ağı) (Ren ve ark. 2017) ile Fast RCNN (Girshick, 2015) modellerinin birleşmiş halidir. Faster RCNN modelinde giriş resmi konveksiyonel sinir ağlarından geçirilerek özellik haritası çıkarılır. Daha sonra RPN oluşturulur. Bölge önerileri bu ağ üzerinde yapılır. Ağ bölgeleri belirlendikten sonra belirlenen bölgeler yeniden şekillendirildikten sonra tam bağlı katmanlarından geçirilir ve sınıflandırma yapılır. Şekil 3.1’de bu anlatımın görselleştirilmiş hali bulunmaktadır.



Şekil 3.1. Faster R-CNN nesne tanıma için tek, birleşik ağıdır. RPN modülü bu birleşik ağın dikkatini sunmaktadır. (Ren ve ark., 2015)

3.2 Materyal

Bu bölümde; çalışmada kullanılan veriler, resimler ve diğer materyallerden bahsedilecektir.

3.2.1 Markaların belirlenmesi

Markaların tespitini yapan çalışmada; Türkiye İstatistik Kurumunun 2017 tarihli “Markalara Göre Trafığe Kaydı Yapılan Otomobil Sayısı” (TÜİK, 2017) isimli çalışmasındaki Trafığe en çok kaydı yapılan 19 Araç markası alınmış bu markalara ek olarak Alfa Romeo markası da çalışmaya dahil edilmiştir. Alfa Romeo logosu içerisindeki simge ve imgelerin karmaşık olması ve BMW, Volkswagen, Skoda gibi markaların logolarına benzemesi sebebiyle eklenmiştir. Bu sayede çalışmadaki programın ayırt ediciliği sınanması amaçlanmıştır. Bununla birlikte Dacia markasının hem eski logosu hem yeni logosu çalışılmıştır. Toplamda 20 farklı marka ve 21 farklı sınıf üzerinde çalışılmıştır. Çizelge 3.1’de Markalara göre trafiğe kaydı yapılan otomobil sayıları ve 2017 yılındaki kaydı yapılan otomobillerin markalarının toplam sayıya oranı gösterilmiştir.

Çizelge 3.1. Markalara Göre Trafîğe Kaydı Yapılan Otomobil Sayısı (TÜİK, 2017)

Marka - Trademark	2016	2017	Oran
Toplam - Total	746.074	741.902	%100,00
Audi	22.064	21.435	%2,89
BMW	27.704	18.255	%2,46
Citroen	16.304	15.745	%2,12
Dacia	40.723	41.236	%5,56
Fiat	50.664	61.305	%8,26
Ford	42.006	40.211	%5,42
Honda	19.518	27.313	%3,68
Hyundai	47.996	50.060	%6,75
Kia	14.668	11.501	%1,55
Mercedes	34.596	29.070	%3,92
Nissan	28.161	32.217	%4,34
Opel	53.194	45.646	%6,15
Peugeot	24.041	27.639	%3,73
Renault	102.829	118.907	%16,03
Seat	20.837	15.987	%2,15
Skoda	28.153	25.110	%3,38
Toyota	46.353	41.401	%5,58
Volkswagen	100.877	91.330	%12,31
Volvo	4.192	4.627	%0,62
Diğer - Other	21.194	22.907	%3,09

Çizelge 3.1'den de görüldüğü üzere çalışma trafiğe kayıtlı otomobillerin yaklaşık olarak %96,91'lik kısmını kapsamaktadır.

Markanın tespitinde sınıflandırma eğitiminde 2 temel kısım vardır. Bunlar eğitim ve test kısımlarıdır. Bu kısımları oluştururken eğitim setinde 1557, test setinde 398 adet resim kullanılmıştır. Marka tespitinin sonuçlarının görülmesi için de ayrıca diğer resimlerden bağımsız 1280 adet resim kullanılmıştır. Bu veri kümesi rasgele seçilen araçların ön ve arka bölümlerinin resimlerinin çekilmesiyle oluşturulmuştur. Resimler farklı mekanlarda ve günün farklı zamanlarında çekilmiştir. Çekilen resimler için iPhone SE, iPhone 6S, Canon 600D olmak üzere 3 adet kamera özellikli cihaz kullanılmıştır. Resimler Eylül 2018 ile Kasım 2018 arasında İstanbul ve Konya'da çekilmiştir.

Çizelge 3.2'de çalışmada kullanılan resimlerin marka, eğitim, sınama ve genel sınama parametrelerine göre sayıları verilmiştir.

Çizelge 3.2. Çalışmada kullanılan resimlerin kullanım alanlarına göre listesi

	Toplam	Eğitim	Sınama	Genel Sınama
Alfa Romeo	60	48	12	51
Audi	83	66	17	87
BMW	100	80	20	55
Citroen	126	100	26	53
Dacia Yeni	92	73	19	50
Dacia Eski	50	40	10	50
Fiat	90	72	18	51
Ford	81	64	17	86
Honda	101	81	20	55
Hyundai	100	79	20	69
Kia	96	77	19	52
Mercedes	103	81	21	55
Nissan	83	66	17	91
Opel	97	78	19	124
Peugeot	100	80	20	37
Renault	107	85	22	62
Seat	81	65	16	50
Skoda	100	80	20	50
Toyota	99	80	19	49
Volkswagen	130	100	30	52
Volvo	80	64	16	51
Genel Toplam	1957	1559	398	1280

3.2.2 Araç modellerinin belirlenmesi

Araç modelinin tespitini yapan çalışmada; tespit edilecek modellerin belirlenmesi aşamasında Hangi model araçtan trafikte kaç adet olduğunu gösteren resmi bir istatistik yoktur. (Temmuz 2019 itibariye). Bu sebeple bu aşamada Çizelge 3.1’de belirlenen markalar temel alınarak model seçimi yapılmıştır. Bu model seçiminde ise Otomotiv Disbrütörleri Derneği’nin “Otomobil Ve H.Ticari Araç Pazarı Marka/Model Perakende Satışlar” (ODD, 2018) başlıklı Çizelgesindeki en çok satış yapılan araç modelleri referans alınmıştır. Çizelge 3.3’de belirlenen araç modelleri listelenmiştir.



Çizelge 3.3. Belirlenen araç marka ve modelleri

Sıra No	Marka	Model	Sıra No	Marka	Model
1	Alfa Romeo	Giuletta	27	Nissan	Xtrail
2	Audi	A3	28	Opel	Astra HB K
3	Audi	A4	29	Opel	Astra Sedan
4	BMW	5 Serisi	30	Opel	Corsa D
5	Citroen	Berlingo	31	Opel	Corsa B
6	Citroen	C-Elysee	32	Peugeot	3008
7	Dacia	Sandero	33	Peugeot	308
8	Dacia	Duster	34	Peugeot	301
9	Fiat	Egea	35	Renault	Megane
10	Fiat	Doblo	36	Renault	Clio
11	Fiat	Linea	37	Renault	Symbol
12	Fiat	Fiorino	38	Seat	Leon
13	Fiat	Şahin	39	Seat	İbiza
14	Ford	Focus Sedan	40	Skoda	Fabia 3
15	Ford	Kuga	41	Skoda	Octavia 3
16	Ford	Tourneo	42	Skoda	Superb
17	Ford	Fiesta 7	43	Toyota	Corolla
18	Honda	Civic9	44	Toyota	CHR
19	Honda	Civic 10	45	Volkswagen	Golf 6
20	Hyundai	Accent Blue	46	Volkswagen	Golf 7
21	Hyundai	i20	47	Volkswagen	Jetta
22	Hyundai	Tucson	48	Volkswagen	Passat
23	Kia	Sportage 3	49	Volkswagen	Polo5
24	Mercedes	E180	50	Volvo	S60
25	Nissan	Qashqai 1	51	Volvo	V40
26	Nissan	Qashqai 2			

Çizelge 3.3. Belirlenen araç marka ve modellerinde toplam 51 araç modeli çalışmaya dahil edilmiştir. Bu da 51 farklı sınıf anlamına gelmektedir.

Araç modelinin tespitinde sınıflandırma eğitiminde 2 temel kısım vardır. Bunlar eğitim ve test kısımlarıdır. Bu kısımlar oluştururken eğitim setinde 4946, test setinde 1214 adet resim kullanılmıştır. Marka tespitinin sonuçlarının görülmesi için de diğer resimlerden bağımsız 2638 adet resim kullanılmıştır. Toplamda çalışmada 8798 adet resim kullanılmıştır. Bu veri kümesi rasgele seçilen araçların farklı açılardan çekilen resimlerden oluşturulmuştur. Resimler farklı mekanlarda ve günün farklı zamanlarında çekilmiştir. Çekilen resimler için iPhone SE, iPhone 6S, Canon 600D olmak üzere 3 adet kamera özellikli cihaz kullanılmıştır. Resimler Eylül 2018 ile Haziran 2019 tarihleri arasında İstanbul, Konya ve Çankırı'da çekilmiştir.

Çizelge 3.4'de çalışmada kullanılan resimlerin marka, model, eğitim, sınama ve genel sınama parametrelerine göre sayıları verilmiştir.

