



**YOL AĞINDAKİ YAPISAL KUSURLARIN KÜRESEL
ÖLÇEKLİ OTOMATİK YOL KUSUR TESPİT
SİSTEMİ İLE BELİRLENMESİ VE
SINIFLANDIRILMASI**

Ömer KAYA

Doktora Tezi

İnşaat Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Muhammed Yasin ÇODUR

2023

Her hakkı saklıdır.



FEN BİLİMLERİ ENSTİTÜSÜ
DOKTORA TEZİ

**YOL AĞINDAKİ YAPISAL KUSURLARIN KÜRESEL ÖLÇEKLİ OTOMATİK
YOL KUSUR TESPİT SİSTEMİ İLE BELİRLENMESİ VE
SINIFLANDIRILMASI**

Ömer KAYA

Tez Danışmanı: Doç. Dr. Muhammed Yasin ÇODUR

Anabilim Dalı: İnşaat Mühendisliği

Erzurum

2023

Her hakkı saklıdır.

ETİK KURALLARA UYGUNLUK BEYANI

Erzurum Teknik Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım bu tez içindeki tüm bilgilerin doğru ve tam olduğunu, bilgilerin üretilmesi aşamasında bilimsel etiğe uygun davrandığımı, yararlandığım bütün kaynakları atıf yaparak belirttiğimi beyan ederim.

29 / 12 / 2023

İmzası

Ömer KAYA

ÖZET

DOKTORA TEZİ

YOL AĞINDAKİ YAPISAL KUSURLARIN KÜRESEL ÖLÇEKLİ OTOMATİK YOL KUSUR TESPİT SİSTEMİ İLE BELİRLENMESİ VE SINIFLANDIRILMASI

Ömer KAYA

Erzurum Teknik Üniversitesi

Fen Bilimleri Enstitüsü

İnşaat Mühendisliği Ana Bilim Dalı

Danışman: Doç. Dr. Muhammed Yasin ÇODUR

Yol ağları farklı üstyapı tasarımları ile oluşturulmaktadır. Genel olarak dünyada en çok kullanılan üstyapı türü olarak esnek kaplama tercih edilmektedir. Bu üstyapıya sahip yol ağları; yol altyapısının hazır olmaması, bitümlü karışımlarda kullanılan bitümün uygulama alanı ile uyumsuzluğu, agrega bitüm oranında yapılan hatalar, döküm sıcaklığı, yetersiz silindir işlemi, kalifiyesiz eleman, mevsimsel değişkenlikler, kar ve buz ile mücadele yöntemleri, trafik hacmi, yetersiz bakım ve onarım süreçleri gibi nedenlerden dolayı bozulmalar yaşamaktadır. Bu bozulmalar zaman içerisinde farklı formlar alarak yol kusurlarını oluşturmaktadır. Kusurların belirlenme süreci yol kaplamasının verimliliği ve trafik bileşenleri için çok önemlidir. Bu tez çalışmasında esnek üst yapıli yol ağlarında meydana gelen yol kusurlarının otomatik olarak belirlenmesi ve sınıflandırılması süreci akıllı bir sistem ile gerçekleştirilmiştir. Sekiz farklı ülkeden elde edilen yol görüntüleri ve 10 farklı yol kusuru çalışma kapsamında dikkate alınmıştır. Kusurlarının algılanma sürecinde YOLOv5, YOLOv7 ve YOLOv8 algılama modelleri kullanılmıştır. Ayrıca farklı ülkelerden oluşan veri seti kapsamında küresel ölçekli otomatik yol kusur belirleme sistemi geliştirilmiştir. Geliştirilen sistemin bir prototip olduğu ve yol ağlarında meydana gelen kusurların gerçek zamanlı olarak algılama ve sınıflama yeteneğine sahiptir. Belirlenen kusurların konum bilgileri de elde edilerek sistemin yol ağı sorumluları için kılavuz olacağı açıktır. Geliştirilen sistem ile yol kusurlarının algılanması, sınıflandırılması ve yerlerinin belirlenmesi yol ağlarının bakım ve onarım sürecini hızlandıracağı gibi hizmet ömrünü de uzatacaktır. Yol ağını kullanan trafik bileşenlerinin yol güvenliği ve konforu da artırılmış olacaktır. Sonuç olarak bir akıllı ulaşım sistemleri uygulama biçimi olan araç-altyapı (V2I) iletişim örneği tez kapsamında sunulmuştur.

2023, 298 sayfa

Anahtar Kelimeler: Kusur tespiti, gerçek zamanlı algılama, gömülü sistem, kusur konumu

ABSTRACT

Ph.D

IDENTIFICATION AND CLASSIFICATION OF STRUCTURAL DEFECTS IN THE ROAD NETWORK USING A GLOBAL SCALE AUTOMATIC ROAD DEFECT DETECTION SYSTEM

Ömer KAYA

Erzurum Technical University
Graduate School of Natural and Applied Sciences
Department of Civil Engineering

Supervisor: Assoc. Prof. Dr. Muhammed Yasin ÇODUR

Road networks are created with different pavement designs. In general, flexible pavement is preferred as the most used superstructure type in the World. Road networks with this superstructure suffers from degradation due to these; due to reasons such as lack of proper road infrastructure, incompatibility of bitumen used in bituminous mixtures with the application area, errors in aggregate bitumen ratio, casting temperature, insufficient roller operation, unqualified personnel, seasonal variations, methods of combating snow and ice, traffic volume, inadequate maintenance and repair processes. These degradations take different forms over time and create road defects. The process of identifying defects is very important for the efficiency of the road pavement and traffic components. In this thesis study, the process of automatic detection and classification of road defects occurring in flexible superstructure road networks was carried out with an intelligent system. Road images obtained from eight different countries and 10 different road defects were taken into consideration within the scope of the study. YOLOv5, YOLOv7 and YOLOv8 detection models were used in the detection process of defects. In addition, a global-scale automatic road defect detection system has been developed within the scope of a data set consisting of different countries. The developed system is a prototype and has the ability to detect and classify defects occurring in road networks in real time. It is clear that the system will be a guide for road network managers by obtaining location information of the identified defects. Detecting, classifying and locating road defects with the developed system will accelerate the maintenance and repair process of road networks and also extend their service life. Road safety and comfort of traffic components using the road network will also be increased. As a result, an example of vehicle-infrastructure (V2I) communication, which is a form of intelligent transportation systems application, is presented within the scope of the thesis.

2023, 298 pages

Keywords: Defect detection and classification, real-time detection, embedded system, defect location

TEŞEKKÜR

Akademik hayatım süresince bilgi ve tecrübesini benimle paylaşarak, tezin gerçekleştirmesinde yardım ve desteğini esirgemeyen saygıdeğer danışmanım Doç. Dr. M. Yasin ÇODUR'a içten bir teşekkürü borç bilip saygılarımı sunarım.

Tezin nihai haline gelmesinde emeği olan Sayın Prof. Dr. Ahmet TORTUM ve Sayın Doç. Dr. Ahmet ATALAY'a hocalarıma katkı, öneri, bilgi ve birikimlerini esirgmeden verdikleri destek için teşekkürlerimi ve saygılarımı sunarım.

Hayatım boyunca maddi ve manevi desteğini esirgemeyen başta annem Birgül KAYA, babam Osman KAYA ve abim Serdar KAYA olmak üzere kayınpederim Prof. Dr. Abdülkadir ÖZER'e ve tüm aileme en kalbi duygularıyla sevgilerimi sunar, sonsuz teşekkür ederim.

Her anımda sevgisiyle güç ve motivasyon veren sevgili eşim Şuheda'ya ve hayatımıza renk katan biricik oğlum Mehmet Ömür'e teşekkür ederim, iyi ki varlar.

Doktora çalışmalarım boyunca TÜBİTAK 2211-A Genel Yurt İçi Doktora Bursu ile şahsımı destekleyen TÜBİTAK'a teşekkürlerimi sunarım.

Bu çalışma, 2023/036 Nolu Erzurum Teknik Üniversitesi Bilimsel Araştırma Projesinden sağlanan destekle yürütülmüştür. Alınan destek ve katkı dolayısıyla, Erzurum Teknik Üniversitesi'ne şükranlarımı sunarım.

Ömer KAYA
Aralık 2023

İÇİNDEKİLER

ÖZET	i
ABSTRACT	ii
TEŞEKKÜR	iii
SİMGELER VE KISALTMALAR DİZİNİ	vi
ŞEKİLLER DİZİNİ	ix
ÇİZELGELER DİZİNİ	xii
1. GİRİŞ	1
1.1. Genel	1
1.2. Türkiye Yol Ağları	5
1.3. Tezin Amacı	7
1.4. Tezin İçeriği	8
2. KAYNAK ÖZETLERİ	9
2.1. Yol Kusurlarının Belirlenmesi	9
2.2. Yol Kaplamasında Meydana Gelen Kusurlarının Belirlenmesine Yönelik Yapılan Çalışmalar	12
3. MATERYAL VE YÖNTEM	33
3.1. Çalışma Alanı.....	33
3.2. Yol Kusur Verileri.....	34
3.3. Model Kurulum Kapsamında Kullanılan Yol Kusur Verileri.....	43
3.4. Veri Toplanması.....	46
3.5. Yapay Zekâ	51
3.6. Görüntü İşleme.....	55
3.7. Nesne Algılama	58
3.8. You Only Look Once (YOLO)	64
3.8.1. You Only Look Once: Birleşik, gerçek zamanlı nesne algılama	64
3.8.2. YOLO9000.....	73
3.8.3. YOLOv3.....	76

3.8.4. YOLOv4.....	79
3.8.5. YOLOv5.....	81
3.8.6. You only learn one representation (YOLOR).....	83
3.8.7. YOLOv6.....	86
3.8.8. YOLOv7.....	90
3.8.9. YOLOv8.....	93
3.9. Coğrafi Bilgi Sistemleri ve Gömülü Sistem İnşası	94
3.10. Akıllı Ulaşım Sistemleri.....	97
3.10.1. AUS uygulamalarında kullanılan teknolojiler	101
3.10.2. AUS uygulamaları.....	110
3.10.3. AUS mimarisi ve Türkiye	132
3.10.4. Ülkemizde AUS kapsamında yapılan çalışmalar	135
3.10.5. Türkiye AUS stratejisi.....	145
3.10.6. Araç içi bilgi ve haberleşme sistemi	146
4. MODEL EĞİTİMİ VE PERFORMANS ANALİZİ.....	151
4.1. YOLOv5 Analiz	151
4.2. YOLOv7 Analiz	170
4.3. YOLOv8 Analiz	179
4.4. YOLOv5, YOLOv7 ve YOLOv8 Modellerinin Karşılaştırılması	189
5. GÖMÜLÜ SİSTEM İNŞASI.....	192
5.1. Yol Kusurlarını Otomatik Olarak Algılayan ve Sınıflayan Sistem.....	192
5.1.1. Yazılım.....	193
5.1.2. Donanım.....	194
6. SONUÇ VE ÖNERİLER.....	201
KAYNAKLAR	205
EKLER.....	218
EK-1	218

SİMGELER VE KISALTMALAR DİZİNİ

Simgeler

Açıklama

Dk	Dakika
Km	Kilometre
Ø	Aktivasyon Fonksiyonu
ms	Milisaniye

Kısaltmalar

ABD	Amerika Birleşik Devletleri
ABHS	Araç İçi Bilgi ve Haberleşme Sistemi
ADAS	Advanced Driver Assistance Systems
AP	Average Precision
AR	Augmented Reality
ATYMS	Akıllı Trafik Yönetimi Sistemi
AUS	Akıllı Ulaşım Sistemleri
AUSDER	Akıllı Ulaşım Sistemleri Derneği
AUSYS	Akıllı Ulaşım Yönetim Sistemi
CACS	Comprehensive Automobile Traffic Control Systems
CDMA	Code Division Multiple
CNN	Convolutional Neural Network
CRDDC	Crowdsensing-based Road Damage Detection Challenge
DAB	Digital Audio Broadcasting
DPM	Deformable Parts Models
DSRC	Dedicated Short-Range Communication
ECU	Electronic Control Unit
EGM	Emniyet Genel Müdürlüğü
ERGS	Electronic Route Guidance System
ESTÜ	Eskişehir Teknik Üniversitesi
FPN	Feature Pyramid Networks
FPS	Frame Per Second
GNSS	Global Navigation Satellite System

GNSS	Global Navigation Satellite System
GPS	Global Positioning System
GPU	Graphics Processing Unit
GRDDC	Global Road Damage Detection Challenge
GSM	Global System for Mobile Communications
GTHS	Gemi Trafik Hizmetleri Sistemi
GTÜ	Gebze Teknik Üniversitesi
HOG	Histogram of Oriented Gradient
IEEE	Institute of Electrical and Electronics Engineers
IFK	Inlandent Fylkeskommune
IoT	Internet of Things
IoU	Intersection over Union
ITS	Intelligent Transportation Systems
İHA	İnsansız Hava Aracı
JGK	Jandarma Genel Komutanlığı
K-AUS	Kooperatif Akıllı Ulaşım Sistemleri
KGM	Karayolları Genel Müdürlüğü
KOSGEB	Küçük ve Orta Ölçekli İşletmeleri Geliştirme ve Destekleme İdaresi Başkanlığı
LIDAR	Laser Imaging Detection and Ranging
LoRaWAN	Long Range Wide Area Network
LPWAN	Low-Power Wide-Area Network
LTE	Long-Term Evolution
MaaS	Mobility as a Service
mAP	Mean Average Precision
MRI	Magnetic Resonance Imaging
NAS	Network Architecture Search
NFC	Near Field Communication
NLP	Natural Language Processing
OBU	On-board Unit
ODTÜ	Orta Doğu Teknik Üniversitesi
OFWNN	Optimal Fuzzy Wavelet Neural Network
OTS	Otomatik Tanımlama Sistemi
PASCAL VOS	PASCAL Visual Object Classes Challenge

PG-GAN	Productive Generative Adversarial Network
PSA	Pyramid Squeeze Attention
QAT	Quantization Aware Training
R-CNN	Region Based Convolutional Neural Networks
RDD	Road Damage Dedector
RDS	Radio Data System
ReLU	Rectified Linear Units
RFID	Radio Frequency Identification
RoI	Region of Interest
RPN	Regison Proposal Network
SGD	Stochastic Gradient Descent
SiLU	Sigmoid Linear Unit
SSD	Single Shot MultiBox Detector
STK	Sivil Toplum Kuruluşları
SVV	Statens Vegvesen
TEKNOFEST	Havacılık, Uzay ve Teknoloji Festivali
TEYDEB	Teknoloji ve Yenilik Destek Programları Başkanlığı
TRIP	National Transportation Research Nonprofit
TÜBİTAK	Türkiye Bilimsel ve Teknik Araştırma Kurumu
UDHB	Ulaştırma Denizcilik ve Haberleşme Bakanlığı
V2I	Vehicle-to-Infrastructure Communication
V2V	Vehicle-to-Vehicle Communication
VGG	Very Deep Convolutional Networks
VR	Virtual Reality
YOLO	You Only Look Once
YÖK	Yüksek Öğretim Kurulu

ŞEKİLLER DİZİNİ

Şekil 2.1. RDD 2018 ve 2019 yol hasar görüntü sayılarının zamanla değişimi	15
Şekil 3.1. Yol görüntülerinin elde edildiği ülkeler	34
Şekil 3.2. Veri dağılım istatistikleri	36
Şekil 3.3. Eğitim verisinde farklı yol hasar türlerine göre dağılımı.....	37
Şekil 3.4. Yol hasar tespiti (RDD) veri kümelerinin evrimi	38
Şekil 3.5. Yol hasar veri setlerinin yıllara göre karşılaştırılması (Arya et al. 2022)	39
Şekil 3.6. Dört hasar türünün ülkelere göre eğitim veri seti dağılımı.....	40
Şekil 3.7. Çalışma kapsamında kullanılan kusur sınıfları.....	45
Şekil 3.8. Çalışma kapsamında kullanılan 10 kusur sınıfı ve yol görüntüleri	46
Şekil 3.9. Gürcistan'a ait yol görüntülerinin toplandığı güzergâh.....	47
Şekil 3.10. Kusur sınıflarının ülkelere göre dağılımı.....	49
Şekil 3.11. Yapay zekânın serüveni	52
Şekil 3.12. Nesne algılama algoritmalarının ortaya çıkış tarihçesi (Kaya ve Çodur 2022)	61
Şekil 3.13. Bir ve iki aşamalı dedektörlerin çalışma prensibi farkı (Bochkovskiy et al. 2020).....	61
Şekil 3.14. YOLO algılama sistemi (Redmon et al. 2015)	65
Şekil 3.15. YOLO algılama modeli (Redmon et al. 2015)	67
Şekil 3.16. YOLO ağ mimarisi (Redmon et al. 2015)	67
Şekil 3.17. Fast R-CNN ve YOLO için hata analizleri (Redmon et al. 2015).....	73
Şekil 3.18. Algılama modellerinin doğruluk ve hız arasındaki ilişki (Redmon and Farhadi 2016).	76
Şekil 3.19. Boyut öncelikleri ve konum tahmini içeren sınırlayıcı kutular (Redmon and Farhadi 2018).	77
Şekil 3.20. YOLOv3 ve diğer algılama modellerinin hız ve doğruluk bakımından karşılaştırılması (Redmon and Farhadi 2018).	78
Şekil 3.21. Algılama modellerinin performans değerlendirmesi (Redmon and Farhadi 2018).....	79
Şekil 3.22. Önerilen YOLOv4 ve diğer son teknoloji nesne dedektörlerinin karşılaştırılması (Bochkovskiy et al. 2020).....	80

Şekil 3.23. YOLOv5 ve diğer algılama modellerinin karşılaştırması (Hoher 2020)	83
Şekil 3.24. Önerilen birleşik ağ tasarımı (Wang et al. 2023).....	84
Şekil 3.25. Modele örtülü bilginin eklenmesi (Wang et al. 2023).....	85
Şekil 3.26. Son teknoloji verimli nesne dedektörlerinin karşılaştırılması (Li et al. 2022)	87
Şekil 3.27. YOLOv7'nin diğer gerçek zamanlı nesne algılayıcılarla karşılaşması (Wang et al. 2022).....	93
Şekil 3.28. YOLOv8 modelinin diğer YOLO modelleri ile karşılaştırılması (Anonymous 2023a).....	94
Şekil 3.29. AUS tarihsel gelişimi.....	99
Şekil 3.30. AUS uygulamalarından etkilenen sektörler (Tektaş ve Tektaş 2019b)	100
Şekil 3.31. LoraWAN teknolojisi (Anonoim 2018).....	107
Şekil 3.32. Kooperatif akıllı ulaşım sistemleri (Anonoim 2023f)	110
Şekil 3.33. MaaS çalışma ağ yapısı (Anonoim 2023j)	111
Şekil 3.34. Kuşaklara göre özel araç sahipliğinin gereksizliği (Anonoim 2023j)	112
Şekil 3.35. ABHS ve bileşenleri (Anonoim 2023u)	147
Şekil 4.1. Sınıf etiketlerinin dağılımı, x - y koordinatları ve yükseklik-genişlik arasındaki korelasyon.	159
Şekil 4.2. İşlenen veri kümesinin etiketlerinin korelogramı	160
Şekil 4.3. Eğitim boyunca gerçekleşen performans analizi (YOLOv5l)	161
Şekil 4.4. Eğitilen modelin doğrulama kümesindeki performans değerlendirmesi, (a) Hassasiyet, (b) Duyarlılık (YOLOv5l).	162
Şekil 4.5. Eğitilen modelin doğrulama kümesindeki performans değerlendirmesi, (a) PR eğrisi, (b) F1 Puanı (YOLOv5l).	163
Şekil 4.6. Doğrulama görüntülerinden sınıfların tahminine ilişkin Karışıklık Matrisi (YOLOv5l).	165
Şekil 4.7. Etiketli doğrulama verileri ve modelin tahmin ettiği kusur kutuları (YOLOv5l)	167
Şekil 4.8. Eğitim boyunca gerçekleşen performans analizi (YOLOv7x)	173
Şekil 4.9. Eğitilen modelin doğrulama kümesindeki performans değerlendirmesi, (a) Hassasiyet, (b) Duyarlılık (YOLOv7x).	174
Şekil 4.10. Eğitilen modelin doğrulama kümesindeki performans değerlendirmesi, (a) PR eğrisi, (b) F1 Puanı (YOLOv7x).....	175

Şekil 4.11. Doğrulama görüntülerinden sınıfların tahminine ilişkin Karışıklık Matrisi (YOLOv7x).....	176
Şekil 4.12. Etiketli doğrulama verileri ve modelin tahmin ettiği kusur kutuları (YOLOv5l).....	177
Şekil 4.13. Eğitim boyunca gerçekleşen performans analizi (YOLOv8x)	183
Şekil 4.14. Eğitilen modelin doğrulama kümesindeki performans değerlendirmesi, (a) Hassasiyet, (b) Duyarlılık (YOLOv8x).	184
Şekil 4.15. Eğitilen modelin doğrulama kümesindeki performans değerlendirmesi, (a) PR eğrisi, (b) F1 Puanı (YOLOv8x).	185
Şekil 4.16. Doğrulama görüntülerinden sınıfların tahminine ilişkin Karışıklık Matrisi (YOLOv8x).	186
Şekil 4.17. Etiketli doğrulama verileri ve modelin tahmin ettiği kusur kutuları (YOLOv8x).	187
Şekil 5.1. Sistemin donanımsal ekipmanları (a) Jetson Xavier NX, (b) kamera modülü, (c) GPS alıcısı, (d) harici hafıza kartı.	195
Şekil 5.2. Sistemin prototip hali.....	196
Şekil 5.3. Prototip sistemin gerçek zamanlı yol kusur algılaması	197
Şekil 5.4. ETÜ kampüs yol ağında var olan kusurların konumsal gösterimi	198
Şekil 5.5. Kusurların meydana geliş yoğunluğu	199

ÇİZELGELER DİZİNİ

Çizelge 1.1. Yol ağlarının yapım-bakım-onarım sorumlulukları (Anonim 2023a).....	6
Çizelge 1.2. Sathi cinsine göre yol ağı uzunlukları (km) (Anonim 2023a)	6
Çizelge 2.1. RDD 2018 veri setinde yer alan yol kusur türleri ve tanımları (Maeda et al. 2018).	13
Çizelge 3.1. Veri setlerinin önceki sürümlerle karşılaştırmalı özeti.....	42
Çizelge 3.2. Eğitim ve doğrulama veri setinin sınıfsal olarak dağılımı.....	48
Çizelge 3.3. Nesne algılama yöntemlerine ait bileşenler (Wu et al. 2020).....	60
Çizelge 3.4. Bir ve iki aşamalı dedektörlü nesne algılama yöntemleri	62
Çizelge 3.5. Farklı nesne algılama modellerinin karşılaştırılması.....	63
Çizelge 3.6. PASCAL VOC 2007'de gerçek zamanlı sistemlerin performans değerleri (Redmon et al. 2015).	71
Çizelge 3.7. PASCAL VOC 2007 üzerinde modellerin algılama çerçeveleri (Redmon and Farhadi 2016).....	75
Çizelge 3.8. Algılama modellerinin karşılaştırılması (Wang et al. 2023)	86
Çizelge 3.9. Diğer YOLO serisi dedektörlerin COCO 2017 ile değerlendirilmesi (Li et al. 2022).	89
Çizelge 3.10. Temel nesne dedektörlerinin karşılaştırılması (Wang et al. 2022).....	92
Çizelge 3.11. Türkiye’de yapılan ABHS girişimleri (Anonoim 2023u).....	150
Çizelge 4.1. YOLOv5 ve varyantlarının parametre değerleri.....	153
Çizelge 4.2. Doğrulama verileri ile değerlendirme kriterlerinin değerleri (YOLOv5s), (a); parti boyutu 16, dönem sayısı 50, (b); parti boyutu 32, dönem sayısı 50, (c); parti boyutu 32, dönem sayısı 75, (d); parti boyutu 32, dönem sayısı 100, (e); parti boyutu 64, dönem sayısı 100.	154
Çizelge 4.3. Doğrulama verileri ile değerlendirme kriterlerinin değerleri (YOLOv5n), (a); parti boyutu 32, dönem sayısı 75, (b); parti boyutu 32, dönem sayısı 100, (c); parti boyutu 64, dönem sayısı 100.	156
Çizelge 4.4. Doğrulama verileri ile değerlendirme kriterlerinin değerleri (YOLOv5m)	158
Çizelge 4.5. Doğrulama verileri ile değerlendirme kriterlerinin değerleri (YOLOv5l).....	158
Çizelge 4.6. YOLOv7 ve varyantlarının parametre değerleri.....	171
Çizelge 4.7. Doğrulama verileri ile değerlendirme kriterleri değerleri(YOLOv7).....	171

Çizelge 4.8. Doğrulama verileri ile değerlendirme kriterleri değerleri(YOLOv7x).....	172
Çizelge 4.9. Doğrulama verileri ile değerlendirme kriterleri değerleri (YOLOv8s)	180
Çizelge 4.10. Doğrulama verileri ile değerlendirme kriterleri değerleri (YOLOv8n)..	181
Çizelge 4.11. Doğrulama verileri ile değerlendirme kriterleri değerleri (YOLOv8m)..	181
Çizelge 4.12. Doğrulama verileri ile değerlendirme kriterleri değerleri (YOLOv8l)...	182
Çizelge 4.13. Doğrulama verileri ile değerlendirme kriterleri değerleri (YOLOv8x)..	182
Çizelge 4.14. Modellere ait performans değerleri	190



1. GİRİŞ

1.1. Genel

Ulaşım altyapısı modern toplum çerçevesinde temel bir rol oynamaktadır. Ulaşım altyapısındaki olumlu gelişmeler iyi ulaşım olanakları sunduğunda insanların ekonomik ve sosyal kalkınması üzerinde önemli bir etkiye sahiptir. Özellikle kamu hizmeti olan sağlık, eğitim, güvenlik gibi işlemlere erişimin kaliteli bir yol ağı ile sağlandığı açıktır. Yol ağları toplumlar arasında köprü görevini üstelenerek birçok yönden etkileşimi artırmaktadır. Etkileşim sayesinde kültürel gelişim, bilgi ve fikir alışverişi, ticaret olanakları artmaktadır. Geçmişten günümüze kadar uzanan tarihsel süreçte ulaşım altyapısındaki gelişmeler toplumları her zaman olumlu etkilemiştir (Yayla 2011).

Karayollarını oluşturan yol ağları gelişen bilimsel teknik ve yöntemler dâhilinde farklı malzeme seçimi ile oluşturulmaktadır. Günümüzde şehir içi ve şehir dışı yol ağları incelendiğinde genellikle esnek üst yapı tercih edilmektedir. Bu durumun ana sebebi olarak; kullanılan malzemelerin kolay temin edilmesi, güvenli ve konforlu sürüş, yapım aşamasından kısa bir süre yolun hizmet verebilmesi gibi avantajlar gösterilmektedir. Esnek üstyapıların zaman içerisinde farklı yol kusurlarına maruz kaldığı bilinmektedir. Yol kusurlarının meydana gelmesinde farklı oluşum ve sebepler mevcuttur (Sabır 2022). Yol altyapısının gereği gibi hazır olmaması, bitümlü karışım altına serilen temel tabakalarının uygun olmayan malzeme seçimi ile oluşturulması ve yetersiz silindir işlemi, kullanılan bitümün uygulama alanı ile uyumsuzluğu, agrega bitüm oranında yapılan hatalar, tabakalar arasında yanlış agrega seçimi, döküm sıcaklığı, yetersiz silindir işlemi, kalifiyesiz eleman kullanımı, mevsimsel değişkenlikler, kar ve buz ile mücadele yöntemi, yol ağı trafik hacmi, yetersiz bakım ve onarım süreçleri yol ağında meydana gelen kusurların başlıca sebepleri olarak gösterilmektedir.

Yol ağlarında oluşan yol hasarları başlıca enine ve boyuna çatlaklar, timsah çatlakları, tekerlek izleri ve çukurlar olarak nitelendirilmektedir (Arya et al. 2022). Bu hasarlar genel olarak tüm ülke yol ağlarında görülmekle beraber erken bakım ve onarım süreci yol ağlarının hizmet süresinde artış sağlamaktadır. Yol bozulmalarının teşhis edilmesi, belirli bir bölgenin ekonomik canlılığının korunması, yerel halkın refahının

sağlanması, güvenli ve yeterli ulaşım hedefine ulaşılması açısından kritik öneme sahiptir. Bakım ve onarım sorumluluğu yol ağının bulunduğu hizmet bölgesine göre değişiklik göstermektedir. Yol kusurlarının belirlenmesi süreci günümüzde üç farklı süreç ile yürütülmektedir. Manuel, yarı otomatik ve otomatik olarak isimlendirilen bu sistemler birbirinden oldukça farklıdır (Liang et al. 2022). Manuel yaklaşımda personel tarafından uzun bir süre boyunca gerçekleştirilen görsel incelemeler, geleneksel olarak bir yolun zaman içerisinde ne ölçüde bozulduğunu belirleme yöntemi olmuştur. Bu yaklaşım önemli bir süredir kullanılmaktadır. Ancak tüm süreçlerin geleneksel olarak ilerlemesi ciddi miktarda paraya mal olma ve oldukça fazla zaman alma potansiyeli bulunmaktadır. Ayrıca görsel denetimler, denetimi yapan kişinin uzmanlığına ve yorumuna bağlı olduğundan subjektif olarak değerlendirilmektedir. Sonuç olarak, değerlendirme bulguları muhtemelen belirli bir miktarda varyasyona tabi olacaktır. Yarı otomatik sistemde ise sorumlu görevlinin yol görüntülerini bir kamera yöntemi ile toplaması ve ofis sürecinde bu görüntülerden manuel olarak kusur çıkarımı yapması ile sonuçlanmaktadır. Ayrıca üç eksenli ivme ölçer ile çukurların belirlenmesi de bu sisteme dahil edilmektedir. Bu sistemde de verimliliğin düşük ve çalışma sürecinde yoğun emek gerektiren oluşum meydana gelmektedir. Otomatik sistemler ise özel ekipmanlar ile donatılmış, kamera ve lazer barındıran yüksek maliyetli araçlardır. Bu sistemde araç ön veya arka tarafında yerleştirilen kamera ve lazer ile yol üstyapısı taranarak bazı yol kusur türleri belirlenmektedir (Zhang et al. 2018). Bu araçların tek amacının yol kusurlarını belirlemek olması ve yüksek maliyetleri dolayısı ile birçok ülke kurumları tarafından tercih edilmemektedir.

İnsan ve nesne algılama teknolojisi, yol ağında meydana gelen yol kusurlarının algılanmasında önemli ölçüde gelişim sağlamıştır. Diğer algılama sistemlerinde meydana gelen subjektif, verimsiz, pratik ve ekonomik olmayan durumlar karşısında derin öğrenme tabanlı bilgisayarlı görme teknolojisi oldukça çözüm odaklıdır. Kurum sorumluları genellikle çatlak, çukur ve diğer sorunlar gibi kusur işaretlerini aramak için yolları görsel olarak incelemişlerdir. Ne yazık ki, bu yaklaşımın hem insan kaynağı hem de mali açıdan külfetli olduğu ortaya çıkarak denetimlerin tek biçimliliği ve kalibresi, denetçinin uzmanlığına ve aşinalığına bağlı olduğu belirlenmiştir. Nesne algılama teknolojisinin kullanılması, bozulma belirtilerini tespit etmek ve sınıflamak için kameraların ve diğer sensörlerin yerleştirilmesi yoluyla yol denetimlerinin otomasyonuna

olanak sağlamıştır. Bozulmuş yolların paternlerini ve niteliklerini belirlemek için derin öğrenme algoritmalarına talimat vermenin mümkün olduğu ve bozulmanın en ince belirtilerini bile ayırt etmelerine olanak tanınması akademisyenler ve araştırmacılar tarafından tercih edilme nedeni olmuştur.

Nesne algılama teknolojisi, yol denetimlerinin doğruluğunu ve etkinliğini artırma, maliyetleri azaltma ve trafik bileşenlerinin güvenliğini artırma yeteneğini sergilemektedir. Ayrıca insan uzmanlığının nesne algılama teknolojisiyle birleştirilmesi denetimlerin hassasiyetini artırmaktadır. Bunun nedeni olarak insan denetçilerinin derin öğrenme algoritmalarının çıktıları anlayıp değerlendirebilmesi ve böylece yol bakımı ve onarımı için bilinçli öneriler sunmalarına olanak sağlaması gösterilmektedir. Yol denetimlerinde nesne algılama teknolojilerinin kullanılması maliyet tasarrufu sağlama potansiyeline sahiptir. Ayrıca veri analizi için yapay zekâ algoritmalarının kullanılması ile daha doğru ve tutarlı sonuçlara ulaşılabilmesi, yol bakım ve onarım çalışmalarının optimizasyonunun kolaylaştırabilmesinin yanı sıra pahalı ve gereksiz onarımların sıklığında azalma gibi olumlu gelişmeler sağlanmaktadır. Ek olarak, yol kusurlarının zamanında tespiti, ciddi hasarların oluşmasını azaltarak ve genellikle daha pahalı olan gelecekteki onarım veya yeniden inşa ihtiyacını en aza indirerek maliyet tasarrufu sağlayabilmektedir. İnsan ve nesne tespit teknolojilerinin kusurlu yolların tespiti üzerindeki potansiyel etkisi, ulaşım altyapımızın güvenliğini ve dayanıklılığını artırmak açısından son derece önemlidir. Yol denetimlerinde nesne algılama teknolojisinin kullanılması, denetimlerin hassasiyetini ve verimliliğini artırma ve yol bakım ve onarım çalışmalarını optimize etme, dolayısıyla maliyet tasarrufu sağlama potansiyeline sahiptir (Mustakim 2023). Özetlemek gerekirse yol kusurlarının tespit sürecinde nesne algılama yöntemlerinin kullanılması mevcut yöntemlere göre maliyet ve verimlilik açısından üstünlük sağlamaktadır. Ayrıca yol kusurlarının erken teşhisi ile hızlı bakım ve onarım sürecinin başlatılması trafik bileşenlerinin konfor ve güvenliğini artırarak yol hizmet ömründe artış sağlamış olacaktır. Yol kusurlarının algılanması ve bakım/onarım süreci trafik bileşenlerini birçok açıdan etkilemektedir.

Yol kusurları, araç koşulları ve trafik güvenliği açısından da önemli bir tehdit oluşturmaktadır. Örneğin Chicago Sun-Times, 2018 yılının ilk iki ayında sürücülerin yol çukurlarıyla ilgili 11.706 şikâyetle yol açtığını bildirmiştir. The Pothole Facts'a göre,

Amerika Birleşik Devletleri'ndeki (ABD) 33.000 trafik kazası kaynaklı ölümünün yaklaşık üçte biri kötü yol koşullarından kaynaklanmaktadır. Bu nedenle yolların sık sık denetlenmesi ve yol kusurlarının onarılmasının gereği çok önemlidir. Manuel görsel inceleme şu anda hala yoldaki çukur tespitinin ana şekli olmakla birlikte bu süreç verimsiz, pahalı ve tehlikelidir. Örneğin Yeni Zelanda'daki yerel belediyeler 2017 yılında çukurları tespit etmek ve onarmak için milyonlarca dolar harcadı (Christchurch yönetimi tek başına 525 bin dolar harcamıştır). Ayrıca ABD'nin San Diego kentinde her yıl 30 binden fazla çukurun onarıldığı bildirilmiştir. Yerel yol bakım departmanının tespit yükünü hafifletmek amacıyla San Diego sakinlerine yol çukurlarını bildirmeleri önerilmiştir (Ma et al. 2022). Amerikan İnşaat Mühendisleri Derneği'nin Amerika'nın altyapısına ilişkin 2021 raporuna göre, ABD'deki ana yolların %43'ü kötü olarak değerlendirilmektedir. Bu tür yollarda araç kullanmak, araç bakımına yılda ilave 130 milyar ABD dolarına mal olmaktadır.