Çizelge 3.4. Araç modellerinin eğitim, sınav ve genel sınav sayıları

Marka	Model	Resim Sayısı	Eğitim	Sınava	Genel Sınava
Alfa Romeo	Giuletta	100	80	20	53
Audi	A3	124	99	25	50
Audi	A4	173	138	35	51
BMW	5 Serisi	133	106	27	50
Citroen	Berlingo	147	118	29	50
Citroen	C-Elysee	127	102	25	52
Dacia	Sandero	102	82	20	50
Dacia	Duster	117	94	23	51
Fiat	Egea	159	127	32	52
Fiat	Doblo	121	97	24	58
Fiat	Linea	101	81	20	51
Fiat	Fiorino	100	80	20	50
Fiat	Sahin	100	80	20	60
Ford	Focus Sedan	109	87	22	52
Ford	Kuga	124	99	25	50
Ford	Tourneo	149	119	30	50
Ford	Fiesta 7	120	96	24	61
Honda	Civic 9	89	71	18	50
Honda	Civic 10	150	120	30	50
Hyundai	Accent Blue	150	120	30	50
Hyundai	i20	146	117	29	50
Hyundai	Tucson 3	69	55	14	50
Kia	Sportage 3	100	80	20	50
Mercedes	E180	84	67	17	50
Nissan	Qashqai 1	69	55	14	52
Nissan	Qashqai 2	97	78	19	50
Nissan	Xtrail	136	109	27	50
Opel	Astra HB K	108	86	22	58
Opel	Astra Sedan	177	142	35	51
Opel	Corsa B	166	133	33	58
Opel	Corsa D	209	167	42	50
Peugeot	3008	83	66	17	50
Peugeot	308	100	80	20	50
Peugeot	301	120	96	24	51
Renault	Megane	118	94	24	54
Renault	Clio	142	114	28	50
Renault	Symbol	110	88	22	53
Seat	Leon	119	95	24	51

Seat	İbiza	97	78	19	52
Skoda	Fabia 3	113	90	23	50
Skoda	Octavia 3	112	90	22	51
Skoda	Superb	134	107	27	50
Toyota	Corolla	108	86	22	50
Toyota	CHR	88	70	18	50
Volkswagen	Golf6	83	66	17	52
Volkswagen	Golf7	301	241	60	58
Volkswagen	Jetta	80	64	16	50
Volkswagen	Passat	104	83	21	52
Volkswagen	Polo5	99	79	20	50
Volvo	s60	90	72	18	50
Volvo	v40	83	66	17	54
Toplam		6160	4946	1214	2639


4. UYGULAMA

Bu çalışmada araçların marka ve modeli tespit edilmeye çalışılmıştır. Model ve markanın tespiti ayrı ayrı yapılmıştır. Bununla beraber endüstriye yönelik bir çalışmada yapılan bu modeller tek bir proje üzerinde gerçekleştirilebilir.

4.1 Marka Tespiti

Araçların markaların tespitinde araçların üzerindeki marka logolarının tespit edilmesi amaçlanmıştır. Logoların tespiti yapılırken ilk önce belirlenen marka logolarının yapay sinir ağları yöntemleriyle eğitilmesi sağlanmıştır. Eğitim aşamasından sonra eğitilmiş model hazırlanan program içerisinde kullanılmıştır. Sonuçların tespiti için hazırlanan materyal üzerinde program test edilmiştir. Elde edilen sonuçlar Çizelge haline getirilmiş ve raporlanmıştır.

Çalışma altı aşamadan oluşmaktadır. Şekil 4.1’de bu aşamalar gösterilmiştir.



Şekil 4.1. Markanın Tespit Edilmesi çalışmasının aşamaları

Markaların belirlenmesi aşamasında çalışmada yapılan uygulamanın hangi markaları tespit edeceği hangilerini göz ardı edileceği belirlenmiştir. Bu aşamada 2017 TUİK “Markalara göre trafiğe kaydı yapılan otomobil sayıları” verileri bazı alınmıştır. (TÜİK, 2017)

Bu sayede trafikteki otomobillerin yaklaşık %96,9'sının markasının tespit edilebilmesi amaçlanmıştır.

Çizelge 3.1'deki ilk 19 otomobil markasına ek olarak Alfa Romeo markası da çalışmaya dahil edilmiştir. Bununla birlikte Dacia markasının logosu 2010 yılında değiştiği için bu markanın eski ve yeni logosu için ayrı ayrı resim toplanmış ve sınıflandırma oluşturulmuştur. Bu sebeple toplamda 20 marka logosu için 21 sınıf planlaması yapılmıştır.

Resim toplama ve etiketleme aşamasında resimlerin toplanması sağlanmıştır. Toplanan resimlerin etiketlemesi de bu aşamada yapılmıştır. Ön işlem aşamasında bu toplama ve etiketlemeden ayrıntılı olarak bahsedilmiştir.

Eğitim öncesi ayarlamalar aşamasında da eğitim öncesi bazı dosyaların derlenmesi ve düzenlenmesi gerekmektedir. Bu derleme ve düzenlemeler bu aşamada gerçekleşmiştir.

Eğitim aşamasında, modelin eğitimi yapılmıştır.

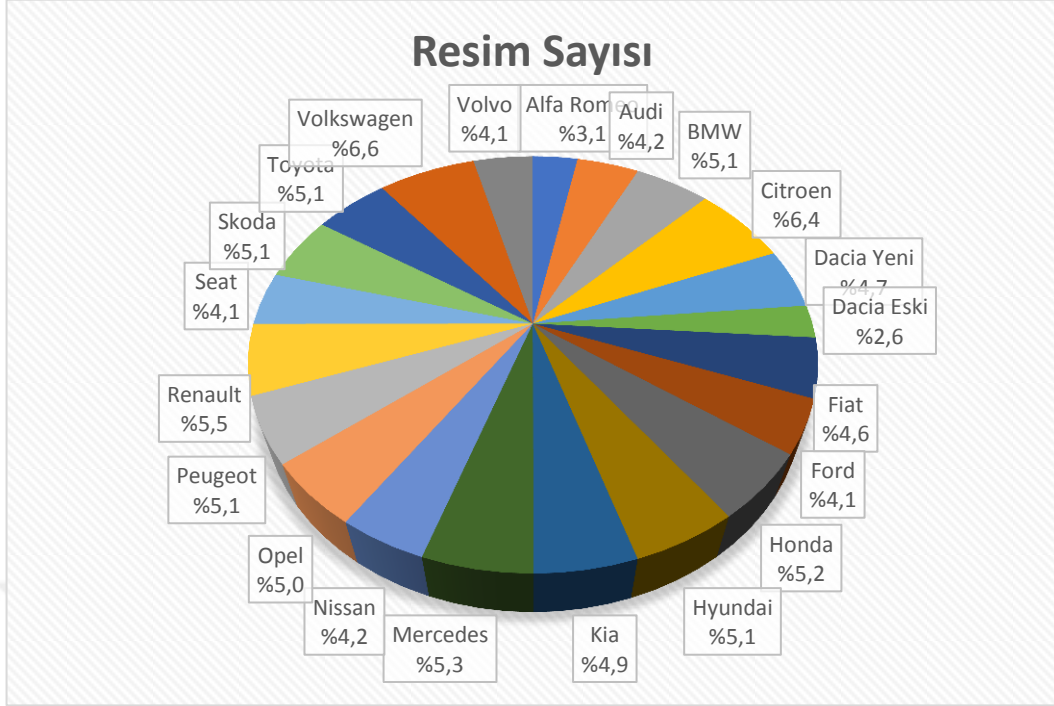
Test aşamasında eğitilen modelin test verileri üzerinde sınanması sağlanmıştır.

Rapor aşamasında ise test aşamasında elde edilen sonuçların belgelendirilip düzenlenmesi yapılmıştır.

4.1.1 Ön işlem aşaması

Ön işlem aşaması resim toplama ve etiketleme, eğitim öncesi ayarlamalar aşamalarını kapsamaktadır.

Ön işlem aşamasında eğitim aşaması için ortalama yaklaşık olarak her bir markadan 93 resim toplanmıştır. Toplamda 1957 resim toplanmıştır. Bununla birlikte çalışmanın test edilmesi için bu resimlerden farklı olarak 1280 tane resim toplanmıştır. 1957 adet resmin markalara göre dağılım Şekil 4.2'deki gibidir.



Şekil 4.2. Resim Sayılarının Markalara Dağılım Grafiği

Çizelge 3.2’de görüldüğü üzere toplamda 3237 adet resim çalışmada kullanılmak üzere toplanmıştır.

Toplanan resimler eğitim aşamasında kullanılacağından resimler çok büyük olmamasına dikkat edilmiştir. Resimlerin dosya boyutunun 500KB’ın altında olması gerekmektedir. Ayrıca resim boyutu olarak 1000x1000’den büyük olmaması eğitimin hızını olumlu yönde etkilemektedir. Bununla birlikte resimlerde marka logosunun gözükmesi ve çok küçük olmamasına dikkat edilmiştir. Eğitim için toplanan resimlerin azami resim boyutu 500x435 olmakla birlikte azami dosya boyutu 73KB olmuştur. Eğitim aşaması için ortalama yaklaşık olarak her bir markadan 93 resim toplanmıştır.

Eğitim aşaması için toplanan resimlerden her bir markanın resim sayısının yüzde 80’i eğitim(train), yüzde 20’si test olarak ayrılmıştır. Bu resimler test ve train adlı klasörlerde toplanmıştır. Eğitim aşaması için toplanan tüm resimler üzerinde markanın logosunun bulunduğu bölgelerin işaretlenmesi gerekmektedir. İşaretleme sonucunda her resim dosyası için xml dosyası oluşturulur. Burada resmin boyutu, konumu, işaretlenen alanın koordinatları gibi bilgiler yer alır. Bu dosyalarının tamamının bilgileri de csv dosyalarında tutulmuştur. Örnek dosya içeriği aşağıdaki gibidir;

```
filename,width,height,class,xmin,ymin,xmax,ymax
```

```
3drot0145.jpg,100,100,volkswagen,3,20,94,81
```

3drot0146.jpg,100,100,volkswagen,5,19,93,81
 alfaromeo.jpg,580,435,alfaromeo,275,294,300,318
 alfaromeo2.jpg,580,435,alfaromeo,291,251,319,277

Dosya içeriği bu şekilde devam etmektedir. Bu çalışmada eğitim için 1557, test için 398 veri kullanılmıştır.

4.1.2 Uygulama aşaması

Uygulama aşaması eğitim, test ve rapor aşamalarını kapsamaktadır.

Eğitim aşamasında eğitim öncesinde yapılan ayarlamalar sonucu eğitim Faster RCNN metodu baz alınarak başlatılır. Bu çalışmada eğitim aşamasında iki adet bilgisayar kullanılmıştır. Bu bilgisayarlara C1 ve C2 isimleri verilmiştir. Bunun nedeni eğitim sürelerinin karşılaştırılmasıdır. Her iki bilgisayarda da eğitim GPU üzerinde gerçekleştirilmiştir. Eğitim aşamasında kullanılan C1 özellikleri şunlardır;

- Intel Core i5 3230M 2,60Ghz Quad-Core İşlemci
- NVIDIA GeForce GT 740M 2 GB Ekran Kartı
- 8 GB DDR3 Ram

C1 bilgisayarında eğitilen modelin eğitim süresi yaklaşık olarak 35043 adım olarak 36 saat sürmüştür.

C2 özellikleri ise şunlardır;

- Intel Core i7 4770 3,40 Ghz İşlemci
- NVIDIA GeForce GTX 1080 6 GB Ekran Kartı
- AMD Radeon R9 200 Series Ekran Kartı
- 16 GB DDR4 Ram

C2 bilgisayarında eğitim süresi 55682 adım olarak yaklaşık 6 saat sürmüştür.

Eğitim sonucunda dondurulmuş model elde edilmiştir.

Test aşamasında, eğitim sonucunda elde edilen dondurulmuş model yazılım içerisinde kullanılmıştır. Test için ayrılan 1280 tane resim üzerinde sınama yapılmıştır.

Rapor aşamasında ise test aşamasında elde edilen sonuçlar çizelgelere kaydedilmiştir. Şekil 4.3'de eğitim gerçekleşirken çekilmiş ekran görüntüsü bulunmaktadır. Bu ekran görüntüsü C2 bilgisayarında yapılan eğitim sırasında alınmıştır. Her bir adım ortalama 0,27 saniyede yapılmaktadır. Bu süre C1 bilgisayarında ortalama 3,5 saniye iken C1 bilgisayarına SSD sabit takılmış halinde ise ortalama 1,5 saniye civarındadır.

```


Administrator: Komut İstemi - python train.py --logtostderr --train_dir=training/ --pipeline_config
INFO:tensorflow:global step 54235: loss = 0.0283 (0.288 sec/step)
INFO:tensorflow:global step 54236: loss = 0.0714 (0.272 sec/step)
INFO:tensorflow:global step 54236: loss = 0.0714 (0.272 sec/step)
INFO:tensorflow:global step 54237: loss = 0.0148 (0.283 sec/step)
INFO:tensorflow:global step 54237: loss = 0.0148 (0.283 sec/step)
INFO:tensorflow:global step 54238: loss = 0.0243 (0.273 sec/step)
INFO:tensorflow:global step 54238: loss = 0.0243 (0.273 sec/step)
INFO:tensorflow:global step 54239: loss = 0.0181 (0.267 sec/step)
INFO:tensorflow:global step 54239: loss = 0.0181 (0.267 sec/step)
INFO:tensorflow:global step 54240: loss = 0.1262 (0.278 sec/step)
INFO:tensorflow:global step 54240: loss = 0.1262 (0.278 sec/step)
INFO:tensorflow:global step 54241: loss = 0.0249 (0.264 sec/step)
INFO:tensorflow:global step 54241: loss = 0.0249 (0.264 sec/step)
INFO:tensorflow:global step 54242: loss = 0.0124 (0.286 sec/step)
INFO:tensorflow:global step 54242: loss = 0.0124 (0.286 sec/step)
INFO:tensorflow:global step 54243: loss = 0.0340 (0.271 sec/step)
INFO:tensorflow:global step 54243: loss = 0.0340 (0.271 sec/step)
INFO:tensorflow:global step 54244: loss = 0.0174 (0.269 sec/step)
INFO:tensorflow:global step 54244: loss = 0.0174 (0.269 sec/step)
INFO:tensorflow:global step 54245: loss = 0.0362 (0.290 sec/step)
INFO:tensorflow:global step 54245: loss = 0.0362 (0.290 sec/step)
INFO:tensorflow:global step 54246: loss = 0.0741 (0.266 sec/step)
INFO:tensorflow:global step 54246: loss = 0.0741 (0.266 sec/step)
INFO:tensorflow:global step 54247: loss = 0.0249 (0.275 sec/step)
INFO:tensorflow:global step 54247: loss = 0.0249 (0.275 sec/step)
INFO:tensorflow:global step 54248: loss = 0.0647 (0.268 sec/step)
INFO:tensorflow:global step 54248: loss = 0.0647 (0.268 sec/step)
INFO:tensorflow:global step 54249: loss = 0.0479 (0.287 sec/step)
INFO:tensorflow:global step 54249: loss = 0.0479 (0.287 sec/step)

```

Şekil 4.3. Eğitimin Gerçekleştirilmesi

Eğitim 55648 adımda durdurulmuştur.

Şekil 4.4'de programın tek resim üzerinde aracın markasının tespiti gösterilmiştir. Aracın markası Toyota'dır. Program ise %99 oranında Toyota olarak tespit etmiştir.




Şekil 4.4. Programın resim içerisinde markayı tespiti

4.2 Model Tespiti

Araçların modellerinin tespitinin şekil bazlı yapılması amaçlanmıştır. Her modelin ayrı bir sınıf olarak belirlenmesinin yanı sıra şekil bazlı tespit olduğundan seçilen modellerden, aynı marka ve modelin farklı kasa tipe sahip olanları da farklı sınıf olarak nitelendirilmiştir. Model sınıfları yapay sinir ağları yöntemlerinden Faster-RCNN metodu ile eğitilmiştir. Eğitim aşamasından sonra eğitilmiş model hazırlanan program içerisinde kullanılmıştır. Sonuçların tespiti için hazırlanan materyal üzerinde program test edilmiştir. Elde edilen sonuçlar Çizelge haline getirilmiş ve raporlanmıştır.

Çalışma altı aşamadan oluşmaktadır. Şekil 4.5’de bu aşamalar gösterilmiştir.



Şekil 4.5. Araç Modelinin Tespit Edilmesi çalışmasının aşamaları

Modellerin belirlenmesi aşamasında uygulamanın hangi modelleri tespit edeceği hangilerini göz ardı edeceği belirlenmiştir. Hangi model araçtan trafikte kaç adet olduğunu gösteren bir istatistik bulunmadığından bu aşamada Çizelge 3.2 ‘de belirlenen markaların, Otomotiv Disbrütörleri Derneği’nin “Otomobil Ve H.Ticari Araç Pazarı Marka/Model Perakende Satışlar” (ODD, 2018) başlıklı çizelgesindeki en çok satış yapılan modeller referans alınmıştır. Çizelge 3.3’de belirlenen araç modelleri listelenmiştir.

Çizelge 3.3’den de görüldüğü gibi bazı modellerin farklı yıllardaki modelleri ardışıl dizilerle isimlendirilmiştir. Çizelge 3.3 baz alınarak 51 farklı sınıf belirlenmiştir.

Resim toplama ve etiketleme aşamasında resimlerin toplanması sağlanmıştır. Toplanan resimlerin etiketlemesi de bu aşamada yapılmıştır. Ön işlem aşamasında bu toplama ve etiketlemeden ayrıntılı olarak bahsedilmiştir.

Eğitim öncesi ayarlamalar aşamasında da eğitim öncesi bazı dosyaların derlenmesi ve düzenlenmesi gerekmektedir. Bu derleme ve düzenlemeler bu aşamada gerçekleşmiştir.

Eğitim aşamasında, modelin eğitimi yapılmıştır.

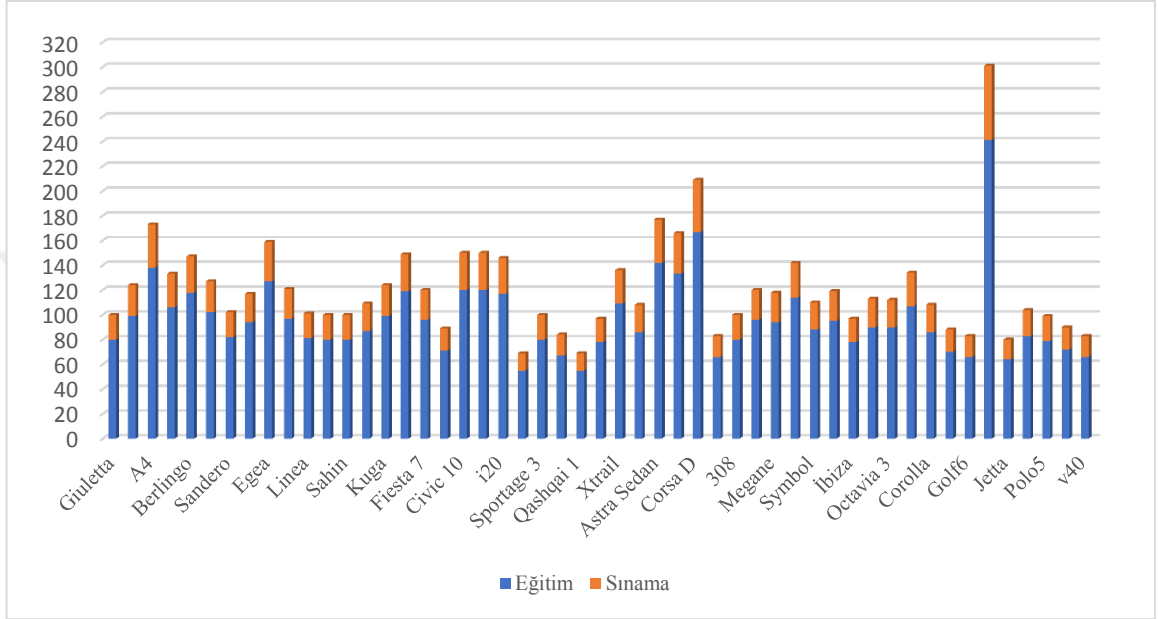
Test aşamasında eğitilen modelin test verileri üzerinde sınanması sağlanmıştır.