Ayrıca bakım maliyetlerinin yanı sıra aracın yakıt maliyeti ve lastik aşınmasının artması gibi işletme maliyetlerini de artırabilmektedir. Avrupa ülkelerinde yapılan bir çalışmada, kötü yollar hem ağır hem de hafif araçların yakıt tüketiminin artmasına neden olmakta ve bu da sırasıyla %12 ve %35 oranında daha yüksek ortalama CO₂ emisyonlarına yol açmaktadır. Ayrıca yol yüzeyinin bakım sürecinin yetersiz olması nedeniyle araç bakım maliyeti sırasıyla %185 ve %129 oranında artabilmektedir. ABD'de, kar amacı gütmeyen ulusal ulaşım araştırması TRIP'in Ocak 2022 tarihli bir raporu, yolların %40'ının kötü ile vasat olduğunu ve bunun da bir araç için tamir ve bakımı için yılda ortalama 621 dolar maliyete yol açtığını söylemiştir. Bu tür hasarlı yol ağları aynı zamanda çok sayıda kazaya da yol açabilmektedir. Hindistan'da 2019 yılında yalnızca çukurlardan kaynaklanan 4.775 trafik kazası meydana gelmiş ve bu kazalar sonucunda 4.013 kişi yaralanmış ve 2.140 kişi hayatını kaybetmiştir (Jana et al. 2023).

Özellikle son yıllarda yol çukurlarının tespiti sadece bir altyapı bakım probleminden daha fazlası haline gelmiştir. Aynı zamanda birçok otomotiv şirketi tarafından L3/L4 otonom arabalara yerleştirilen gelişmiş sürücü destek sistemlerinin (ADAS) bir fonksiyonu olarak yeni ortaya çıkmaktadır. Otonom sürüş sistemleri daha yüksek yol bakım standardı gerektirmektedir. Jaguar ve Land Rover, sürücüleri çukur konumları konusunda bilgilendirmek ve arabayı yavaşlatmak için uyarılar vermek üzere

1. GİRİŞ

veri odaklı teknolojiler üzerinde deneyler yaparken, ClearMotion, yoldaki çukurların neden olduğu şoklar ve titreşimleri öngöründe bulunmak, absorbe etmek ve tepki vermek için donanım ve yazılımın bir kombinasyonunu kullanan akıllı bir süspansiyon sistemi geliştirmiştir (Ma et al. 2022).

Yol kusurlarının algılanması sürecinde ele alınan yöntemler, bakım ve onarımının hızlı gerçekleşmesi için gerekli istatistiki bilgiler ve derin öğrenme tabanlı çözüm trendi hakkında bazı bilgiler yukarıda sağlanmıştır. Nesne algılama tabanlı çözüm önerilerinin günümüzde birçok açıdan daha uygulanabilir olduğu açık bir gerçektir. Bu durumun irdelenmesi gereken önemli bir husus olarak öne çıkması ve geliştirilebilir potansiyelinin olmasının yanı sıra yol ağlarına sahip olan tüm kurum ve kuruluşlar yol kusurlarının otomatik olarak belirlendiği bir Akıllı Ulaşım Sistemleri (AUS) uygulamasına ihtiyaç duymaktadır.

1.2. Türkiye Yol Ağları

Osmanlı Devleti sınırları içerisinde 4.000 km'si iyi durumda toplam 18.000 km yol ağı Türkiye Cumhuriyetine devredilmiştir. Cumhuriyetin ilk yıllarında demiryolu ulaşımına ağırlık verilmiştir. İkinci dünya savaşı ile birlikte tüm dünyada olduğu gibi ülkemizde de karayolu ağına öncelik verilmiştir. 1948 Marshall yardımları ile birlikte karayolu ulaşımına ayrılan destek daha da artmıştır (Çetin vd 2011).

1950 yılında Karayolları Genel Müdürlüğü kurularak ülkenin her bölgesine ulaşabilmeyi hedeflemiştir. 1950 - 1960 yılları arasında temel amaç, toplumsal hizmetler olan sağlık ve eğitimin ülkenin her bölgesine erişilebilir hale getirilmesi için yolların her mevsimde geçilebilir hale getirilmesiydi. Bu dönemde, aşamalı inşaat sistemi kullanılarak hem trafik yoğunluğuna uygun olarak yollar iyileştiriliyor hem de yeni rotalar belirlenerek, modern standartlara uygun yol şeritleriyle ülkenin ekonomik bölgeleri arasında bağlantı sağlanıyordu. 1960'lı yıllara gelindiğinde, hızlı inşaat teknikleri kullanılarak Türkiye'nin ihtiyaç duyduğu 60.000 kilometrelik bir yol ağı oluşturulmuştur. Ancak, yol ağı belirli bir noktaya ulaştıktan sonra, artan trafik nedeniyle 1960-1970 yılları arasında asfalt kaplamaya ağırlık verilmesi zorunlu hale gelmiştir. 1970'lerde motorlu taşıt endüstrisinin kurulması, karayolu politikasına yeni boyutlar sağlamıştır. Trafik

1. GİRİŞ

sıkışıklığı olan bazı ana arterlerde ve büyük şehir çevrelerinde, çok şeritli otoyolların inşası ekonomik bir seçenek haline gelmiştir. Bu tür yolların planlanması, finansmanı, proje tasarımı ve inşası diğer yollara göre daha karmaşık olduğundan, yeni bir teknoloji gerektirmiştir. Ülkemizin karayolu ağı sistemi, kendi ulusal gelişimine ek olarak, bulunduğu bölgede bütünlüğün ve genel olarak kalkınmanın sağlanabilmesi için bir gereklilik oluşturmaktadır.

Aşağıda yer alan Çizelge 1.1’de ülkemizde var olan yol ağları ve sorumluları yer almaktadır. Otoyol, devlet yolu, il yolları ve turistik yollar (Kültür ve Turizm Bakanlığı tarafından finansman edilmektedir.) KGM sorumluluğundadır. Köy yolları İl Özel İdare Müdürlüklerinin, Orman yolları Tarım ve Orman Bakanlığı’nın, Şehir içi yolları ise belediyelerin sorumluluğundadır (Anonim 2023a).

Çizelge 1.1. Yol ağlarının yapım-bakım-onarım sorumlulukları (Anonim 2023a)

KGM	Tarım ve Orman Bakanlığı	İl Özel İdare Müdürlükleri	Belediyeler
Otoyol	Orman Yolları	Köy Yolları	Şehir içi Yollar
Devlet Yolu	-	-	-
İl Yolu	-	-	-
Turistik Yollar	-	-	-

Ülkemiz yol ağları toplam yedi sınıfta toplanmaktadır. Dört farklı kurum ve kuruluşlar tarafından bu yol sınıflarının yapım-bakım-onarım süreçleri yönetilmektedir. Var olan bu yollar sathi cinslerine göre; asfalt betonu, sathi kaplama, parke, stabilize, toprak ve diğer yollardan oluşmaktadır. 01.01.2023 tarihi itibarıyla otoyol, devlet yolları ve il yollarının sathi kaplama cinsine göre uzunlukları Çizelge 1.2’de verilmektedir (Anonim 2023a).

Çizelge 1.2. Sathi cinsine göre yol ağı uzunlukları (km) (Anonim 2023a)

	Asfalt betonu	Sathi Kaplama	Parke	Stabilize	Toprak	Diğer Yollar	Toplam
Otoyol	3.633	-	-	-	-	-	3.633
Devlet Yolları	19.701	10.869	47	22	-	301	3.0940
İl Yolları	5.844	25.315	240	311	323	2.083	34.116
Toplam	29.178	36.184	287	333	323	2.384	68.689

1. GİRİŞ

Çizelge 1.2’de yer alan yol ağlarının uzunlukları bölünmüş ve bölünmemiş yol ağlarının toplam uzunluğudur. Bölünmüş yol uzunlukları ise otoyollar 3.633, devlet yolu 21.467 ve il yolu 2.258 olmak üzere toplam 27.358 km uzunluğundadır.

Otoyol: Yol ağı üzerinde seyahat hızının yüksek ve erişme kontrolünün olduğu, trafik akışında asgari hız sınırlaması uygulanan ve yüksek standartlara sahip karayolu olarak tanımlanmaktadır.

Devlet Yolları: Transit trafiği, illere, limanlara, tersanelere, hava alanlarına, demiryolu istasyonlarına, sınır kapılarına kesintisiz olarak ulaştıran ayrıca belediyeler veya diğer kurumların sorumluluğunda bulunan yollar dışında kalan karayolu ağları olarak tanımlanmaktadır.

İl Yolları: İlleri birbirine, Devlet yollarına, limanlara, tersanelere, demiryolu istasyonlarına, hava alanlarına ve kamu ihtiyacının gerektirdiği diğer yerlere bağlayan ve bir il sınırı içinde başlayıp biten ayrıca belediyeler veya diğer kurumların sorumluluğunda bulunan yollar dışında kalan karayolu ağları olarak tanımlanmaktadır.

Genel olarak var olan yol ağlarının yapım-bakım-onarım işlerinin daha efektif ilerlemesi için ülkemiz KGM tarafından 18 ayrı bölgeye ayrılmıştır. Bu bölgeler sırası ile İstanbul, İzmir, Konya, Ankara, Mersin, Kayseri, Samsun, Elazığ, Diyarbakır, Trabzon, Van, Erzurum, Antalya, Bursa, Kastamonu, Sivas ve Kars’tır.

1.3. Tezin Amacı

Bu çalışmada, esnek kaplamaya sahip yol ağlarında oluşan yol kusurlarının otomatik olarak belirlenmesi amaçlanmaktadır. On adet yol kusurunu belirleme yeteneğine sahip olan sistemin ayrıca küresel ölçekte algılama yapabilmesi için çalışma kapsamında sekiz farklı ülke yol ağı ele alınmıştır. Yol kusurlarının tüm trafik bileşenleri üzerindeki doğrudan ve dolaylı olumsuz etkilerinin en az seviye indirgenmesi hedeflenmektedir. Bu hedef ve amaç doğrultusunda araç içi entegre katma değerli bir gömülü sistem oluşturulmuştur. Bu sistem, yol kusurlarını algılama, sınıflandırma ve

konumsal verileri tutma yeteneği ile trafik bileşenlerinin güven ve konforunu artırma yaklaşımını ele almıştır.

1.4. Tezin İçeriği

Çalışma giriş kısmından sonra yol ağlarında meydana gelen hasarların belirlenmesine yönelik çalışmaların derlenmesini içermektedir. Ayrıca yol hasarlarını ana tema olarak ele alan yarışmalar ve sunulan açık veriler hakkında detaylı bilgiler bu kısımda yer almaktadır.

Üçüncü bölümde ise küresel ölçekli algılama ve sınıflama sisteminin elde edilmesinde katkı sağlayan yol görüntülerinin ülkelere göre dağılımları ve kusur sınıfları detaylandırılmıştır. Ayrıca yazar tarafından elde edilen yol görüntülerinin toplanma şekli ve detaylı bilgileri de yer almaktadır. Ayrıca oluşturulan sistemin temelini oluşturan nesne algılama modellerinin geçmişten günümüze kapsamlı şekilde açıklaması da bulunmaktadır. Sistemin sağlamış olduğu verilerin işlenmesi ve kusur haritası elde edilmesinde kullanılan yöntemlerden bahsedilmiştir. Sistemin bir akıllı ulaşım örneği teşkil ettiği için akıllı ulaşım sistemleri hakkında kapsamlı bilgiler sunulmuştur.

Dördüncü bölümde yol kusurlarını algıyan ve sınıflandıran algılama modellerine ait detaylı analiz sonuçlarına yer verilmiştir. Farklı algılama modellerinin çeşitli kombinasyonlar ile eğitim süreçlerinin tamamlanması ve bu işlemlerin sonuçları karşılaştırmalı olarak sağlanmıştır.

Beşinci bölümde elde edilen sistemin yazılım ve donanım kısımları detaylandırılmıştır. Kullanılan ekipmanların özellikleri ve birleştirilmesi aşamaları yer almaktadır. Sistemin test aşaması sonucunda elde edilen sonuçlar ve kusur haritası bu kısımda yer almaktadır.

Son olarak altıncı bölümde bu çalışmanın sonuçlarının özet hali bulunmaktadır. Yol kusurlarının farklı ülke görüntüleri ile eğitilmesi ve en iyi modelin sisteme entegre edilmesi gerçekleştirilmiştir. Bu sistem gerçek zamanlı olarak yol ağlarında var olan kusurları algılama, sınıflandırma ve konumlandırma yeteneklerine sahiptir.

2. KAYNAK ÖZETLERİ

Yol ağları tarihten günümüze medeniyetlerin var olmasında ve gelişmesinde anahtar rol oynamaktadır. Yol ağları ülkeler için ulaşım kolaylığı, ekonomik kalkınma, ticaretin artması, istihdam olanakları, tarım ve endüstriyel gelişim, turizm ve kültürel gelişim, acil durumlarda erişim, şehir planlaması ve trafik akışı, toplum entegrasyonu, yatırım çekme ve bölgesel kalkınma gibi hayati fonksiyonların oluşumuna katkı sağlamaktadır (Yayla 2011). Unutulmamalıdır ki oluşturulan bir ürünün hizmet/kullanım ömrü olduğu gibi yol ağlarının da belirli bir hizmet ömrü vardır. Bu ömrü uzatmak için yol ağlarında meydana gelen yol kusurlarını hızlıca bakım ve onarımdan geçirmek trafik bileşenlerinin konfor ve güvenliği için önemlidir. Bu kısımda yol kusurları, uluslararası yol kusur veri temini ve bunların algılanmasında kullanılan çalışmalar detaylı olarak açıklanmaktadır.

2.1. Yol Kusurlarının Belirlenmesi

Yol ağında meydana gelen yol kusurları birçok nedene bağlı olarak oluşmaktadır. Bir karayolu yol ağı yapılırken yol altyapısının şartnameye uygun olmaması, uygun alt temel karışımının sağlanmaması, silindir işleminin yetersiz olması, kalifiyesiz eleman çalıştırılması, kullanılan bitüm miktarının yol ağının geçtiği bölgeye uygun olmaması, yol serim işleminin uygun iklim koşullarında yapılmaması, bitümlü agreganın döküm ısisına uyulmaması, üzerindeki trafik miktarı, ağır tonajlı araçların miktarı, yol bakım ve onarımda gecikme gibi onlarca sebep yol kusurlarına neden olmaktadır. Tüm bu sebepler düşünüldüğünde yol ağlarının yapım aşamasının bilimsel faktörlere bağlı olduğu ve en ufak bir hatanın yol ağının hizmet süresinde azalmaya neden olacağı görülmektedir.

Bununla birlikte, yol yüzeyi; konum, yaş, trafik hacmi, hava durumu, mühendislik çözümleri ve onu inşa etmek için kullanılan malzemelerle ilgili faktörlerden dolayı zamanla aşınır ve bozulur. Bu nedenle, bozulma derecesinin, bozulmanın nerede olduğu ve bozulma türünün bilinmesi verimli ve uygun maliyetli bakım/onarım için kritik öneme sahiptir. Ayrıca yol ağını kullanan araç-yolcu-yaya-sürücülerin konforlu ve güvenli ulaşım durumunu korumak önemli bir amaçtır. Bazı araştırmacılar tarafından karayolu eksikliklerinin güvenlik ve ekonomi üzerindeki etkisi geniş çapta incelenmiştir (Miller

and Zaloshnja 2009; Rojo et al. 2018). Üstyapı durumu özelliklerinden biri olan üstyapı bozulması yani yol kusur durumu, dünya genelinde gelişmişlik ve ekonomik duruma göre üç yaklaşım kullanılarak değerlendirilmektedir. Bu yaklaşımlar manuel, yarı otomatik ve tam otomatik olarak ifade edilmektedir (Pierce et al. 2013).

Manuel yaklaşım, denetçilerin (yerel belediye sorumlusu, devlet kurum yetkilisi vs.), yavaş hareket eden bir araç kullanarak kaplama yüzeyinin görsel incelemesini veya kaldırım yüzeyi boyunca yürüyerek yol kaplamasını gözlemleyerek kusurları not aldığı ilkel bir yöntemdir. Yol yüzeyinin manuel görsel denetimi, denetçilerin öznel yargılarından muzdariptir. Yol ağlarının uzunluğu göz önüne alındığında, zaman alıcı olduğu kanıtlanmış bu yaklaşımın gerçekleşmesi için önemli bir insan müdahalesi gerekmektedir. Ayrıca, denetçilerin genellikle güvenlik şeridinde fiziksel olarak bulunmaları potansiyel olarak tehlikeli koşullara maruz bırakabileceği için yol kusur durumunun nesnel olarak analiz edilmesi mümkün değildir. Bununla birlikte, manuel inceleme, yoğun emek isteyen, maliyetli ve zaman alıcı olabilir. Ayrıca manuel inceleme, insan görme hatası, geçen araçlar nedeniyle güvenlik sorunlarına ve trafik akışını olumsuz engelleme gibi sorunlara yatkındır (Naddaf-Sh et al. 2020). Manuel yaklaşımda yol kusurlarının yüksek doğruluk ile belirlenme oranı düşük ve trafik güvenliğini azaltıcı etkenler barındırdığından tercih edilmemesi gereken bir yaklaşımdır.

Yarı otomatik kaplama kusur durumu değerlendirmelerinde, yol görüntüleri hareket eden bir araçtan cep telefonu, harici kameralar ile otomatik olarak toplanmaktadır. Ancak yol kusur tespiti ofisteki iş istasyonlarında çalışan çevrimdışı bir süreç ile belirlenir (Pierce et al. 2013; Zalama et al. 2014). Yol ağındaki yol kaplama görüntülerinin elde edilmesi sürecin otomatikleşme tarafı olarak nitelendirilmektedir. Ancak yol kusurlarının algılanması manuel olarak yapıldığı için bu süreç yarı otomatik olarak isimlendirilmektedir. Bu yaklaşım da manuel yaklaşımda olduğu üzere sürecin birçok alanında insan faktörünü barındırdığı için yol kusurlarının düşük doğruluk ile belirlenmesine ve nesnellikten uzak olmasına neden olmaktadır. Ayrıca yol kusur algılama sürecinin uzun süreçlere yayılacağı ve fazla insan gücüne ihtiyaç duyulacağı açıktır.

Tam otomatik kaplama kusur durumu değerlendirmelerinde genellikle karmaşık ve pahalı sensörlerle donatılmış araçlar kullanılır (Van Der Horst et al. 2019; Anonymous

2022a). Görüntü biçiminde toplanan veriler daha sonra yoldaki kusur durumunu belirlemek için örüntü tanıma (sürekli devam ve tekrar eden şekiller olan örüntüleri tanımaya yarayan bir teknoloji) yazılımı kullanılarak işlenir. Veri işleme süreci, veri toplama sırasında veya daha sonra ofiste gerçekleştirilebilir.

Otomatik kaplama denetimi için kullanılan özel araçlar, kaplama görüntüleri de dahil olmak üzere yol varlıklarını yakalamak ve yolun uzunlamasına ve enine profillerini elde etmek amacıyla genellikle lazer tarayıcılar, yol profil oluşturunucular (Road Profiler: bu cihazlar, ön tampon boyunca monte edilen lazerler ve ivmeölçerlerle arayüzlenen bir araç bilgisayarı ile donatılmış araçlardır.) ve kameralar gibi çoklu sensörlerle donatılmıştır (Eisenbach et al. 2017; Zhang et al. 2018). Ancak bu tür araçlar pahalıdır ve bu tür sistemleri satın almanın maliyeti, içerdiği sensörlere bağlı olarak yarım milyon dolara ulaşabilmektedir. Mobil lazer tarama ile donatılmış araçların yol kusur tespitinde kullanılması gelişmekte olan veya ekonomik şartların elverişsiz olduğu birçok ülkede maliyet açısından oldukça yüksektir (Arya et al. 2021).

Özetlemek gerekirse yol kusurlarının tespitinde genel olarak üç yaklaşım bulunmaktadır. Ancak son yıllarda yapay zekâ ve alt dallarındaki gelişim dikkate alındığında araştırmacılar ikinci yaklaşım olan yarı-otomatik kaplama hasar durumu üzerinde çalışmalar yapmaktadır. Yol kusurlarının algılanma süreci insan manuel belirlemesi yerine yapay zekâ algoritmaları ile yürütülmektedir. Çünkü ana amacın yol ağında var olan yol kusur tespitinin belirlenmesi olduğu ve bu amacın en doğru, hızlı, verimli ve düşük maliyetli olarak gerçekleşmesi yapay zekâ tabanlı sistemler ile olacağı ön görülmektedir.

Yol kusurları hakkında hem ulusal hem de uluslararası çalışmalar detaylı olarak incelenmiş ve analiz edilmiştir. Literatürde yer alan çalışmalar incelendiğinde özellikle 2016 yılı itibariyle bu alanda bir eğilim olduğu gözlemlenmiştir. Bunun birçok sebebi olabilir. Yol ağlarının zamanla eskimesi ve üzerinde oluşan hasarlar, AUS alanında disiplinler arası çalışma arzusu, yapay zekâ ve alt dallarına erişebilirlik, geleceğin yapay zekâda olacağı düşüncesi ve yol hasar tespit araçlarının yüksek maliyetli olması gibi birçok sebep düşünülebilir. Ayrıca teknoloji alanında yapılan akademik çalışmaların yayınladığı ve en prestijli kuruluşlardan bir tanesi olan Institute of Electrical and Electronics Engineers (IEEE) 2014 yılından itibaren Big Data ana başlığı altında farklı

konularda konferanslar düzenlemektedir. 2020 Yılında düzenlemiş olduğu konferansın ana teması “Yol hasar tespit mücadelesi” olarak ilan edilmiştir. Bu bağlamda onlarca farklı ülkeden 121 ayrı takım, sunulan veri seti ile en iyi yol hasar tespit yaklaşımını önermek için mücadele etmişlerdir. Aslında bu durum yol hasar tespitinin farklı bakış açıları ile gerçekleşmesinin uluslararası platformlarda ne kadar önem arz ettiğinin ispatı olarak ifade edilebilir. IEEE ayrıca 2018 ve 2019 yılında düzenlemiş olduğu konferanslarda ana tema yol hasarı olmasa da bu alanda var olan ihtiyacı gördüğü için yol hasar verilerinin toplanması için bazı araştırmacılardan destek almıştır. Yol hasar verilerinin açık kaynak olarak sunulması 2018 yılı itibariyle başlamıştır. Yol hasar veri seti (RDD) olarak literatüre kazandırılmıştır (Anonymous 2021). Kitle algılama tabanlı Yol Hasarı Tespit Yarışması (CRDDC2022) ile toplam altı farklı ülkeden elde edilen yol hasar verileri ile birlikte bu alanda yapılan çalışma trendi daha da hız kazanmıştır. Birçok takımın katılım sağladığı bu yarışmada son teknoloji nesne algılama modelleri kullanılmıştır.

2.2. Yol Kaplamasında Meydana Gelen Kusurlarının Belirlenmesine Yönelik Yapılan Çalışmalar

Yol ağları, yapım aşamasından belirli bir süre sonra yaşlanmakta ve denetleme iş yükü giderek artmaktadır. Denetlenecek yol ağı uzunluğunun önümüzdeki dönemde hızla artması beklenmektedir. Buna ek olarak, yol ağlarının eskimiş ve etkilenen kısımlarının keşfi şu ana kadar yalnızca deneyimli saha mühendislerinin uzmanlığına bağlı olmakla birlikte yerel yönetimlere bağlı yol ağları daha kalifiyesiz denetime maruz kalmaktadır. Ancak denetimlere olan talebin artması nedeniyle birçok alanda saha teknisyeni (uzman) ve mali kaynak sıkıntısı yaşanmaktadır. Özellikle mali kaynak veya uzman eksikliği nedeniyle uygun denetimleri sağlayamayan yerel belediyelerin sayısı artmaktadır. Bu problem sadece ülkemiz için değil Japonya ve ABD gibi gelişmiş ülkeler için de mevcuttur (Maeda et al. 2018). Altyapı bakımı ve yönetiminde yaşanan sorunların tüm dünya ülkeleri tarafından yaşanması muhtemeldir. Altyapı bakımı ve yönetimindeki bu olumsuz eğilim göz önüne alındığında, etkin ve gelişmiş altyapı bakım yöntemlerine acilen ihtiyaç duyulduğu açıktır. Bu soruna çözüm olarak, lazer teknolojisi veya görüntü işleme kullanan yöntemler gibi altyapıyı, özellikle de yol koşullarını verimli bir şekilde denetlemek için birçok yöntem incelenmiştir. Ayrıca 1989'dan 2000'e kadar geçen 11

2. KAYNAK ÖZETLERİ

yılda inşaat mühendisliği problemlerinde sinir ağlarını kullanan birçok çalışma bulunmaktadır (Adeli 2001). Son zamanlarda yol yüzeyi incelemesini otomatikleştirmek için bilgisayarlı görme ve makine öğrenme teknikleri başarıyla uygulanmıştır (Zalama et al. 2014; Jo and Ryu 2015). Yol hasar verileri IEEE'nin düzenlediği Big Data konferansları ile açık kaynak olarak sunulmaya ve her geçen yıl geliştirilmeye devam etmektedir. 2018 yılında başlayan süreç günümüzde halen devam etmektedir.

Tüm bu süreçler dikkate alındığında Maeda et al. (2018) 2018 yılında sekiz adet yol kusur veri seti oluşturmuşlardır. Yol yüzeyi kusuru çeşitli kategorilere ayrılmış olmasına rağmen Japonya'da, Yol Bakım ve Onarım Rehberi'ne göre sekiz kategoriden oluşmaktadır. Bu çalışmada yeni, büyük ölçekli bir yol kusur veri seti geliştirilmiş ve ardından en son teknolojiye sahip evrişimli sinir ağı (CNN) yöntemini temel alan bir kusur tespit modelini eğitip değerlendirilmiştir. Yol kusur verilerinin toplanması için yedi yerel yönetim (Ichihara şehri, Chiba şehri, Sumida bölgesi, Nagakute şehri, Adachi bölgesi, Muroran şehri ve Numazu şehri) seçilmiştir. Toplamda yaklaşık 1.500 km yol kat edilerek 163.664 yol görüntüsü elde edilmiştir. Yedi belediye kentsel alanları, hava durumu ve mali kısıtlamalar gibi bölgesel özellikleri açısından çok çeşitlidir. Aracın ön camına yerleştirilen akıllı telefon kamerası yardımı ile görüntüler elde edilmiştir. Çizelge 2.1'de farklı kusur türleri ve tanımları listelenmektedir. Bu yazıda her hasar türü D00 gibi bir sınıf adı ile temsil edilmektedir. "D" harfi kusur anlamına gelen "defect" kelimesinden gelmektedir.

Çizelge 2.1. RDD 2018 veri setinde yer alan yol kusur türleri ve tanımları (Maeda et al. 2018).

Kusur türü		Detay	Sınıf ismi
Çatlak	Doğrusal Çatlak	Boyuna Yol kenarı çatlağı(Wheel-marked part)	D00
		Derz çatlakları(Construction joint part)	D01
		Düşük ısı çatlakları(Equal interval)	D10
		Derz çatlakları(Construction joint part)	D11
	Timsah Çatlağı		D20
Diğer hasarlar		Çukur	D40
		Yaya geçit bulanıklığı	D43
		Şerit çizgisi bulanıklığı	D44

Elde edilen veri seti 9.053 adet etiketli yol kusur görselinden oluşmaktadır. Bu 9.053 görüntüden 15.435 sınırlayıcı kusur kutusu açıklanmıştır. Japonya'nın çeşitli bölgelerinde çok sayıda yol fotoğrafı çekilmiştir ancak bazı verilerin yanlış olması önlenememiştir. Örneğin D40 gibi hasarlar daha ciddi bir tehlike oluşturmakta ve dolayısıyla yol yöneticileri bu hasarları meydana gelir gelmez onarmaktadır. Dolayısıyla gerçekte çok fazla D40 hasar türü elde edilmesi zordur. Elde edilen verilerin eğitilmesinde Tek Atış Çoklu Kutu Dedektörü (SSD) Inception V2 ve SSD MobileNet çerçeveleri tercih edilmiştir (Liu et al. 2016). Derin öğrenmeyi kullanan nesne tespit algoritmasında verilerden öğrenilen parametreler çok büyük olduğu için araştırmacılar tarafından belirlenen hiper parametrelerin sayısı da oldukça fazladır. Model sonuçları incelendiğinde genel olarak, SSD MobileNet daha iyi sonuçlar vermektedir. Tespit sonuçlarını daha iyi anlamak için hata analizi yapılarak hatalar, yanlış pozitifler ve yanlış negatifler olarak sınıflandırılmıştır. Yan olukların ve rögar kapaklarının hasar olarak değerlendirildiği ve ön cam sileceklerinden gelen yansımanın yaya geçidinde bulanık olduğuna karar verilen örnekler yer almaktadır.


Maeda et al. (2020) gerçekleştirdiği çalışmada, Yol Hasarı Veri Seti 2018'i (RDD2018) (Maeda et al. 2018) güncellenmiş ve buna Yol Hasarı Veri Seti 2019 (RDD2019) adını vermiştir. Güncellemeler, etiketli yol görüntüsü verilerinin eklenmesini ve her görüntünün etiketleme kalitesinde iyileştirmeler içermektedir. Ayrıca bu çalışmada, çukur hasarının yollarda konfor ve güveni olumsuz etkilediğinden RDD2019 ile çukur tespit doğruluğunu iyileştirmiştir. Çukur tespit doğruluğunun bir ilerici büyüyen üretken adversarial ağ (PG-GAN) ve Poisson harmanlama yöntemleri kullanılarak geliştirilebileceğini göstermektedir (Gao et al. 2019). Kısaca, PG-GAN kullanılarak yapay olarak sadece verilen dikdörtgenin içinde bir çukur oluşturulmakta ve bu görüntüler Poisson harmanlama yoluyla zarar görmeden yol görüntüleri ile birleştirilmektedir. Oluşturulan görüntüler yeni/ek eğitim verileri olarak kullanılmıştır. PG-GAN, düşük çözünürlüklü olanlardan yüksek çözünürlüklü görüntüler oluşturmak için artımlı çok aşamalı eğitim kullanarak gerçekçi görüntüler üretmektedir (Karras et al. 2018). Bu çalışmada, yüksek çözünürlüklü çukur görüntülerini eğitmek için 128×128 sentetik görüntü oluşturmak üzere PG-GAN kullanılmıştır. İnşaat mühendisliğinde bir nesne algılama görevi için GAN tabanlı veri artırmayı uygulayan ilk çalışmadır. Ancak bazı araştırmalar, eğitim süreci sırasında ve orijinal veri kümesi küçük olduğunda veri

2. KAYNAK ÖZETLERİ

önyargılarının artabileceğini öne sürmekte; bu nedenle, GAN tabanlı veri artırma daha düşük doğruluğa yol açabilmektedir. Bu nedenle, bu çalışmayla oluşturulan görüntülerin kaliteli olup olmadığını doğrulamak için uzman yol yöneticileri tarafından görsel test ile dikkatli bir şekilde analiz edilmiştir (Salimans et al. 2016). Önerilen yöntem dört adımdan oluşmaktadır.

- RDD 2018 veri setinde çukuru içeren bir dikdörtgen kutu kesilir.
- PG-GAN kullanarak üretken modeli eğitilir ve sentetik görüntüler oluşturulur.
- Oluşturulan görüntüleri Poisson harmanlama kullanarak hasarsız yol görüntüleri ile birleştirilir.
- PG-GAN ve Poisson harmanlaması tarafından oluşturulan sentetik görüntüleri RDD2019 ile birleştirilerek yol hasarı tespit modeli eğitilir.

2018 yol hasarı veri kümesine ek olarak rögar kapağı kusur türü de D50 olarak bu çalışma ile eklenmiştir. 2018 yol hasar görüntüsü 9.053 iken 2019'da 13.135'e yükseltilmiştir. Her iki veri setine ait kusur türü bazlı karşılaştırma Şekil 2.1'de verilmiştir. Yeni eklenen görüntülerden 2.000 adeti test aşaması için kullanırken geri kalan verileri 9'a 1 olacak şekilde eğitim ve doğrulama için ayrılmıştır. Bu çalışma, önceki makalede bahsedilen metodolojiyi takip etmiştir (Maeda et al. 2018). Bu araştırmada Howard et al. (2017) tarafından oluşturulan MobileNet ile SSD ve Resnet50 ile SSD kullanılmıştır.



Şekil 2.1. RDD 2018 ve 2019 yol hasar görüntü sayılarının zamanla değişimi

2018 ve 2019 yılında IEEE tarafından gerçekleştirilen Big Data konferanslarında yol hasarları ile ilgili çalışmalar bazı araştırmacılar tarafından gerçekleştirilmiş olup konferansın ana başlıkları altında yer almamıştır. Ancak 2020 yılında düzenlenen konferansın ana temalarından bir tanesi de yol hasarıdır. Çünkü önceki iki yılda elde edilen ve yeni eklenen veriler ile birlikte büyük veri hazırlığı tamamlanmıştır. Yol hasarlarının belirlenmesinin altında birçok neden yer almaktadır. Yol ağları insanların yaşamları üzerinde doğrudan ve önemli bir etkisi olduğundan, yolların bakım ve yönetiminin kapsamlı bir şekilde yapılması gerekmektedir. Bununla birlikte, yol hasarı değerlendirmesine yönelik geleneksel yöntemler manuel incelemeyi içerir ve zaman alıcıdır, maliyetlidir, oldukça öznel ve hataya açıktır. Bu tür yol hasarlarını değerlendirebilecek ve onarım çalışmaları için en uygun kaynak tahsisine ilişkin karar verebilecek uzmanların sayısı sınırlı olduğundan sorun daha da kötüleşmektedir. Ayrıca mali kaynak yetersizliği birçok yerel yönetimin yeterli denetimleri zamanında yapamamasına neden olmaktadır. Bazı belediyeler, yüksek performanslı sensörler kullanarak yol hasarı tespitini otomatik hale getirmektedir. Bununla birlikte, bu sensörlerin yüksek maliyeti, denetlenecek yolların geniş alanı nedeniyle bunların ülke düzeyinde kullanılmasını olanaksız kılmaktadır. Bu nedenle yol hasarlarının değerlendirilmesini kolaylaştıracak, yol yüzeyindeki hasarları düşük maliyetle ve daha kısa sürede tespit edebilecek bir sisteme ihtiyaç ortaya çıkmaktadır. 2018 yılı itibarıyla bu düşünce için çözüm önerileri başlatılmış ve bu yarışma ile daha sağlam çözüm önerileri elde edilmiştir.

Yarışma komitesi Hindistan, Japonya ve Çek Cumhuriyeti'nden elde edilen veriler ile birlikte 2018 yılına göre veri seti sayısını üç katına çıkarmıştır. Ancak yol hasar sınıflamasında sınırlamaya gidilmiştir. D00, D10, D20 ve D40 hasar türleri için çalışmalar devam etmiştir. Bu durumun ana sebebi olarak diğer yol hasarlarının toplanmasının zor ve maliyetli oluşu gösterilmiştir. Katılımcıların üç ülkeden alınan görüntüdeki yol hasarlarını otomatik olarak tanıyabilecek bir algoritma önermeleri gerekmektedir. Veri seti; Eğitim, Test1 ve Test2 olarak üç bölüme ayrılmıştır. Araştırmacıların uygulamış oldukları modellerin performans değerlendirme kriteri F1 puanı ile ölçülmüştür.

Arya et al. (2020), IEEE Uluslararası Büyük Veri Konferansı 2020'nin bir parçası olarak düzenlenen bir Büyük Veri Kupası olan Küresel Yol Hasarı Tespit Yarışmasını (GRDDC) bu çalışma ile özetlemektedir. Yarışmaya farklı ülkelerden 121 takım katılım sağlamıştır. Bu çalışma en iyi 12 çözümü ele almaktadır. En iyi performans gösteren model, Test1'de 0,67 ve Test2'de 0,66 F1 puanı elde etmek için YOLO tabanlı topluluk öğrenimini kullanmaktadır. Makale, sunulan yarışmada başarılı olan modellerin ve gelecekteki yarışmayı geliştirilebilecek yönlerin bir incelemesiyle sona ermektedir.

Naddaf-Sh et al. (2020) yol hasar tespitinde doğruluk, gerçek zamanlı performans ve ölçeklenebilirlik arasındaki dengeyi sağlamak için EfficientDet adı verilen tek aşamalı bir ağ ailesi kullanmıştır. Tan et al. (2019)'ları tarafından geliştirilen EfficientDet, donanım kaynağı kısıtlamalarına göre verimli bir şekilde ölçeklenebilen tek aşamalı, tek modelli ve tek ölçekli bir nesne dedektörüdür. Ayrıca eğitilen model, sınırlı donanım ve güç kaynaklarına sahip mobil cihazlardan çoklu Grafik İşleme Ünitesi (GPU) istasyonlarına kadar çeşitli uç cihazlarda dağıtılabilir. EfficientDet'te çok ölçekli özellik çıkarma görevi EfficientNet omurgası tarafından gerçekleştirilir (Tan and Le 2019). Dört farklı yol hasar sınıfı ile gerçekleşen algılama süresi farkı parti boyutu (Batch size) ve çıkarım süreleri ile gerçekleştirilmiştir. Önerilen modeller %52 ile %56 arasında değişen F1 puanları ve saniyede 10-178 görüntü arasında ortalama çıkarım süresiyle sonuçlanmıştır.

Pei et al. (2020) bu makale ile üç ülkeden (Hindistan, Japonya ve Çek Cumhuriyeti) alınan görüntülerde yer alan mevcut yol hasarlarını tespit etmek için GRDDC'de kullandığı çözümü sunmaktadır. Yarışma sürecinde, görüntülerdeki nesneleri tespit etmek için temel model olarak Cascade R-CNN seçilmiştir (Cai and Vasconcelos 2018). Büyük bir veri kümesinde kesin bir açıklama yapmanın, nesne algılama performansı açısından çok önemli olduğu ve her görüntüdeki her nesne için sınırlayıcı kutular yerleştirmenin zaman alıcı ve maliyetli olduğu yaygın olarak bilinmektedir. Eğitim aşamasında etiketli verilere bir dizi veri artırma tekniği (yol bölümlleme, çevirme, karıştırma) uygulanmaktadır. Farklı algılama modelleri ve omurga ağları ile veri seti eğitilerek karşılaştırma süreci gerçekleştirilmiştir. Son olarak, önerilen yöntem, sırasıyla Test1 veri kümesinde 0,6290 ve Test2 veri kümesinde 0,6219 ortalama F1 puanı elde ederek yarışmayı 3. sırada tamamlamıştır.

Vishwakarma and Vennelakanti (2020) bu çalışma ile model seçimi, ayarlama stratejisi ve GRDDC için elde edilen sonuçları içeren çözüm hakkında bir rapor sunmaktadır. Nesne algılama için tek ve çok aşamalı ağ mimarileri değerlendirilmiş ve Detectron2 ve YOLOv5 (Hoher 2020) gibi son teknoloji ürünü açık kaynaklı PyTorch çerçeveleri kullanarak bir kıyaslama sağlanmıştır. Eğitimin etkisi tek bir genelleştirilebilir modele göre ülke bazında incelenmiştir. Deep Residual Network (Resnet) (He et al. 2016) ve Özellik Piramit Ağı (FPN) (Lin et al. 2016) omurgasına sahip iki aşamalı Faster R-CNN (Ren et al. 2017) üzerinde gerçekleştirilen deneyler için ayarlama stratejisi kısaca açıklanmıştır. Ek olarak, tek aşamalı dedektör olan YOLOv5 modeliyle karşılaştırılmalı analiz sağlanmıştır. Sırasıyla Resnet-50 ve Resnet-101 omurgalarına sahip çok aşamalı Faster R-CNN modeli kullanarak Test2'de 0,542 ve Test1 veri kümelerinde 0,536 ortalama F1 puanı elde edilmiştir. Deneyler, K80'e sahip Google Colab ve 1080Ti, NVIDIA tüketici sınıfı GPU'ya sahip bir Linux bilgisayar kullanılarak gerçekleştirilmiştir.

Mandal et al. (2020) yol kaplama bozukluklarının otomatik olarak algılanması ve sınıflandırılması, kaplama yüzeylerinin zamanında bakım ve onarım edilmesi açısından kritik öneme sahip olduğunu vurgulamışlardır. Bu çalışmada yazarlar, yol hasarlarını tespit etmek ve karakterize etmek için farklı ağ omurgalarına dayalı son teknoloji ürünü derin öğrenme algoritmalarını kullanmaktadırlar. Sınıflandırma performanslarını değerlendirmek için CSPDarknet53, Hourglass-104 ve EfficientNet gibi farklı omurga modellerinin etkisi incelenmiştir. Modeller; Japonya, Çek Cumhuriyeti ve Hindistan'ın kentsel ve kırsal sokaklarında çekilen 21.041 görüntü kullanılarak eğitilmiştir. Son olarak modeller, hasarları tahmin etme ve sınıflandırma yeteneklerine göre değerlendirilmiş ve istatistiksel hassasiyet ve duyarlılık değerlerinden elde edilen F1 puanı kullanılarak test edilmiştir. En iyi performans gösteren YOLO modeli, GRDDC tarafından yayınlanan iki test veri setinde 0,58 ve 0,57 F1 puanı elde etmiştir. Modellerin timsah tipi çatlakları ve çukurları tespit etmede genel olarak iyi performans gösterdiğini ancak enine çatlakları tespit etmekte zorluk yaşadıklarını gösteriyor. Önerilen çözüm ile yarışmaya katılan dünya çapındaki 121 takım arasında 4. sırada yer almasına katkı sağlamıştır.

Liu et al. (2020) geleneksel yol hasarı tespitinin büyük miktarda manuel çaba gerektirmesi nedeniyle, yol hasarlarını otomatik olarak tespit edebilen görüntü tabanlı

sistemlerin önerilmesi gerektiğini düşünmektedir. Bu çalışmada yol hasarlarını verimli bir şekilde tespit etmek için derin öğrenme modellerini kullanmaktadır. Özellikle yol alanlarını tespit etmek ve ham görüntüler için bir yol ilgi haritası oluşturmak amacıyla bir segmentasyon yöntemi uygulanmıştır. Daha sonra tespitin tamamlanması için Faster R-CNN ve YOLOv4'ü (Bochkovskiy et al. 2020) içeren son teknoloji ürünü derin hedef tespit modelini benimsenmiştir. Ayrıca daha iyi sonuçlar için tek model tahminlerinden oluşan bir topluluk stratejisi önerilerek Test1 için 0,5636 ve Test2 için 0,5707 F1 puanları elde edilmiştir.

Kortmann et al. (2020) yol hasarlarının federal karayolu otoriteleri ve onların altyapı yönetiminin yanı sıra otonom sürüş görevi ve dolayısıyla araç yolcularının güvenliği ve konforu açısından da önem arz ettiği fikrine sahiptirler. Bu nedenle farklı türdeki yol hasarlarının otomatik olarak tespit edilmesi araştırılmıştır. Çalışmanın veri temeli Japonya, Hindistan ve Çek Cumhuriyeti'nden çok sayıda etiketli görselin yer aldığı RDD2020 veri seti tarafından sağlanmaktadır. Derin öğrenme tabanlı önceden eğitilmiş Faster R-CNN algılama modeli olarak kullanılmıştır. Tek tahminci ve bölgesel uzman için makro, mikro ve ağırlıklı F1 puanları incelendiğinde 0,487'lik bir değere ulaşıldığı gözlenmektedir.

Zhang et al. (2020) yol denetiminin otomasyonu için hızlı ve doğru yol hasarı tespitinin çok önemli olduğunu ve derin öğrenmeye dayalı dijital görüntülerde tipik yol hasarı tespiti için çözüm önerisini bu çalışmada gerçekleştirmiştir. Yakın zamanda önerilen YOLOv4 temel ağ olarak seçilirken veri artırmanın, aktarım öğreniminin, optimize edilmiş bağlantıların ve bunların birleşiminin etkileri değerlendirilmiştir. Tek bir modelle çok sınıflı örnekler üretebilen, üretken rakipsel bir ağa dayalı yeni bir yol hasarı veri üretme yöntemi önerilmiştir. Yol hasar verilerini oluşturmak için GAN kullanılması ve böylece eğitim setindeki örneklerin zenginleştirilmesi önerilmiştir. GAN tarafından üretilen 1.126 sentetik görüntüden sonra RDD 2020 veri setinin Test1 ve Test2 kısmında 0,5538 ve 0,5412 F1 puanlarına ulaşılmıştır.

Hascoet et al. (2020) yaşanan altyapının bakımı, şu anda dünyanın her yerindeki yerel ve ulusal yöneticilerin karşılaştığı bir zorluk olduğunu ve etkin altyapı bakımının önemli bir ön koşulu olarak çok büyük yapıların durumunun sürekli olarak izlenmesi

olduğunu düşünmektedir. Bilgisayarlı görme, özellikle derin öğrenme modellerinin başarılı uygulamalarındaki ilerlemeler daha önce otomatikleştirilmesi mümkün olmayan görüntü görevlerinin otomasyonuna olanak tanınmakta ve yöneticilere altyapı bakım operasyonlarını optimize etme konusunda umut verici olanaklar sunmaktadır. Bu bağlamda, GRDDC derin öğrenme ve bilgisayarlı görüntü araştırmacılarına sürece dahil olma ve yol ağlarındaki kaplama hasarlarını doğru bir şekilde takip etme fırsatı vermektedir. Önerilen yaklaşım basitlik açısından Faster RCNN iki aşamalı algılama mimarisine dayanıyordu. Çoğu deneyde temel omurga olarak bir ResNet-50 kullanılmıştır. Modelin bu test setlerinde elde ettiği F1 puanı, Test1 ve Test2 için sırasıyla 0,541 ve 0,543'tür. Modeli yerel bir karayolu ağında uygulamaya koyma hedefiyle RaspBerry Pi 4 ve görüntü yakalamak için PiCamera HQ kamera kullanılmıştır.

Pham et al. (2020) yol ağlarının yaşamın birçok yönü için hayati öneme sahip olduğunu ve yol bakımının insan güvenliği açısından ele alınması gerektiğini savunmuşlardır. Yol hasarlarının zamanında onarılmasına olanak tanıyan kritik görevlerden biri, bunların hızlı ve verimli bir şekilde tespit edilmesi ve sınıflandırılmasıdır. Bu çalışma, bu görevler için değerlendirilen stratejileri ve deneyleri detaylandırmaktadır. Spesifik olarak, Detectron2'nin Faster R-CNN uygulamasını farklı temel modeller ve konfigürasyonlar kullanarak değerlendirilmiştir. Sonuçlar, Detectron2'nin varsayılan yapılandırmalarına sahip Faster R-CNN için X101-FPN temel modelinin, bu zorlukta farklı ülkelere aktarılabilecek kadar verimli ve genel olduğunu göstermektedir. Bu yaklaşım, yarışmanın Test1 ve Test2 setleri için sırasıyla %51,0 ve %51,4 F1 puanlarıyla sonuçlanır. Her ne kadar görselleştirmeler iyi tahmin sonuçları gösterse de F1 puanları düşük kalmaktadır. Bu nedenle, bu veri kümesi için etiketleme sürecini iyileştirecek stratejiler de önerilerek daha iyi sonuçlar elde edileceği açıklanmıştır.

Doshi and Yilmaz (2020) teknolojideki, özellikle de bilgisayarlı görme alanındaki son gelişmelerle birlikte, artık farklı türdeki yol hasarlarını tespit etmenin ve sınıflandırmanın mümkün hale geldiğini ifade etmektedirler. Bu çalışmada GRDDC'de sunulan yol hasarlarının etkili bir şekilde tespiti ve sınıflandırılması için bir topluluk modeli sunulmaktadır. Önerilen yaklaşımda YOLOv4 nesne dedektörünün kullanılmıştır. Topluluk yaklaşımı, birkaç farklı model versiyonuyla kapsamlı bir şekilde test edilmiştir

ve Test1 veri kümesinde 0,628 ve Test2 veri kümesinde 0,6358 F1 puanı elde etmeyi başarmıştır.

Jeong (2020) derin öğrenmeye dayalı teknoloji, gerçek dünyamızdaki nesne algılama görevlerinin kilidini açmak için iyi bir anahtar olduğunu düşünmektedir. Derin sinir ağlarını kullanarak yol hasarlarını tespit etmek gibi tehlikeli ve çok zaman alan ayrıca her gün yapılması gereken bir sorunu ortadan kaldırma zorluğunu benimsemiştir. Bu çalışma, GRDDC’de çeşitli yol hasarlarını tespit etmek için YOLO kullanan çözümü açıklamaktadır. YOLOv5x tabanlı çözüm yaklaşımı hafif ve hızlı olmakla birlikte yüksek doğruluk oranına sahiptir. Test zamanlı çoğaltma topluluk modeli kullanarak 0,58’lik bir F1 puanı elde edilmiş olup ve bu değer, gerçek yol hasarını gerçek zamanlı olarak tespit etmek için yeterli bir çözüm önerisi olduğu belirtilmiştir.

Hegde et al. (2020)’a göre etkili yol bakımı için yol idare ekiplerinin zahmetli ve zaman alıcı manuel incelemelerini önlemek amacıyla otomatik bir izleme sistemi gereklidir. Potansiyel bir çözüm olarak ise gözetleme kameraları, araç içi kameralar veya akıllı telefonlar gibi çeşitli görüntü kaynaklarının hâlihazırda mevcut olması nedeniyle görüntü işleme tabanlı teknolojilerin kullanılması planlanmaktadır. Bu tür görüntü tabanlı çözümler yol hasarlarının tespit edilmesini ve sınıflandırılmasını sağlamaktadır. Bu makale, yol hasarı tespiti ve sınıflandırması için derin öğrenmeye dayalı görüntü analizini tanıtmaktadır. Test süresini artırmaya yönelik toplu öğrenme yaklaşımları GRDDC veri kümesi kullanılarak kapsamlı bir şekilde değerlendirilmiştir. İlk önce Faster R-CNN, YOLOv3 (Redmon and Farhadi 2018) ve ultralytics-YOLO dâhil olmak üzere çeşitli CNN tabanlı nesne algılama yöntemleri değerlendirilmiştir. u-YOLO'nun hem Faster R-CNN hem de YOLOv3'ten daha iyi performans göstermiştir. Deneysel sonuçlar, önerilen yaklaşımın 0,67'ye kadar F1 puanı elde ettiğini göstermektedir.

Yolların insanların yaşamları üzerinde doğrudan ve önemli bir etkiye sahip olduğu göz önüne alındığında, yolların bakım ve onarımının zamanında ve kapsamlı bir şekilde yapılması gerekmektedir. Ancak mali kaynak yetersizliği birçok yerel yönetimin yeterli denetimleri zamanında yapamamasına neden olmaktadır. Bazı belediyeler, yüksek performanslı sensörler kullanarak yol hasarı tespitini otomatik hale getirmektedir.

2. KAYNAK ÖZETLERİ

Bununla birlikte bu sensörlerin yüksek maliyeti ve denetlenecek yolların geniş alanı nedeniyle bunların ülke düzeyinde kullanılmasını olanaksız kılmaktadır.

Önceki yarışmalarda katılımcılar, modelleri eğitmek için yalnızca yarışma veri kümesini kullanmakla sınırlıydı. CRDDC2022 ile katılımcıların kendi veri setlerini geliştirmelerine/önermelerine olanak tanınarak bu kısıtlama ortadan kaldırılmıştır (Anonymous 2022b). Bu yarışmanın ana teması, katkıda bulunanların seçimine göre toplanan sensör verilerinin kitlesel olarak kaynaklanması anlamına gelen "Kitlesel Algılama"dır. Bu yarışma Hindistan, Japonya, Çek Cumhuriyeti, Norveç, ABD ve Çin gibi altı farklı ülkeden hasarlı kısımları barındıran yol görüntülerini içermektedir. Hasar bilgisi, sınırlayıcı kutunun koordinatları ve kutuyla ilişkili hasarın türünü gösteren bir etiket olarak sağlanır. Veri seti eğitim ve test olmak üzere iki bölüme ayrılmıştır. Eğitim verilerinin etiketlenmiş olarak araştırmacılara sağlanırken test seti yalnızca modelleri test etmeye yönelik olduğu için etiketsiz olarak sunulmuştur. Yeni eklenen ülkelerden Norveç ve ABD'den gelen verilerin RDD2020 verileri formatını takip ettiği belirtilebilir (yol görüntüleri, araca monteli kameralar kullanılarak yol yüzeyine paralel olarak yakalanır). Çin için, diğer ülkelerden farklı bir açıda yakalanan veriler (drone/el tipi akıllı telefon kullanılarak çekilen yukarıdan aşağıya/eğik görüntüler) kullanılmaktadır. Bu verileri eklemenin amacı veri kümesinin heterojenliğini arttırmaktır. Kullanıcılar, modeli eğitirken veri kümesini bir bütün olarak mı kullanacağına veya yukarıdan aşağıya görüntüleri atlayıp atmayacağına karar verebilir.

Arya et al. (2022) bu çalışma ile IEEE Uluslararası Büyük Veri Konferansı'nın bir parçası olarak düzenlenen CRDDC'yi özetlemektedir. Büyük Veri Kupası yarışması, yayınlanmış bir veri kümesini ve net değerlendirme ölçütleriyle iyi tanımlanmış bir sorunu içermektedir. Yarışmalar, katılımcılar için gerçek zamanlı bir çevrimiçi değerlendirme sistemi sağlayan bir veri rekabeti platformunda gerçekleştirilir. Sunulan vakada veriler Hindistan, Japonya, Çek Cumhuriyeti, Norveç, ABD ve Çin'den toplanan 47.420 yol görüntüsünden oluşuyor ve bu ülkelerdeki yol hasarlarının otomatik olarak tespit edilmesine yönelik yöntemler önerilmektedir. Bu yarışmaya 19 ülkeden 70'in üzerinde takım kayıt yaptırmıştır. Bu makale, bu ekipler tarafından önerilen en iyi 11 çözümü özetlemektedir. En iyi performans gösteren model, altı ülkenin tamamından

2. KAYNAK ÖZETLERİ

alınan test verileri için %76'lık bir F1 puanı elde etmek üzere YOLO ve Faster-RCNN serisi modellerine dayalı toplu öğrenmeyi kullanmaktadır.

Wang et al. (2022) bilgisayarlı görme alanındaki gelişmeler, otomatik ve etkili görüntü tabanlı yol hasarı tespiti için fırsatlar yaratacağını bildikleri için derin evrişimli sinir ağları sayesinde yol hasarının lokalizasyonu ve sınıflandırılması işleminin aynı anda gerçekleştirilebilir olacağını planlamaktadırlar. Bu makale, YOLOv5 ağını ve dikkat modüllerini temel alan test süresini artırmaya sahip bir topluluk modeli önermektedir. Görüntülerde yola daha fazla odaklanmak için dikkat modüllerine sahip beş adet geliştirilmiş YOLOv5 modeli önerilmektedir. Ayrıca, model genellemesini ve tespit performansını iyileştirmek için topluluk öğrenimi ve test süresinin artırılması benimsenmiştir. Farklı topluluk modelleri, beş test veri kümesinde ortalama 0,65177 F1 puanı elde etmiştir.

Ding et al. (2022) kentlerin büyümesi ve araç sayısının artmasıyla birlikte yolların bakımı ve onarımının daha fazla ilgi gördüğünü ayrıca işçilik maliyetini azaltmak için farklı coğrafi ortamlardan ve algılama cihazlarından alınan yol hasarı görüntülerinden en iyi şekilde yararlanmanın kaçınılmaz olduğunu vurgulamaktadır. Bu çalışmada CRDDC'de en iyi sonuca ulaşan birincilik çözümü açıklanmaktadır. Sırasıyla tek aşamalı ve iki aşamalı temel modelleri olarak YOLO serisi modelleri ve Faster RCNN kullanılmaktadır. Önerilen modeller toplam altı ülkenin veri kümeleri üzerinde doğrudan eğitilmiştir. Ayrıca, topluluk öğrenimi ve test süresinin artırılmasıyla topluluk modeli, ince ayar yapmadan her bir ülkenin (Hindistan, Japonya, ABD ve Norveç) sıralama tablosunda en iyi sonuçları elde etmektedir. Topluluk modeli, genel ve ortalama skor tablosunda 0,7699 ve 0,7160'lık F1 puanlarına ulaşarak iyi bir performans sergilemiştir.

Bhavsar et al. (2022) görüntü tabanlı teknoloji, gözetleme kameraları veya araç içi kameralar gibi çeşitli görüntülerin yaygın olarak elde edilebilmesi nedeniyle önemli bir seçenek olarak görmektedirler. Bu çözüme yönelik olarak bu makale, farklı ülkelerden toplanan çeşitli görüntülerdeki yol hasarlarını tespit etmek ve sınıflandırmak için derin öğrenmeye dayalı bir yaklaşım sunmaktadır. Önerilen yaklaşım, ülke başına eğitilen bireysel modelleri ve tüm ülkeler için eğitilen genel bir modeli bütünleştirmektedir.

2. KAYNAK ÖZETLERİ

Deneysel sonuçlar, YOLOv5x yaklaşımının 0,73'e kadar F1 puanı elde ettiğini göstermektedir.

Okran et al. (2022) bu çalışmada, altı ülkede farklı toplama sistemleri (araçlara ve dronlara monte edilmiş kameralar ve akıllı telefon kameraları) tarafından elde edilen görüntülerde çatlak tespiti için derin öğrenmeye dayalı etkili bir model önermektedir. Başarılı eğitim prosedürleri kullanılarak ve çok ölçekli özellik çıkarım modelleri dâhil edilerek son teknoloji nesne algılama tekniği YOLOv7'nin etkili varyasyonları kullanılarak oluşturulmuştur (Wang et al. 2022). Üst çatlak tespit modelleri, önerilen topluluk modelini oluşturmak için maksimum olmayan bastırma yöntemi kullanılarak birleştirilir. Önerilen çatlak tespit modeli, CRDDC2022 veri seti kullanılarak eğitilmiş ve doğrulanmıştır. Test seti ile önerilen model, CRDDC2022'nin tüm liderlik tablolarıyla ortalama 0,65 F1 puanı üretmiştir.

Pokrywka (2022)'ya göre yol bakım denetimi, özel ekipmanlara sahip pahalı özel araçlar yerine, arabaya monte edilen düşük bütçeli akıllı telefonlar kullanılarak gerçekleştirilebilir. Ancak bu yaklaşım, görüntülerin işlenmesi için yüksek kaliteli bilgisayarlı görme sistemleri gerektirmektedir. Bu makale, CRDDC2022 sırasında geliştirilen bir yöntemi açıklamaktadır. Yöntem, model eğitimi sırasında verimli GPU kullanımına, farklı mimariler ve veri artırma ayarlarıyla çeşitlendirilmiş bir topluluk oluşturmaya odaklanmaktadır. Önerilen çözüm önerisi, tüm görseller için 0,60 F1 puanı ve tüm liderlik tablolarında ortalama 0,53 F1 puanı ile iyi bir sonuç elde etmektedir.

Yang et al. (2022) mevcut yöntemlerin karmaşık yol koşulları ve yol hasarının içerdiği seyrek özellikler nedeniyle iyi performans göstermediğine inanmaktadır. Bu nedenle daha gelişmiş çok ölçekli bağlamsal özellikler elde edebilecek yeni bir yol hasarı tespit ağı olan YPLNet'i önermektedir. Spesifik olarak bu makalede önerilen ağ YOLOv5'e dayalıdır, Piramit Sıkış Dikkati (PSA) modülünün omurga ağına eklenmesiyle özellik alanını zenginleştirmek için özellik haritasının çoklu ölçekte mekânsal bilgisi elde edilmektedir. Ayrıca özellik birleştirme aşamasında çok ölçekli alıcı alanlar altında bağlamsal özellikler elde etmek için farklı modüllerden yararlanılır ve bu bağlamsal özellikler zengin düşük seviyeli ve yüksek seviyeli bilgiler içermektedir. Önerilen ağ modeli yarışmada 0,635 ortalama F1 puanına ulaşmaktadır.

Pham et al. (2022) bu çalışmada, Google Sokak görünümünü kullanarak yol hasarı verilerini toplamayı, etiketlemeyi ve otomatik yol hasarı tespiti ve sınıflandırması için derin öğrenme modellerini eğitmek üzere etiket yumuşatma ve birleştirme yöntemi gibi koordineli dikkat ve ilgili doğruluk ince ayar teknikleriyle birlikte YOLOv7'yi kullanmayı önermektedir. Sonuçlar, Google Sokak görünümünden veri toplamanın verimli olduğunu ve önerilen derin öğrenme yaklaşımının sokak görünümünü kullanarak ABD'den toplanan yol hasarı verilerinde %81,7 ve tümünde %74,1 F1 puanı elde edilmesini sağladığını göstermektedir. Bu sonuçlar göre yazarlar bu alandaki 54 lider (özel şirket ve akademik kurum) arasında bu yarışmada veri katkısı olarak 2. (gümüş ödül), tahmin modeli olarak 3. (bronz ödül) olmuşlardır.

Kumari Saha and Sekimoto (2022) çatlak, çukur vb. farklı yol hasar türlerini düşük maliyetle tespit etmek için yol koşullarının otomatik olarak izlenmesi, hasarların erken tespiti ve zamanında bakımı açısından önem olduğunu vurgulamaktadır. Bu doğrultuda, akıllı telefonlardan veya araca monteli kameralardan çekilen geniş görüşlü yol görüntüleri üzerinde görüntü işleme teknikleri ve derin öğrenme kullanılarak yol hasarı tespiti son birkaç yılda aktif olarak araştırılmaktadır. Bu makale, derin öğrenmeye dayalı sinir ağları önermekte ve yol hasarı tespiti için farklı ülkelerden alınan yol hasarı verilerini birleştirmenin fizibilitesini araştırmaktadır. Modeller, CRDDC2022'nin bir parçası olarak sunulan veri kümesi üzerinde eğitildi ve eğitilen modeller test veri kümeleri üzerinde kapsamlı bir şekilde değerlendirilmiştir. Önerilen yaklaşım ortalama 0,628 F1 puanı elde ederek yarışmada ilk 10'a girmektedir. Genel olarak Hindistan, Japonya, Norveç ve ABD'den elde edilen F1 puanları sırasıyla 0,697-0,493-0,715-0,461 ve 0,775 olmaktadır.

Jeong and Kim (2022) yapmış oldukları çalışma ile yol hasarı tespit görevini derin öğrenme tabanlı bir teknoloji olan YOLO'yu kullanarak çözmektedir. Norveç'te çekilen yüksek çözünürlüklü yol hasarı görüntülerini diğer benzer boyutlu çözünürlüklü görüntülerle doğru bir şekilde kullanmak için görüntü döşeme tekniği benimsenmiştir ve dört farklı yol hasarı türünü tespit etmek için topluluk yöntemini kullanmak üzere on iki YOLOv5x modeli eğitilmiştir. Son olarak önerilen çözüm yaklaşımı ile ortalama 0,6744 F1 puanı ve 1 saniye başına işlenen kare sayısı (FPS) çıkarım hızı elde edilmiştir.

Saha et al. (2022) görüntü işleme teknikleri ve derin öğrenme kullanılarak yol hasarı tespiti üzerine araştırmaların son birkaç yılda aktif olarak yürütüldüğünü ancak bu araştırmaların çoğunlukla çatlakların, çukurların ve bunların varyantlarının tespitine odaklandığını fark etmiştir. Yol tekerlek izlerinin tespiti üzerine çok az araştırma yapılmıştır. Bu makale, 949 görüntüden oluşan ve hem nesne düzeyinde hem de piksel düzeyinde açıklamalar sağlayan yeni bir yol tekerlek izi veri kümesi önermektedir. Önerilen veri seti üzerindeki yol tekerlek izlerini tespit etmek için nesne tespit modelleri ve semantik bölümlendirme modelleri kullanılmıştır. Model performansını değerlendirmek ve yol tekerlek izi tespitinde karşılaşılan zorlukları belirlemek için model tahminlerinin niceliksel ve niteliksel analizi yapılmıştır. Nesne algılama modeli YOLOX'ler %61,6'lık ortalama hassasiyet (mAP) ve birim üzerindeki kesişmede (IoU) 0,5 değerine ulaşır ve semantik segmentasyon modeli 54,69'luk IoU'ya ve 72,67'lik doğruluğa ulaşır, böylece gelecekte benzer çalışmalar için bir kıyaslama doğruluğu sağlamaktadır.

Soyturk vd (2014), bu çalışma ile yol yüzeyinde yer alan çukur ve tümseklerin konumsal olarak belirlenebilmesi için 3-boyutlu ivme algılayıcılarından yararlanan bir sistem önermişlerdir. Araç içine yerleştirilen sistem yardımıyla araç bu gibi alanlardan geçtiğinde sarsıntının şiddeti hesaplanarak veri tabanına aktarılmakta ve elde edilen verilerin analizi sonucunda yol ağında var olan çukur veya tümseklerin yerleri tespit edilmektedir.

Chun and Ryu (2019) trafik güvenliğinde oldukça önemli bir paya sahip olduğu düşünülen kaplama durumunda meydana gelen kusurların erken tespiti ve onarımı için CNN tabanlı bir çalışma önermişlerdir. Araç içi kamera sistemi ile eğitim veri seti toplanmıştır. Veri büyütme/çoğaltma işlem adımları uygulayarak 6.756 eğitim görüntüsü sayısı artırılmıştır. Ayrıca bu çalışmada yol yüzey hasar tespit performansını artırmak amacıyla sahte etiketli veri kullanılmıştır. Son olarak elde edilen model performansını doğrulamak amacıyla 450 adet değerlendirme veri seti oluşturularak her bir görüntü uzman bir ekip ile test edilmektedir. Önerilen yaklaşım neticesinde modelin F1 puanı 0,8917 olduğu gözlenmiştir. Bu çalışmada yol işaretleme, yol tesisleri, yol oyukları ve gölgeler hasar türü olarak ifade edilmiştir.

Anaissi et al. (2019) bu çalışma ile yol koşullarını sürekli olarak izleyen, yöneticilere ve mühendislere karar desteği sağlayan bir sanal yol ağı denetçisi önermektedir. Bu denetçi, yol koşullarını değerlendirmek için araca monteli sensörlerden gelen titreşim ve ivme verilerini kullanmaktadır. Düşey ve yanal ivme verilerine uygulanan iki uyarlanabilir tek sınıflı destek vektör makine modeline dayalı yeni bir yol hasarı tespit yöntemi önermektedir. Bu yöntemi Avustralya'nın New South Wales kentindeki okul otobüslerindeki gerçek bir dağıtımdan elde edilen veriler üzerinde değerlendirilmiştir. Elde edilen sonuçlar göstermektedir ki yol hasarı olan çukurları %97,5 doğruluk oranında tespit etmektedir.

Asci and Karsligil (2020) bu çalışmada yol hasarı tespitinin sınıflandırılması işlemini gerçekleştirmezken kurmuş olduğu mobil kamera sistemi ile hasarın var veya yok olduğu sonucuna varan Alexnet modeli kullanmıştır. Bu durum pahalı sensör kurulumu gerektirmediği gibi hatalı hasar bildirimi oranını da düşürmektedir. Algılama doğruluğunun %96 başarı sağladığı gözlenmiştir.

Yin et al. (2021) M2det'i temel alan Çok Seviyeli Özellik Piramitleri yöntemini sunmaktadır. Mevcut yöntemlerde sığ ve derin katmanlar aynı anda çıkarılamadığından daha az örnekle nesnelerin tespitinde iyi performans göstermemektedir. Önerilen yaklaşımda özellik katmanı çok ölçekli ve çok seviyeli bir mimariye sahip olduğundan daha fazla bilgi ve belirgin özellikler içeren özellik katmanı çıkarılabilir. Ayrıca veri setindeki yerel sınır kutularının doğruluğunu artırmak için bir dikkat mekanizması kullanılmaktadır.

Lee et al. (2021) bu çalışmada, tam evrişimli sinir ağı modeli kullanılarak toplanan görüntülerdeki yol-yüzey anormalliklerini tespit etmek ve aynı zamanda eş zamanlı olarak toplanan üç eksenli ivme verilerini aynı zaman diliminde işlemek için bir sistem geliştirilmiştir. Geliştirilen sistem, bir aracın ön camına yerleştirilen bir akıllı telefona kurularak halka açık yollarda test edilmiştir. Sinir ağı modeli tabanlı yol yüzeyi anormalliği tespit yöntemini ivmeölçer tabanlı veri toplamayla birleştiren sistem, yer çekimi eksenli ivmelerindeki eşzamanlı değişimleri belirli aralıklara sınıflandırarak sinir ağı modeli tarafından tanımlanan yol yüzeyi anormalliklerinin boyutunu belirlenmesine olanak sağlamıştır. Bu çalışmada gösterilen sistem, otomatik yol yüzeyi anormallik

tespitinin yaygın olarak uygulanması için umut vericidir. Ancak mevcut çalışma, araç tipinin ve araç hızının elde edilen bilgilerin netliği üzerindeki etkisini belirleyememiştir.

Li and Liu (2021) yol yüzeyinde meydana gelen çukurların tespiti ve boyutunu belirlemek için stereo kamera, bir lazer diade ve YOLOv3 algılama modelini kullanılmıştır. Kamera ile yol görüntüleri elde edilirken lazer diyot ile çukurların boyutları belirlenmektedir. YOLOv3 ile yolda var olan çukurların yerleri tespit edilmektedir. Elde edilen veri seti yardımıyla asfalt kaplama, beton kaplama ve toprak yol üzerindeki çukurlar doğru bir şekilde tespit edilmektedir. Eğitilen model sayesinde modelin mAP'si farklı çukur türlerine bağlı olarak %80-%99,4 arasında değerlere sahiptir. Ayrıca çukurların hacimleri %97,2 gibi yüksek doğrulukla hesaplanmaktadır. Yazarlar önerilen bu sistemin uygun veri kümesi ile eğitilmesi durumunda otonom araçlar için oldukça yardımcı olacağını ifade etmektedirler.

Xu et al. (2023) bu makalede, yol görüntülerindeki hasar bilgilerini bölümlere ayırabilen ve yol hasarı tespitinin etkinliğini artırabilen, yol hasarı tespit ağı için çok ölçekli özellik öğrenme transformatörü önermiştir. Ağ yapısı üç ayrı katkı sağlamaktadır. İlk olarak, özellik çıkarımının algısal alanını genişletmek için çapraz şekilli bir dikkat mekanizması benimseyerek ve bu mekanizmanın küresel dikkati ağıın özellik tanımını etkili bir şekilde geliştirmektedir. İkinci olarak, farklı ölçeklerdeki yerel bilgileri entegre etmek için yoğun çok ölçekli özellik öğrenme modülü kullanılarak çok ölçekli hedefleri tespit etme zorluğunun üstesinden gelebilmektedir. Son olarak, önceki özellik öğrenimini genelleştirmek ve nihai bir tespit sonucu elde etmek için çok katmanlı bir evrişimli bölümlenme kafası kullanılmaktadır. Deneysel sonuçlar, önerilen ağıın yoldaki çatlak ve çukur görüntülerinde %99,83'lük bir doğruluk puanının yanı sıra %79,39'luk bir F1 puanı elde edilmesini sağlamıştır.