Rapor aşamasında ise test aşamasında elde edilen sonuçların belgelendirilip düzenlenmesi yapılmıştır.

4.2.1 Ön işlem aşaması

Ön işlem aşaması resim toplama ve etiketleme, eğitim öncesi ayarlamalar aşamalarını kapsamaktadır.

Ön işlem aşamasında eğitim aşaması için ortalama yaklaşık olarak her bir modelden 120 olmak üzere toplamda 6160 adet resim toplanmıştır. Bununla birlikte çalışmanın test edilmesi için bu resimlerden farklı olarak 2639 tane resim toplanmıştır. 6160 adet resmin **markalara** göre dağılımı Şekil 4.6'deki gibidir.



Şekil 4.6. Resim Sayılarının Modellere göre Dağılım Grafiği

Çizelge 3.4'de görüldüğü üzere toplamda 8799 adet resim çalışmada kullanılmak üzere toplanmıştır

Eğitim için toplanan resimlerin azami resim boyutu 2000x1300 olmakla birlikte azami dosya boyutu 461KB olmuştur. Eğitim aşaması için ortalama yaklaşık olarak her bir modelden 120 resim toplanmıştır.

Eğitim aşaması için toplanan resimlerden her bir modelin resim sayısının yüzde 80'i eğitim(train), yüzde 20'si sınama(test) olarak ayrılmıştır. Bu resimler test ve train adlı klasörlerde toplanmıştır. Eğitim aşaması için toplanan tüm resimler üzerinde aracın bulunduğu bölgenin işaretlenmesi gerekmektedir. İşaretleme sonucunda her resim dosyası için xml dosyası oluşturulur. Burada resmin boyutu, konumu, işaretlenen alanın koordinatları gibi bilgiler yer alır. Bu dosyalarının tamamının bilgileri de cvs dosyalarında tutulmuştur. Örnek dosya içeriği aşağıdaki gibidir;

```
filename,width,height,class,xmin,ymin,xmax,ymax
```

```
a3_001.jpg,300,225,a3,11,14,297,199
```

a3_002.jpg,300,225,a3,1,11,266,173

a3_003.jpg,300,225,a3,2,30,300,195

a3_004.jpg,300,225,a3,1,23,297,204

Dosya içeriği bu şekilde devam etmektedir. Bu çalışmada eğitim için 4946, test için 1214 veri kullanılmıştır.

4.2.2 Uygulama aşaması

Uygulama aşaması eğitim, test ve rapor aşamalarını kapsamaktadır.

Eğitim aşamasında eğitim öncesinde yapılan ayarlamalar sonucu eğitim Faster RCNN metodu baz alınarak başlatılır. Bu çalışmada eğitim aşamasında aşağıdaki özelliklere sahip bilgisayar kullanılmıştır. Bilgisayarda da eğitim GPU üzerinde gerçekleştirilmiştir. Eğitim aşamasında kullanılan bilgisayar özellikleri şunlardır;

- Intel Core i5 3230M 2,60Ghz Quad-Core İşlemci
- NVIDIA GeForce GT 740M 2 GB Ekran Kartı
- 8 GB DDR3 Ram
- 256 Gb SSD Hard Disk

Eğitilen modelin eğitim süresi yaklaşık olarak 73368 adım olarak 28 saat sürmüştür. Eğitim sonucunda dondurulmuş model elde edilmiştir.

Test aşamasında, eğitim sonucunda elde edilen dondurulmuş model yazılım içerisinde kullanılmıştır. Test için ayrılan 2638 tane resim üzerinde sınaama yapılmıştır.

Rapor aşamasında ise test aşamasında elde edilen sonuçlar çizelgelere kaydedilmiştir. Şekil 4.7’de model eğitimin gerçekleştirilirken çekilmiş ekran görüntüsü verilmiştir. Eğitim başlangıcında loss değerinin 6,0517 olduğu 18. Adımda 2,3637’ye indiği görülmektedir.



```

Komut İstemi - python train.py --logtostderr --train_dir=training/ --pipeline_config_path=training/faster_rcnn_inception_v2_pets.config
there could be performance gains if more memory were available.
2019-07-24 00:24:08.171316: W tensorflow/core/common_runtime/bfc_allocator.cc:237] Allocator (GPU_0_bfc) ran out of memory
trying to allocate 2.92GiB with freed_by_count=0. The caller indicates that this is not a failure, but may mean that
there could be performance gains if more memory were available.
2019-07-24 00:24:12.928696: W tensorflow/core/common_runtime/bfc_allocator.cc:237] Allocator (GPU_0_bfc) ran out of memory
trying to allocate 396.17MiB with freed_by_count=0. The caller indicates that this is not a failure, but may mean that
there could be performance gains if more memory were available.
2019-07-24 00:24:13.070695: W tensorflow/core/common_runtime/bfc_allocator.cc:237] Allocator (GPU_0_bfc) ran out of memory
trying to allocate 793.64MiB with freed_by_count=0. The caller indicates that this is not a failure, but may mean that
there could be performance gains if more memory were available.
I0724 00:24:13.176654 14604 supervisor.py:1050] Recording summary at step 0.
I0724 00:24:21.568097 9740 learning.py:507] global step 1: loss = 6.0517 (22.516 sec/step)
I0724 00:24:23.302406 9740 learning.py:507] global step 2: loss = 5.8431 (1.516 sec/step)
I0724 00:24:34.179727 9740 learning.py:507] global step 3: loss = 5.9802 (10.877 sec/step)
I0724 00:24:35.695301 9740 learning.py:507] global step 4: loss = 5.7741 (1.516 sec/step)
I0724 00:24:37.195253 9740 learning.py:507] global step 5: loss = 5.2577 (1.500 sec/step)
I0724 00:24:38.710829 9740 learning.py:507] global step 6: loss = 5.1335 (1.516 sec/step)
I0724 00:24:40.210777 9740 learning.py:507] global step 7: loss = 4.9708 (1.500 sec/step)
I0724 00:24:41.710727 9740 learning.py:507] global step 8: loss = 5.0206 (1.500 sec/step)
I0724 00:24:43.226302 9740 learning.py:507] global step 9: loss = 4.1969 (1.516 sec/step)
I0724 00:24:44.726253 9740 learning.py:507] global step 10: loss = 3.6111 (1.500 sec/step)
I0724 00:24:46.226205 9740 learning.py:507] global step 11: loss = 3.7028 (1.484 sec/step)
I0724 00:24:47.726155 9740 learning.py:507] global step 12: loss = 3.1450 (1.500 sec/step)
I0724 00:24:49.236367 9740 learning.py:507] global step 13: loss = 3.0207 (1.510 sec/step)
I0724 00:24:50.762958 9740 learning.py:507] global step 14: loss = 2.5409 (1.527 sec/step)
I0724 00:24:52.268525 9740 learning.py:507] global step 15: loss = 1.9830 (1.505 sec/step)
I0724 00:24:53.771386 9740 learning.py:507] global step 16: loss = 2.0481 (1.502 sec/step)
I0724 00:24:55.286961 9740 learning.py:507] global step 17: loss = 1.9143 (1.516 sec/step)
I0724 00:24:56.786911 9740 learning.py:507] global step 18: loss = 2.3637 (1.500 sec/step)

```

Şekil 4.7. Model Eğitimin Gerçekleştirilmesi

Eğitim 73368 adımda durdurulmuştur. Başlangıçta 6,0517 olan Total Loss değeri eğitim sonunda 0,1197'e kadar düşmüştür. Şekil 4.8'de total loss değerinin eğitim süresi boyunca değişimi grafiksel olarak verilmiştir. Şekil 4.8'de total loss değerinin genel düşüş eğiliminde olduğu görülebilmektedir



Şekil 4.8. Total Loss değerinin değişimi

Şekil 4.9'da programın tek resim üzerinde aracın modelinin tespiti gösterilmiştir. Araç Opel markasına ait Corsa modelinin D diye isimlendirilen kasasıdır. Program ise %99 oranında Corsa D olarak tespit etmiştir.



Şekil 4.9. Programın resim içerisinde araç modelini tespiti

5. SONUÇ VE TARTIŞMA

Markanın tespitinde Faster RCNN metodu kullanılmıştır. Faster RCNN metodunun farklı versiyonları geliştirilmiştir. Bu çalışmada bu versiyonlardan “Resnet 50” versiyonu kullanılmıştır.

Eğitim sonunda geliştirilen model test verileri üzerinde sınanmıştır. Ekde edilen sonuçlar özet çizelge (Çizelge 5.1) ve konfüsyon matrisi (Çizelge 5.2) çizelgelerinde gösterilmiştir.