Luo et al. (2023) karmaşık görüntülerde yol hasarının doğru ve etkili bir şekilde tespit edilmesinin her zaman zorlu bir görev olduğunu düşünerek bu çalışmada geliştirilmiş hafif bir ağ olan E-EfficientDet önermektedir. İlk olarak bir özellik çıkarma geliştirme modülü, alıcı alanı artırmak ve daha zengin çok ölçekli özellik bilgileri çıkarabilen ağıın özellik ifade etme yeteneğini geliştirmek için tasarlanmıştır. İkinci olarak, ağdaki farklı katmanlar arasında özellik bilgisinin yeniden kullanımını teşvik

etmek ve çok ölçekli bağlam bilgisinden tam olarak yararlanmak için yarı yoğun bağlantı fikrine dayalı olarak farklı yapılara sahip dört piramit modülü tasarlanmıştır. Son olarak, farklı donanım kaynağı kısıtlamaları altında yol hasarı tespit görevlerini karşılamak için bu makalede bileşik ölçeklendirme stratejisine dayalı olarak E-EfficientDet-D0~D2 ağları önerilmektedir. Deneysel sonuçlar, E-EfficientDet-D0'ın tespit doğruluğunun, kamuya açık yol hasarı veri setinde orijinal EfficientDet-D0 ile karşılaştırıldığında %2,41 arttığını ve YOLOv5s, YOLOv7-tiny, YOLOv4-tiny, Faster R-CNN ve SSD gibi diğer ağlardan daha iyi performans gösterdiğini göstermektedir.

Deepa and Sivasangari (2023) farklı yol hasarlarını tespit etmek için bir veri çoğaltma modeli önermektedir. Başlangıçta yol hasarı örneklerinin kalitesini artırmak için giriş yolu görüntüsü alınır ve uyarlanabilir bir Gauss ikili filtresi kullanılarak önceden işlenmektedir. Etkili yol hasarı tespiti ve sınıflandırmasını gerçekleştirmek için süper ve yarı denetimli remora çekişmeli çözünürlük öğrenme üretken tespit modeli tanıtılmaktadır. Bu modelde süper çözünürlük, yol görüntüsü netliğini iyileştirmeyi ve algılama performansını iyileştirmeyi amaçlamaktadır. Son olarak ağırlığı güncellemek ve kayıp fonksiyonunu en aza indirmek için biyotik remora meta-sezgisel optimizasyon stratejisi uygulanmaktadır. Önerilen model ile doğruluk (%99,12), duyarlılık (%98,64), hassasiyet (%98,51) ve F1 puanı (%98,57) değerleri elde edilmektedir.

Xin et al. (2023) yol hasarlarının algılanması için katılımcı kullanıcılar tarafından yüklenen ivmeölçer verileri ile araç içi video verilerinin birleşiminden yararlanan bir yöntem önermektedir. Bu yaklaşımın temelinde ivmeölçer tabanlı algılamanın kapsama alanının sınırlı ve sürüş hızına duyarlı olması ve görüntü tanıma tabanlı algılama sistemlerinde ise ortam ışığından oldukça etkilenmesi yatmaktadır. Önceden işlenmiş ivmeölçer verileri ve yakalanan video kareleri daha sonra gerçek değerli vektörlere kodlanarak kamusal alana yansıtılmıştır. Güvenilirliği artırmak ve tespit sonuçlarını optimize etmek için çok araçlı bir senaryoda uzamsal yoğunluğa dayalı kümeleme uygulanmıştır. Önerilen model yaklaşımı sonucunda %83,6 'lık F1 puan değerlerine ulaşıldığı görülmektedir.

Yukarıdaki çalışmalar genel olarak hasar türlerinin oluş şeklinde doğal afetlerin olmadığı durumları ele almıştır. Yol yapım tekniği, iklim koşulları, trafik hacmi ve olağan

durumlardan kaynaklı yol hasarlarının algılanması süreci detaylı olarak sunulmuştur. Aşağıda yer alan çalışmalar ise doğal afetlerden dolayı meydana gelen yol hasarlarının algılanma sürecine dair çalışmalar yer almaktadır.

Li et al. (2010) önerdiği yolların hasar tespit yönteminin geçerliliğini göstermek üzere 8.0 büyüklüğünde depremin vurduğu Çin'in Wenchuan ilçesinde uygulamaktadır. Depremin meydana gelmesinden sonra afet yardım ekiplerinin olay yerine müdahalesinin önündeki engellerden birisi olarak yol hasarı gösterilmektedir. Hasarlı yol kesimi, sorunlu bölge ile bağlantının kesilmesine ve gerekli desteğin iletilmemesine neden olmaktadır. Bu durum dikkate alınarak yapılan çalışmada yeni bir yol hasar değerlendirmesi yaklaşımı sunulmaktadır. Bu çalışmanın ana amacı olarak yolun hasar derecesinin afet sonrası yolun gerçek trafik kapasitesini yansıtabileceğinin farkına vararak yeni bir hasar tespit modeli kurmaktadır. Bu model ile afet için karar desteği sağlamasını ve kurtarma eylemlerinin uygulanmasına yardımcı olması sağlanır.

Ma et al. (2013) bu çalışmada, yüksek çözünürlüklü uydu görüntüleri ve yol haritalarını kullanarak yol hasarlarını yol kenarı çizgilerine dayalı olarak hızlı bir şekilde çıkarmak için otomatik bir yaklaşım önermektedir. Yol kenar çizgisi, hem deprem öncesi hem de deprem sonrası görüntülerde sabit geometrik özelliklerden biridir ve yol kenar çizgisinin değişmesi, yol hasarının mevcut olduğuna dair dikkate değer bir kanıttır. Yaklaşım, öncelikle deprem sonrası elde edilen görüntülerden hasarsız yol kenar çizgilerini çıkarmakta ve daha sonra bu yol kenar çizgilerini, yol haritaları ile sağlanan deprem öncesi yol çizgileriyle karşılaştırmaktadır. Hasarlı bölümler karşılaştırma yoluyla çıkarılabilir. Yöntemin performansı WenChuan deprem felaketi bölgesindeki QuickBird görüntüleri ile yapılan bir deneyle değerlendirilmiştir.

Ma et al. (2022) yol görüntüleme ve çukur tespitinde kullanılan derin öğrenme modelleri hakkında sistematik araştırma makaleleri eksikliği bulunduğunu vurgulamıştır. 2 boyutlu ve 3 boyutlu yol verisi toplama için kullanılan algılama sistemlerini klasik 2 boyutlu görüntü işleme, 3 boyutlu nokta bulutu modelleme ve segmentasyon ve yol çukurlarının tespiti için geliştirilen makine/derin öğrenme dâhil olmak üzere bilgisayarlı görme algoritmalarını kapsamlı bir şekilde incelemektedirler. Bu makale aynı zamanda

2. KAYNAK ÖZETLERİ

bilgisayar görüşü tabanlı yol çukuru tespit yaklaşımlarının mevcut zorluklarını ve gelecekteki gelişim eğilimlerini de tartışmaktadır.

Alamgeer et al. (2023) taşkınların en şiddetli ve en sık görülen doğal afetlerden biri olduğunu ve çok büyük ekonomik hasara neden olarak yol ağlarına verdiği zararın yapay zekâ yöntemleri kullanılarak tespit edilebileceğini vurgulamıştır. Bu nedenle bu çalışma, su baskını yönetimi için en uygun bir Bulanık Dalgacık Sinir Ağı tabanlı Yol Hasarı Tespiti (OFWNN-RDD) tekniği tasarlamaktadır. OFWNN-RDD tekniği, farklı yol türlerini sınıflandırmak için uzaktan algılama görüntülerinden yararlanmayı amaçlamaktadır. Son olarak yol hasarı tespiti için FWNN görüntü sınıflandırma yaklaşımı kullanılmıştır. Simülasyon değerleri %98,56 oranında geliştirilmiş yol hasarı tespit doğruluğu ile OFWNN-RDD tekniğinin diğer modellere göre üstünlüğünü göstermektedir.

Silva et al. (2023) yapmış oldukları çalışma ile İnsansız Hava Aracı (İHA) görüntüleri ve derin öğrenme tekniklerini kullanarak yeni bir otomatik yol hasarı tespit yaklaşımı sunmaktadır. Karayolu altyapısının bakımı, güvenli ve sürdürülebilir bir ulaşım sisteminin sağlanması açısından kritik öneme sahiptir. Bu nedenle, yol hasarı tespitinin verimliliğini ve doğruluğunu önemli ölçüde artırmak için İHA'ların ve yapay zekâ teknolojilerinin kullanılması önerilmiştir. Önerilen yaklaşım ile İHA görüntülerinde nesne tespiti ve lokalizasyonu için YOLOv4, YOLOv5 ve YOLOv7 olmak üzere üç algoritma kullanılmaktadır. Bu algoritmaları, RDD2022 Çin veri kümesi ile İspanyol yol veri kümesinin bir kombinasyonunu kullanarak eğitilip test edilmiştir. Deneysel sonuçlar, yaklaşımımızın verimli olduğunu ve YOLOv5 sürümü için %59,9 mAP50, YOLOv7 modeli için %73,20 mAP50 değerleri elde edilmektedir.

Bu sonuçlar, otomatik yol hasarı tespiti için İHA'ların ve derin öğrenmenin kullanılma potansiyelini ortaya koymakta ve bu alanda gelecekteki araştırmaların önünü açmaktadır.

Yukarıda yer alan çalışmalar yol hasarları hakkında yapılan çalışmaların bir özeti olarak ifade edilebilir. Yol hasarlarının belirlenmesi ve hangi amaca hizmet etmesi bakımından farklılık göstermesi yazarların kullandığı yöntemlere bağlıdır. Özellikle son

yıllarda yapay zekâ tabanlı yol kusurlarının otomatik belirlenmesi alanındaki çalışmalar oldukça yaygındır. Bu popüleritenin ana sebebi olarak IEEE'nin düzenlemiş olduğu konferans gösterilse de yol hasarlarının belirlenmesinde kurumların büyük bir ihtiyaç gereksinimi olduğu açıktır. Konferansın çıktısı olarak yol hasarlarının belirlenmesi alanında onlarca makale ve bildiri meydana gelmiştir. Bu çalışmalar incelendiğinde yazarlar genel olarak Bilgisayar Mühendisliği kökenli veri bilimci araştırmacılardan oluşmaktadır. Aslında yol hasarlarına İnşaat Mühendisliği perspektifi ile bakmayıp sadece var olan büyük verinin (IEEE'nin vermiş olduğu yol hasar veri seti) en doğru şekilde işlenip analiz edilmesi ve analiz sonucunda doğruluk payı yüksek en iyi algoritmaya sahip olmaktır.




3. MATERYAL VE YÖNTEM

Esnek üstyapı kaplamalı yol ağları belirli zaman dilimleri için de bakım ve onarıma ihtiyaç duymaktadır. Yol ağı kaplamasında var olan yapısal problemin teşhisi ve onarımı ne kadar hızlı olur ise yol kaplamasının hizmet ömrü de o kadar uzun olmaktadır (Arya et al. 2020; Saha et al. 2022). 1967 yılında var olan toplam devlet ve il yolları uzunluğu 59.257 km iken bu değer 2000 yılında 61.090 km olarak güncellenmiştir. 2000 yılından günümüze yol ağı uzunluğu yaklaşık 4.000 km artarak 65.056 km uzunluğuna ulaşmıştır. Bu yol ağı uzunluğunun 25.545 km'si asfalt betonu ile kaplıdır (Anonim 2023b). Genel olarak 2000 yılından itibaren yapılan yol ağlarının kaplamalarında yol kusurları meydana gelmesi beklenmektedir. Hizmet ömrü devam etmekte olan yol ağlarının kaplamalarında yer alan kusurların tespitinde hızlı olmak bakım/onarım sürecini geliştireceği için yol ağının hizmet süresinde artış sağlanacaktır. Bu husus var olan yol ağlarımız için oldukça önemli olup milli servetimizin korunması amaçlanarak trafik bileşenlerinin konfor ve güvenliğini de artıracaktır.

3.1. Çalışma Alanı

Bu tez çalışması kapsamında küresel ölçekli otomatik yol kusur tespit sistemi oluşturulmuştur. “Küresel” kelimesi bu çalışmada birçok anlamı ifade etmektedir. Elde edilen sistemin dünyanın farklı ülkelerindeki yol ağlarında var olan yol kusurlarını algılama doğruluğunun benzer değerlere sahip olacak şekilde çalışması oldukça önemlidir. Bu hedef doğrultusunda kusur örneklemeleri farklı coğrafyalardan alınarak küresel ölçekte kusur algılama süreci başlatılmıştır. Sekiz farklı ülke yol ağlarına ait yol görüntüleri tez kapsamında kullanılmıştır. Ülkelerin dünya siyasi haritası üzerindeki konumsal gösterimi Şekil 3.1’de sunulmuştur.



Şekil 3.1. Yol görüntülerinin elde edildiği ülkeler

Haritadan da anlaşılacağı üzere Asya kıtasında Rusya'nın olduğu bölge ile Afrika ve Güney Amerika bölgesinden veri örnekleme bulunmamaktadır. Bu bölgeler dışında dünyanın diğer kısımlarında yer alan ülkeleri temsil edecek veri çeşitliliği mevcuttur. Veri çeşitliliği ile elde edilen sistemin küresel ölçekte çalışacağı hedeflenmektedir. Tam otomatik olarak adlandırılan tespit sistemlerinin maliyet yönü baz alındığında bu çalışmada ele alınan yaklaşım ile elde edilen gömülü sistemin dünyanın birçok bölgesinde pazar payına sahip olacağı ön görülmektedir. Katma değerli ürün elde edilmesi ve bu sistemin diğer ülkelerde de yüksek doğrulukla çalışabilmesi için elde edilen verilerin küresel ölçekte olması gerekmektedir.


3.2. Yol Kusur Verileri

Yapay zekâ ve alt dallarının son yıllarda araştırmacılar ile buluşmasından sonra birçok sektör kendini yenilemeye başlamıştır. Bu durumun sektör içindeki rakipler için zorunluluk haline geldiği açıktır. Tarihten günümüze bir önceki dönem için geleneksel ifadesi her zaman kullanılmıştır. Yeniliğin şimdi ve gelecek için daha olumlu olacağı genel bir yargıdır. Günümüzün trendi olan yapay zekâ çözümleri artık tüm insanlık tarafından kabul görmüş bir gerçektir.

Ulaştırma alanında ise sorunlara çözüm sunan, işleyişi daha pratik ve sürdürülebilir hale getiren, kullanıcı profiline göre kolaylık sağlayan, rekabet ortamı yaratan, katma değerli somut çıktılar sunan programın adı AUS olarak literatüre


kazandırılmıştır. AUS hakkında detaylı bilgiler bir sonraki bölümde verilmektedir. Genel olarak ülkemiz AUS’u uygulama konusunda gelişmiş ülkelere göre bir adım geri kalmaktadır. Bu durum farklı sebepler ile açıklanabilir. Ancak son yıllarda açık kaynaklı yapay zekâ uygulamaları ve uygulanan politikalar sayesinde araştırmacıların birçok sektörün ihtiyaç duyduğu sorunlara çözüm önerileri ürettiği görülmektedir. Özellikle ilki 2018 yılında olmak üzere ve halen devam eden TEKNOFEST Havacılık, Uzay ve Teknoloji Festivali genç araştırmacılar için mücadele sahası olmuştur (Anonim 2023c). İlkokul çağından itibaren geniş katılım imkânı sunması festivalin en büyük avantajlarından biridir. Ayrıca yaklaşık 44 farklı başlık altında tüm sektörleri içinde barındırmaktadır. Bu başlıklar içinde Akıllı Ulaşım Yarışması da yer almaktadır. Teknofest, ülkemizde araştırmacıların çözüm önerilerini sektör temsilcilerine sunduğu bilimsel açık hava sahası olarak ifade edilebilir.

Ayrıca yapılan birçok çalışmanın arkasında yatan en önemli etkenlerden birisi de veridir. Büyük veri adı altında yapılan çalışmalar, toplantılar ve konferanslar araştırmacılar için son derece önemlidir. Uluslararası bilimsel yayıncılık alanındaki yetkin kuruluşlardan birisi olan IEEE’nin 2018 yılında başlattığı büyük veri konferansları araştırmacılara akademik anlamda büyük katkı sağlamıştır. Bu konferansın ana temalarında biriside yol hasar tespiti ve sınıflandırma zorlukları olarak belirlenmiştir. Bu konferans ile yol hasarlarının belirlenmesi süreci hız kazanmıştır. Çünkü yol ağında birçok yapısal yol hasarı meydana gelmekte ve bu hasarların otomatik olarak algılanması uzun ve zor bir süreçtir (Maeda et al. 2018). 2019 yılında düzenlenen konferansta ise önceki yılın yol hasar verilerinde artırma süreci gözetilmiştir (Maeda et al. 2020). İki yıl sonra 2020 yılında IEEE tarafından GRDDC adı altında yeni bir büyük veri konferansı düzenlenmiştir. Bu konferansın ana teması yol hasarlarının algılanması olarak belirlenmiştir. 2018 yılından 2020 yılına kadar üç farklı ülkeye ait yol kusur verileri toplanarak elde edilmiştir (Arya et al. 2020). Bu konferansın amacı dünyadaki bazı ülke yol ağlarında meydana gelen yol hasarlarının farklı çözüm önerileriyle belirlenmesi ve sorumlu yöneticilere fikir vermesidir. Bu süreç araştırmacıların farklı yaklaşımlarıyla gerçekleşmiş olsa da temel uygulama yöntemleri görüntü işleme teknikleri olmuştur. Yarışmaya farklı ülkelerden 121 takım katılım sağlamıştır. Toplanan verilerin ülkelere göre dağılımı Şekil 3.2’de yer alırken verilerin hasarlara göre dağılımı ise Şekil 3.3’de yer almaktadır. Bu kısımda sunulan istatistikî bilgiler açık kaynaklı verilere aittir.



Şekil 3.2. Veri dağılım istatistikleri


Test verilerinde Japonya, Hindistan ve Çek Cumhuriyeti birbirine yakın veri değerlerine sahip olsa da eğitim veri seti değerlerinde fark mevcuttur. Oransal olarak eğitim ve test veri setlerinde fark neredeyse aynıdır. Ancak görüntü sayısı kapsamında büyük fark mevcuttur. Yol hasarlarının görüntü işleme yöntemleri ile belirlenmesinde bu veri değerleri yeterlidir. Ancak veri çeşitliliği ve kalitesi algılama doğruluğunu artıran temel etkenlerdir. Özellikle nesne algılama modellerinin farklı algılama senaryolarında başarı oranları düşmektedir. Bu durumun ana sebebi veri setlerindeki algılama sınıfları arasında veri dengesizliği ve veri homojenliğidir.



Şekil 3.3. Eğitim verisinde farklı yol hasar türlerine göre dağılımı

Birçok yol hasarı mevcut olup bu verilerin elde edilmesi oldukça zor ve uzun süreç istemektedir. Yarışma neticesinde birinci olan takım YOLO tabanlı topluluk öğrenmesi yöntemini tercih etmiştir. Yarışma komitesi değerlendirme kriteri olarak F1 puanını kullanmış ve birinci olan takım Test1’de 0,67 iken Test2’de 0,66 değerlerini elde etmiştir. Arya et al. (2021)’un yapmış olduğu çalışmalarda takımlar ve RDD2020 verileri hakkında detaylı bilgiler mevcuttur.


Tüm bu süreçlerin ardından IEEE 2022 yılında Japonya’da CRDDC2022 adı altında konferans düzenlemiştir. Bu konferansta Japonya, Hindistan, Çek Cumhuriyeti, Norveç, ABD ve Çin olmak üzere altı farklı ülkeden 47.420 yol görüntüsünü içeren yol hasarı veri kümesi oluşturulmuştur. Diğer yarışmalardan farklı olarak katılımcılar belirli kurallar çerçevesinde yol hasar veri kümesini genişletme imkânlarına sahiptir. Yol hasarlarını otomatik olarak algılamak ve sınıflandırmak için derin öğrenme tabanlı yöntemlerin uygulanmasını tasarlayan bu konferans yol kusur verisi olarak araştırmacılara büyük imkân sağlamıştır (Arya et al. 2022). 2018’den 2022 yılına kadar olan veri değerlerinin değişimi Şekil 3.4’de gösterilmektedir.



Şekil 3.4. Yol hasar tespiti (RDD) veri kümelerinin evrimi


Dört yıl içinde tek ülke ile başlayan veri toplama süreci son olarak altı farklı ülke ve binlerce veri ile devam etmektedir. Bu durum yol ağlarımızda bulunan yol hasarlarının otomatik olarak belirlenmesinin ne derecede önemli olduğunu vurgulamaktadır. Şekil 3.4’de veri sayıları ve toplanan ülkeler ifade edilirken Çizelge 2.1’de hasar türleri, detaylar ve sınıf isimlendirmeleri ifade edilmiştir.

Çizelge 2.1’den de anlaşılacağı üzere kusurlar çatlaklar ve diğer hasarlar olarak iki sınıfa ayrılmışlardır. Alt kusur türleri olarak toplam sekiz adet kusur çeşidi bulunmaktadır. Çatlaklar, doğrusal ve timsah çatlağı olarak iki bölüme ayrılmıştır. Şerit çizgisi ve yaya geçiti bulanıklığı sadece 2018 yılında Japonya için elde edilmiştir. Diğer beş ülke için sadece boyuna çatlak (D00), enine çatlak (D10), timsah çatlağı (D20) ve çukurlar (D40) olarak veri seti toplanmıştır. Bu çatlakların genel olarak bütün ülkelerde bulunması ve yol kaplamasının yapısal durumunu bozmaya elverişli olması ortak sorun olarak görülmektedir. Ayrıca yol hasar verilerinin toplanmasının zor ve uzun süreçler istediğinin kanıtı olarak da gösterilebilir. Bir diğer problem ise toplanan bir yol görüntüsünde birden çok hasar türü yer alabilir. Bu durum veriler arasında dengesizliği artırmaktadır. Nesne algılamada görüntüde yer alan tüm hasar sınıflarının etiketlenmesi gerekmektedir. Aksi halde model eğitiminde tutarsızlık ve algılamada düşük doğruluk oranı meydana gelmektedir. Yıllara göre verilerin istatistiksel olarak karşılaştırması Şekil 3.5’de verilmektedir.



Şekil 3.5. Yol hasar veri setlerinin yıllara göre karşılaştırılması (Arya et al. 2022)

Farklı ülke yol ağlarının da taranması ile birlikte dört hasar türü için toplanan görüntü sayısının her yıl giderek arttığı görülmektedir. Bu durum veri çeşitliliğinin artırılmasına neden olmaktadır. Ayrıca Arya et al. (2020)'da yer alan bilgiye göre 2018 yılında sadece Japonya'da toplanan veri seti ile eğitilen ağ modelinin Japonya dışındaki diğer ülke yol ağlarındaki algılama oranı ciddi oranda düşmüştür. Bu çıkarım tam olarak bu tez çalışmasındaki küresel kelimesinin ne anlam ifade ettiğini daha iyi anlaşılabilir kılmaktadır. Çünkü farklı ülkelere elde edilen veri çeşitliliği hatta aynı ülkenin farklı şehirlerinden elde edilen verilerin önemi giderek artacaktır. Şekil 3.6'da verilerin ülkelere göre dağılımı görselleştirilmiştir. Veri setinde heterojenlik arttıkça farklı yol ağlarında uygulanabilirliğine imkân sağlanmaktadır.



Şekil 3.6. Dört hasar türünün ülkelere göre eğitim veri seti dağılımı (Arya et al. 2022)

En çok var olan verinin boyuna çatlak olduğu, yanal (enine) ve timsah çatlağının veri sayısının yaklaşık aynı olduğu en az veri sayısına sahip olan hasar türü ise çukurlar olduğu gözlemlenmektedir. Bu durum yol ağlarımızda var olan kusurların hangi sıklıkla meydana geldiği konusunda ipuçları vermektedir. Çukur hasar türü trafik bileşenlerini diğer hasar türlerinden daha fazla olumsuz etkilediği için sorumlu yöneticiler tarafından daha hızlı onarılmaktadır. Böylece çukur hasar veri toplanması daha da zor olmaktadır. Hasar türlerinde olan tutarsızlık tez çalışması kapsamında da devam etmektedir. Bu durumun ana sebebi olarak elde edilen bir yol görüntüsü üzerinde birden çok hasar türünün olması ve özellikle boyuna çatlak hasar türünün diğer hasar türlerinden fazlaca meydana gelmesidir. CRDDC2022 kapsamında sunulan verilerin toplandığı ülkeler hakkında kısa bilgiler aşağıda verilmiştir (Arya et al. 2022).

Japonya: Yol kusur verileri yedi farklı yerel eyaletten toplanmıştır. Toplam sekiz adet farklı yol kusur veri setinin toplandığı yerel eyaletler sırasıyla; Ichihara şehri, Chiba şehri, Sumida bölgesi, Nagakute şehri, Adachi şehri, Muroran şehri ve Numazu şehridir. Bu yerel belediyeler iklim koşulları ve bütçe durumları olarak birbirinden farklıdır. Bu farklılık veri çeşitliliğine neden olmaktadır.

Hindistan: Yol hasar verileri genel olarak Delhi ve Haryana eyaletinde bulunan şehir içi yollar, il yolları ve otoyollardan elde edilmiştir. Yol ağı olarak eğimi az yol kesimleri tercih edilmiştir. Bunlara ek olarak yol ağındaki kusurların daha iyi görüntülenmesi için trafik akışının az olduğu zaman dilimleri ve açık hava koşulları tercih edilmiştir.

Çek Cumhuriyeti: Yol görüntülerin büyük bir kısmı Olomouc, Prag ve Bratislava sınırları içinde toplanmıştır. Birinci, ikinci, üçüncü sınıf yollar ile şehir içi yol kesimlerinde yol tarama işlemleri yapılarak yol hasar verileri toplanmıştır. Veri esnekliğini artırmak adına bazı otoyol kesimlerinden de yol görüntüleri elde edilmiştir.

Norveç: Yol görüntüleri otoyollar ve il yolları taranarak elde edilmiştir. Veri toplama süreci Norveç Kamu Karayolu İdaresi (SVV) ve Inlandet Fylkeskommune (IFK) tarafından yürütülmüştür. SVV tarafından sağlanan görüntüler, Norveç'teki Trondheim şehrini İsveç'teki Sundsvall'a bağlayan Avrupa E14 Yolu üzerinde toplanmıştır. Aynı zamanda IFK'dan alınan görüntüler ise Norveç'in Inllanndet ilçesi içindeki farklı yollara aittir. Veri toplama sürecinde ışık durumu dikkate alınmamış olup farklı hava koşullarında görüntü toplama işlemi devam etmiştir.

Çin: Yol görüntüleri drone ve motor bisiklete entegre kamere ile Çin'in Nanjing kentindeki Dongji bulvarı'ndan ve Southeast Üniversitesi Jiu long hu kampüsünde toplanmıştır. Normal ışık, gölgeli ortam ve ıslak zemin görüntüleri ile veri çeşitliliği sağlanmıştır.

ABD: Google Sokak Görünümü özelliği yardımı ile California, Massachusetts ve New York dâhil olmak üzere birden çok konumda yer alan yol ağları görüntüleri elde edilmiştir. Özellikle California'da yer alan yol ağlarından görüntü toplama işlemi daha ağırlıklıdır.

Ülkelere ait kısa bilgiler verdikten sonra toplanan yol görüntülerine ait detaylı bilgiler ayrı ayrı Çizelge 3.1'de sunulmaktadır.

Çizelge 3.1. Veri setlerinin önceki sürümlerle karşılaştırmalı özeti

	RDD2018	RDD2019	RDD2020	RDD2022
Görüntü	9.053	13.133	26.336	47.420
Görüntüleme cihazı	Akıllı telefon	Akıllı telefon	Akıllı telefon	Akıllı telefon, Yüksek çözünürlüklü kamera, Google sokak görünümü
Veri toplama aracı	Otomobil	Otomobil	Otomobil	Otomobil, Motosiklet, Drone
Görüntü çözünürlüğü	600x600	600x600	600x600 720x720	512x512 600x600 720x720 3650x2044
Yol görünümü	Geniş açı	Geniş açı	Geniş açı	Geniş açı, Ekstra geniş açı, üstten görünüş
Yol kusur türü sayısı	8	8	4	4
Veri toplanılan ülkeler	1 (Japonya)	1 (Japonya)	3 (Japonya, Hindistan, Çek Cumhuriyeti)	6 (Japonya, Hindistan, Çek Cumhuriyeti, Norveç, Çin, ABD)

IEEE RDD komitesinin yol kusur verilerinin açık olarak paylaşmasının birkaç hedef ve amacı vardır.

- Bu verilerin akıllı telefon tabanlı otomatik yol hasar tespiti için temel oluşturabileceği ve yol ağlarının hasar denetiminin yapılmasının daha düşük bütçe ile yapılmasının sağlanacağını düşünmektedirler. İlgili kurumlar ve yerel belediyeler için düşük maliyetli sistemlerin oluşabileceği anlamı ortaya çıkmaktadır.
- Literatürde birçok nesne algılama yöntemleri mevcuttur. Sunulan veriler ile yeni derin evrişimli sinir ağı mimarilerin ortaya çıkarılması veya geliştirilmesi desteklenebilir. Ayrıca mevcut mimariler ile farklı konfigürasyonlar çalışılabilir.
- Araştırmacılar için bu veriler yol hasarlarını belirleyen algoritmaları eğitmek, doğrulamak ve test etmek için kullanılabilir.

- Toplanan verilerin bir kısmı araç içi entegre kamere sistemi ile elde edilmiştir. Bu durum hareket halindeki araçlar ile yol hasar tespiti yapılabileceği imkânı sunmakta ve denetleme sürecinin hızlanmasına izin vermektedir.
- Araştırmacılar görüntü sınıflandırma ve nesne algılama gibi uygulamaları hedefleyen farklı algoritmaların performansını karşılaştırmak için bu yol hasar verilerini kullanabilir.

3.3. Model Kurulum Kapsamında Kullanılan Yol Kusur Verileri

Esnek yol üstyapısına sahip yol ağları genel olarak beş ayrı katmandan oluşmaktadır. Alt temel, temel, bitümlü temel, binder ve aşınma olarak bu katmanlar sıralanabilir. Yapılan tez çalışması esnek üstyapılarda meydana gelen yol kusurlarının otomatik olarak belirlenmesini içermektedir. Bu çalışmada rijit ve yarı rijit üstyapılarda yer alan kusur türleri incelenmemektedir. Esnek üstyapılar trafiğe açıldıktan sonra; trafik etkisi, iklim ve çevre etkisi, yapım ve tasarım hatalarının etkisi ve malzeme hatalarının etkisi ile birçok yol kusuru ile karşılaşmaktadır. Bu kusurlar çatlamalar, ayrışmalar ve deformasyonlar şeklinde üç tip olarak görülmektedir. Bu kusurların oluşumunu destekleyen başlıca nedenler, kusurların tipine bağlı olarak bu kısımda özetlenmiştir (Tunç 2004).

Deformasyonlar: Stabilitate bozuklukları ya da kalıcı şekil değiştirmeler olarak adlandırılan bu deformasyonların oluşma sebepleri; düşük kayma mukavemeti, düşük kütle karışım viskozluğu ve düşük eylemsizlik direnci olarak sıralanmaktadır. Deformasyonlar genel olarak asfalt kaplama imalatından bir süre sonra görülen yapısal bozukluklardır. Sürüş konforu, emniyeti ve yol hizmet seviyesini olumsuz etkilediğinden dolayı bölgesel bakım ve onarım işleminin yapılması gerekmektedir. Oluşan deformasyonlara örnek olarak teker izleri, üniform olmayan düzensiz yüzey bozuklukları, bölgesel oturmalar, dalgalanma veya yığılmalar, kabarmalar ve lastik deseni verilmektedir.


Ayrışmalar: Trafik ve iklim etkisi ile yol kaplamasından küçük parçalar halinde yüzeysel kopma ve parçalanmaların sonucu oluşan ayrışmalardır. Ayrışmalar; yapım hataları, kalitesiz malzeme kullanımı, uygun olmayan serim ısısı, heterojen karışım ve

yetersiz adezyona sahip asfalt gibi nedenlerden oluşmaktadır. Ayrışmalar neticesinde çukurlar, parça ve tabakalar halinde sökülmeler ve kaygan yüzeyler meydana gelmektedir. Hızlı bakım ve onarım ile bu yol kusurları giderilmez ise trafik ve iklim etkisi ile alan ve derinlik bakımından git gide artış gösterecektir.

Çatlamalar: Yol ağı kaplama yüzeyinde trafik, çevre ve iklim etkisinden kaynaklı olarak farklı şekilde, genişlikle ve derinlikte meydana gelen kusurlardır. Oluşan bu çatlaklar yansıma, yorulma ve stabilite çatlakları olarak sınıflandırılmaktadır. Stabilite çatlakları yapısal olduğundan dolayı tabakaların altında oluşmakta ve zamanla üst taraflarda görülmektedir. Yorulma çatlakları ise ağır trafik yükleri altında kaplamanın yorulma mukavemetini aşması neticesinde oluşmaktadır. Yansıma çatlaklarının oluş nedeni olarak fleksibilitesi çok düşük temel tabakasında oluşmuş çatlakların trafik ve iklim etkisi ile en üstteki tabakaya kadar ilerlenmesi ile yani alt tabakada oluşan çatlakların üst tabakaya yansıma ile meydana gelmektedir.


Timsah sırtı çatlaklar, kümes teli veya bal peteği görünümünde olup farklı boyutlarda kaplamanın belirli veya tüm kısmında meydana gelmektedir. Yetersiz drenaj, aşırı trafik yükü gibi nedenlerden oluşmaktadır. İlk olarak trafik yönünde kılcal çatlaklar olarak başlar ve enine çatlaklar ile birleşerek bloklar şeklinde timsah sırt görünümüne dönüşür. Kenar, ek yerleri (derz), kayma (ötelenme), büzülme, enine ve yansıma çatlakları olarak farklı türde yol kaplamasında görülmektedir. Düşük ısı çatlakları da asfalt kaplamasının soğuk havalarda büzülmesiyle oluşmaktadır. Soğuk iklime sahip bölgelerde yüksek penetrasyonlu asfalt kullanmak bu tür çatlakların oluşmasını en az seviyeye indirebilir.

Yukarıdaki kısımda yol kaplamasında oluşan yol kusurlarının özetleri sunulmuştur. Bu çalışma kapsamında 10 adet yol kusur türü değerlendirmeye alınmıştır. Bu kusur türlerinin birlikte kullanıldığı ilk çalışma olarak literatüre kazandırılmıştır. Şekil 3.7’de çalışmada kullanılan kusur türleri yer almaktadır.



Şekil 3.7. Çalışma kapsamında kullanılan kusur sınıfları

CRDDC2022 verileri eğitim ve test olarak iki bölüme ayrılmış şekilde araştırmacılara sunulmuştur. Eğitim verileri D00, D10, D20 ve D40 olarak etiketlenmiştir. Yapılan tez çalışmasında bu eğitim verileri yeniden etiketlenme sürecine ve veri ayıklanma işlemine tabi tutulmuştur. Birbirini tekrarlayan görsel ve kusur türleri, görüntü kalitesi düşük olan yol görüntüleri eğitim setinden çıkarılmıştır. Ayrıca D30 kusur türü ilk defa bu çalışma kapsamında literatüre kazandırılmıştır. CRDDC2022 verilerinde yer alan 6 ülke içerisinde D30 verisine yeniden etiketleme sürecinde dikkat edilmiştir. Japonya, ABD ve Çek Cumhuriyeti ülkelerinde var olan bu yapım şekli etiketleme sürecine tabi tutularak çalışma kapsamında değerlendirilmiştir. Bazı durumlarda D00 ve D20 olarak da etiketlendiği görülmüş olup bu durum düzeltilmiştir. D90 genel olarak sıklıkla karşılaşılan bir kusur türü olmayıp elde edilmesi zordur. Saha et al. (2022), D90 kusur türü hakkında yapmış olduğu çalışmada yaklaşık 950 yol görüntüsü kullanmıştır. Ancak çalışma kapsamında bu değer yaklaşık 60'lara indirgenmiştir. Yol görüntülerinin çözünürlüklerin düşük olması ve D90'ı barındırmaması modelimizin sağlamlığını düşüreceği ön görülmüştür. Şekil 3.8'de 10 adet yol kusurunun temsili görüntüleri verilmektedir. Eğitim verilerinin etiketlenme süreci Roboflow üzerinden sağlanmıştır.



Şekil 3.8. Çalışma kapsamında kullanılan 10 kusur sınıfı ve yol görüntüleri

3.4. Veri Toplanması

Çalışma kapsamında altı ülkeye ait yol hasar veri seti CRDDC2022'den alınmıştır. Bu ülkelere ek olarak Türkiye ve Gürcistan ülkelerine ait yol görüntüleri yazar tarafından elde edilmiştir. Gürcistan'a ait verilerin toplandığı yol ağı Şekil 3.9'da gösterilmiştir. Yol görüntülerinin toplanma tarihi 30 Eylül 2023 ve saat dilimi ise sabah 07.00 ile akşam 17.30 olarak belirtilmiştir. Yaklaşık 800 km'lik yol ağında 12 saat süren yolculuk neticesinde araç dikiz aynasına monte edilen akıllı telefon yardımı ile 3.000'e yakın görüntü elde edilmiştir. Kullanılan telefon Iphone 11 olup kamere özellikleri detaylı olarak verilmiştir. Çift 12 MP ultra geniş ve geniş kameralar, ultra geniş: $f/2.4$ diyafram ve 120° görüş alanı, optik görüntü stabilizasyonu (geniş) ve 326 ppi yoğunlukta 1792 x 828 piksel çözünürlük sağlayan ekran özelliği ile yol görüntülerin toplanması gerçekleştirilmiştir. Ayrıca görüntüler 3024x4032 boyutunda kayıt altına alınmıştır.

3. MATERYAL VE YÖNTEM



Şekil 3.9. Gürcistan’a ait yol görüntülerinin toplandığı güzergâh

Aktaş Sınır Kapısı ile başlayan b11 karayolunu b8 ve E60 karayolu ile tamamlanan güzergâh boyunca çift yönlü olarak görüntüler toplanmıştır. Yaklaşık 3000 görüntü içerisinde çalışmada kullanılmak üzere 798 adet görüntü seçilmiştir. Bu görüntüler üzerinden veri etiketleme işlemleri tamamlanmıştır. Elde edilen görüntüler üzerinde D70 yol kusuru yer almamıştır. Bu durumun ana sebebi olarak görüntü toplanılan yol ağının şehirlerarası yol olması gösterilebilir. Rögar kapakları genel olarak yerleşim bölgelerinde yer almaktadır.

Ülkemizde ise yol görüntüleri iki farklı süreçten elde edilmiştir. Erzurum şehir merkezi, Erzurum-Ardahan il yolu (D950, D062, D955, D060), Ardahan şehir merkezi ve Erzurum-İspir (E80 ve D925) karayolları araç ile taranarak mobil telefon ile yaklaşık yedi bin görüntü elde edilmiştir. Yol görüntüsü elde edilebilmesi için yaklaşık olarak 1.400 km’lik karayolu ağı taranmıştır. Ayrıca Google Sokak Görünümü ile Erzurum ve Erzincan illerine ait 138 yol görüntüsü elde edilmiştir. Görüntü kalitesindeki düşüklükten dolayı bu sayının düşük tutulması tercih edilmiştir. Bu görüntülere ait görüntü boyutları değişkenlik gösterdiği için bilgileri paylaşılmamıştır. Tüm bu görüntüler veri ayıklama sürecine tabi tutulduktan sonra çalışma kapsamında 4.132 adeti değerlendirilmiştir. Tüm yol kusurları bu veri setinde yer almaktadır.


3. MATERYAL VE YÖNTEM

Çalışma kapsamında sekiz farklı ülkeye ait yol kusur veri seti çalışma kapsamında değerlendirilmiştir. Çalışmanın amaçları arasında yer alan küresellik oluşumu için büyük bir adım sağlanmıştır. Ayrıca değerlendirilen kusur sınıflarındaki artış ve diğer ülke verilerinin yeniden etiketlenme süreci yoğun bir iş yükü getirmiştir. Sekiz ülkeye ait yol kusur görüntülerinin sınıfsal dağılımları Çizelge 3.2’de sunulmaktadır. Bu görüntüler eğitim ve doğrulama aşamalarında kullanılmaktadır. Çalışma kapsamında eğitim ve doğrulama aşaması için 23.925 adet görüntü kullanılmıştır. Ayrıca test seti içinde 3.435 adet veri kullanılırken çalışma genelinde dikkate alınan test görüntü sayısı toplamı 84’dür.

Çizelge 3.2. Eğitim ve doğrulama veri setinin sınıfsal olarak dağılımı

	Japonya	Hindistan	Çek C.	Norveç	ABD	Çin	Gürcistan	Türkiye
Görüntü Sayısı	7.198	1.221	992	2.803	4.804	1.977	798	4.132
D00	2.161	355	707	2.435	3.928	1.424	179	1.254
D10	1.882	30	296	999	2.394	747	147	1026
D20	3.717	594	128	355	756	489	232	126
D30	194	-	24	-	8	-	130	2.143
D40	1.136	468	137	252	130	164	54	457
D50	623	30	43	22	51	24	15	102
D60	1.198	364	48	826	246	119	429	306
D70	2.163	14	99	14	312	167	-	96
D80	296	2	37	70	96	223	130	55
D90	5	-	2	8	3	-	3	65

Ülkelere ait verilerin oransal olarak daha iyi anlaşılabilmesi için Şekil 3.10’de çizgisel grafik sunulmuştur. Bazı kusur türlerine ait verilerin bazı ülkelerde olmadığı açıktır. Özellikle D90 kusur sınıfının yol ağlarında sık yaşanmadığı görülmektedir. Ayrıca D30 uygulama şeklinin her ülkede olmadığı anlaşılmaktadır. Genel olarak çatlakların sıklıkla meydana geldiği görülmektedir. D40 kusur türünün bakım ve onarım hızı diğer kusur türlerine göre daha yüksek olduğu için elde edilmesi güçtür.



Şekil 3.10. Kusur sınıflarının ülkelere göre dağılımı

Yol kusur görüntülerinin ülkelere göre dağılımı incelendiğinde Japonya, ABD ve Türkiye diğer ülkelere göre daha fazla görüntü sağlamaktadır. Norveç ve Çin yol görüntü sayıları birbirine yakınlık gösterirken Gürcistan, Hindistan ve Çek Cumhuriyeti de görüntü sayısı olarak yakın değerlere sahiptir. Görüntü sayısı benzerlikleri olarak sekiz ülke üç gruba ayrılmış olarak ifade edilebilir.

Yapay zekâ ile birlikte tüm sektördeki araştırmacıların sorunlara çözüm önerileri sunma gayreti mevcut geleneksel yöntemlerin değişmesine yol açmaktadır. Bu değişimin hızı yapay zekâyâ olan ilgiden dolayı giderek artmaktadır. Sektör devlerinin temsilcileri geleceklerini yapay zekâ tabanlı çözümlerin oluşturacağını ifade ettiği sürece bu alan trendinin uzun yıllar süreceği ön görülmektedir. Ulaşım sektöründe ise teknoloji tabanlı uygulamaların genel ismi AUS olarak isimlendirilmiştir. Yapılan tez çalışması AUS kapsamında olmakla birlikte esnek üstyapıya sahip yol ağının olduğu tüm ülkelerin karşılaştığı yol kusur problemlerini ele almaktadır. Yol ağlarında birçok yol kusuru meydana gelmekte ve bu kusurların belirlenme süreci değişkenlik göstermektedir. Bu tez çalışması kapsamında tek aşamalı dedektörlü nesne algılama yöntemleri kullanılarak yol kusurlarının algılanması ve sınıflandırılması süreci gerçekleştirilmiştir. Bu yöntemlerin kullanılmasının ana sebebi olarak tez çalışması kapsamında gerçek zamanlı algılama süreci ele alınmıştır. Ayrıca bu süreç gömülü sistem inşası ile devam ederek katma değerli ürün elde edilmesi sağlanmıştır. Elde edilen prototip ürünün bir vasıtaya entegre edilerek Erzurum Teknik Üniversitesi kampüs yol ağlarında yol kusur tarama işlemi yapılarak

kusurların yerleri konumsal olarak tespit edilmiştir. Noktasal olarak koordinatları belirlenen kusurların CBS ortamına aktarımı sağlanarak yol ağının kusur bakımından röntgeni çekilmiştir. İlgili kurum ve yerel yönetimler için elde edilen ürünün ekonomik ve işlevsel olduğu açıktır. Böylece yol ağlarımızda var olan yol kusurların otomatik olarak tespit edilmesi mümkün olacaktır.

Bu bölümde sıkça isimlerini duyacağımız yapay zekâ, makine öğrenmesi, derin öğrenme, görüntü işleme ve AUS kalıplarının tanımları yapılmıştır. Yapay zekâ, makine öğrenmesi, görüntü işleme ve derin öğrenme birbirleriyle bağlantılı ancak farklı kavramlar ve alanlardır.

Yapay zekâ, bilgisayar sistemlerinin insan benzeri düşünme ve problem çözme yetenekleri kazanmasını amaçlayan bir alanıdır. Yapay zekâ, algoritma ve programlar aracılığıyla karmaşık sorunları çözmek, karar vermek, öğrenmek ve adaptasyon göstermek gibi insan zekâsına benzer özellikleri taklit etmeye çalışır (Pirim 2006; Arslan 2020).

Makine öğrenmesi, yapay zekânın alt alanlarından biridir ve bilgisayar sistemlerinin verilerden öğrenme ve deneyim yoluyla kendilerini geliştirme yeteneğini ifade eder. Makine öğrenmesi, algoritmaların verileri analiz ederek desenleri ve ilişkileri öğrenmesini ve bu öğrenmeyi gelecekteki verilere uygulamak suretiyle tahminler yapmasını içerir (Atan 2016; Özdemir ve Örsülü 2019).

Görüntü işleme, dijital görüntülerin alınması, işlenmesi ve analiz edilmesi ile ilgilenen bir alandır. Görüntü işleme, görüntülerdeki nesneleri algılama, tanıma, takip etme, düzenleme ve analiz etme gibi çeşitli görevleri içerir (Ağın ve Malaslı 2016; Eldem vd 2017; Baltacıoğlu vd 2023).


Derin öğrenme, yapay sinir ağları adı verilen derin ve çok katmanlı yapılar kullanan makine öğrenmesinin bir alt dalıdır. Derin öğrenme, büyük veri kümelerini işleyerek karmaşık desenleri ve temsilleri otomatik olarak öğrenme yeteneğine sahiptir. Özellikle görüntü, ses ve doğal dil işleme gibi alanlarda başarıyla kullanılmaktadır (Doğan ve Türkoğlu 2019; Aslan 2022). Bu terimler arasındaki ilişkiler şu şekildedir:

Yapay zekâ, insan benzeri zekâ ve öğrenme yeteneklerini bilgisayar sistemlerine kazandırmayı amaçlar. Makine öğrenmesi, yapay zekâ için kullanılan bir yöntemdir ve verileri kullanarak modeller oluşturur, desenleri öğrenir ve gelecekteki verileri tahmin eder. Görüntü işleme, görüntüleri işleyerek nesneleri tanıma, sınıflandırma ve analiz etme gibi görevleri içerir. Derin öğrenme, makine öğrenmesinin bir alt alanıdır ve yapay sinir ağları kullanarak büyük veri kümelerinden otomatik olarak öğrenme yeteneğine sahiptir. Görüntü işleme ve doğal dil işleme gibi alanlarda derin öğrenme başarılı bir şekilde kullanılmaktadır.

Genel olarak, yapay zekâ geniş bir kavramı ifade ederken, makine öğrenmesi ve derin öğrenme gibi alt alanlar belirli görevleri gerçekleştirmek için kullanılan teknikleri içerir. Görüntü işleme ise, belirli bir görev olan görüntülerin analizi ve işlenmesi ile ilgilenen bir uygulama alanıdır ve genellikle makine öğrenmesi ve derin öğrenme tekniklerini kullanarak hedeflerine ulaşır.

3.5. Yapay Zekâ

Yapay zekâ, bilgisayar sistemlerine insan benzeri düşünme ve problem çözme yetenekleri kazandırmayı amaçlayan bir bilim ve mühendislik dalıdır. Yapay zekâ, insanların gözlem, öğrenme, mantık yürütme ve karar verme gibi süreçlerini taklit etmeye çalışır ve bu şekilde çeşitli görevleri yerine getirebilir. Yapay zekâ, tarihsel olarak farklı aşamalardan geçerek günümüze kadar gelişmiştir. Tarihsel gelişiminin basit bir gösterimi Şekil 3.11’de yer almaktadır.



Şekil 3.11. Yapay zekânın serüveni

Günümüzde ise yapay zekânın kullanım alanları oldukça fazladır. Bu alanlar hakkında kısa bilgiler aşağıda sunulmuştur.

Görüntü ve Ses Tanıma: Görüntü ve ses işleme teknolojileri, nesne tanıma, yüz tanıma, plaka tanıma, hatta duygusal durum analizi gibi birçok alanda kullanılır. Örneğin, güvenlik kameralarında yüz tanıma ile suçluların tespiti, tıbbi görüntülerde hastalıkların teşhisi, otonom araçlarda yol ve trafik işaretlerinin tanınması gibi alanlarda yapay zekâ kullanılır (Poyraz vd 2021).

Doğal Dil İşleme (NLP): NLP, bilgisayarların insan dilini anlamasına ve işlemesine olanak sağlayan bir alandır. Chatbotlar, metin tabanlı duygusal analiz, metin çevirisi, metin sınıflandırma, konuşma tanıma ve konuşma sentezi gibi birçok uygulama NLP'nin altında yer alır. Sesli asistanlar (Siri, Google Asistan) NLP'nin bir örneğidir.

Otomasyon ve Robotik: Endüstriyel robotlar ve yapay zekâ tabanlı otomasyon süreçleri, üretim, lojistik, tarım gibi birçok sektörde verimliliği artırmak için kullanılır. Ayrıca, kişisel asistanlar ve hizmet robotları (temizlik robotları) gibi alanlarda da yapay zekâ ve robotik teknolojileri kullanılır.

Sağlık ve Tıp: Tıp alanında yapay zekâ hastalıkların teşhisi ve tedavisi için kullanılır. Radyolojide görüntü analizi, patolojide hücre analizi, tıbbi veri analizi ve ilaç keşfi gibi birçok alanda yapay zekâ kullanılmaktadır (Kandemir ve Azizoğlu 2023).

Finans ve Ekonomi: Yapay zekâ, finansal piyasalarda yatırım kararları vermede ve dolandırıcılığı tespit etmede kullanılır. Özellikle yüksek frekanslı ticaret, kredi değerlendirme ve müşteri hizmetleri gibi alanlarda yapay zekâ kullanımı önemli rol oynar (Yıldız 2022).

Eğitim: Eğitimde yapay zekâ, öğrenci performansını analiz ederek kişiselleştirilmiş eğitim programları sunabilir, otomatik sınav değerlendirme ve geri bildirim sağlayabilir (Arslan 2020).

Sanat ve Eğlence: Müzik, resim, edebiyat gibi alanlarda da kullanılır. Örneğin, şarkı yazma, resim yapma veya oyun karakterlerinin davranışlarını yönetme gibi uygulamalar yapay zekâ algoritmalarıyla mümkündür.

Güvenlik: Siber güvenlikte saldırı tespiti, kötü amaçlı yazılım taraması ve veri ihlallerini engellemede etkili bir araç olarak kullanılır (Gönen et al. 2021).

Uzay Keşfi: Uzay keşfinde yapay zekâ, teleskopların verilerini analiz ederek yeni gezegenler, yıldızlar ve diğer gök cisimlerini keşfetmede kullanılır.

Ulaşım sektörü de yapay zekâ teknolojilerinin yaygın olarak kullanıldığı ve büyük bir potansiyele sahip olduğu önemli bir alandır. Yapay zekâ, ulaşım sektöründe çeşitli alanlarda kullanılarak verimlilik, güvenlik ve kullanıcı deneyimi gibi önemli unsurları geliştirmeye yardımcı olmaktadır. Otonom araçlar, trafik yönetimi, güzergâh planlama ve lojistik, araç güvenliği ve bakımı, toplu taşıma planlanması, sürücü destek ve güvenlik sistemleri gibi birçok uygulama alanında yapay zekâ örnekleri mevcuttur. Ulaşım sektörü, yapay zekâ teknolojileri sayesinde büyük bir dönüşüm geçiriyor ve bu alanda yapılan çalışmalar ve uygulamalar hızla artmaktadır. Önümüzdeki yıllarda yapay zekâ ile güçlendirilmiş AUS, daha güvenli, verimli ve sürdürülebilir bir ulaşım ortamının temelini oluşturacaktır.

Yapay zekâ kullanımı ve gelişimi konusunda arkasında büyük bir destek olsa da bu teknolojinin gelişimine karşı gelen düşünceler de mevcuttur. Bu kısımda yapay zekânın avantaj ve dezavantajları verilmiştir (Ahmed 2018; Bhbosale et al. 2020).

Avantajlar:

- Hız ve Verimlilik: Yapay zekâ, insanların yaptığı işleri daha hızlı ve verimli bir şekilde yapabilir. Büyük veri kümelerini anlamlandırarak, analiz yaparak ve karmaşık problemleri çözerek süreçleri optimize edebilir.
- Hata Azaltma: İnsanların yorgunluk, dikkat dağınıklığı gibi nedenlerle yaptığı hataları yapay zekâ önemli ölçüde azaltabilir.
- Tahmin ve Öngörü: Yapay zekâ, büyük veri kütlelerini analiz ederek gelecekteki eğilimleri, trendleri ve olası sonuçları tahmin etmede yardımcı olabilir.
- Tekrarlanabilirlik: Bir kez eğitilen bir yapay zekâ modeli aynı görevi tekrar etmek için sürekli olarak kullanılabilir.

Dezavantajlar:

- İstihdam Kaybı: Yapay zekânın otomasyon yetenekleri bazı işlerin insan iş gücü yerine makineler tarafından yapılmasına yol açabildiği için bu da işsizlik sorununa neden olabilir.

- Veri Mahremiyeti: Yapay zekâ sistemleri büyük miktarda veri kullanmakta ve veri mahremiyeti ve güvenliği risklerini artırabilir.
- Önyargı ve Adaletsizlik: Eğitim verilerindeki önyargılar yapay zekâ sistemlerinde de yansiyabilir ve ayrımcılık ve adaletsizliğe yol açabilir.
- KontROLSÜZLÜK: Yapay zekâ sistemlerinin karar alma süreçleri bazen açıklanamaz veya anlaşılamaz olabilmekte ve bu da güvenilirlik sorunlarına yol açabilir.
- Moral ve Etik Sorunlar: Bazı yapay zekâ uygulamaları etik ve ahlaki sorunları beraberinde getirebilir. Örneğin, otonom silahlar veya insan benzeri yapay zekâlı robotlar etik tartışmalara neden olabilir.

Yapay zekânın yaygınlaşması ve kullanımı insan toplumunda ciddi etkileri olan bir dönüm noktası olarak kabul edilir. Dolayısıyla yapay zekâ geliştirme ve kullanım süreçlerinde dikkatli olunması, etik ve sosyal konuların göz önünde bulundurulması gerekmektedir.

3.6. Görüntü İşleme

Görüntü işleme, dijital görüntülerin alınması, işlenmesi ve analiz edilmesi ile ilgilenen bir bilgi işlem disiplini. Bu alanda, görüntülerin pikseller ve matematiksel işlemler kullanılarak işlenmesi ve çeşitli analizlerin yapılmasıyla bilgi elde edilir. Görüntü işleme, görsel bilgiyi anlamak, geliştirmek ve yorumlamak için çeşitli yöntemler ve algoritmalar kullanır.

Görüntü işlemenin temel adımları şunlardır (Teletar vd 2014):

Veri edinme: Dijital görüntüleri elde etme sürecidir. Kameralar, tarayıcılar, sensörler veya medikal görüntüleme cihazları gibi çeşitli kaynaklardan elde edilebilir.

Ön işleme: Görüntüyü analiz için hazırlama sürecidir. Gürültü giderme, kontrast artırma, keskinleştirme ve düzeltme gibi işlemler bu adımda yapılır.

Özellik çıkarımı: Görüntüden faydalı bilgilerin çıkarılmasıdır. Renk, kenar, doku ve yoğunluk gibi özellikler görüntüden belirlenir.

Bölütleme ve nesne algılama: Görüntüdeki farklı nesnelerin tespiti ve ayrıştırılmasıdır. Görüntüdeki nesnelerin sınıflandırılması ve tanınması bu adımda gerçekleştirilir.

Sınıflandırma ve tanıma: Görüntüdeki nesnelerin veya sahnelerin belirli kategorilere atanmasıdır. Örneğin, bir görüntüdeki köpek veya kedi tespit edilir ve sınıflandırılır.

Görüntü işleme birçok alanda kullanılır:

Tıp ve sağlık: Tıp alanında, röntgen ve MRI gibi görüntüleme yöntemleri kullanılarak hastalıkların tanısı ve teşhisi için görüntü işleme teknikleri uygulanır.

Güvenlik: Güvenlik kameraları ve video izleme sistemleri, yüz tanıma ve nesne tespiti gibi görüntü işleme tekniklerini kullanarak güvenlik önlemlerini artırır.

Otomotiv: Otonom sürüş teknolojilerinde, araçların çevresini algılayarak yol ve trafik işaretlerini tanımlamak için görüntü işleme kullanılır.

Sanayi ve üretim: Otomasyon sistemlerinde, ürün kalitesini kontrol etmek ve hataları tespit etmek için görüntü işleme kullanılır.

Tarım: Bitki hastalıklarının tespiti, verimliliği artırmak ve tarımsal faaliyetleri izlemek için tarım alanında görüntü işleme teknikleri uygulanır.

Eğlence ve oyunlar: Görüntü işleme teknikleri, eğlence sektöründe özel efektler, hareket yakalama ve artırılmış gerçeklik gibi alanlarda kullanılır.

Görüntü işleme, birçok endüstride ve uygulamada insanların işini kolaylaştırmak, verimliliği artırmak ve yeni olanaklar sunmak için önemli bir rol oynamaktadır.

Nesne algılama süreci, insanlar için genellikle önemsiz bir görev olarak kabul edilir. Bir insan, doğduğu andan itibaren birkaç ay sonra olağan dışı bir durum olmadığı sürece nesneleri algılamaya, tanımaya ve sınıflandırmaya başlayabilir (Zaidi et al. 2022). Ancak bu yeteneği bilgisayarlara öğretmek, geçmişte oldukça zor ve mucizevi bir görevdi (Sultana et al. 2019). Ancak 2012 yılından itibaren nesne algılama alanında yeni bir dünya ortaya çıktı. Artan nüfus, hareketlilik ve suç oranları gibi gerçek dünya sorunları kontrol mekanizmalarının otomatikleştirilmesi ihtiyacını doğurmuştur. Ayrıca, otonom sürüş teknolojilerinin gelişimi, ulaşımda nesne algılama sürecini hızlandırmada büyük bir rol oynamıştır.

Tez çalışmasında nesne algılama ve sınıflandırma süreci kapsamlı şekilde uygulanmıştır. Görüntü işleme ve nesne algılama arasında fark vardır. Bazı durumlarda birbirlerinin yerine kullanılan bu kavramların tanımları, amaçları ve teknikleri birbirinden farklıdır. Görüntü işleme ve nesne algılama her ikisi de görüntülerle ilgilenen bilgisayar bilimleri alanlarında yer alan farklı kavramlardır. Görüntü işleme ile nesne algılama arasındaki temel farklar aşağıda yer almaktadır (Jalled and Voronkov 2016; Dhiman and Mohammad 2018).

Görüntü işleme, dijital görüntülerin alınması, işlenmesi ve analiz edilmesi sürecidir. Görüntüdeki gürültüyü giderme, keskinleştirme, renk düzeltme gibi ön işleme adımlarıyla düzenleyerek desen tanıma gibi analizlerle bilgi çıkarma işlemlerini içerir.

Nesne algılama, görüntülerde belirli nesnelerin tespit edilmesi ve konumlarının belirlenmesi sürecidir. Yani nesne algılama, görüntü işleme ile başlayan bir adım olarak düşünülebilir. Amaç, görüntüdeki nesneleri tespit etmek ve onların sınırlayıcı kutularını çizmek veya sınıflandırmak için yapay zekâ teknikleri kullanmaktır.

Görüntü işleme, görüntü kalitesini artırmak, gürültüyü azaltmak, parlaklığı ayarlamak gibi temel işlemleri gerçekleştirerek görüntüler üzerinde belirli düzenlemeler ve iyileştirmeler yapmayı amaçlar.

Nesne algılama, belirli nesnelerin görüntülerde otomatik olarak tespit edilmesi ve sınıflandırılması için kullanılır. Yani belirli nesnelerin var olup olmadığını ve nesnelerin konumlarını belirlemek amacıyla kullanılır.

Görüntü İşleme, görüntülerin analizine yönelik matematiksel ve istatistiksel işlemler, filtreler ve dönüşümler içerir. Örneğin, histogram eşitleme, kenar algılama ve bulanıklaştırma gibi işlemler görüntü işlemenin temel tekniklerindendir.

Nesne algılama, görüntüde nesnelerin tespiti ve sınıflandırılması için genellikle makine öğrenmesi ve derin öğrenme algoritmaları kullanır. Yapay zekâ teknikleri, görüntüdeki nesneleri tanıma ve sınıflandırmak için eğitilmiş modelleri kullanarak nesne algılamada etkili bir rol oynar.

Sonuç olarak, görüntü işleme görüntüleri analiz etmek ve düzenlemek için kullanılırken, nesne algılama görüntülerdeki belirli nesneleri otomatik olarak tespit etmek ve sınıflandırmak için bir adım daha ileri gitmektedir. Nesne algılama, yapay zekâ ve derin öğrenme tekniklerini kullanarak görüntülerdeki nesneleri tanıma ve konumlarını belirleme yeteneğine sahiptir.

3.7. Nesne Algılama

İlk nesne algılama modelleri, Viola-Jones dedektörü (Viola and Jones 2001) ve Yönlendirilmiş Gradyan Histogramı (HOG) (Dalal and Triggs 2005) gibi el yapımı özellik çıkarıcılarından oluşan bir topluluk olarak geliştirilmiştir. Ancak bu modeller genellikle yavaş ve hatalı sonuçlar verdiği için performansları düşüktür. Daha sonra CNN ve derin öğrenme, nesne algılama serüvenini tamamen değiştirmiştir.

Krizhevsky and Hinton (2012)'un AlexNet'i ile başlayan nesne algılama süreci gün geçtikçe güçlenerek devam etmektedir. Günümüzde nesne algılama teknolojisi, sürücüsüz arabalardan, kimlik algılamaya, güvenlik uygulamalarından tıbbi kullanımlara kadar geniş bir yelpazede uygulama alanına sahiptir. Bu durum araştırmacıların kendilerini sürekli olarak güncel tutma ihtiyacını ortaya çıkarmaktadır. Son yıllarda teknolojiye gelişmeler, nesne algılama alanındaki çalışmalara üstel bir katkı sağlamış


ve yeni yöntemlerin hızla gelişmesini sağlamıştır. Literatürde yapılan çalışmalarda derin öğrenme tabanlı nesne algılayıcıları ve hafif sınıflandırma mimarileri hakkında kapsamlı bilgiler yer almaktadır (Gauen et al. 2017; Huang et al. 2017; Agarwal et al. 2018; Zhao et al. 2019; Zou et al. 2019; Borji et al. 2019; Zhao et al. 2019; Zou et al. 2019; Borji et al. 2019; Liu et al. 2020; Zaidi et al. 2022)

Video veya görüntülerdeki nesneleri ayırt etmek, algılamak ve sınıflandırmak için kullanılan bilgisayarlı görme işlemi, nesne algılama olarak adlandırılır. Bu işlem için birçok nesne algılama algoritması geliştirilmiş olup, genellikle makine öğrenimi veya derin öğrenme temeline dayanır. Nesne algılama algoritmaları, yol güvenliğini artırmak için araç-yol-yaya arasındaki bağlantıyı sürücü destek sistemleriyle güçlendirmeyi hedefler. Bu teknolojiyi oluşturma isteği nesne algılama yöntemlerine olan ihtiyacı ortaya çıkarmıştır. Literatürde nesne algılama için farklı tasarımlara sahip algılama bileşenleri, öğrenme stratejileri ve uygulamalar bulunmaktadır. Detaylı bilgiler Çizelge 3.3’de yer almaktadır.

Çizelge 3.3. Nesne algılama yöntemlerine ait bileşenler (Wu et al. 2020)


NESNE ALGILAMA				
Algılama Bileşenleri			Öğrenme Stratejisi	Uygulamalar ve Kıyaslamalar
Algılama Ayarları	Algılama Paradigmaları	Omurga Mimarisi	Eğitim Aşaması	Uygulamalar
Sınırlayıcı kutu	İki aşamalı dedektör	VGG, ResNet, DenseNet	Veri çoğaltma	Yüz tanıma
Piksel maskeleme	Bir aşamalı dedektör	MobileNet, ResNext	Dengesizlik örnekleme	Yaya tanıma
		DetNet, Hourglass Net	Yerelleştirme iyileştirme	Diğer
			Kademeli öğrenme	
			Diğer	
Öneri Oluşturma		Özellik Sunumu	Test Aşaması	Genel Kıyaslamalar
Geleneksel Bilgisayarla Görme Yöntemleri		Çok Ölçekli Özellik Öğrenme	Yinelenen Kaldırma	MSCOCO, Pascal VOC, Open Images
Anchor Tabanlı Yöntemler		Bölge Özelliği Kodlaması		
Keypoint Tabanlı Yöntemler		Bağlamsal Akıl Yürütme	Modeli Hızlandırma	FDDDB, WIDER FACE
Diğer Yöntemler		Deforme Özellik Öğrenme	Diğer	KITTI, ETH, CityPersons

Derin öğrenme tabanlı nesne algılama işlemi için iki temel yaklaşım mevcuttur. İlk yaklaşım, özel bir nesne dedektörü oluşturma ve bunu eğitme sürecini içermektedir. Bu yaklaşımda, uzman kişiler yeni bir ağ mimarisi tasarlar ve bu ağı sıfırdan eğitmek için zaman ve eğitim verileri gereklidir. CNN katmanları ve ağırlıkları manuel olarak ayarlanır. İkinci yaklaşım ise önceden eğitilmiş bir nesne dedektörü kullanmaktır. Bu yaklaşım, nesne algılama yöntemlerini kendi özel veri setleri ile uygulamak isteyen araştırmacılar için uygundur. Önceden eğitilmiş bir ağ, kendi uygulamaları için ince ayar yapmalarına imkân verir ve daha hızlı sonuçlar elde edilmesini sağlar. Bu ağlar binlerce hatta milyonlarca görüntü üzerinden eğitildiği için daha iyi performans gösterirler. Şekil 3.12, nesne algılama yöntemlerinin yıllara göre ortaya çıkış zaman çizelgesini göstermektedir. 2012 yılı CNN tabanlı nesne algılamasında bir dönüm noktası olarak kabul edilmektedir (Kaya ve Çodur 2022).



Şekil 3.12. Nesne algılama algoritmalarının ortaya çıkış tarihçesi (Kaya ve Çodur 2022)

Literatürde, birçok nesne algılama algoritması ve yöntemi bulunmaktadır. Bu yöntemler sürekli olarak araştırmacılar ve geliştiriciler tarafından güncellenmektedir. Bu da nesne algılama alanında çalışan grupların kendilerini sürekli olarak güncel tutmaları gerektiği anlamına gelmektedir. Literatürde iki tür nesne algılama dedektörü bulunmaktadır ve bunlar bir aşamalı ve iki aşamalı dedektörler olarak isimlendirilmektedir (Zaidi et al 2022). Genel olarak literatürde yer alan çalışmalar bu iki tür dedektöre dayalı nesne algılama yöntemlerini kullanmaktadır. Bochkovskiy et al. (2020) tarafından yapılan çalışmaya göre iki dedektör arasındaki çalışma düzeni farkı Şekil 3.13'de gösterilmiştir.



Şekil 3.13. Bir ve iki aşamalı dedektörlerin çalışma prensibi farkı (Bochkovskiy et al. 2020).

Bir ve iki aşamalı dedektörler prensibine göre nesne algılama yöntemleri Çizelge 3.4'de ortaya çıkış tarihe göre verilmektedir (Lohia et al. 2021).

Çizelge 3.4. Bir ve iki aşamalı dedöktörlü nesne algılama yöntemleri

Kaynak	Yıl	Modeller	Kullanılan dedektör
(Girshick et al. 2014)	2014	R-CNN: Bölge tabanlı CNN dedektör	İki aşamalı dedektör
(Girshick 2015)	2015	Fast R-CNN: R-CNN'nin daha hızlı versiyonu	İki aşamalı dedektör
(Ren et al. 2007)	2017	Faster R-CNN: Yeni RPN kullanımı	İki aşamalı dedektör
(He et al. 2017)	2017	Mask R-CNN: Faster R-CNN'in eklentisi	İki aşamalı dedektör
(Lin et al. 2016)	2016	FPN: Özellik Piramit Ağı	İki aşamalı dedektör
(Redmon et al. 2015)	2015	YOLO: You Only Look Once	Bir aşamalı dedektör
(Redmon and Farhadi 2016)	2016	YOLOv2:YOLO'nun ikinci versiyonu	Bir aşamalı dedektör
(Redmon and Farhadi 2018)	2018	YOLOv3:YOLO'nun üçüncü versiyonu	Bir aşamalı dedektör
(Liu et al. 2016)	2016	SSD: Tek çekim çoklu kutu algılama	Bir aşamalı dedektör
(Lin et al. 2017)	2017	RetinaNet	Bir aşamalı dedektör
(Zhang et al. 2017)	2017	RefineDet	Bir aşamalı dedektör
(Ghiasi et al. 2019)	2019	NAS-FPN	Bir aşamalı dedektör
(Tan et al. 2019)	2019	EfficientDet	Bir aşamalı dedektör
(Bochkovskiy et al. 2020)	2020	YOLOv4:YOLO'nun dördüncü versiyonu	Bir aşamalı dedektör
(Hochoer 2020)	2021	YOLOv5:YOLO'nun beşinci versiyonu	Bir aşamalı dedektör
(Li et al. 2022)	2022	YOLOv6:YOLO'nun altıncı versiyonu	Bir aşamalı dedektör
(Wang et al. 2022)	2022	YOLOv7:YOLO'nun yedinci versiyonu	Bir aşamalı dedektör
(Anonymous 2023a)	2022	YOLOv8:YOLO'nun sekizinci versiyonu	Bir aşamalı dedektör

Bir aşamalı ağlarda, ağ yapısı CNN'den oluştuğu için görüntü üzerinden ağ tahminleri üretir ve nihai olarak sınırlayıcı kutular (bounding boxes) üzerinden nesne algılama yapılır. Bu yaklaşım, iki aşamalı ağlardan daha hızlıdır ancak küçük nesnelerin algılanması konusunda aynı doğruluk düzeyine ulaşması mümkün değildir (Bochkovskiy et al. 2020).