Çizelge 5.1. Araç markasının Faster-RCNN ile tespitinde elde edilen sonuçlar

Marka	Resim Sayısı	Doğru Tahmin Sayısı	Yanlış Tahmin Sayısı	Doğru Oranı	Hata Oranı
Alfa Romeo	51	44	7	%86,27	%13,73
Audi	87	74	13	%85,06	%14,94
BMW	55	49	6	%89,09	%10,91
Citroen	53	52	1	%98,11	%1,89
Dacia Eski	50	39	11	%78,00	%22,00
Dacia Yeni	50	49	1	%98,00	%2,00
Fiat	51	50	1	%98,04	%1,96
Ford	86	66	20	%76,74	%23,26
Honda	55	54	1	%98,18	%1,82
Hyundai	69	57	12	%82,61	%17,39
Kia	52	46	6	%88,46	%11,54
Mercedes	55	49	6	%89,09	%10,91
Nissan	91	81	10	%89,01	%10,99
Opel	124	117	7	%94,35	%5,65
Peugeot	37	29	8	%78,38	%21,62
Renault	62	58	4	%93,55	%6,45
Seat	50	46	4	%92,00	%8,00
Skoda	50	46	4	%92,00	%8,00
Totota	49	44	5	%89,80	%10,20
Volkswagen	52	50	2	%96,15	%3,85
Volvo	51	47	4	%92,16	%7,84
Toplam	1280	1143	137	%89,76	%10,24

Çizelge 5.1’de araç markasının adı, araç markalarının bulunduğu resim sayısı, doğru tahmin sayısı, yanlış tahmin sayısı, doğru oranı ve hata oranı gibi alanlar bulunmaktadır. Markanın logosunun tespit edilemediği, yanlış tespit edildiği veya logonun bulunduğu bölgenin dışında bir yerde tespit ettiği gibi durumlar yanlış tahmin, marka logosunun bulunduğu bölge üzerinde ve doğru tespit edildiği durumlar doğru tahmin olarak işaretlenmiştir. Çizelge 5.1’den de görüldüğü üzere 10 markada %90 ve üzeri, 8 markada %80 ile %90 arasında, 4 markada %80’in altında doğru oranlarına ulaşmıştır.

Markaların tespitinde resimde hangi markanın bulunduğu, yazılımın hangi markayı tespit ettiği Çizelge 5.2’de konfüsyon matrisine aktarılmıştır. Çizelge 5.2’de çizelgenin okunabilirliğinin artırılması bakımından renk ölçekleri kullanılmıştır. Yüksek sayılar yeşil, düşük sayılar kırmızıdır.

Çizelge 5.2. Marka tespiti konfüsyon matrisi

	alfaromeo	audi	bmw	citroen	dacia_eski	dacia_yeni	fiat	ford	honda	hyundai	kia	mercedes	nissan	opel	peugeot	renault	seat	skoda	toyota	volkswagen	volvo	Boş
alfaromeo	44	0	2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2	1	2	0	0
audi	0	74	0	0	0	0	0	0	0	5	3	0	0	1	0	0	0	0	0	0	1	3
bmw	2	0	49	0	0	0	1	0	0	0	0	0	0	0	0	0	0	1	0	0	0	2
citroen	0	0	0	52	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1
dacia_eski	0	0	0	0	39	2	0	0	0	0	0	1	2	0	1	0	0	0	0	0	3	2
dacia_yeni	0	0	0	0	0	49	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1
fiat	0	0	0	0	0	0	50	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0
ford	0	0	0	0	0	0	0	66	0	1	17	0	0	0	0	0	0	0	0	0	1	1
honda	0	0	0	0	0	0	0	0	54	0	0	0	0	0	0	0	0	0	0	0	0	1
hyundai	0	0	2	0	0	0	0	3	1	57	5	0	0	1	0	0	0	0	0	0	0	0
kia	0	0	0	0	0	0	0	4	0	1	46	0	0	0	0	0	0	0	1	0	0	0
mercedes	0	0	0	0	0	0	0	0	0	0	0	49	0	6	0	0	0	0	0	0	0	0
nissan	0	0	0	1	0	0	0	1	0	1	0	0	81	4	0	0	0	0	0	0	3	0
opel	1	0	1	0	0	0	0	0	0	0	0	0	1	117	1	1	0	0	0	0	1	1
peugeot	1	0	0	2	0	0	0	0	1	1	0	0	0	0	29	0	0	0	0	0	1	2
renault	0	0	0	0	0	0	0	0	1	0	0	1	0	0	0	58	0	0	0	0	0	2
seat	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	46	0	0	0	0	3
skoda	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	46	1	2	0	0
toyota	0	0	0	0	0	0	0	2	0	0	0	0	1	1	0	0	0	0	44	0	0	1
volkswagen	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	50	0	1
volvo	0	0	0	0	0	0	0	0	0	0	0	0	1	3	0	0	0	0	0	0	47	0

Çizelge 5.2’ye bakıldığında çalışmanın hangi markalarda daha başarılı olduğu, hangi markalarda daha başarısız olduğu daha net görülmektedir. Çizelge 5.2’de görüldüğü üzere bazı markalarda başarı oranı çok yüksekken bazı markalarda başarı oranı daha düşüktür. Başarı oranı düşük olan bu markalar genel başarı oranını da düşürmüştür. Örneğin çalışmada

geliştirilen yazılım 4 araç markasında kullanılan resimler içerisinde sadece birer tane yanlış tespitte bulunmuştur. Bununla birlikte Ford markasının bulunduğu 86 resimden, 66 tanesinde araç markasını doğru tespit ederken, 20 tanesinde farklı markaları tespit etmiştir. Ford markasının yanlış tespit ettiği resimlerinden 17 tanesinde markayı şeklen Ford markasına benzeyen Kia markasına benzetmiştir.

Şekil 5.1. Modelin Ford markası ve Kia markasından ayırt edememesine örnek resimler gösterilmiştir. Şekil 5.1'den de görüldüğü üzere Kia markası ile Ford markasının şekilleri oldukça benzerdir. İki markanın şekli de elipstir.



Şekil 5.1. Modelin Ford markası ve Kia markasından ayırt edememesine örnek

Marka tespitinde elde edilen sonuçlar daha önce yapılan çalışma ve yaklaşımlarla karşılaştırılmıştır. Çizelge 5.3 belirtilen yaklaşımlar ve açıklamaları şu şekildedir;

BoF(Sivic ve Zisserman, 2003): BoF metodu SIFT(Lowe, 2004)'i yerel özellik olarak olduğu gibi çıkarır ve denetimsiz bir yolda k-means aracılığıyla SIFT kod defterini öğrenir. SIFT çözümlesinin yapıldığı sırada SIFT özelliği kod defterindeki bir kelime ile ilişkilendirilir. BoF'un resim sunumu sum-pooling ve araç sınıflandırmasında için kullanılan doğrusal SVM ile oluşturulmuştur. BoF'da yerel tanımlayıcılarda mekansal bilgi atılır. SIFT özellikleri her 4 pikseklik yamalar şeklinde 16x16, 24x24 ve 32x32 boyutlarındaki parçalardan çıkartılır. SIFT kod defterinin boyutu 1024'tür.

SPM: Yerel tanımlayıcılardaki uzamsal bilgiyi BoF temelli kullanır. SPM (Lazebnik ve ark., 2006) görüntüyü piramit ızgaralar şeklinde böler(1×1 , 2×2 ve 4×4) ve Her ızgara için ayrı ayrı bölge temsilini hesaplar. SPM'nin son görüntü gösterimi tüm bölge özelliklerinin birleştirilmesidir. Doğrusal SVM; SPM temelli resim gösterimini temel alan araba sınıflandırma için kullanılır.

LLC: BoF ve SPM'de her bir SIFT özelliği, kod defterinde bir kelimeye atanır. Bu da büyük miktar hatasına neden olur. LLC metodu (Wang ve ark., 2010) kod defterindeki birden fazla kelimeye SIFT özelliği atar. Bu sayede SIFT özelliği için en iyi kodları elde ederek

büyük miktar hatasını en aza indirir. LLC'nin yapısı max-pooling ve araba sınıflandırması için kullanılan SVM ile oluşturulmuştur. LLC'nin SIFT özellikleri ve kod defteri BoF ile aynıdır.

Discriminative Patch: Discriminative Patch(Singh ve ark., 2012) yöntemi ayırt edici orta seviye görüntü özelliklerini denetimsiz yoldan öğrenir. Discriminative Patch yöntemi için çok ölçekli HOG özellikleri kullanılır. Otomobilin tanınması için 1000 farklı desen öğrenilir.

CNN: Yukarıdaki yöntemlerin yanı sıra, önerilen yöntemler HOG ve SIFT gibi el yapımı özelliklere dayanmaktadır. CNN (LeCun ve ark., 1989) ise görüntü sınıflandırma için özellikleri öğrenir. Büyük ölçekli nesne tanıma için üst düzey performans sergilemektedir.

Çizelge 5.3. Çalışmanın yapılmış diğer çalışmalarla karşılaştırılması (Hu ve ark., 2015)

Marka	Audi	BMW	Mercedes	Honda	KIA	Peugeot	Toyota
LLC+SPM	<u>0,93</u>	<u>0,94</u>	<u>0,97</u>	0,67	0,72	<u>0,97</u>	0,57
LLC	0,77	0,79	0,78	0,43	0,53	0,88	0,38
BoF+SPM	0,83	0,85	0,89	0,50	0,59	0,90	0,41
BoF	0,65	0,70	0,67	0,35	0,44	0,77	0,29
CNN	<u>0,93</u>	<u>0,94</u>	<u>0,97</u>	0,67	0,59	<u>0,97</u>	0,43
Disc. Patch	0,75	0,79	0,66	0,18	0,22	0,72	0,20
Bu Çalışma	0,85	0,89	0,89	0,98	0,88	0,78	0,90
Marka	Nissan	Skoda	Hyundai	Citroen	Volkswagen	Ford	Ortalama
LLC+SPM	0,78	<u>0,97</u>	0,63	0,94	0,63	<u>0,83</u>	0,81
LLC	0,56	0,84	0,39	0,79	0,41	0,64	0,63
BoF+SPM	0,64	0,93	0,47	0,84	0,46	0,65	0,69
BoF	0,45	0,75	0,31	0,65	0,34	0,48	0,53
CNN	0,55	0,89	0,39	0,77	0,63	0,59	0,72
Disc. Patch	0,16	0,76	0,13	0,12	0,38	0,32	0,41
Bu Çalışma	0,89	0,92	0,83	0,98	0,96	0,77	0,89

Çizelge 5.3'de bu çalışma, yapılan önceki çalışmalara karşılaştırılmıştır. Çizelge 5.3'de her bir markada en yüksek başarı oranına sahip değer/değerler altı çizilerek belirtilmiştir. Çizelge 5.3'den görüldüğü üzere bu çalışma, karşılaştırması yapılan 13 markadan 7 tanesinde en yüksek başarı oranını yakalamıştır. Bununla birlikte 4 markada diğer çalışmalar en yüksek başarı oranını yakalamıştır. Karşılaştırması yapılan 13 markanın genel başarısında ise bu çalışma %89 ile en yüksek başarı oranına sahiptir.