İki aşamalı nesne algılama ağlarında, ilk aşamada görüntüdeki potansiyel nesne bölgeleri, nesne önerileri olarak adlandırılan alt kümeler belirlenir. Bu adım nesne önerisi

3. MATERYAL VE YÖNTEM

oluşturma olarak bilinir. Dedektörler görüntüdeki muhtemel nesne bölgelerini tespit etmeye çalışır (Zaidi et al. 2022). İkinci aşamada ise nesne önerileri içindeki bölgeler sınıflandırılır. Bu şekilde yüksek doğruluk düzeylerine ulaşan nesne algılama sonuçları elde edilir. İki aşamalı yapısından dolayı bir aşamalı ağırlara göre daha yavaş çalışır (Daoud et al. 2022).

İki farklı türdeki (iki ve bir aşamalı) nesne algılama modellerini karşılaştırmak oldukça zor bir süreçtir. Çünkü performans, doğruluk ve hız gibi birçok farklı öğeye bağlıdır. Nesne algılama modellerinin performansı; özellik çıkarıcı ağı yapısı, giriş görüntüsü çözünürlüğü, eşleştirme stratejisi ve IoU eşiği, teklif veya tahmin sayısı ve kayıp fonksiyonu gibi çeşitli faktörlere bağlıdır. Çizelge 3.5'te PASCAL VOC 2012 ve Microsoft COCO veri kümelerinde çeşitli nesne algılama modellerinin performans karşılaştırması verilmiştir. Bu tabloda yer alan değerler ilgili nesne algılama yöntemlerinin yayınlandığı makalelerden elde edilmiştir. Modeller, çıkarım zamanında ortalama hassasiyet (AP), FPS, aşama sayısı ve gerçek zamanlı algılama yeteneği açısından karşılaştırılır. AP50, tahmin edilen sınırlayıcı kutunun IoU'su > 0.5 olduğunda tüm sınıfların ortalama kesinliğini temsil eder. Bu sayede nesne algılama modellerinin performansının ve karşılaştırmalarının detaylı bir şekilde analiz edilmesi amaçlanmaktadır. Yapılan karşılaştırmalar nesne algılama algoritmalarının farklı veri kümesi ve özelliklerde nasıl performans gösterdiğini daha net şekilde ifade eder.

Çizelge 3.5. Farklı nesne algılama modellerinin karşılaştırılması

Model	Yıl	Omurga	AP50 %	FPS	Gerçek Zamanlı Algılama	Aşama Sayısı	Not: * ile işaretlenmiş modeller PASCAL VOC 2012'de, diğerleri ise MS COCO'da karşılaştırılmıştır.
R-CNN*	2014	AlexNet	58,50	~0,02	Hayır	İki	
Fast R-CNN*	2015	VGG-16	65,70	~0,43	Hayır	İki	
Faster R-CNN*	2016	VGG-16	67,00	5	Hayır	İki	
FPN	2017	ResNet-101	59,10	5	Hayır	İki	
Mask R-CNN	2018	ResNeXt-101-FPN	62,30	5	Hayır	İki	
YOLO*	2015	(Modifiye edilmiş) GoogleNet	57,90	45	Evet	Bir	
SSD	2016	VGG-16	41,20	46	Evet	Bir	
RetinaNet	2018	ResNet-101-FPN	49,50	12	Hayır	Bir	
EfficientDet-D2	2020	Efficient-B2	62,30	41,7	Evet	Bir	
CenterNet	2019	Hourglass-104	61,10	7,8	Hayır	Bir	

Özellikle iki aşamalı nesne algılama yöntemlerinin FPS değerlerinin oldukça düşük oldukları görülmektedir. Bu değerler gerçek zamanlı algılama uygulamalarında kullanımlarının son derece düşük performans sağlayacağı anlamına gelmektedir. Bu durum gerçek zamanlı algılama uygulamalarında tek aşamalı dedektörlerin kullanılması zorunluluğunu getirmektedir. Bu dedektörler arasında en iyi performansı genel olarak YOLO ailesi sağlamaktadır. Tez çalışması kapsamında YOLO ailesine ait en iyi performans sergileyen algılama modelleri kullanılmıştır.

3.8. You Only Look Once (YOLO)

YOLO ailesi bir aşamalı nesne algılama modelleri arasında araştırmacılar tarafından sıklıkla kullanılmaktadır. Özellikle sağladığı yüksek FPS ve algılama başarısı gerçek zamanlı algılama araştırmalarında tercih edilmesine neden olmaktadır. Bu kısımda YOLO ailesine ait algılama modellerinin detayları aktarılmıştır.

3.8.1. You Only Look Once: Birleşik, gerçek zamanlı nesne algılama

İnsanlar yapay zekâ ile yapılması planlanan işlevleri kusursuz şekilde yapmaktadır. İnsan görsel sistemi oldukça hızlı ve doğrudur. İnsanlar bir görüntüye bakar ve görüntüde hangi nesnelerin olduğunu, nerede olduklarını ve nasıl etkileşime girdiklerini anında belirlerler. Birçok karmaşık süreç insan için basit ve olağan durumdur.

Mevcut algılama sistemleri, algılamayı gerçekleştirmek için sınıflandırıcıları kullanmaktadır. Bir nesneyi algılamak için nesneye ait sınıflandırıcı alınır ve görüntü üzerinde çeşitli konum ve ölçeklerde değerlendirilir. Bu süreçte sınıflandırıcının tüm görüntü üzerinde eşit aralıklı konumlarda çalıştırıldığı bir kayan pencere yaklaşımı kullanılır.

R-CNN gibi daha yeni yaklaşımlar ise önce bir görüntüde potansiyel sınırlayıcı kutular oluşturmak ve ardından bu önerilen kutular üzerinde bir sınıflandırıcı çalıştırmak için bölge önerme yöntemlerini kullanır. Sınıflandırma işleminden sonra sınırlayıcı kutuları iyileştirmek, yinelenen algılamaları ortadan kaldırmak ve sahnedeki diğer nesnelere dayalı olarak kutuları yeniden puanlamak için son işleme süreci gerçekleştirilir.

(Girshick et al. 2014). Her bir bileşenin ayrı ayrı eğitilmesi gerektiğinden bu karmaşık işlem yavaş ve optimize edilmesi zordur.

Redmon et al. (2015) önerdikleri YOLO ile doğrudan görüntü piksellerinden sınırlayıcı kutu koordinatlarına ve sınıf olasılıklarına kadar tek bir regresyon problemi olarak yeniden çerçevelendirilmiştir. YOLO ile hangi nesnelerin mevcut olduğunu ve nerede olduklarını tahmin etmek daha kolay hale gelmiştir.



Şekil 3.14. YOLO algılama sistemi (Redmon et al. 2015)

Şekil 3.14'den de anlaşıldığı üzere tek bir evrişimli ağ aynı anda birden çok sınırlayıcı kutuyu ve bu kutular için sınıf olasılıklarını tahmin etmektedir. YOLO görüntünün tamamının üzerinden eğitim işlemini tamamlar ve algılama performansını doğrudan optimize eder. Birleştirilmiş bu modelin geleneksel nesne algılama yöntemlerine göre çeşitli avantajları bulunmaktadır.

- YOLO algılama işlemini bir regresyon problemi olarak çerçevelediği için son derece hızlıdır. Tespitleri tahmin etmek için sinir ağı test zamanında yeni bir görüntü üzerinde çalıştırılmaktadır. Toplu işleme olmadan saniyede 45 kare hızında çalışmakta ve hızlı bir sürüm ile 150 FPS'den daha yüksek hızlarda çalışmaktadır. YOLO'nun bu özelliği video akışını 25 milisaniyeden daha az gecikmeyle gerçek zamanlı olarak işleyebileceğimiz anlamına gelmektedir. Ayrıca YOLO, diğer gerçek zamanlı sistemlerin mAP değerinden iki katından fazlasını elde etmektedir.
- Kayan pencere ve bölge önerisine dayalı tekniklerin aksine, YOLO, eğitim ve test süresi boyunca görüntünün tamamını görmektedir. Böylece nesneleri sınıflamada ve bunların görünümü hakkındaki bağlamsal bilgileri kodlamada yeteneklidir. En iyi algılama yöntemlerinden biri olan Fast R-CNN, daha geniş bağlamı göremediği için bir görüntüdeki arka plan yamalarını nesnelerle karıştırmaktadır.

YOLO, Fast R-CNN'e kıyasla arka plan hatalarının yarısından daha azını yapmaktadır.

- YOLO, doğal görüntüler üzerinde eğitildiğinde ve gerçek veriler üzerinde test edildiğinde R-CNN gibi en iyi algılama yöntemini açık bir farkla geride bırakmaktadır. YOLO oldukça genelleştirilebilir olduğundan yeni alanlara veya beklenmedik girdilere uygulandığında bozulma olasılığı daha düşüktür.

YOLO'nun sağlamış olduğu avantajlarının yanı sıra doğruluk açısından son teknoloji algılama sistemlerinin gerisinde kalmaktadır. Görüntülerdeki nesneleri hızlı bir şekilde tanımlayabilse de bazı nesneleri özellikle küçük olanları tam olarak yerelleştirmekte zorlanmaktadır.

Nesne algılamanın ayrı bileşenleri tek bir sinir ağına birleştirilmiştir. Ağ her bir sınırlayıcı kutuyu tahmin etmek için görüntünün tamamındaki özellikleri kullanmaktadır. Aynı zamanda bir görüntü için sınıflardaki tüm sınırlayıcı kutuları aynı anda tahmin etme yeteneğine sahiptir. YOLO tasarımı yüksek ortalama hassasiyeti korurken uçtan uca eğitim ve gerçek zamanlı algılama için yüksek hız sağlamaktadır.

Sistem giriş görüntüsünü bir $S \times S$ ızgarasına bölmektedir. Bir nesnenin merkezi bir ızgara hücresine düşerse, bu ızgara hücresi o nesneyi algılamaktan sorumludur. Her ızgara hücresi, B sınırlayıcı kutuları ve bu kutular için güven puanlarını tahmin etmektedir. Bu güven puanları, modelin kutunun bir nesne içerdiğinden ne kadar emin olduğunu ve ayrıca kutunun tahmin ettiğinin ne kadar doğru olduğunu düşündüğünü yansıtmaktadır. Bu hücrede herhangi bir nesne yoksa güven puanları sıfır olmalıdır. Aksi takdirde güven puanının, tahmin edilen kutu ile temel gerçek (Ground truth) arasındaki kesişme noktasına eşit olması istenmektedir.

Her sınırlayıcı kutu 5 tahminden (x, y, w, h ve güven puanı) oluşmaktadır. (x, y) koordinatları, ızgara hücresinin sınırlarına göre kutunun merkezini temsil eder. Genişlik ve yükseklik (w, h), görüntünün tamamına göre tahmin edilir. Son olarak güven tahmini, tahmin edilen kutu ile herhangi bir temel gerçeği kutusu arasındaki IoU'yu temsil eder. YOLO modelinin algılama süreci Şekil 3.15'de görselleştirilmiştir.

Ayrıca hızlı nesne algılamanın sınırlarını zorlamak için tasarlanmış hızlı bir YOLO sürümü de eğitilmiştir. Hızlı YOLO, daha az evrişim katmanı (24 yerine 9) ve bu katmanlarda daha az filtre içeren bir sinir ağı kullanmaktadır. Ağın boyutu dışında tüm eğitim ve test parametreleri YOLO ile Hızlı YOLO arasında aynıdır. Ağın son çıktısı $7 \times 7 \times 30$ tahmin tensörüdür. Alternatif 1×1 evrişimli katmanlar özellik alanını önceki katmanlardan azaltır. ImageNet sınıflandırma görevindeki evrişimli katmanlar yarı çözünürlükte (224×224 giriş görüntüsü) önceden eğitildiği için algılama için çözünürlüğü ikiye katlanmıştır. Algılama genellikle ince taneli görsel bilgi gerektirmekte ve bu nedenle ağın giriş çözünürlüğünü 224×224 'ten 448×448 'e yükseltilmiştir.

Ağ eğitim sürecinde ise evrişimli katmanlar ImageNet 1000 sınıf veri setinde önceden eğitilmiştir (Russakovsky et al. 2015). Ön eğitim için ilk 20 evrişimli katmanı ardından bir ortalama havuzlama katmanı ve tamamen bağlı bir katman kullanılmıştır. Bu ağ yaklaşık bir hafta boyunca eğitilmiştir. Tüm eğitim ve çıkarım süreci için Darknet çerçevesi kullanılmıştır (Joseph 2013). Rastgele başlatılan ağırlıklara sahip dört evrişimli katman ve iki tamamen bağlı katman eklenerek algılama performansı artırılmıştır.

Son katman hem sınıf olasılıklarını hem de sınırlayıcı kutu koordinatlarını tahmin etmektedir. Sınırlayıcı kutu genişliğini ve yüksekliğini 0 ile 1 arasına düşecek şekilde görüntü genişliği ve yüksekliğine göre normalleştirmektedir. Son katman için doğrusal bir aktivasyon fonksiyonu kullanılmakta ve diğer tüm katmanlar aşağıdaki düzeltilmiş doğrusal aktivasyonu kullanmaktadır:

$$\phi(x) = \begin{cases} e^x & \text{eğer } x > 0, \\ 0 & \text{değilse,} \end{cases} \quad (3.1)$$

Modelin çıktısında toplam kare hatası için optimizasyon yapılmıştır. Ancak ortalama kesinliği en üst düzeye çıkarma hedefi ile tam olarak uyumlu değildir. Yerelleştirme hatasını ideal olmayan sınıflandırma hatasıyla eşit olarak ağırlıklandırmaktadır. Ayrıca her görüntüdeki birçok ızgara hücresi herhangi bir nesne içermez. Bu, hücrelerin "güven" puanlarını sıfıra doğru itmekte ve genellikle nesne içeren hücrelerden gelen gradyanı bastırmaktadır. Bu durum model istikrarsızlığına yol açarak eğitimin erkenden farklılaşmasına neden olmaktadır. Bunu düzeltmek için sınırlayıcı kutu

koordinat tahminlerinden kaynaklanan kayıp artırılmakta ve nesne içermeyen kutular için güven tahminlerinden kaynaklanan kayıplar azaltılmaktadır.

Toplam kare hatası ayrıca büyük kutulardaki ve küçük kutulardaki hataları eşit olarak ağırlıklandırmaktadır. YOLO, ızgara hücresi başına birden fazla sınırlayıcı kutu tahmin etmektedir. Eğitim zamanında her nesneden yalnızca bir sınırlayıcı kutu tahmincisi sorumludur. Ağ, PASCAL VOC 2007 ve 2012'den alınan eğitim ve doğrulama veri kümeleri üzerinde yaklaşık 135 dönem (Epoch) boyunca eğitilmiştir. Eğitim boyunca 64'lük bir parti boyutu, 0,9'luk bir momentum ve 0,0005'lik bir azalma (decay) kullanılmaktadır. Öğrenme oranı çizelgesi şu şekildedir: İlk dönemler için öğrenme oranını 10^{-3} 'ten 10^{-2} 'ye yavaşça yükseltilir.

YOLO ağ modelinin literatüre kazandırılması ile diğer algılama modelleri arasında birtakım farklılıklar bulunmaktadır. Bu kısımda var olan farklılıklardan bahsedilmiştir. YOLO algılama sistemini, temel benzerlikleri ve farklılıkları vurgulanarak birkaç üst düzey algılama çerçevesiyle karşılaştırılmıştır.

Deforme olabilen parça modelleri (DPM); DPM nesne algılama için kayan pencere yaklaşımını kullanmaktadır (Felzenszwalb et al. 2010). DPM, statik özellikleri ayıklamak, bölgeleri sınıflandırmak ve yüksek puan alan bölgeler için sınırlayıcı kutuları tahmin etmek için ayırık bir işlem hattı kullanır. YOLO ise tüm bu farklı parçaları tek bir evrişimli sinir ağıyla değiştirir. Ağ, eşzamanlı olarak özellik çıkarma, sınırlayıcı kutu tahmini, maksimal olmayan bastırma ve bağlamsal akıl yürütme gibi süreçleri tek ağ yapısında gerçekleştirir. Birleştirilmiş YOLO mimarisi DPM'den daha hızlı ve daha doğru bir model sağlar.

R-CNN; R-CNN ve türevleri, görüntülerdeki nesneleri bulmak için kayan pencereler yerine bölge önerilerini kullanır (Cai and Vasconcelos 2018). Seçici Arama potansiyel sınırlayıcı kutular üretir, evrişimli bir ağ öznetelikleri çıkarır, bir destek vektör matrisi kutuları puanlar, doğrusal bir model sınırlayıcı kutuları ayarlar ve maksimum olmayan bastırma ise yinelenen algılamaları ortadan kaldırır. Bu karmaşık ağ hattının her aşaması bağımsız olarak hassas bir şekilde ayarlanmalıdır. Ayrıca ortaya çıkan sistem çok yavaştır ve test zamanında görüntü başına 40 saniyeden fazla sürer. Bunların yanı sıra

YOLO, R-CNN ile bazı benzerlikler barındırmaktadır. Her ızgara hücresi potansiyel sınırlayıcı kutular önerir ve evrimsel özellikleri kullanarak bu kutuları puanlar. Bununla birlikte YOLO, aynı nesnenin birden fazla algılanmasını azaltmaya yardımcı olan ızgara hücresi tekliflerine uzamsal kısıtlamalar koyar. Son olarak YOLO bu bireysel bileşenleri ortaklaşa optimize edilmiş tek bir modelde birleştirir.

Diğer hızlı dedektörler; Fast ve Faster R-CNN, seçici arama yerine bölgeleri önermek için hesaplamayı paylaşarak ve sinir ağlarını kullanarak R-CNN çerçevesini hızlandırmaya odaklanır. R-CNN'e göre hız ve doğruluk iyileştirmeleri sunarken her ikisi de gerçek zamanlı performansın gerisinde kalmaktadır. YOLO, büyük bir algılama işlem hattının bileşenlerini tek tek optimize etmeye çalışmak yerine işlem hattını tamamen devre dışı bırakır ve bu durum tasarım gereği hız kazandırır. Yüzler veya insanlar gibi tek sınıflar için dedektörler çok daha az varyasyonla uğraşmaları gerektiğinden yüksek oranda optimize edilebilir (Viola and Jones 2004). Ancak YOLO, çeşitli nesneleri aynı anda algılamayı öğrenen genel amaçlı bir dedektördür.

Derin Çoklu Kutu (Deep MultiBox); R-CNN'den farklı olarak Szegedy et al. (2015) seçici arama kullanmak yerine RoI tahmin etmek için evrimsel bir sinir ağı eğitmiştir. MultiBox ayrıca güven tahminini tek bir sınıf tahmini ile değiştirerek tek nesne algılaması gerçekleştirebilir. Bununla birlikte MultiBox genel nesne algılaması gerçekleştiremez. Hem YOLO hem de MultiBox bir görüntüdeki sınırlayıcı kutuları tahmin etmek için evrimsel bir ağ kullanır ancak YOLO eksiksiz bir algılama sistemidir.

OverFeat; Sermanet et al. (2014), yerelleştirmeyi sağlamak için evrimsel bir sinir ağı eğitimini tamamlamış ve algılamayı gerçekleştirecek şekilde yerelleştiriciyi uyarlamıştır. OverFeat her ne kadar kayan pencere algılamayı verimli bir şekilde gerçekleştirse de ayrı bir sistemdir. OverFeat optimize etme işlemini sistemin algılama performansı için değil yerelleştirmek için yapar. DPM gibi yerelleştirici de bir tahmin yaparken yalnızca yerel bilgileri görür. OverFeat küresel bağlam hakkında akıl yürütemez ve bu nedenle tutarlı tespitler üretmek için önemli bir son işleme gerektirir.

YOLO ve diğer ağ sistemlerinin çalışma prensipleri hakkında genel bir karşılaştırma yapılmıştır. Ancak YOLO'nun en ayırt edici özelliği gerçek zamanlı

algılama sistemleri arasından performans olarak sıyrılmış olmasıdır. Nesne algılamadaki birçok araştırmancının çabası, standart algılama düzenlerini hızlı hale getirmeye odaklanmasıdır (Dean et al. 2013; He et al. 2014; Yan et al. 2014). Ancak sadece Sadeghi and Forsyth (2014) gerçek zamanlı (saniyede 30 kare veya daha iyi) çalışan bir algılama sistemi üretmiştir. Saniyede 30 kareden az performans sergileyen nesne algılama yöntemlerinin gerçek algılama süreçlerinde kullanılamaz olduğu görülmektedir. Dedektörler arasındaki karşılaştırmanın somut çıktıları Çizelge 3.6'de yer almaktadır.

Çizelge 3.6. PASCAL VOC 2007'de gerçek zamanlı sistemlerin performans değerleri (Redmon et al. 2015).

Gerçek zamanlı dedektörler	Eğitim	mAP	FPS
100Hz DPM	2007	16	100
30Hz DPM	2007	26,1	30
Fast YOLO	2007+2012	52,7	155
YOLO	2007+2012	63,4	45
FPS<30	Eğitim	mAP	FPS
Fastest DPM	2007	30,4	15
R-CNN Minus R	2007	53,5	6
Fast R-CNN	2007+2012	70	0,5
Faster R-CNN VGG-16	2007+2012	73,2	7
Faster R-CNN ZF	2007+2012	62,1	18
YOLO VGG-16	2007+2012	66,4	21

Fast YOLO, PASCAL üzerindeki en hızlı nesne algılama yöntemidir. %52,7 mAP ile gerçek zamanlı algılama konusunda önceki çalışmalardan iki kattan daha fazla doğrudur. YOLO ise gerçek zamanlı performansı korurken mAP'ı %63,4'e çıkarır. Korunan performans değeri saniyede 30 karenin üzerindeki algılama oranıdır. YOLO, hızlı sürümden 10 mAP daha hassastır ve hız açısından gerçek zamanın çok üzerindedir. YOLO'nun FPS değerindeki düşüşün sebebi VGG-16 kullanarak eğitilmesidir. VGG-16 hassas ağ yapısına sahip olduğu için yavaş çıkarıma neden olmaktadır. Fastest DPM çok fazla mAP'den ödün vermeden DPM'yi etkili bir şekilde hızlandırır ancak yine de gerçek zamanlı performansı iki kat oranında kaçırmaktadır. R-CNN Minus R ise R-CNN'den çok daha hızlı olmasına rağmen yine de gerçek zamanın gerisinde kalıyor. Hızlı R-CNN, R-CNN'nin sınıflandırma aşamasını hızlandırır ancak yine de sınırlayıcı kutu teklifleri oluşturmak için görüntü başına yaklaşık 2 saniye sürebilen seçici aramaya dayanır. Bu nedenle yüksek mAP'ye sahip olup 0,5 FPS ile hala gerçek zamandan çok uzaktır. Yapılan

testlerde en doğru modeli 7 FPS değerine ulaşırken daha küçük, daha az doğru olan modeli 18 FPS'de çalışmaktadır. Faster R-CNN'nin VGG-16 versiyonu YOLO'dan 10 mAP daha yüksek olup aynı zamanda 6 kat daha yavaştır. ZeilerFergus Faster R-CNN, YOLO'dan yalnızca 2,5 kat daha yavaş olup aynı zamanda daha az doğrudur. YOLO ve son teknoloji dedektörler arasındaki farkları daha fazla incelemek için VOC 2007'deki sonuçların ayrıntılı bir dökümüne bakılmalıdır.

Hoiem et al. (2012)'un sağlamış olduğu metodoloji ve araçlar kullanılmıştır. Her tahmin ya doğrudur ya da hatanın türüne göre sınıflandırılır anlayışı üzerine hata türleri aşağıdaki gibi isimlendirilmektedir.

Doğrulama: doğru sınıf ve $IoU > 0,5$ (3.2)


Yerelleştirme: doğru sınıf, $0,1 < IoU < 0,5$ (3.3)

Benzerlik: sınıf benzerdir, $IoU > 0,1$ (3.4)

Diğer: yanlış sınıf, $IoU > 0,1$ (3.5)

Arka plan: herhangi bir nesne, $IoU < 0,1$ (3.6)

Hızlı R-CNN ve YOLO için çeşitli kategoriler için en iyi N (kategorideki nesne sayısı) tespitindeki yerelleştirme ve arka plan hatalarının yüzdesi Şekil 3.17'de gösterilmektedir. Şekil 3.17, 20 sınıfın tamamında ortalaması alınan her bir hata türünün dökümünü göstermektedir. YOLO'nun yerelleştirme hata oranı kendi içindeki diğer hata oranlarından fazladır. Fast R-CNN ise çok daha az yerelleştirme hatası yapar ancak çok daha fazla arka plan hatası yapar. Hızlı R-CNN, arka plan algılamalarını tahmin etme olasılığı YOLO'dan neredeyse 3 kat daha fazladır.



Şekil 3.17. Fast R-CNN ve YOLO için hata analizleri (Redmon et al. 2015)

3.8.2. YOLO9000

9.000'den fazla nesne kategorisini algılayabilen, son teknoloji ürünü, gerçek zamanlı bir nesne algılama sistemi olan YOLO9000, Redmon and Farhadi (2016) tarafından 2016 yılında literatüre kazandırılmıştır. YOLO9000, YOLO'nun ikinci versiyonu olarak hız ve doğruluk arasında kolay bir denge sağlayarak farklı boyutlarda çalışabilir şekilde tasarlanmıştır. YOLOv2'nin YOLO'nun ilk versiyonundan daha iyi, güçlü ve hızlı olduğunun detayları aşağıda yer almaktadır.

YOLO, son teknoloji algılama sistemlerine göre çeşitli eksikliklerden muzdariptir. YOLO'nun Fast R-CNN ile hata analizi karşılaştırmasında YOLO'nun önemli sayıda yerleştirme hatası yaptığını göstermektedir. Ayrıca YOLO, bölge teklifine dayalı yöntemlere kıyasla nispeten düşük duyarlılık (Recall) değerine sahiptir. Bu nedenle sınıflandırma doğruluğu korunurken esas olarak duyarlılık ve yerleştirmeyi iyileştirmeye odaklanılmıştır. Geleneksel olarak daha iyi performans genellikle daha büyük ağırları eğitmeye veya birden çok modeli bir araya getirmeye bağlıdır. Ancak ağı büyütme yerine ağı basitleştirme ve ardından temsili öğrenmeyi kolaylaştırma performansı olumlu etkilemiştir.

Toplu normalleştirme, diğer düzenleme biçimlerine olan ihtiyacı ortadan kaldırırken yakınsamada önemli gelişmeler sağlamaktadır (Ioffe and Szegedy 2015). YOLO'daki tüm evrişim katmanlarına toplu normalleştirme eklenerek, mAP'de %2'den

fazla iyileştirme elde edilmektedir. Toplu normalleştirme ile aşırı öğrenme (overfitting) olmadan modelden çıkılma imkânı sunulmaktadır.

Tüm son teknoloji algılama yöntemleri ImageNet üzerinde önceden eğitilmiş sınıflandırıcı kullanmaktadır (Russakovsky et al. 2015). AlexNet ile başlayan çoğu sınıflandırıcı 256×256 'dan daha küçük girdi görüntüleri üzerinde çalışmaktadır. Orijinal YOLO ise sınıflandırıcı ağını 224×224 'te eğitir ve algılama için çözünürlüğünü 448'e yükseltmektedir. Bu durum ağı aynı anda öğrenme nesnesinin algılamaya geçmesi ve yeni giriş çözünürlüğüne ayarlanması gerektiği anlamına gelir. YOLOv2 için ilk olarak ImageNet üzerinde 10 dönem için tam 448×448 çözünürlükte sınıflandırma ağına ince ayar (fine tune) yapılmaktadır. Bu durum ağı filtrelerini daha yüksek çözünürlüklü girdilerde daha iyi çalışacak şekilde ayarlaması için zaman sağlamaktadır. Bu yüksek çözünürlüklü sınıflandırma ağı yaklaşık %4'lük bir mAP artışı sağlayarak YOLOv2'yi daha performanslı hale getirmiş olmaktadır.

YOLO, evrişimli özellik çıkarıcının üzerindeki tamamen bağlı katmanları kullanarak sınırlayıcı kutuların koordinatlarını doğrudan tahmin etmektedir. Fast R-CNN ise koordinatları doğrudan tahmin etmek yerine elle seçilmiş öncelikleri kullanarak sınırlayıcı kutuları tahmin eder (Ren et al. 2017). Faster R-CNN'deki bölge öneri ağı (RPN) yalnızca evrişimli katmanları kullanarak bağlantı kutuları için ofsetleri ve güvenleri tahmin eder. Tahmin katmanı evrişimli olduğundan, RPN bir özellik haritasındaki her konumda bu ofsetleri tahmin eder. Koordinatlar yerine ofsetleri tahmin etmek sorunu basitleştirir ve ağı öğrenmesini kolaylaştırır. Bu durum dikkate alınarak tamamen bağlı katmanlar YOLO'dan kaldırılarak sınırlayıcı kutuları tahmin etmek için bağlantı kutuları kullanılır. Ardından ağı evrişimli katmanlarının çıktısını daha yüksek çözünürlükte sağlamak için bir havuzlama katmanı kaldırılmıştır. Ayrıca ağı giriş görüntüsünde küçülmeye gidilmiştir. Çapa kutularının kullanılması doğrulukta küçük bir düşüşe neden olmaktadır. YOLO görüntü başına yalnızca 98 kutu öngörmektedir ancak bağlantı kutuları ile model binden fazla kutu tahmin etme yeteğine kavuşmuştur. Çapa kutuları olmadan ara model %81 duyarlılık ile 69,5 mAP değerine ulaşmaktadır. Bağlantı kutuları ile model %88 duyarlılık ile %69,2 mAP elde etmektedir. mAP değeri azalsa da duyarlılıktaki artış modelin geliştirilecek daha fazla alanı olduğu anlamına gelmektedir.


Orijinal YOLO 448×448 giriş çözünürlüğü kullanmaktadır. Ancak bağlantı kutularının eklenmesiyle çözünürlüğü 416×416 olarak değiştirilmiştir. Modelin evrişimli ve havuzlama katmanları kullandığından anında yeniden boyutlandırılabilme esnekliği vardır. YOLOv2'nin farklı boyutlardaki görüntüler üzerinde çalışmaya dayanıklı olması için model özel olarak eğitilmiştir. YOLOv2 girdi görüntü boyutunu sabitlemek yerine ağı birkaç yinelemede bir değiştirmektedir. Ağ her 10 parti boyutunda bir rastgele yeni bir görüntü boyutu seçmektedir. Ağ modeli 32'lik örnekleme yapacak şekilde tasarlandığı için en küçük seçenek 320×320 ve en büyük seçenek 608×608 olmaktadır. Bu özellik ağı çeşitli girdi boyutlarında iyi tahmin etmeyi öğrenmeye zorlar. Bu, aynı ağı farklı çözünürlüklerde algılamaları tahmin edebileceği anlamına gelir. Ağ, daha küçük boyutlarda daha hızlı çalıştığı için YOLOv2, hız ve doğruluk arasında kolay bir denge sağlar. Düşük çözünürlüklerde YOLOv2 ucuz ve oldukça doğru bir dedektör olarak çalışır. Bu yeteneği onu daha küçük GPU'lar, yüksek kare hızlı videolar veya çoklu video akışları için ideal hale getirmektedir. Yüksek çözünürlükte YOLOv2, VOC 2007'de %78,6 mAP ile gerçek zamanlı hızların üzerinde çalışırken son teknoloji ürünü bir dedektördür. YOLOv2'nin VOC 2007'deki diğer modeller ile karşılaştırması Çizelge 3.7'de verilmiştir.

Çizelge 3.7. PASCAL VOC 2007 üzerinde modellerin algılama çerçeveleri (Redmon and Farhadi 2016).

Algılama modelleri	Eğitim	mAP(%)	FPS
Fast R-CNN	2007+2012	70	0,5
Faster R-CNN VGG-16	2007+2012	73,2	7
Faster R-CNN ResNet	2007+2012	76,4	5
YOLO	2007+2012	63,4	45
SSD300	2007+2012	74,3	46
SSD500	2007+2012	76,8	19
YOLOv2 288x288	2007+2012	69	91
YOLOv2 352x352	2007+2012	73,7	81
YOLOv2 416x416	2007+2012	76,8	67
YOLOv2 480x480	2007+2012	77,8	59
YOLOv2 544x544	2007+2012	78,6	40

YOLOv2, önceki algılama yöntemlerinden daha hızlı ve daha doğrudur. Ayrıca hız ve doğruluk arasında kolay bir denge sağlamak için farklı çözünürlüklerde çalışabilir. Her YOLOv2 girişi aslında aynı ağırlıklara sahip aynı eğitilmiş model olmakla birlikte

sadece farklı bir boyutta değerlendirilir. Modellerin VOC 2007'de doğruluk ve hız arasındaki görsel sunum Şekil 3.18'de verilmiştir.



Şekil 3.18. Algılama modellerinin doğruluk ve hız arasındaki ilişki (Redmon and Farhadi 2016).

Birçok modelin algılama doğruluğu yüksek değere sahip olsa da gerçek zamanlı algılama için kritik eşik olan 30 FPS değerinin altında olduğu görülmektedir. Ancak YOLOv2 modelinin farklı boyuttaki girdiler üzerindeki tüm denemeleri hem doğruluk bakımından yüksek hem de FPS eşik değerinin çok üstündedir. YOLOv2, Darknet-19 omurga ağı ile ağ yapısını oluşturarak 171 FPS değerine ulaşarak diğer algılama modellerini gerçek zamanlı algılama başarısında geride bırakmıştır.

3.8.3. YOLOv3

Redmon and Farhadi (2018) tarafından 2018 yılında YOLO ailesinin diğer bir sürümü olan YOLOv3 modeli literatüre kazandırılmıştır. Önceki versiyondan farklı olarak yapılan iyileştirme ve geliştirmeler bu kısımda yer almıştır.

YOLO9000'in ardından sistem, bağlantı kutuları olarak boyut kümelerini kullanarak sınırlayıcı kutuları tahmin etmektedir. Ağ, her sınırlayıcı kutu için dört koordinat (t_x, t_y, t_w, t_h) tahmin etmektedir. Hücre, görüntünün sol üst köşesinden (c_x, c_y) kadar kaydırılırsa ve öndeki sınırlayıcı kutunun genişliği ve yüksekliği p_w, p_h ise tahminler şuna karşılık gelir:


$$b_x = \sigma(t_x) + c_x \quad (3.7)$$

$$b_y = \sigma(t_y) + c_y \quad (3.8)$$

$$b_w = p_w e^{t_w} \quad (3.9)$$

$$b_h = p_h e^{t_h} \quad (3.10)$$

Yukarıda verilen eşitliklerin daha iyi anlaşılabilmesi için Şekil 3.19’de boyut önceliklendirmesi ve konum tahmini ile sınırlayıcı kutu gösterimi sunulmuştur. YOLOv3 lojistik regresyon kullanarak her sınırlayıcı kutu için bir nesnellik puanı tahmin etmektedir. Önceki sınırlayıcı kutu bir yer gerçeği nesnesiyle önceki diğer sınırlayıcı kutulardan daha fazla örtüşüyorsa bu 1 olmalıdır.