Marka tespitini yapan başka bir çalışmada (Eski, 2008) elde edilen sonuçlar Çizelge 5.4'de karşılaştırılmıştır.

Çizelge 5.4 Marka tespitinde yapılan başka bir çalışma (Eski, 2008) ile karşılaştırılması

Marka	Başarı Oranları		Marka	Başarı Oranları	
	Eski(2008)	Bu Çalışma		Eski(2008)	Bu Çalışma
Audi	%76,90	<u>%85,06</u>	Nissan	%83,70	<u>%89,01</u>
BMW	%87,80	<u>%89,09</u>	Opel	%93,00	<u>%94,35</u>
Citroen	%71,70	<u>%98,11</u>	Peugeot	<u>%95,70</u>	%78,38
Dacia	%90,00	<u>%98,00</u>	Renault	<u>%95,00</u>	%93,55
Fiat	%93,40	<u>%98,04</u>	Seat	%88,20	<u>%92,00</u>
Ford	<u>%96,20</u>	%76,74	Skoda	%83,60	<u>%92,00</u>
Honda	%88,80	<u>%98,18</u>	Toyota	<u>%93,20</u>	%89,80
Hyundai	<u>%84,40</u>	%82,61	Volkswagen	%95,10	<u>%96,15</u>
Kia	%80,00	<u>%88,46</u>	Volvo	%66,60	<u>%92,16</u>
Mercedes	%88,20	<u>%89,09</u>	Genel Ortalama	%86,92	<u>%90,57</u>

Çizelge 5.4 incelendiğinde Eski'nin çalışmasında (2008) ortak çalışılan modellerin genel başarı oranı %86,92 olmuştur. Bu çalışmanın başarısı ise %90,57'dir. Çalışılan markalardan elde edilen sonuçlara göre daha yüksek başarı elde eden değer altı çizilmiştir. Bu tez çalışmasında geliştirilen metot 20 markadan 14'ünde üstünlük sağlarken, Eski'nin çalışması 6 markada üstünlük sağlamıştır. Genel ortalamada ise bu çalışmada geliştirilen metot üstünlük sağlamıştır.

Araç modelin tespitinde Faster RCNN metodu kullanılmıştır. Faster RCNN metodunun farklı versiyonları geliştirilmiştir. Bu çalışmada bu versiyonlardan "Resnet 50" versiyonu kullanılmıştır.

Eğitim sonunda geliştirilen model test verileri üzerinde sınanmıştır. Elde edilen sonuçlar özet çizelge (Çizelge 5.5) ve konfüsyon matrisi (Çizelge 5.6) çizelgelerinde gösterilmiştir.

Çizelge 5.5. Araç modelinin tespitinde elde edilen sonuçlar

Marka	Model	Resim Sayısı	Doğru Tahmin Sayısı	Yanlış Tahmin Sayısı	Doğru Oranı	Hata Oranı
Alfa Romeo	Giuletta	53	39	14	%73,58	%26,42
Audi	A3	50	7	43	%14,00	%86,00
Audi	A4	51	45	6	%88,24	%11,76
BMW	5 Serisi	50	28	22	%56,00	%44,00
Citroen	Berlingo	50	35	15	%70,00	%30,00
Citroen	C-Elysee	52	19	33	%36,54	%63,46
Dacia	Sandero	50	42	8	%84,00	%16,00
Dacia	Duster	51	33	18	%64,71	%35,29
Fiat	Egea	52	21	31	%40,38	%59,62
Fiat	Doblo	58	57	1	%98,28	%1,72
Fiat	Linea	51	19	32	%37,25	%62,75
Fiat	Fiorino	50	45	5	%90,00	%10,00
Fiat	Sahin	60	29	31	%48,33	%51,67
Ford	Focus Sedan	52	31	21	%59,62	%40,38
Ford	Kuga	50	48	2	%96,00	%4,00
Ford	Tourneo	50	47	3	%94,00	%6,00
Ford	Fiesta 7	61	42	19	%68,85	%31,15
Honda	Civic 9	50	11	39	%22,00	%78,00
Honda	Civic 10	50	31	19	%62,00	%38,00
Hyundai	Accent Blue	50	29	21	%58,00	%42,00
Hyundai	i20	51	40	11	%78,43	%21,57
Hyundai	Tucson 3	50	38	12	%76,00	%24,00
Kia	Sportage 3	50	35	15	%70,00	%30,00
Mercedes	E180	50	44	6	%88,00	%12,00
Nissan	Qashqai 1	52	17	35	%32,69	%67,31
Nissan	Qashqai 2	50	43	7	%86,00	%14,00
Nissan	Xtrail	50	45	5	%90,00	%10,00
Opel	Astra HB K	58	34	24	%58,62	%41,38
Opel	Astra Sedan	51	41	10	%80,39	%19,61
Opel	Corsa B	58	52	6	%89,66	%10,34
Opel	Corsa D	50	48	2	%96,00	%4,00
Peugeot	3008	50	45	5	%90,00	%10,00
Peugeot	308	50	28	22	%56,00	%44,00
Peugeot	301	51	26	25	%50,98	%49,02
Renault	Megane	54	53	1	%98,15	%1,85
Renault	Clio	50	44	6	%88,00	%12,00
Renault	Symbol	53	28	25	%52,83	%47,17

Seat	Leon	51	48	3	%94,12	%5,88
Seat	İbiza	52	34	18	%65,38	%34,62
Skoda	Fabia 3	50	42	8	%84,00	%16,00
Skoda	Octavia 3	51	45	6	%88,24	%11,76
Skoda	Superb	50	32	18	%64,00	%36,00
Toyota	Corolla	50	28	22	%56,00	%44,00
Toyota	CHR	50	38	12	%76,00	%24,00
Volkswagen	Golf6	52	24	28	%46,15	%53,85
Volkswagen	Golf7	58	51	7	%87,93	%12,07
Volkswagen	Jetta	50	37	13	%74,00	%26,00
Volkswagen	Passat	52	50	2	%96,15	%3,85
Volkswagen	Polo5	50	36	14	%72,00	%28,00
Volvo	s60	50	42	8	%84,00	%16,00
Volvo	v40	54	17	37	%31,48	%68,52
	Toplam	2639	1840	799	%69,72	%30,28

Çizelge 5.5’de araç markasının adı, modeli araç modelinin bulunduğu resim sayısı, doğru tahmin sayısı, yanlış tahmin sayısı, doğru oranı ve hata oranı gibi alanlar bulunmaktadır. Araç modelinin tespit edilemediği, yanlış tespit edildiği veya aracın bulunduğu bölgenin dışında bir yerde tespit ettiği gibi durumlar yanlış tahmin, aracın bulunduğu bölge üzerinde ve doğru tespit edildiği durumlar doğru tahmin olarak işaretlenmiştir. Çizelge 5.5’den de görüldüğü üzere yazılım tüm araçların %69,72’lik kısmını doğru olarak tespit etmiş %30,28’lik kısmını ise yanlış tespit etmiştir.

Araç modelinin tespitinde resimde hangi modelin bulunduğu, yazılımın hangi modeli tespit ettiği Çizelge 5.6’de konfüsyon matrisine aktarılmıştır.

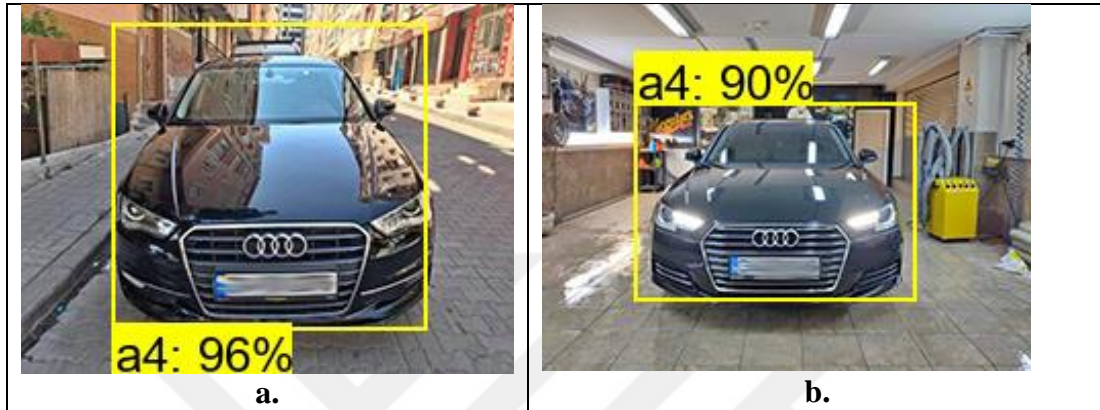
Çizelge 5.6'e bakıldığında çalışmanın hangi modellerde daha başarılı olduğu, hangi modellerde başarısız olduğu daha net görülmektedir. Çizelge 5.6'de görüldüğü üzere bazı modellerde başarı oranı çok yüksekken bazı araç modellerinde başarı oranı çok düşüktür. Örneğin çalışmada geliştirilen yazılım Fiat firmasına ait Doblo modelinin bulunduğu 58 resim üzerinden 57 tanesinde; resim içerisinde bulunan aracın Doblo olduğunu, 1 tanesinde ise Polo5 olduğunu tespit etmiştir. Benzer şekilde yazılım Volkswagen firmasına ait Golf 7 modelinin bulunduğu 58 resimden 51 tanesinde aracın Golf 7 olduğunu tespit etmiş, 2 tanesinde yine Volkswagen firmasına ait Passat modeline benzetmiş, 2 tanesinde Seat İbiza, 2 tanesinde Skoda Fabia, 1 tanesinde ise Seat Leon modeline benzetmiştir. Şekil 5.2'de yazılımın doğru tespit ettiği araç modellerine örnek resimler gösterilmiştir.





Şekil 5.2. Yazılımın doğru şekilde tespit ettiği araç modelleri

Yazılımın tespit edemediği, yanlış tespit ettiği; kısaca başarı oranının düşük olduğu modeller incelenecek olursa; Audi A3 modeli %14 gibi düşük bir başarı oranına sahiptir. Çizelge 5.6'deki konfüsyon matrisi incelendiği görülmektedir ki; yazılım Audi A3'ün bulunduğu 50 resim içerisinde 7 tanesinde A3, 22 tanesinde ise aynı markanın bir üst modeli olan A4 modeline benzetmiştir. Şekil 5.3'de Audi A3 ve A4 modelleri gösterilmiştir

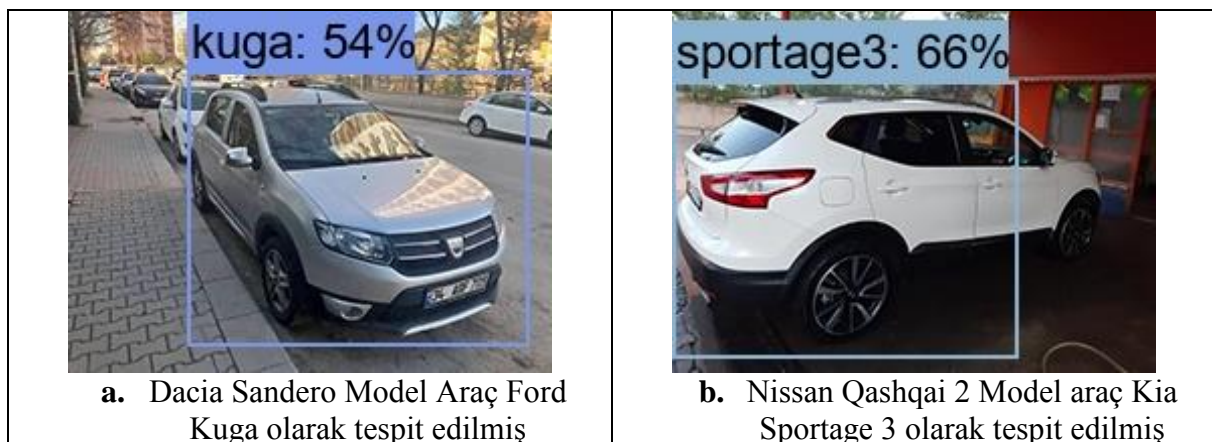


Şekil 5.3. Audi A3 ve A4 modellerinin gösterimi

Yazılım Şekil 5.3'deki araçlardan a. aracını %96 oranında A4, b. aracını %90 oranında A4 olarak tanımlamıştır. Fakat a. aracı Audi A3, b. aracı ise Audi A4'tür.

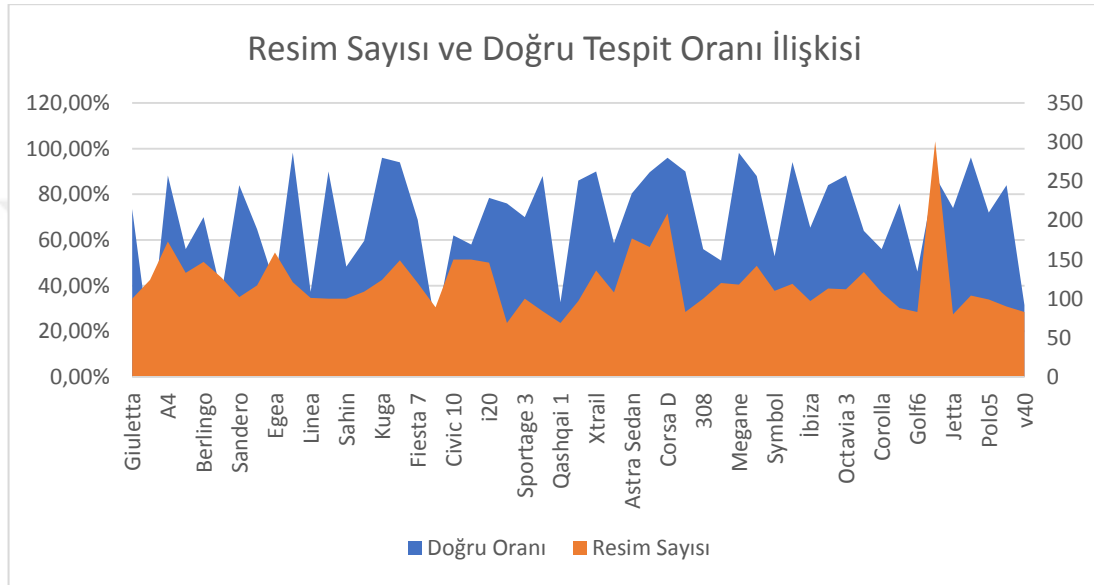
Yazılımın başarı oranının düşük olduğu bir diğer model ise Honda markasının Civic 9 modelidir. Honda Civic 9; firmanın 2013 ve 2016 yılları arasında çıkardığı araç modelidir(Auto-Data, 2019). Yazılım Honda Civic 9'un bulunduğu 50 resimden 10 tanesinde doğru tespit yapmış. 40 resimde çeşitli araçları yanlış tespit etmiştir.

Şekil 5.4'de yanlış tespit edilen araçlara örnek resimler bulunmaktadır.



Şekil 5.4. Yazılımın hatalı tespit ettiği resimler

Bununla birlikte Çizelge 3.4'deki Golf 6, Civic 9, Qashqai 1 gibi araçların eğitim için toplanan resim sayılarına bakıldığında az sayıda örnekleme ve sonuçlarda düşük başarı oranlarının olduğu görülmektedir. Benzer şekilde Opel Corsa B, Opel Corsa D, Volkswagen Golf 7 gibi araçların eğitim için toplanan resim sayılarına bakıldığında da yüksek sayıda örnekleme ve yüksek başarı oranlarının olduğu görülmektedir. Çizelge 3.4'de listelenen resim sayıları ile Çizelge 5.5'de listelenen doğru tespit oranı ilişkisi Şekil 5.5'de gösterilmiştir.



Şekil 5.5. Resim Sayısı ve Doğru Oranı İlişkisi

Şekil 5.5 incelediğinde resim sayısı ile doğru tespit arasındaki doğru oran görülmektedir.

Model tespitinde daha önceki yapılan çalışmalardan Tuna'nın çalışmasında (Tuna, 2011) 3 marka markada elde edilen sonuçlar paylaşılmıştır Toyota Corolla için % 99.546, Volkswagen Passat için % 99.784 ve Renault Megane için % 98.351 olduğunu belirtmektedir. Fakat çalışmasında elde edilen sonuçlar tek resim üzerinden elde edilen sonuçlardır. Bu yüzden karşılaştırma imkânı yoktur.

5.1 Değerlendirme

Sonuçlardan da görüldüğü üzere yapay sinir ağlarıyla Faster-RCNN metodu kullanılarak gerçekleştirilen marka tespitinde %89,76 olmuştur. Markaların eğitiminde kullanılan resimler artırılarak, marka logosunun daha net gözüktüğü resimler kullanılarak daha iyi bir dondurulmuş model elde edilebilir. Kullanılan resimler, yapılacak olan uygulamaya ne kadar benzer olursa alınacak sonuçlar da o denli yüksek olacaktır. Örneğin yol üzerinde geçen araçların markalarını tespit eden bir uygulama yapılmak istenirse; araçların geçtiği yol üzerine kurulan sabit bir kamera ile sabit açıdan görüntü alınıp ve bu görüntüler eğitim aşamasında kullanıldığında uygulamanın başarısı çok daha yüksek olacaktır. Ford ve Kia markaları gibi şekil olarak benzeyen markaların eğitiminde resim sayıları fazla tutularak başarı oranı artırılabilir.

Marka tespitinde çalışmanın daha önce yapılan ve karşılaştırılan çalışmalara göre daha başarılı olduğu görülmektedir.

Model tespitinde genel başarı oranı %69,72 olmuştur. Model eğitiminde araçların her açıdan çekilmiş görüntüleri kullanılmıştır. Bu başarı oranını düşürmüştür. Model tespitinde aracın genel görüntüsünden çok aracın tek bir yönüne odaklanıp standart olarak eğitilen ve onun üzerine geliştirilen uygulamalar daha faydalı olacaktır.

Faster RCNN şekil bazlı bir model olduğundan birbirine çok benzeyen araçların tek bir yönüne(far, belirgin bir bölüm) odaklanıp resimlerin o yönde eğitilmesi nispeten daha iyi sonuçlar sağlayacaktır. Şekil 5.5'ten de görüldüğü üzere eğitime katılan resim sayısı arttıkça daha iyi sonuçlar edinilmektedir. Bu sebeple örnekleme sayısı artırılırsa daha iyi sonuçlar elde edilebilir.

Model tespitinde endüstriye yönelik uygulamalarda aracın farklı açılardan çekilmiş resimlerden ziyade aracın tek bir yönüne odaklanıp, tek bir kameradan sabit bir açıyla çekilmiş görüntüler eğitim aşamasında kullanılırsa ve geliştirilen bu model aynı kameradan ve aynı açıyla çekilen görüntülere uygulanırsa yüksek doğrulukta sonuçlar elde edilebilir. Örneğin yol üzerinde araçları tepeden gören bir kameradan görüntüler alınıp bu görüntülerin etiketlenmesi, eğitimi yapılırsa daha yüksek oranda başarı oranı sağlanacaktır.