Şekil 3.19. Boyut öncelikleri ve konum tahmini içeren sınırlayıcı kutular (Redmon and Farhadi 2018).


Her kutu çok etiketli sınıflandırmayı kullanarak sınırlayıcı kutunun içerebileceği sınıfları tahmin etmektedir. İyi performans için bağımsız lojistik sınıflandırıcılar kullanılır. Eğitim sırasında sınıf tahminleri için ikili çapraz entropi kaybını kullanarak performans artışı hedeflenmiştir. Çok etiketli bir yaklaşım verileri daha iyi modeller. Özellik çıkarımı gerçekleştirmek için yeni bir ağ kullanılmış ve art arda 3×3 ve 1×1 evrişimli katmanlar kullanılarak 53 evrişimli katman elde edilmiştir. Bu yeni ağ,

3. MATERYAL VE YÖNTEM

Darknet19'dan çok daha güçlü ResNet-101 veya ResNet-152'den daha verimli olarak tasarlanmış olan Darknet-53'tür.


Darknet-53, son teknoloji sınıflandırıcılarla eşit performans gösterir. Darknet-53, ResNet-101'den daha performanslıdır ve 1,5 kat daha hızlıdır. Darknet-53, ResNet-152 ile benzer performansa sahiptir ve 2 kat daha hızlıdır. Darknet-53 ayrıca saniyede ölçülen en yüksek kayan nokta işlemlerini gerçekleştirir. Bu, ağ yapısının GPU'yu daha iyi kullanması, değerlendirmeyi daha verimli ve dolayısıyla daha hızlı hale getirmesi anlamına gelir. Bunun nedeni ResNet'lerin çok fazla katmanı olması ve çok verimli olmamasıdır.

Ancak mAP'nin IoU= 0,5'teki tespit metriğine bakıldığında YOLOv3 oldukça güçlüdür. RetinaNet ile neredeyse eşit ve SSD varyantlarının çok üzerinde olması YOLOv3'ün nesneler için uygun kutular üretmede üstün olan çok güçlü bir dedektör olduğunu gösterir. Ancak YOLOv3'ün kutuları nesneyle mükemmel şekilde hizalamakta zorlandığını gösteren IoU eşiği arttıkça performans önemli ölçüde düşmektedir. AP50 metriğinde doğruluk ve hızı çiziminin yapıldığı Şekil 3.20'de YOLOv3'ün diğer algılama sistemlerine göre önemli avantajlara sahip olduğunu görüyoruz.



Şekil 3.20. YOLOv3 ve diğer algılama modellerinin hız ve doğruluk bakımından karşılaştırılması (Redmon and Farhadi 2018).

Var olan nesne algılama modelleri ve YOLOv3 için modellerin uygulama süresi, FPS ve doğruluklarının basitleştirilmiş görsel sunumu Şekil 3.21’de verilmiştir. Açıkça görülmektedir ki YOLOv3 modeli hem uygulama süresi bakımından hem de FPS yüksekliğinden dolayı gerçek zamanlı algılama çözümlerine uygundur.




Şekil 3.21. Algılama modellerinin performans değerlendirilmesi (Redmon and Farhadi 2018).

3.8.4. YOLOv4

Bochkovskiy et al. (2020), YOLO ailesinin dışından bir araştırmacı olarak YOLO’nun yeni versiyonu olan YOLOv4’ü literatüre kazandırmışlardır. Bu durum artık YOLO’nun diğer araştırmacılar tarafından güncellenebileceği anlamına gelmektedir. Bu kısımda YOLOv4’ün sağlamış olduğu yenilik ve farklılıklar yer almaktadır. Temel amaç, düşük hesaplama hacimli teorik göstergeden ziyade yapay sinir ağlarının üretim sistemlerinde hızlı çalışma ve paralel hesaplamalar için optimizasyonudur.

Modern bir dedektör genellikle iki parçadan oluşur; ImageNet üzerinde önceden eğitilmiş bir omurga (backbone) ve nesnelerin sınıflarını ve sınırlayıcı kutularını tahmin etmek için kullanılan bir kafa (head) yapısı. GPU platformunda çalışan dedektörler için omurgaları VGG (Simonyan and Zisserman 2015), ResNet (He et al. 2016), ResNeXt (Xie et al. 2017) veya DenseNet (Huang et al. 2017) olabilir. Kafa kısmına gelince genellikle iki türe ayrılır; tek aşamalı nesne dedektörü ve iki aşamalı nesne dedektörü. Son yıllarda geliştirilen nesne algılayıcıları genellikle omurga ve kafa arasına bazı katmanlar yerleştirir ve bu katmanlar genellikle özellik haritalarını toplamak için kullanılır. Yukarıdaki modellere ek olarak bazı araştırmacılar nesne tespiti için doğrudan yeni bir omurga veya yeni bir tam model oluşturmaya önem vermektedir.

YOLOv4 modeli omurga için CSPDarknet53, boyun için SPP (He et al. 2014) ve PAN (Liu et al. 2018) son olarak kafa için ise YOLOv3 kullanılarak oluşturulmuştur. YOLOv4, giriş ağı çözünürlüğü, evrişimli katman sayısı, parametre numarası ve katman çıkışlarının sayısı arasında en uygun dengeyi bulmayı hedeflemektedir. Alıcı alanı önemli ölçüde artırdığı, en önemli bağlam özelliklerini ayırdığı ve ağı işlem hızında neredeyse hiç azalmaya neden olmadığı için bloğa CSPDarknet53 eklenmiştir. YOLOv3'te kullanılan FPN yerine farklı dedektör seviyeleri için farklı omurga seviyelerinden parametre toplama yöntemi olarak PANet kullanılmıştır. Son olarak, YOLOv4'ün mimarisi olarak CSPDarknet53 omurgası, SPP ek modülü, PANet yol toplama boynu ve YOLOv3 kafası seçilmiştir. Gelecekte dedektör için teorik olarak bazı sorunları çözebilen ve dedektör doğruluğunu artırabilen ve her bir özelliğin etkisini deneysel bir şekilde sırayla kontrol edebilen içeriği önemli ölçüde genişletme imkânı YOLOv4 ile sağlanmıştır. Birçok terimsel kargaşaya girmeden YOLOv4'ün diğer algılama modelleri ile karşılaştırmalı grafiği Şekil 3.22'de sunulmuştur.



Şekil 3.22. Önerilen YOLOv4 ve diğer son teknoloji nesne dedektörlerinin karşılaştırılması (Bochkovskiy et al. 2020).

Şekilde de görüldüğü üzere YOLOv4, karşılaştırılabilir performansla EfficientDet'ten iki kat daha hızlı çalışır. YOLOv3'e ait AP ve FPS değerleri sırasıyla %10 ve %12 artmaktadır. YOLOv4'ün hem doğruluk hem de FPS değerleri onu gerçek zamanlı algılayıcı olarak kullanılmasını tetiklemektedir. Farklı eğitim iyileştirme

tekniklerinin ImageNet (ILSVRC 2012 val) veri kümesindeki sınıflandırıcının doğruluğu üzerindeki etkisi ve ardından MS COCO (test-dev 2017) veri kümesindeki dedektörün doğruluğu üzerindeki etkisi test edilmiştir.

3.8.5. YOLOv5

YOLOv5, Hoher (2020) tarafından geliştirilmiş güçlü bir nesne algılama algoritmasıdır. Bu modelin yayınlanmış bir makalesi bulunmamaktadır. Online sayfa üzerinden literatüre girmiş ve hala günümüzde birçok araştırmacı tarafından kullanılmaktadır. Ortaya çıkış amacı gerçek zamanlı algılamada daha yüksek hız ve yüksek doğrulukla sonuçlar elde etmektir. YOLOv5'in mimarisi üç ana bölümden oluşmaktadır.

Omurga: Bu, ağın ana gövdesidir. YOLOv5 için omurga, önceki sürümlerde kullanılan Darknet mimarisinin bir modifikasyonu olan yeni CSP-Darknet53 yapısı kullanılarak tasarlanmıştır.

Boyun: Bu kısım omurga ile kafayı birbirine bağlar. YOLOv5'te SPPF ve New CSP-PAN yapıları kullanılmaktadır.

Kafa: Bu kısım nihai çıktının oluşturulmasından sorumludur. YOLOv5, bu amaçla YOLOv3 kafasını kullanmaktadır.

YOLOv5, önceki versiyonlara kıyasla bazı küçük değişiklikler getirmiştir. Önceki sürümlerde bulunan odak yapısı değiştirilerek verimliliğin artması sağlanmıştır. Ayrıca bu işlem ile algılama hızı iki kattan fazla artırılmıştır. YOLOv5, modelin aşırı uydurmayı genelleştirme ve azaltma yeteneğini geliştirmek için çeşitli veri artırma teknikleri kullanılmaktadır. YOLOv5, modelin performansını artırmak için birkaç gelişmiş eğitim stratejisi uygulamaktadır.

Çok ölçekli eğitim: Giriş görüntüleri eğitim sürecinde orijinal boyutlarının 0,5 ile 1,5 katı aralığında rastgele yeniden ölçeklendirilir.

Otomatik bağlantı: Bu strateji önceki bağlantı kutularını özel verilerinizdeki kesin doğruluk kutularının istatistiksel özelliklerine uyacak şekilde optimize eder.

Warmup ve Cosine LR Scheduler: Model performansını artırmak için öğrenme oranını ayarlamakta kullanılan bir yöntemdir.

Üstel hareketli ortalama: Eğitim sürecini stabilize etmek ve genelleme hatasını azaltmak için geçmiş adımlardaki parametrelerin ortalamasını kullanan bir stratejidir.


Karma hassasiyet eğitimi: İşlemleri yarı hassasiyet formatında gerçekleştirmek, bellek kullanımını azaltmak ve hesaplama hızını artırmak için kullanılan yöntemdir.

Hiper parametre evrimi: Optimum performans elde etmek için hiper parametreleri otomatik olarak ayarlama stratejisine gidilmiştir.

Uygulanan eğitim stratejileri ile modelin performans değerinin artırılması hedeflenirken üç ayrı kayıp bileşeninin bir kombinasyonu olarak YOLOv5'in kaybı azaltılmaya çalışılmıştır. Ayrıca YOLOv5 mimarisi, YOLO'nun önceki sürümlerine kıyasla kutu tahmin stratejisinde bazı önemli değişiklikler gerçekleştirmiştir. YOLOv2 ve YOLOv3'te kutu koordinatları, son katmanın aktivasyonu kullanılarak doğrudan tahmin edilmiştir. Bununla birlikte, YOLOv5'te ızgara hassasiyetini azaltmak ve modelin sınırsız kutu boyutlarını tahmin etmesini önlemek için kutu koordinatlarını tahmin etmeye yönelik formül güncellenerek daha verimli hale getirilmiştir.

Sonuç olarak YOLOv5, gerçek zamanlı nesne algılama modellerinin geliştirilmesinde önemli bir adımı temsil etmektedir. Çeşitli yeni özellikleri, geliştirmeleri ve eğitim stratejilerini birleştirerek performans ve verimlilikte YOLO ailesinin önceki sürümlerini geride bırakıyor. Şekil 3.23'de YOLO'nun son sürüm nesne algılama modelleri ile karşılaştırmalı grafiği sunulmuştur. YOLOv5'teki birincil geliştirmeler, dinamik bir mimarinin kullanımını, kapsamlı bir veri artırma teknikleri yelpazesini, yenilikçi eğitim stratejilerini, hesaplama kayıplarında ve hedef oluşturma sürecinde önemli ayarlamaları içerir. Tüm bu yenilikler, YOLO modellerinin anahtarı

olan yüksek hız derecesini korurken nesne algılamanın doğruluğunu ve verimliliğini önemli ölçüde artırır.




Şekil 3.23. YOLOv5 ve diğer algılama modellerinin karşılaştırması (Hochoer 2020)

3.8.6. You only learn one representation (YOLOR)

Wang et al. (2023) örtük ve açık bilgiyi entegre etmek için birleşik bir ağ önermesi, öğrenilen modelin genel bir temsil içermesini ve bu genel temsilin çeşitli görevler için uygun alt temsilleri mümkün kılmasını sağlamak için YOLOR nesne algılama modelini literatüre kazandırmışlardır.

İnsanlar aynı veri parçasını çeşitli açılardan analiz edebilir. Bununla birlikte, eğitilmiş bir CNN modeli genellikle yalnızca tek bir hedefi gerçekleştirebilir. Genel olarak eğitilmiş bir CNN'den çıkarılabilen özellikler genellikle diğer sorun türlerine yeterince uyarlanamaz. Bu sorunun ana nedeni nöronlardan yalnızca özniteliklerin çıkarılması ve CNN'de bolca bulunan örtük bilginin kullanılmamasıdır. Gerçek insan beyni çalışırken yukarıda belirtilen örtük bilgi beyne çeşitli görevleri yerine getirmesi için etkili bir şekilde yardımcı olabilir. Örtük bilgi, bilinçaltı bir durumda öğrenilen bilgiyi ifade eder. Bununla birlikte örtük öğrenmenin nasıl işlediğine ve örtük bilginin nasıl elde edileceğine dair sistematik bir tanım yoktur. Yapay sinir ağlarının genel tanımında sık katmanlardan elde edilen öznitelikler genellikle açık bilgi, derin katmanlardan elde edilen öznitelikler ise örtük bilgi olarak adlandırılır.

Örtük ve açık bilgiyi entegre etmek için birleşik bir ağ YOLOR ile önerilmiştir. Öğrenilen modelin genel bir temsil içermesini ve bu genel temsilin çeşitli görevler için uygun alt temsilleri mümkün kılması sağlanmıştır. Şekil 3.24 önerilen birleşik ağ mimarisini göstermektedir.



Şekil 3.24. Önerilen birleşik ağ tasarımı (Wang et al. 2023)


Bir CNN'nin özellik haritasını yeniden oluşturmak ve onu daha sağlam hale getirmek için seyrek kodlama kullanılmıştır. YOLOR ile sağlanan katkılar aşağıda sıralanmıştır.

- Çeşitli görevleri yerine getirebilen birleşik bir ağ önerilmiş, örtük bilgi ile açık bilgiyi bütünleştirerek genel bir temsili öğrenir ve bu genel temsil yoluyla çeşitli görevler tamamlanabilir. Önerilen ağ, modelin performansını çok küçük bir ek maliyetle etkili bir şekilde geliştirir.
- Örtük bilgi öğrenme sürecine kernel alanı hizalaması, tahmin iyileştirmesi ve çoklu görev öğrenimi eklenerek bu özelliklerin etkililiği doğrulanmıştır.
- Örtük bilginin modellenmesi için bir araç olarak vektör, sinir ağı veya matris çarpanlarına ayırma kullanılmış ve aynı zamanda etkinliği doğrulanmıştır.
- Önerilen örtülü temsilin belirli bir fiziksel özelliğe tam olarak karşılık gelebileceği doğrulanmıştır. Ayrıca, bir hedefin fiziksel anlamına uyan operatörlerin örtük bilgi ile açık bilgiyi entegre etmek için kullanılabileceğini ve çarpan etkisi oluşturacağı kanıtlanmıştır.

Birleştirilmiş modelin matematiksel detayları ve eğitim sürecine bu kısımda değinilmemiştir. Elde edilen modelin ağ yapısı ile yapılan deneysel sonuçların bilgileri bu kısımda verilmiştir. Nesne algılama, örnek bölümlleme, panoptik bölümlleme, anahtar

nokta algılama, parça bölümleme, görüntü altyazısı ve çok etiketli görüntü sınıflandırması dâhil olmak üzere birçok farklı görevde temel gerçeği sağladığı için YOLOR deneyleri MS COCO veri seti ile gerçekleştirilmiştir.

Deneyisel tasarımda, örtük bilgiyi FPN için özellik hizalama, tahmin iyileştirme ve tek bir modelde çoklu görev öğrenme dâhil olmak üzere üç yöne uygulama seçilmiştir. Çok görevli öğrenmenin kapsadığı görevler arasında nesne algılama, çok etiketli görüntü sınıflandırma ve özellik yerleştirme yer almaktadır. Deneylerde temel model olarak YOLOv4-CSP (Wang et al. 2021) seçilmiştir ve Şekil 3.25'de okla gösterilen konumda modele örtülü bilgi eklenmiştir. Tüm eğitim hiper parametreleri ScaledYOLOv4'ün varsayılan ayarıyla karşılaştırılmaktadır.



Şekil 3.25. Modele örtülü bilginin eklenmesi (Wang et al. 2023)

Son olarak, önerilen yöntemin etkinliğini belirlemek için nesne algılamanın en son yöntemleriyle karşılaştırılmıştır. Tüm eğitim süreci için ölçeklendirilmiş YOLOv4 eğitim süreci takip edilmiştir. İlk olarak 300 dönem ile sıfırdan eğitim ve ardından 150 dönem ile ince ayar sağlanmıştır. Çizelge 3.8 ise en son yöntemlerle yapılan karşılaştırmaları göstermektedir.

Çizelge 3.8. Algılama modellerinin karşılaştırılması (Wang et al. 2023)

Model	AP (%)	AP50	AP75	FPS
YOLOv4	55,4	73,3	60,6	30
ScaledYOLOv4	55,5	73,4	60,8	16
EfficientDet	55,1	74,3	89,9	6,5
SwinTransformer	57,7	-	-	-
CenterNet2	56,4	74	61,6	-

3.8.7. YOLOv6


Li et al. (2022), çeşitlendirilmiş kullanım durumlarını barındırmak için çeşitli ölçeklerde konuşlandırmaya hazır ağılar paketi oluşturduğu modele YOLOv6 ismini vermişlerdir. YOLOv6 algılama modelinin oluşturulması ve geliştirilmesi hakkında bilgiler bu kısımda yer almaktadır.

YOLO serisi, hız ve doğruluk arasındaki mükemmel dengesi nedeniyle endüstriyel uygulamalarda en popüler algılama çerçeveleri olmuştur. YOLO serisinin öncü çalışmaları, sonraki önemli gelişmelerle birlikte tek aşamalı dedektörlerde yeni bir çığır açan YOLOv3'tür. YOLOv4, algılama çerçevesini (omurga, boyun ve kafa) yeniden düzenleyerek tek bir GPU'da eğitim için uygun bir çerçeve tasarlayarak ücretsiz çantalar ve özel çantalar doğrulanmasını sağlamıştır.

Li et al. (2022), YOLO çerçevesini yeniden düzenlenmesi için birkaç önemli faktörü ampirik olarak gözlemlemişlerdir. RepVGG'den yeniden parametrelendirmede algılamada henüz tam olarak kullanılmayan üstün bir tekniktir (Ding et al. 2021). Ayrıca RepVGG blokları için basit model ölçeklendirmenin pratik olmadığı ve bunun için küçük ve büyük ağılar arasındaki ağ tasarımının zarif tutarlılığının gereksiz olduğunu ifade edilmiştir. Yeniden parametrelendirmeye dayalı dedektörlerin nicelenmesi de titiz bir işlem gerektirmektedir. Aksi takdirde eğitim ve çıkarım sırasında heterojen konfigürasyonu nedeniyle performans düşüşüyle başa çıkmak zordur.

Önceki araştırmacılar gecikme sürelerini genellikle NVIDIA V100 gibi yüksek maliyetli makinelerle hesaplamıştır. Gerçek hizmet verme ortamı söz konusu olduğunda ise bir donanım boşluğu vardır. Tipik olarak, Tesla T4 gibi düşük güçlü GPU'lar daha az

maliyetlidir ve oldukça iyi çıkarım performansı sağlamaktadır. Etiket atama ve kayıp fonksiyon tasarımı gibi gelişmiş alana özgü stratejiler ve mimari değişkenlik göz önünde bulundurularak daha fazla doğrulamaya ihtiyaç duymaktadır. Belirtilen bu gözlemleri göz önünde bulundurarak doğruluk ve hız açısından şimdiye kadarki en iyi denge politikasını gerçekleştiren YOLOv6'nın doğuşu gerçekleştirilmiştir. Şekil 3.26'de benzer bir ölçekte YOLOv6'nın diğer algılama modelleriyle karşılaştırması gösterilmiştir.



Şekil 3.26. Son teknoloji verimli nesne dedektörlerinin karşılaştırılması (Li et al. 2022)

YOLOv6'nın ana yönleri aşağıdaki gibi özetlenebilir;

- Farklı senaryolarda endüstriyel uygulamalar için uyarlanmış farklı boyutlardaki bir ağ hattı yeniden şekillendirilmiştir. Farklı ölçeklerdeki mimariler, küçük modellerin düz tek yollu bir omurgaya sahip olduğu ve büyük modellerin verimli çok dallı bloklar üzerine inşa edildiği en iyi hız ve doğruluk sağlamak için değişiklik göstermektedir.
- YOLOv6, hem sınıflandırma görevi hem de regresyon görevi üzerinde gerçekleştirilen bir kendi kendini damıtma stratejisiyle doldurulmuştur. Bu arada öğrenci modelinin tüm eğitim aşamalarında bilgiyi daha verimli bir şekilde öğrenmesine yardımcı olmak için etiketlerden gelen bilgiler dinamik olarak ayarlanmıştır.
- Etiket atama, kayıp fonksiyonu ve veri artırma teknikleri için gelişmiş tespit tekniklerini kapsamlı bir şekilde doğrulanmış ve performansı daha da artırmak için bunlar seçici olarak uygulanmıştır.
- Ding et al. (2022)'un sunduğu RepOptimizer ve Shu et al. (2021) tarafından geliştirilen kanal bazında damıtma yardımıyla algılama için niceleme şeması yeniden düzenlenmiştir.

YOLOv6'nın yenilenmiş tasarımı; etiket ataması, kayıp fonksiyonu, veri artırma, sektöre uygun iyileştirmeler, niceleme ve dağıtım gibi bileşenlerden oluşmaktadır.

Diğer ana akım mimarilerle karşılaştırıldığında, RepVGG omurgalarının küçük ağlarda benzer bir çıkarım hızında daha fazla özellik temsil gücü ile donatıldığını, oysa parametrelerin büyümesi ve hesaplama maliyetleri nedeniyle daha büyük modeller elde etmek için neredeyse hiç ölçeklenemeyeceği anlaşılmıştır. Bu bağlamda küçük ağlar için yapı taşı olarak RepBlock tercih edilmiştir. Büyük modeller için CSPStackRep Block adlı daha verimli bir CSP bloğu revize edilmiştir (Wang et al. 2020). YOLOv6'nın boynu, YOLOv4 ve YOLOv5'in ardından PAN topolojisini benimsemiştir. RepPAN'a sahip olmak için boyun RepBlocks veya CSPStackRep Blocks ile geliştirilmiştir. Ayrıştırılmış kafayı daha verimli hale getirmek için basitleştirilmiştir.

Nesne dedektörlerinin kayıp fonksiyonları sınıflandırma kaybı, kutu regresyon kaybı ve nesne kaybını içermektedir. Her bir kayıp için bunu mevcut tüm tekniklerle sistematik olarak denenmiş ve son olarak sınıflandırma kaybı olarak VariFocal Loss (Zhang et al. 2021) seçilmiştir. Ayrıca aşırı performans elde etmek için kanal bazında damıtma ve grafik optimizasyonu ile QAT benimsenmiştir. Sayısallaştırılmış YOLOv6-S, %42,3 AP ve 869 FPS (parti boyutu=32) ile yeni bir teknoloji harikasına ulaşmaktadır.

YOLOv6'nın elde edilme amacının endüstriyel uygulamalar için ağlar oluşturmak olduğunu göz önünde bulundurarak modelin hız performansına odaklanılmıştır. YOLOv6 ve bazı diğer nesne algılama modellerinin detaylı karşılaştırması Çizelge 3.9'da sunulmuştur.

Çizelge 3.9. Diğer YOLO serisi dedektörlerin COCO 2017 ile değerlendirilmesi (Li et al. 2022).

Method	Girdi Boyutu	AP(%)	AP50	FPS	Gecikme(ms)
YOLOv5-N	640	28	45,7	602	1,7
YOLOv5-S	640	37,4	56,8	376	2,7
YOLOv5-M	640	45,4	64,1	182	5,5
YOLOv5-L	640	49	67,3	113	8,8
YOLOX-Tiny	416	32,8	50,3	1143	1,4
YOLOX-S	640	40,5	59,3	396	3
YOLOX-M	640	46,9	65,6	179	6,4
YOLOX-L	640	49,7	68	103	10,6
YOLOv7-Tiny	416	33,3	49,9	1196	1,3
YOLOv7-Tiny	640	37,4	55,2	519	2,4
YOLOv7	640	51,2	69,7	122	9
YOLOv6-N	640	35,9	51,2	1234	1,2
YOLOv6-T	640	40,3	56,6	659	2,2
YOLOv6-S	640	43,5	60,4	495	2,8
YOLOv6-M	640	49,5	66,8	133	5,6
YOLOv6-L	640	52,5	70	121	10,2

FPS ve gecikme, TensorRT ile aynı ortamda bir Tesla T4 üzerinde FP16 hassasiyetinde ölçülmüştür. Tüm YOLOv6 varyantları, ön eğitim veya herhangi bir dış veri olmaksızın 300 dönem için eğitilmiştir. Modellerin hem doğruluğu hem de hız performansı 640×640 giriş çözünürlüğü ile değerlendirilmektedir.

YOLOv6, YOLOv5, YOLOX ve YOLOv7 dâhil olmak üzere YOLO serisinin diğer son teknoloji dedektörleriyle karşılaştırılmıştır. TensorRT ile aynı Tesla T4 GPU üzerinde FP16 hassasiyetine sahip tüm resmi modellerin hız performansı test edilmiştir. YOLOv7-Tiny'nin performansı, 416 ve 640 giriş boyutunda açık kaynaklı kodlarına ve ağırlıklarına göre yeniden değerlendirilmiştir. YOLOv5-N/YOLOv7-Tiny (giriş boyutu=416) ile karşılaştırıldığında, YOLOv6 sırasıyla %7,9-%2,6 oranında önemli ölçüde gelişmiştir. Ayrıca hem verim hem de gecikme açısından en iyi hız performansına sahiptir. YOLOv6-M, benzer bir hızda YOLOv5-M'yi %4,2 daha yüksek AP ile geride bırakır ve daha yüksek bir hızda YOLOX-M/PPYOLOE-M'den %2,7-%0,6 daha yüksek AP elde eder. YOLOX-L/PPYOLOE-L/YOLOv7'yi hem doğruluk hem de hız açısından geride bırakarak 8,8 ms gecikmeyle %51,7 AP'ye ulaşır.

3.8.8. YOLOv7

Wang et al. (2022)'ları tarafından 5 FPS ila 160 FPS aralığında hem hız hem de doğruluk açısından bilinen tüm nesne dedektörlerini geride bırakarak gerçek zamanlı nesne dedektörleri arasında en yüksek doğruluğa sahip YOLO'nun yedinci versiyonunu literatüre kazandırmışlardır.

YOLOv7 nesne algılama modeli ile birçok yenilik ve katkı araştırmacılara sunulmuştur. Ayrıca hız ve doğrulukta sağlamış olduğu üstün performans gerçek zamanlı nesne algılama kullanım süreçlerinde büyük avantaj sağlayacaktır. YOLOv7'nin sağlamış olduğu katkılar;

- Gerçek zamanlı nesne algılamanın çıkarım maliyetini artırmadan algılama doğruluğunu büyük ölçüde artırabilmesi için birkaç eğitilebilir bedava çanta yöntemi tasarlanmıştır.
- Yeniden parametreleştirilmiş modülün orijinal modülü nasıl değiştirdiği ve dinamik etiket atama stratejisinin farklı çıktı katmanlarına atamayı nasıl ele aldığı nesne algılama yöntemlerinin gelişimi için iki yeni sorun olarak fark edilmiştir. Bu sorunlardan kaynaklanan zorlukları gidermek için yöntemler önerilmiştir.
- Parametreleri ve hesaplamayı etkili bir şekilde kullanabilen gerçek zamanlı nesne dedektörü için "genişletme" ve "bileşik ölçekleme" yöntemleri önerilmiştir.
- Önerilen yöntem ile son teknoloji ürünü gerçek zamanlı nesne dedektörünün parametresini yaklaşık %40 ve hesaplamasını %50 oranında etkili bir şekilde azaltabilir ve daha hızlı çıkarım hızına ve daha yüksek algılama doğruluğuna ulaştırır.

Modern bir gerçek zamanlı nesne dedektörü olabilmek için genellikle aşağıdaki özellikler gerekir: (1) daha hızlı ve daha güçlü bir ağ mimarisi, (2) daha etkili bir özellik entegrasyon yöntemi, (3) daha sağlam bir kayıp fonksiyonu, (4) daha verimli bir etiket atama yöntemi ve (5) daha verimli bir eğitim yöntemi. YOLOv7'de ek veri veya büyük model gerektiren öz denetimli öğrenme veya bilgi damıtma yöntemlerini keşfetme niyeti yerine en son teknoloji yöntemlerden türetilen sorunlar için yeni eğitilebilir bedava çanta yöntemi tasarlanmıştır.

Nihai çıkarım modelini elde etmek için model düzeyinde yeniden parametreleştirme için iki yaygın uygulama vardır. Birincisi, farklı eğitim verileriyle birden çok özdeş modeli eğitmek ve ardından birden çok eğitilmiş modelin ağırlıklarının ortalamasını almaktır. Diğeri ise farklı iterasyon sayılarındaki modellerin ağırlıklarının ağırlıklı ortalamasını almaktır. Modül düzeyinde yeniden parametreleştirme son zamanlarda daha popüler bir araştırma konusudur. Bu tür bir yöntem, eğitim sırasında bir modülü birden çok özdeş veya farklı modül dallarına böler ve çıkarım sırasında birden çok dallanmış modülü tamamen eşdeğer bir modüle entegre eder. Ancak önerilen yeniden parametreleştirilmiş modüllerin tümü farklı mimarilere mükemmel şekilde uygulanamaz. Bu durum dikkate alınarak yeniden parametrelendirme modülü YOLOv7 için geliştirilmiş ve çeşitli mimariler için ilgili uygulama stratejileri tasarlanmıştır.

Model ölçekleme yöntemi, ağ parametrelerinin miktarı, hesaplama, çıkarım hızı ve doğruluğa ulaşmak için genellikle çözünürlük (giriş görüntüsünün boyutu), derinlik (katman sayısı), genişlik (kanal sayısı) ve aşama (özellik piramidi sayısı) gibi farklı ölçeklendirme faktörleri kullanır. Ağ mimarisi araması (NAS), yaygın olarak kullanılan model ölçeklendirme yöntemlerinden biridir. NAS'ın dezavantajı, model ölçekleme faktörlerini aramayı tamamlamak için çok pahalı hesaplamalar gerektirmesidir. DenseNet veya VoVNet (Lee et al. 2019) gibi tüm birleştirme tabanlı modellerin derinliği ölçeklendiğinde bazı katmanların giriş genişliğini değiştireceği YOLOv7 yazarları tarafından gözlemlenmiştir. Önerilen mimari birleştirme tabanlı olduğundan bu model için yeni bir bileşik ölçeklendirme yöntemi tasarlamak gerekmektedir.

Yeniden parametrelendirilmiş evrişimin farklı ağlarla nasıl birleştirilmesi gerektiğini analiz etmek için gradyan akış yayılma yolları YOLOv7 için kullanılmıştır. Buna göre planlı yeniden parametrelendirilmiş evrişim tasarlanmıştır. YOLOv7 yazarlarına göre kalıntı veya birleştirme içeren bir evrişim katmanı yeniden parametrelendirilmiş bir evrişim ile değiştirildiğinde, kimlik bağlantısı olmamalıdır.

Deneyler yapmak ve nesne algılama yöntemini doğrulamak için Microsoft COCO veri kümesi kullanılmıştır. Tüm deneyler önceden eğitilmiş modelleri kullanmayarak tamamlandığından modeller sıfırdan eğitilmiştir. Geliştirme sürecinde eğitim için train 2017 seti, ardından doğrulama ve hiper parametre seçimi için val 2017 seti kullanılmıştır.


Son olarak test 2017 setinde nesne algılama performansını gösterilerek en son teknoloji nesne algılama algoritmalarıyla karşılaştırılmıştır. Edge GPU, normal GPU ve cloud GPU için temel model tasarlanmış ve bunlar sırasıyla YOLOv7-tiny, YOLOv7 ve YOLOv7-W6 olarak adlandırılmaktadır. Aynı zamanda, farklı hizmet gereksinimleri ve farklı model türleri elde etmek için model ölçeklendirme ile temel model kullanımı sağlamaktadır. YOLOv7 için boyunda yığın ölçekleme yapılır ve tüm modelin derinliğini ve genişliğini ölçeklendirmek için önerilen bileşik ölçeklendirme yöntemini kullanılarak YOLOv7-X elde edilir. YOLOv7-E6 ve YOLOv7-D6'yı elde etmek için yeni önerilen bileşik ölçeklendirme yöntemi kullanılmıştır. YOLOv7-tiny, uç nokta GPU odaklı bir mimari olduğundan aktivasyon işlevi olarak sızdıran ReLU kullanılmıştır. Diğer modellerde olduğu gibi aktivasyon fonksiyonu olarak SiLU kullanılmıştır. Çizelge 3.10'da bazı nesne algılama modelleri ile YOLOv7 varyantlarının performans karşılaştırması yer almaktadır.

Çizelge 3.10. Temel nesne dedektörlerinin karşılaştırılması (Wang et al. 2022)

Model	Parametre	Girdi Boyutu	AP (%)	AP50
YOLOv4	64,4	640	49,7	68,2
YOLOv4-u5	46,5	640	50,2	68,7
YOLOv4-CSP	52,9	640	50,3	68,6
YOLOv4-CSP	52,9	640	50,8	69,5
YOLOv7	36,9	640	51,2	69,7
YOLOv7-CSP-X	96,9	640	52,7	71,3
YOLOv7-X	71,3	640	52,9	71,1
YOLOv4-tiny	6,1	416	24,9	42,1
YOLOv7-tiny	6,2	416	35,2	52,8
YOLOv4-tiny-3I	8,7	320	30,8	47,3
YOLOv7-tiny	6,2	320	30,8	47,3
YOLOv7-E6	115,8	1280	55,7	73,2
YOLOv7-E6	97,2	1280	55,9	73,5
YOLOv7-D6	151,7	1280	56,1	73,9
YOLOv7-D6	154,7	1280	56,3	73,8
YOLOv7-E6E	154,7	1280	56,8	74,4

Algılama sonuçlarına bakıldığında, YOLOv4 ile karşılaştırıldığında YOLOv7'nin %75 daha az parametreye, %36 daha az hesaplama yapma kapasitesine ve %1,5 daha yüksek AP getirdiği görülmektedir. Son teknoloji ürünü YOLOv7 ile karşılaştırıldığında, YOLOv7 %43 daha az parametreye, %15 daha az hesaplama yapma


%0,4 daha yüksek AP'ye sahiptir. Minik modelin performansında, YOLOv4-tiny-31 ile karşılaştırıldığında YOLOv7-tiny, parametre sayısını %39 ve hesaplama miktarını %49 azaltarak aynı AP değerini korumaktadır. Ayrıca karşılaştırmalı sonuçların daha iyi anlaşılabilir olması açısından Şekil 3.27'de YOLOv7'nin diğer gerçek zamanlı nesne algılayıcılarla karşılaştırılması görselleştirilmiştir.



Şekil 3.27. YOLOv7'nin diğer gerçek zamanlı nesne algılayıcılarla karşılaştırması (Wang et al. 2022).