KAYNAKLAR

- Auto-Data, 2019, Honda Civic, <https://www.auto-data.net/tr/honda-civic-model-1307/>: [25.07.2019].
- Bingöl, O. ve Kuşçu, Ö., 2008, Bilgisayar Tabanlı Araç Plaka Tanıma Sistem, *Bilişim Teknolojileri Dergisi*, 1 (3).
- Çevik, K. K. ve Çakır, A., 2011, Görüntü İşleme Yöntemleriyle Araç Plakalarının Tanınarak Kapı Kontrolünün Gerçekleştirilmesi, *AKÜ Fen Bilimleri Dergisi* 2010 (01).
- Dehghan, A., Zain Masood, S., Shu, G. ve Ortiz, E. G., 2017. View Independent Vehicle Make, Model and Color Recognition Using Convolutional Neural Network. arXiv e-prints. Erişim Adresi, <https://ui.adsabs.harvard.edu/#abs/2017arXiv170201721D>.
- Du, D., Qi, Y., Yu, H., Yang, Y., Duan, K., Li, G., Zhang, W., Huang, Q. ve Tian, Q., 2018. The Unmanned Aerial Vehicle Benchmark: Object Detection and Tracking. arXiv e-prints. Erişim Adresi, <https://ui.adsabs.harvard.edu/#abs/2018arXiv180400518D>.
- Eski, S., 2008, Görüntü İşleme Yöntemleri ile Araç Marka ve Türlerinin Tanınması, *İstanbul Teknik Üniversitesi*, 53.
- Fuad Rachmadi, R. ve Ketut Eddy Purnama, I., 2015. Vehicle Color Recognition using Convolutional Neural Network. arXiv e-prints. Erişim Adresi, <https://ui.adsabs.harvard.edu/#abs/2015arXiv151007391F>.
- Heitz, G. ve Koller, D., 2008, Learning Spatial Context: Using Stuff to Find Things, Berlin, Heidelberg, 30-43.
- Hu, C., Bai, X., Qi, L., Wang, X., Xue, G. ve Mei, L., 2015, Learning Discriminative Pattern for Real-Time Car Brand Recognition, *IEEE Transactions on Intelligent Transportation Systems*, 16 (6), 3170-3181.
- Karaimar, H. C., Cinaroglu, I. ve Bastanlar, Y., 2015, Combining shape-based and gradient-based classifiers for vehicle classification, *2015 Ieee 18th International Conference on Intelligent Transportation Systems*, 800-805.
- Kısa, M. ve Borsalı, F. M., 2015, Bir Aracın Önünde Seyreden Aracın Uzaklığının Tek Kamera Kullanarak Tahmini, *İzmir, Uluslararası Katılımlı 17. Makina Teorisi Sempozyumu*, 5.
- Koon Cheang, T., Shean Chong, Y. ve Haur Tay, Y., 2017. Segmentation-free Vehicle License Plate Recognition using ConvNet-RNN. arXiv e-prints. Erişim Adresi, <https://ui.adsabs.harvard.edu/#abs/2017arXiv170106439K>.
- Krizhevsky, A., Sutskever, I. ve Hinton, G. E., 2012, ImageNet classification with deep convolutional neural networks. Proceedings of the 25th International Conference on

- Neural Information Processing Systems - Volume 1. Lake Tahoe, Nevada, Curran Associates Inc.: 1097-1105.
- Lazebnik, S., Schmid, C. ve Ponce, J., 2006, Beyond Bags of Features: Spatial Pyramid Matching for Recognizing Natural Scene Categories, *2006 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'06)*, 2169-2178.
- LeCun, Y., Boser, B., Denker, J. S., Henderson, D., Howard, R. E., Hubbard, W. ve Jackel, L. D., 1989, Backpropagation Applied to Handwritten Zip Code Recognition, *Neural Computation*, 1 (4), 541-551.
- Leitloff, J., Rosenbaum, D., Kurz, F., Meynberg, O. ve Reinartz, P., 2014, An Operational System for Estimating Road Traffic Information from Aerial Images, *Remote Sensing*, 6 (11), 11315-11341.
- Lowe, D. G., 2004, Distinctive Image Features from Scale-Invariant Keypoints, *Int. J. Comput. Vision*, 60 (2), 91-110.
- Nazemi, A., Javad Shafiee, M., Azimifar, Z. ve Wong, A., 2018. Unsupervised Feature Learning Toward a Real-time Vehicle Make and Model Recognition. arXiv e-prints. Erişim Adresi, <https://ui.adsabs.harvard.edu/#abs/2018arXiv180603028N>.
- ODD, 2018, Otomobil Ve H.Ticari Araç Pazarı Marka/Model Perakende Satışlar (Aralık'2018)
(RETAIL PC & LCV BRAND SALES December'2018)
Turkey.
- Ogier du Terrail, J. ve Jurie, F., 2018. Faster RER-CNN: application to the detection of vehicles in aerial images. arXiv e-prints. Erişim Adresi, <https://ui.adsabs.harvard.edu/#abs/2018arXiv180907628O>.
- OpenCV, 2019, About, <https://opencv.org/about.html>: [17.02.2019].
- Özbay, S., 2006, AUTOMATIC VEHICLE IDENTIFICATION BY PLATE RECOGNITION
Gaziantep University.
- Płaczek, B., 2011. Vehicles Recognition Using Fuzzy Descriptors of Image Segments. arXiv e-prints. Erişim Adresi, <https://ui.adsabs.harvard.edu/#abs/2011arXiv1112.4064P>.
- Python, 2010, Python, *Booklist*, 106 (21), 56.
- Razakarivony, S. ve Jurie, F., 2015, Vehicle Detection in Aerial Imagery : A small target detection benchmark, *Journal of Visual Communication and Image Representation*.
- Ren, S., He, K., Girshick, R. ve Sun, J., 2015. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. arXiv e-prints. Erişim Adresi, <https://ui.adsabs.harvard.edu/#abs/2015arXiv150601497R>.

- Saghaei, H., 2016. Proposal for Automatic License and Number Plate Recognition System for Vehicle Identification. arXiv e-prints. Erişim Adresi, <https://ui.adsabs.harvard.edu/#abs/2016arXiv161003341S>.
- Singh, S., Gupta, A. ve Efros, A. A., 2012, Unsupervised Discovery of Mid-Level Discriminative Patches, Berlin, Heidelberg, 73-86.
- Sivic ve Zisserman, 2003, Video Google: a text retrieval approach to object matching in videos, *Proceedings Ninth IEEE International Conference on Computer Vision*, 1470-1477 vol.1472.
- Sochor, J., Špaňhel, J. ve Herout, A., 2017. BoxCars: Improving Fine-Grained Recognition of Vehicles using 3-D Bounding Boxes in Traffic Surveillance. arXiv e-prints. Erişim Adresi, <https://ui.adsabs.harvard.edu/#abs/2017arXiv170300686S>.
- Soleimani, A., Nasrabadi, N. M., Griffith, E., Ralph, J. ve Maskell, S., 2018. Convolutional Neural Networks for Aerial Vehicle Detection and Recognition. arXiv e-prints. Erişim Adresi, <https://ui.adsabs.harvard.edu/#abs/2018arXiv180808560S>.
- Tensorflow, 2018, About TensorFlow, [29.11.2018].
- Tuna, G., 2011, Çok Markalı Servis İstasyonları için Yapay Sinir Ağları ile Görüntü Tabanlı Araç Marka ve Modeli Tanıma Yazılımı, *BAÜ Fen Bil. Enst. Dergisi*, 13, 13.
- TÜİK, 2017, Markalara göre trafiğe kaydı yapılan otomobil sayısı. İstatistikleri, M. K. T., TÜİK.
- Ülker, B., 2015, AUTOMATIC VEHICLE DETECTION AND OCCLUSION HANDLING AT ROAD INTERSECTIONS, *MIDDLE EAST TECHNICAL UNIVERSITY*.
- Vaquero, V., Pino, I. d., Moreno-Noguer, F., Solà, J., Sanfeliu, A. ve Andrade-Cetto, J., 2017, Deconvolutional networks for point-cloud vehicle detection and tracking in driving scenarios, *2017 European Conference on Mobile Robots (ECMR)*, 1-7.
- Wang, J., Yang, J., Yu, K., Lv, F., Huang, T. S. ve Gong, Y., 2010, Locality-constrained Linear Coding for image classification, *2010 IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 3360-3367.
- Watkins, R., Pears, N. ve Manandhar, S., 2018. Vehicle classification using ResNets, localisation and spatially-weighted pooling. arXiv e-prints. Erişim Adresi, <https://ui.adsabs.harvard.edu/#abs/2018arXiv181010329W>.

6. ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Mehmet Furkan KUNDURACI
Uyruğu : TC
Doğum Yeri ve Tarihi : Meram / 16.08.1990
Telefon : 0541 329 05 61
Faks :
e-mail : furkankunduraci@gmail.com

EĞİTİM

Derece	Adı, İlçe, İl	Bitirme Yılı
Lise	: Fatih Endüstri Meslek Lisesi	2007
Üniversite	: Selçuk Üniversitesi	2012

İŞ DENEYİMLERİ

Yıl	Kurum	Görevi
2018-	Türkiye Gazetesi Mesleki ve Teknik Anadolu Lisesi	Öğretmen
2017-2018	İstanbul İTO Bilim ve Sanat Merkezi	Öğretmen
2016-2017	Türk Telekom Mesleki ve Teknik Anadolu Lisesi	Öğretmen
2013-2016	Siverek Vakıf Ortaokulu	Öğretmen

UZMANLIK ALANI

Görüntü işleme, Nesne Tanıma Sistemleri

YABANCI DİLLER

İngilizce