3.8.9. YOLOv8

Ultralytics tarafından 2022 yılında geliştirilen ve YOLO ailesinin son üyesi olan YOLOv8 araştırmacılar tarafından sıklıkla kullanılmaktadır. YOLOv8, önceki YOLO sürümlerinin başarısını temel alan, performansı ve esnekliği daha da artırmak için yeni özellikler ve iyileştirmeler sunan son teknoloji ürünü bir modeldir. YOLOv8 hızlı, doğru ve kullanımı kolay olacak şekilde tasarlanmıştır; bu da onu çok çeşitli nesne algılama ve izleme, örnek bölümlendirme, görüntü sınıflandırma ve poz tahmin görevleri için mükemmel bir seçim haline getirmektedir. Bu çok yönlülük kullanıcıların çeşitli uygulamalar ve alanlarda YOLOv8'in yeteneklerinden yararlanmasına olanak sağlamaktadır. YOLOv8'e ait yayınlanmış bir makale olmayıp hakkındaki bilgiler internet sayfası üzerinden paylaşılmaktadır. YOLOv8'in diğer bazı YOLO modellerine göre sağladığı üstün performans sağladığı grafiksel gösterim Şekil 3.28'de verilmektedir.



Şekil 3.28. YOLOv8 modelinin diğer YOLO modelleri ile karşılaştırılması (Anonymous 2023a).

YOLOv8 beş adet farklı varyantlara sahip olmakla birlikte diğer algılama modellerine ait varyant türlerine göre de doğruluk ve çıkarım oranında daha üstün performans sergilemiştir. Çıkarım hızı arttıkça doğruluk oranında düşüş olması normal bir süreçtir. Bu durum tek ve çift aşamalı dedektörler arasındaki temel farkı oluşturmaktadır. Özellikle gerçek zamanlı algılama süreçlerinde tek aşamalı dedektörlerin kullanılmasının temel amacı budur. Hızlı çıkarım süresi ve kabul edilebilir doğruluk oranı gerçek zamanlı algılayıcılar için tercih sebebidir.

3.9. Coğrafi Bilgi Sistemleri ve Gömülü Sistem İnşası

CBS, verilerin toplanması, saklanması, analiz edilmesi gibi birçok işlevleri içeren bir bilgi sistemidir. Birçok veri tipinin birleşmesinden oluşan CBS, kökenini Coğrafya biliminden almakla birlikte günümüzde birçok alanda kullanılmaktadır. Literatürdeki çalışmalar incelendiğinde CBS'nin sıkça kullanıldığı görülmektedir (Liu et al. 2013; Sun et al. 2016; Ibrahim et al. 2019; Ağaçsapan and Çabuk 2020; Zhang et al. 2021). CBS, hayatımızın her alanına giren mekânsal konumların analizinden, 3B sahnelerde görselleştirme yapılmasına kadar birçok kolaylık sağlar. Bu benzersiz yetenekle CBS, kullanıcıların daha bilimsel bir şekilde karar vermelerine yardımcı olmak için veriler arası modellemeler yaparak ve ilişki kurarak kullanıcıya daha derin bir bakış açısı sunmaktadır (Anonim 2019a; Eren 2020). Bahsedilen katkılar ve literatürde kabul edilmiş bir uygulama olduğu için bu tez çalışmasında da CBS'den faydalanılacaktır. Yol kusurlarının görsel analizi için ArcGIS'in bir uygulaması olan ArcMap 10.6 paket programı kullanılmıştır. ArcMap, harita oluşturmak, mekânsal analiz yapmak ve verileri yönetmek gibi birçok olanağa imkân sağlayan önemli bir CBS programıdır.

Yol kusur türlerine ait verilerin CBS ortamına aktarılması sürecinde hassas ve özenli davranılmasının çalışmanın doğruluğu üzerindeki etkisi oldukça büyüktür. Excel ortamındaki verilerin ve diğer uzantılı verilerin (.sbn, .shp, .style, .tif, mdb, .csv, .sbn, .dbf) ArcMap ortamına aktarımı mümkündür. Aktarım yapıldıktan sonra verilerin analize uygun hale getirilmesi için verileri düzenleme işlemi yürütülmektedir. Belirlenen kriter verilerinin karakteristik yapılarına göre uygun analiz türlerinin yapılması hayati öneme sahiptir. Özellikle literatürdeki görsel analizlerin yapıldığı CBS çalışmaları incelendiğinde en çok kullanılan analiz türlerinin; kernel ve point density (yoğunluk), euclidean distance (öklidyen mesafe), slope (eğim), inverse distance weight (ters uzaklık ağırlıklandırma) olduğu gözlemlenmiştir (Demesouka et al. 2013; Montgomery et al. 2013; Erbaş et al. 2018; Ibrahim et al. 2019; Jena et al. 2020; Khan et al. 2020; Niu et al. 2020; Verma and Dash 2020; Wojnarowska et al. 2021; Zarandi et al. 2021; Zhang et al. 2021).

Kernel yoğunluk analizi: Tanımlı bir yarıçapa sahip çember içerisine düşen noktaların yoğunluğu ile bu kaynaktan itibaren uzaklaştıkça değişen noktasal yoğunluğu ifade eder.

Nokta yoğunluk analizi: Her çıktı raster hücresi etrafındaki nokta özelliklerinin yoğunluğu hesaplanır. Kavramsal olarak her raster hücre merkezinin etrafında bir bölge tanımlanır ve bölgeye düşen noktaların sayısı toplanıp bölgenin alanına bölünmesini ifade eder.

Öklidyen mesafe analizi: Bu analize kuş uçuşu mesafe de denmekte ve Pisagor teoremine göre iki nokta arası en kısa mesafe hesaplanabilir. Bunu yaparken rasterda belirlediğiniz hücrenin merkez noktasından hedef hücrenin merkez noktasına doğru hesaplama yapar.

Ters uzaklık ağırlıklandırma analizi: Bu analizde tahmin edilecek nokta değeri, bu nokta civarında bulunan komşu noktaların uzaklığı ve büyüklüğünün bir fonksiyonu olup, komşu noktaların tahmini yapılacak değer üzerindeki etkisi mesafedeki değişime bağlıdır.

Eğim analizi: Sayısal yüksek haritasının analiz edilmesi ile bir yüzeye ait eğim değerinin elde edilmesinde kullanılır.

CBS hakkında kısa bilgiler bu kısımda verilmiştir. Erzurum Teknik Üniversitesi kampüsü yol ağlarında bulunan yol kusur haritası CBS tabanlı ArcMap ile ortaya konulacaktır. 10 adet yol kusurunu algılama ve sınıflandırma yeteneğine sahip olan akıllı sistemin her bir yol kusurunun bulunduğu alanı noktasal olarak kullanıcıya verecektir. Elde edilen bu koordinat verileri ArcMap ortamına aktarılarak yoğunluk analizleri yapılarak bölgenin yol kusur röntgeni elde edilecektir.

Gömülü sistemler, birçok farklı uygulama alanında kullanılan özel amaçlı bilgisayar sistemleridir. Bu sistemler, belirli bir işlevi yerine getirmek için tasarlanmış ve genellikle küçük, düşük güç tüketimi ve düşük maliyetli bileşenlerden oluşurlar (Güçlü vd 2022).

Nesne algılama tabanlı gömülü sistemler, belirli nesneleri tanımlama ve sınıflandırma görevlerini yerine getiren sistemlerdir. Bu sistemler bir kamera veya sensör aracılığıyla görüntüleri veya verileri işleyerek nesneleri tespit eder, sınıflandırır ve takip eder. Nesne algılama tabanlı gömülü sistemler; otomotiv, güvenlik, tarım, tıp ve robotik gibi farklı uygulama alanında kullanılır (Duran ve Teke 2019).

Nesne algılama tabanlı bir gömülü sistem kurmak için gereken işlem adımları: (Duran ve Teke 2019; Güçlü vd 2022; Kaçmaz vd 2022)

- Donanım seçimi: Nesne algılama işlemi için uygun bir işlemci, bellek, depolama ve giriş/çıkış bileşenleri seçilmelidir. Ayrıca bir kamera veya sensör gibi algılama cihazlarına ihtiyaç duyulmaktadır.
- Yazılım seçimi: Nesne algılama algoritması için uygun bir yazılım kütüphanesi veya araç seçilmelidir. OpenCV, TensorFlow ve PyTorch gibi popüler kütüphanelerden biri kullanılabilir.
- Algoritma geliştirme: Seçilen nesne algılama aracı kullanarak nesne algılama algoritması kullanıcı odaklı özelleştirilmelidir.

- Donanım ve yazılımın birleştirilmesi: Seçilen nesne algılama algoritması, seçilen donanım bileşenleriyle birleştirilmeli ve sistem oluşturulmalıdır.
- Test etme: Oluşturulan sistemin test edilmesi ve nesne algılama algoritmasının doğruluğu ve performansı değerlendirilmelidir.
- Geliştirme: Sistemi geliştirme, güncelleme veya özelleştirme süreçleri kullanıcı bilgi ve deneyimi ile gerçekleştirilmektedir.

Önerilen çalışma kapsamında işlem adımları:

- Araç içi entegre kamera ile yol kusur verilerinin toplanması ve diğer ülkelere ait veriler ile birleştirilmesi
- Bütün verilerin etiketlenmesi
- YOLOv5, YOLOv7 ve YOLOv8 nesne algılama modelleri ile veri setinin eğitilerek ağırlık dosyalarının elde edilmesi
- Elde edilen ağırlık dosyası ile gömülü sistem entegrasyonun sağlanması
- Elde edilen katma değerli ürünün test aşamasına sunulması

3.10. Akıllı Ulaşım Sistemleri

Son dönemlerde bilgi ve iletişim teknoloji alanlarında yapılan gelişim ve yatırımların artması, toplumun ulaşım anlayışının ve beklentilerinin değişmesine yol açmıştır. Ayrıca hareketliliğin artması ve beklentilerin karşılanmasında AUS'a ait çözümler oldukça hayati öneme sahiptir. AUS genel olarak; yol ağında var olan tüm kullanıcı bileşenlerin ve altyapı elemanlarının izlenmesi, yönetimi ve analizi için bilgi ve iletişim teknolojilerinin kullandığı sistem olarak nitelendirilmektedir (Anonim 2019b; Anonim 2020). Bu ifadeden de anlaşıldığı üzere teknoloji alanında meydana gelen her değişiklik AUS sistemini doğrudan etkileyerek yeni ve farklı çözümler sunmasını sağlamaktadır. AUS'un gelişimi sadece teknolojik gelişimlere bağlı olmayıp mevcut dönemin ihtiyaçlarına uygun olarak sosyo-ekonomik yapıda göz önünde bulundurularak bölgelerin hızlı kentleşmesi, artan nüfus ve araç sayısı, hareketlilik isteği, toplu taşımaya özendirme ve mikro mobilite araçlarına dönüşüm gibi birçok parametreye de bağlıdır. Bu bölümde AUS'a genel bakış, AUS mimarisi, AUS'un ülkemizdeki durumu hakkında bilgiler sunulmuştur.

Trafik bileşenlerinin oluşturmuş olduğu yoğunluk neticesinde bir takım sorunlar ortaya çıkmaktadır. Bu sorunlar; seyahat süresinin artması, trafik güvenliği ve konforunun azalması, mevcut yol ağı kapasitelerinin yetersiz ve verimsiz kullanılması, hareketlilik isteğinin karşılanamaması, enerjinin verimsiz kullanılması, çevreye verilen zararın artması gibi sıralanabilir. Tüm bu sorunların çözümü ve verilerin tek merkezden analiz edilmesinde AUS önemli rol oynamaktadır. Araç-altyapı-kullanıcı bileşenleri ve trafik izleme merkezleri arasında veri alışverişinin sağlanması ile bilgi ve iletişim teknolojileri tabanlı izleme, ölçme, analiz ve kontrol mekanizmalarını içeren sistem AUS'dur (Tektaş ve Tektaş 2019a).

AUS uygulamaları tarihi ülkemizde çok eski olmasa da bazı ülkelerin AUS ile ilişkisi geçmişe dayanmaktadır. ABD'de Elektronik Rota Kılavuzluk Sistemi (ERGS) ve Japonya da Kapsamlı Otomobil Trafik Kontrol Sistemleri (CACS) 1960'larda uygulanarak tarihteki ilk AUS uygulamaları olarak not edilmiştir. AUS'un temel teknolojisi olan haberleşmede olan gelişmeler ile birlikte 1980'ler AUS için ivme kazanma dönemi olmuştur. AUS uygulamalarının şehirlerle ve ulaşımına farklı bir vizyon kazandıracağı düşüncüleri devlet ve sanayi işbirliklerini artırmıştır. Bu ortaklık elektronik ücret toplama, trafik kontrol merkezleri, yolcu ve sürücü bilgilendirme sistemleri gibi büyük projelerin başlamasına sebep olmuştur.

Artık AUS tüm ülkeler için ele alınması gereken ulaşımın anahtar sistemleri haline gelmeye başlamıştır. Bu doğrultuda ilk uluslararası AUS kongresi 1994 yılında Paris'te düzenlenmiş ve günümüze kadar düzenli olarak farklı ülkelerde gerçekleşmeye devam etmiştir. AUS hakkındaki etkinlikler ve araştırmacıların bu alanda yapmış olduğu akademik çalışmalar neticesinde kazanılan bilgi ve birikim ile ortaya çıkan teknolojilerin ülkelerin yaşamış olduğu sorunlara çözüm sunabilmesi için birleştirilmesi gerekliliği her ülke için AUS organizasyonlarını gerekli kılmıştır. Ancak bölgesel olarak AUS alanında öncü olan temel kuruluşlar bu alana yön vermektedir. ERTICO, ITS Amerika ve ITS Asya Pasifik öncü kuruluşlar olarak faaliyetlerine devam etmektedir. AUS'un ortaya çıktığı ilk günlerden günümüze kadar tarihsel gelişimi hakkında bilgiler Şekil 3.29'da sunulmaktadır (Anonim 2020).



Şekil 3.29. AUS tarihsel gelişimi

Özellikle AUS pazarındaki getiriler gelişmiş ülkeleri 2015 yılı ile birlikte yüksek rekabet durumuna getirmiştir. Ülke yönetimlerinin proje çalışmalarına, altyapı ve teknoloji yatırımlarına teşvik oranını artırması ve AUS stratejilerini uygulamaya geçirmesi bu rekabetin göstergelerindendir. Unutulmamalıdır ki bilgi ve iletişim teknolojilerindeki gelişim AUS tabanlı çözüm önerilerine uygulanmadıkça tek başına yetersiz kalmaktadır. AUS'a ait teknoloji ve uygulama çeşitliliğin artırılması ve yaygınlaştırılması için yönetimler imkânlar sunmaya devam etmektedir. Ayrıca AUS uygulamalarının diğer bir özelliği ise tüm sektörleri içinde barındırdığı için disiplinler arası çalışmalara kapı aralamasıdır. AUS uygulamalarının çözüm ürettiği ve etkilenen sektörlerin genel şeması Şekil 3.30'de verilmektedir (Tektaş ve Tektaş 2019b). Ayrıca teknolojik uygulamaların sağlayacağı avantaj ve dezavantajlarda dikkate alınarak

3. MATERYAL VE YÖNTEM

AUS'un hukuk, psikoloji ve finans gibi birçok alan ile de etkileşim halinde olduğu söylenebilir.



Şekil 3.30. AUS uygulamalarından etkilenen sektörler (Tektaş ve Tektaş 2019b)

Dünya genelinde olduğu gibi ülkemizde de nüfus dağılımında farklılıklar ve kentleşmenin giderek arttığı görülmektedir. Ülkemizde 1927 yılında nüfusun %75,8'i belde ve köylerde ikamet ederken bu değer 2000'li yıllarda %35,10'lara kadar gerilemiştir. Kentleşmenin giderek artması ve günümüzde bu değer %6,6'lara kadar gerilemesi çevresel, ekonomik, sosyal ve ulaşım alanlarında günlük yaşamı etkileyen birçok değişimleri zorunlu kılmıştır (Anonim 2023e). Bu göç yolculuğunun temel sebebi kentsel alanlardaki iş olanaklarının kırsal bölgelere göre daha fazla olmasıdır. Nüfus yoğunluğunun kentlerde fazla olması ve bu nüfusun iş, okul, seyahat ve diğer ihtiyaçlarını gidermek için hareket isteği trafik sorunlarında beraberinde getirmektedir. Oluşan araç ve yaya trafiğinin çözümünde geleneksel yöntemlerin kullanılmasının yetersizliği AUS uygulamalarını beraberinde getirmiştir. Ayrıca oluşan trafik yoğunluğu sadece gecikmelere neden olmayıp buna bağlı olarak yakıt tüketimin artması ile birlikte zararlı gazların salınımı da beraberinde getirmektedir. Bu olumsuzlukları ortadan gidermesi, insan kaynaklı hataları minimize etmesi, gecikme kaynaklı zaman kayıplarının önüne geçilmesi, ölümlü ve yaralanmalı kazaları azaltması gibi olanakların sağlanması için AUS uygulamaları kaçınılmaz olmaktadır. Genel ve yerel yönetimlerin AUS uygulamalarının yaygınlaşmasını desteklemesi ile söz konusu problemlere çözüm önerileri

üretilebilecektir. Önerilen çözümler neticesinde aşağıdaki faydaların sağlanması beklenmektedir.

- Seyahat sürelerinde azalma
- Yakıt tasarrufu ve çevreye daha az zararlı gaz salınımı
- Hareketliliğin artması
- Toplu ulaşım kullanımının yaygınlaştırılması
- Trafik sıkışıklığında azalma
- Son tamamlayıcı olarak mikro-mobilité kullanımının yaygınlaştırılması
- Araç yıpranmasında azalma ve bakım maliyetlerinde tasarruf
- Olay müdahale süresinde iyileştirme ve etkinliğinin artırılması
- Trafik güvenliği ve konforunun artırılması
- Araç-araç, araç-altyapı, araç-merkez ve altyapı-altyapı haberleşme sistemleri ile verimli ulaşım olanakları
- Toplu ulaşım destekleyici mobil uygulamaların sağlanması
- Kamera ve sensör algılayıcılar ile büyük trafik verisinin ulaşımında kolaylık sağlaması için analizi
- Gerçek zamanlı izleme ile kamu güvenliğinin sağlanması
- Gerçek zamanlı verilerin analizi neticesinde yolcu ve yük hareketliliğinin optimize edilmesi
- Yol ağlarının yapısal olarak güvenliğinin sağlanması
- Yol bakım, onarım ve yapımında hızlı müdahale imkânı sunması

AUS tarafından sağlanan faydaların bunlar ile sınırlı olmayıp birçok avantaj sağladığı açıktır. AUS akıllı şehirler kapsamında nüfusun kullandığı ortak alanları kapsadığı için birçok sektörün faydalandığı vazgeçilemez uygulama topluluğudur.

3.10.1. AUS uygulamalarında kullanılan teknolojiler

AUS uygulamalarının genel olarak telekomünikasyon, elektronik ve bilgisayar teknolojileri tabanlı olması teknolojik altyapının gerekliliğini kılmaktadır. Mobil uygulamadan, yol ağı trafik yoğunluğuna, sinyalizasyon sistemlerinden acil müdahale

sistemlerine kadar birçok alanda yüksek teknoloji kullanılmaktadır. Kullanılan başlıca haberleşme ve algılama teknolojilerden bu kısımda bahsedilmiştir (Anonoim 2018).

Küresel seyrüsefer uydu sistemi (GNSS), dünya genelinde konum belirleme, hız ve zaman bilgisi sağlayan bir uydu tabanlı navigasyon sistemidir. GNSS, uydu yörüngelerinde dönen ve yeryüzündeki alıcı cihazlar tarafından yakalanarak kullanılan uydu ağlarından oluşur. GNSS, dünyanın farklı bölgelerindeki alıcı cihazlar tarafından kullanılarak gerçek zamanlı konum ve zaman bilgisi sağlar. Bu sistemler yer tabanlı navigasyonun yanı sıra hava, deniz ve uzayda da kullanılır. Küresel Konumlandırma Sistemi (GPS), ABD tarafından geliştirilen ilk GNSS sistemi ve en yaygın olarak kullanılanıdır. Ancak diğer ülkeler de benzer sistemleri geliştirmiştir. Örneğin, Rusya'nın GLONASS, Avrupa Birliği'nin Galileo ve Çin'in BeiDou gibi GNSS sistemleri bulunmaktadır. GNSS özellikle seyahat, haritalama, hava ve deniz trafiği, askeri operasyonlar, acil durum yönetimi, tarım, coğrafi bilgi sistemleri ve daha birçok alanda kullanılmaktadır. Uydu sinyallerini alarak konum tespiti yapabilen alıcılar, bu sistemler sayesinde hassas ve güvenilir bir şekilde navigasyon yapabilirler.

Radyo Frekansıyla Tanımlama (RFID), nesnelerin benzersiz kimliklerini ve verilerini kablosuz olarak ileten ve alabilen bir teknolojidir. RFID sistemi, özel etiketlerin veya etiketlere entegre edilmiş mikroçiplerin radyo frekansıyla iletişim kurduğu bir alıcı-okuyucu cihazından oluşur. Bu teknoloji, nesnelerin otomatik tanınmasını ve izlenmesini sağlar. RFID sistemi genellikle üç ana bileşenden oluşur:

RFID etiketi: Bu etiket, bir mikroçip ve bir anten içermektedir. Mikroçip, nesnenin benzersiz kimliği veya diğer verileri depolar. Anten ise radyo frekansı sinyallerini alır ve etiketin mikroçipine iletim sağlar. RFID etiketleri, pasif (enerji kaynağı gerektirmeyen) veya aktif (kendi enerji kaynağına sahip) olabilir.

RFID okuyucu: Okuyucu, etiketlerle iletişim kurabilen bir cihazdır. Etiketlerden gelen radyo frekansı sinyallerini alır ve bunları veri haline çevirir. Ardından bu veriler, bir veri tabanında veya merkezi bir sistemde işlenir.

Veri tabanı veya yazılımı: RFID sisteminde toplanan veriler genellikle bir veri tabanında saklanır veya özel yazılımlar aracılığıyla işlenir. Bu veriler, nesnelerin kimlikleri, konumları, tarihleri veya diğer özelleştirilmiş bilgileri içerebilir.

RFID teknolojisi, perakende, lojistik, depo yönetimi, üretim takibi, tıbbi envanter yönetimi, hayvan izleme, akıllı kartlar ve daha birçok alanda kullanılmaktadır. Çünkü RFID, nesnelerin otomatik ve kablosuz olarak tanınmasını ve izlenmesini sağlayarak veri toplama ve yönetimini daha verimli hale getirir.

Tahsis Edilmiş Kısa Mesafeli Haberleşme (DSRC), araçlar arasında ve araçlar ile altyapı arasında kablosuz iletişim kurmayı sağlayan bir teknolojidir. DSRC, özel olarak ayrılmış radyo frekans bantlarını kullanarak kısa mesafeli haberleşmeyi destekler. DSRC, genellikle yol güvenliği, trafik yönetimi ve AUS gibi uygulamalarda kullanılır. Araçlar arasında ve yol altyapısıyla iletişim kurarak trafiği daha verimli hale getirebilir, kazaları azaltabilir ve sürüş deneyimini geliştirebilir. DSRC teknolojisinin bazı kullanım alanları şunlar olabilir:

Trafik yönetimi: DSRC ile araçlar ve trafik yönetim merkezleri arasında iletişim kurarak trafik sıkışıklığını azaltabilir, trafik ışıkları ile senkronizasyon sağlayabilir ve trafik akışını daha iyi yönetebilir.

Güvenlik uygulamaları: DSRC, araçlar arasında hızlı ve güvenilir iletişim sağlayarak çarpışma önleme sistemlerini destekleyebilir. Bu sayede sürücülere tehlike uyarıları göndererek kazaları engellemeye yardımcı olabilir.

Otopark yönetimi: DSRC teknolojisi, sürücülere boş otopark alanlarını bulma konusunda yardımcı olabilir ve otopark ücretlerini otomatik olarak tahsil etmeyi sağlayabilir.

Acil durum hizmetleri: Acil durumlarda araçların hızlıca müdahale ekiplerine bilgi iletebilmesini sağlayarak acil durum hizmetlerini hızlandırabilir.

DSRC, genellikle araçların taşıdığı özel donanım veya cihazlar aracılığıyla çalışır. Ancak, gelecekteki kablosuz iletişim teknolojileri ve standartlarının gelişmesiyle DSRC'nin yerini alabilecek alternatifler de olabilir.

Yakın Alan Haberleşmesi (NFC), kısa mesafelerde (genellikle birkaç santimetre veya daha az) kablosuz iletişim kurmayı sağlayan bir teknolojidir. NFC, iki cihaz arasında veri alışverişi yapma yeteneği sağlar ve genellikle cihazların birbirine dokunması veya çok yakın olması gerekmektedir. NFC teknolojisi, radyo frekansı ile çalışır ve genellikle pasif (enerji alabilen) ve aktif (kendi enerjisini taşıyan) cihazlar arasında iletişim sağlar. NFC cihazları, veri paylaşımı, ödeme işlemleri, akıllı kartlar, akıllı etiketler, mobil cüzdanlar, erişim kontrolü, akıllı ev sistemleri ve daha birçok uygulama alanında kullanılır. NFC'nin bazı temel özellikleri ve kullanım alanları şunlar olabilir:

Veri paylaşımı: NFC cihazları, dokunarak veya çok yakın bir mesafede veri (dosyalar, fotoğraflar, videolar, iş kartları) paylaşabilir.

Mobil ödeme: NFC teknolojisi, özellikle akıllı telefonlar aracılığıyla yapılan mobil ödemelerde kullanılır. NFC destekli ödeme sistemleri, telefonunuzu ödeme terminallerine dokundurarak ödemeleri gerçekleştirmenizi sağlar.

Akıllı etiketler ve eşyalar: NFC etiketleri, ürünlerin veya nesnelerin üzerine yerleştirilerek bu nesneler hakkında daha fazla bilgiye erişim sağlar. Örneğin, müze sergileri için bilgi sağlamak veya ürünlerin izlenmesi ve yönetilmesi için kullanılabilir.

Erişim kontrolü ve kimlik doğrulama: NFC, kapı girişlerinde veya güvenli alanlara erişim sağlamak için kullanılabilir. Akıllı kartlar veya NFC destekli akıllı telefonlar, kullanıcının kimliğini doğrulamak ve giriş izinleri vermek için kullanılabilir.

Akıllı ev ve nesnelerin interneti (IoT): NFC, ev otomasyonu ve IoT cihazlarının yönetimi için kullanılabilir. Örneğin, akıllı cihazlar arasında iletişim kurarak ev içi aydınlatma, ısıtma ve soğutma gibi sistemleri kontrol edebilirsiniz. NFC, kullanımı kolay ve güvenli bir teknoloji olarak kabul edilir ve mobil cihazlarda genellikle standart bir özellik olarak bulunur.

Hücresel Haberleşme Ağları, kablosuz iletişim için kullanılan ve genellikle birbiriyle örtüşen hücrelerden oluşan bir ağ yapısıdır. Bu hücreler, radyo verilerinin ve sinyallerinin iletilmesi için kullanılır. Her hücre, bir baz istasyonu veya baz istasyonu grubu tarafından yönetilmekle birlikte bu istasyonlar birbirleriyle ve merkezi bir kontrol noktasıyla iletişim kurarlar. Hücresel ağlar, genellikle mobil telefonlar, veri kartları, tabletler ve diğer kablosuz cihazlar gibi taşınabilir iletişim cihazlarıyla kullanılırlar. Temel amacı, geniş bir coğrafi alanı kapsayacak şekilde kablosuz iletişim sağlamaktır. Hücresel ağlar, insanların sesli görüşme, metin mesajlaşma, veri indirme/yükleme ve internete erişim gibi iletişim hizmetlerinden yararlanmalarını sağlar. 3G, 4G, 4.5G ve yakın gelecekte devreye girecek 5G mobil haberleşme teknolojileri güvenlik, navigasyon, araç içi bilgilendirme sistemleri ve eğlence hizmetleri gibi birçok AUS uygulamasında kullanılabilir. Hücresel ağlar, genellikle şu temel özellikleri içerir:

Hücre yapısı: Büyük bir coğrafi bölgeyi daha küçük hücelere böler. Her hücre, bir baz istasyonu tarafından kapsanır.

Frekans yönetimi: Aynı frekans aralığında bulunan hücrelerin birbirine müdahale etmemesi için frekanslar yönetilir. Her hücre farklı frekanslar veya zaman dilimleri kullanabilir.

El değiştirme: Hareket halindeki bir cihaz, bir hücreden diğerine geçerken (örneğin, araba sürerken) sinyal kalitesini korumak için otomatik olarak el değiştirme işlemi gerçekleştirir.

Veri ve ses iletimi: Hücresel ağlar, ses ve veri iletişimini destekler. Geleneksel olarak sesli görüşme odaklı olsalar da günümüzde daha fazla veri iletişimi (örneğin, internet erişimi) için kullanılmaktadır.

Mobil cihazlar ve abonelikler: Hücresel ağlar, mobil cihazların (örneğin, cep telefonları) çalışmasını sağlar. Aboneler, hücresel ağa abone olarak hizmetlerden yararlanabilirler.

En yaygın hücresel ağ standartlarından biri, Global System for Mobile Communications (GSM) olarak bilinir. Bununla birlikte, farklı ülkelerde ve bölgelerde farklı hücresel ağ standartları da kullanılabilir, örneğin Code Division Multiple Access (CDMA) veya Long-Term Evolution (LTE).

Radyo Veri Sistemi (RDS) ve Sayısal Radyo Yayını (DAB), radyo iletişimi teknolojileridir. Her ikisi de radyo yayıncılığını daha verimli ve gelişmiş hale getirmek amacıyla kullanılan sistemlerdir. Bu yayınlar geniş alanlara trafik, seyahat ve acil durum anonslarının yapılmasının yanı sıra yolda meydana gelen olaylara dair sürücülere yapılacak bilgilendirmeler de bu yayın ile sağlanmaktadır.

RDS, FM radyo yayınlarında kullanılan bir teknolojidir. Temel olarak metin tabanlı bilgi ve veri iletimini sağlar. RDS, FM radyo istasyonları tarafından kullanılarak aşağıdaki gibi bilgileri gönderebilir: İstasyon adı ve frekansı, şarkı isimleri ve sanatçı bilgileri, trafik durumu ve hava raporları, saat ve tarih bilgileri, diğer anonslar ve metin tabanlı içerikler yayınların daha etkili ve kullanıcı dostu olmasını sağlayarak dinleyicilere daha fazla bilgi sunma imkânı sağlar.

DAB, geleneksel analog radyo yayınlarının yerine daha kaliteli ses ve daha fazla içerik sağlayan bir teknolojidir. DAB, sesi sayısal formatta ileterek daha net ve gürültüsüz bir ses deneyimi sunar. Ayrıca daha fazla kanal ve hizmet sunma kapasitesine sahiptir. DAB+ gibi geliştirilmiş versiyonlar, daha yüksek sıkıştırma oranları ve daha iyi ses kalitesi sağlar. DAB, aynı frekansta birden çok kanalın iletilmesine olanak tanır ve radyo dinleme deneyimini daha çeşitli ve interaktif hale getirebilir.

Hem RDS hem de DAB, radyo dinleyicilerine daha fazla içerik, bilgi ve ses kalitesi sunarak geleneksel radyo yayıncılığını modernleştirir. DAB özellikle sayısal ses kalitesi ve daha fazla kanal seçeneği sunmasıyla önemli bir yenilik getirirken, RDS metin tabanlı bilgi iletiminde kullanılan bir teknolojidir.

Düşük Güç Geniş Alan Ağı (LPWAN), uzun menzilli kablosuz iletişim teknolojileri grubunu ifade eder. Bu teknolojiler, düşük enerji tüketimi, geniş kapsama alanı ve uzun pil ömrü ile öne çıkarlar. LPWAN teknolojileri, genellikle nesnelerin


3. MATERYAL VE YÖNTEM

interneti cihazları için kullanılır ve uzak yerlere dağılmış cihazların düşük maliyetle ve uzun süreli iletişimini sağlar. İşte bazı önemli LPWAN teknolojileri:

Uzun Menzilli Geniş Alan Ağı (LoRaWAN): LoRaWAN, düşük veri hızlarında uzun menzilli iletişim sağlamak amacıyla tasarlanmıştır. Sensörler, cihazlar ve diğer IoT uygulamaları için uygundur. LoRaWAN, düşük enerji tüketimi ile uzun pil ömrü sunar ve genellikle kırsal alanlarda veya düşük yoğunluklu nesne ağlarında kullanılır.

Weightless: LPWAN teknolojilerinden bir diğeridir. Farklı varyantları bulunsa da genel olarak düşük güç tüketimi, uzun menzil ve düşük maliyetli iletişim sunar. Endüstriyel IoT ve tarım gibi alanlarda kullanımı yaygındır.

Bu LPWAN teknolojileri genellikle büyük veri transfer hızlarına ihtiyaç duymayan ve enerji tüketimi konusunda hassas olan uygulamalarda tercih edilir. Nesnelerin interneti alanında yaygın olarak kullanılmaktadırlar ve uzak noktalardaki cihazların etkili bir şekilde yönetilmesine olanak tanır. LoraWAN teknolojisinin çalışma prensibinin görsel olarak şematik gösterimi Şekil 3.31’de sunulmaktadır.



Şekil 3.31. LoraWAN teknolojisi (Anonoim 2018)

Algılama teknolojileri, fiziksel veya kimyasal değişiklikleri tespit etmek ve ölçmek amacıyla kullanılan yöntemler ve cihazlar grubunu ifade eder. Bu teknolojiler, nesnelerin varlığını, konumunu, hareketini, sıcaklığını, basıncını, ışık seviyelerini, sesi, kimyasal bileşenleri ve daha birçok özelliğini belirlemek için kullanılırlar. Algılama teknolojileri çeşitli endüstrilerde ve uygulamalarda kullanılır ve çevresel verileri

toplamak, analiz etmek ve yönetmek için önemli bir rol oynarlar. Algılama teknolojileri akıllı ulaşımın temel taşlarından biridir çünkü trafik ve ulaşım yönetimini daha etkili ve verimli hale getirir. Algılama teknolojilerinin akıllı ulaşımında kullanımına örnekler:

Trafik akışı ve yoğunluğu izleme (Anonim 2023f): Algılama teknolojileri, yolların üzerine veya yanına yerleştirilen sensörler aracılığıyla trafik akışını ve yoğunluğunu izleyebilir. Bu veriler, trafik yönetim merkezlerine gönderilerek trafik sıkışıklığının önceden tahmin edilmesine ve yönetilmesine yardımcı olabilir.

Trafik ışıkları kontrolü: Algılama sistemleri, trafik ışıklarını gerçek zamanlı olarak yönetmek için kullanılabilir. Trafik yoğunluğuna göre ışık döngülerini ayarlamak, trafik akışını optimize etmeye yardımcı olabilir.

Otopark yönetimi: Algılama teknolojileri, boş otopark yerlerini tespit edebilir ve sürücülere yönlendirme yaparak otopark yönetimini kolaylaştırabilir.

Araç takip ve yönetimi: Algılama sistemleri, akıllı taşıma sistemlerinde kullanılarak toplu taşıma araçlarının konumunu izleyebilir, sefer zamanlarını tahmin edebilir ve yolculara bilgi sağlayabilir.

Kaza tespit ve acil durum yönetimi: Algılama sistemleri, anormal trafik durumları veya kazaları tespit ederek acil durum yönetim ekiplerine bildirimde bulunabilir.

Sürücü destek sistemleri: Algılama teknolojileri, araç içi sensörler ve kameralar aracılığıyla sürücü davranışlarını izleyebilir ve tehlike anlarında uyarılar göndererek güvenli sürüşü teşvik edebilir.

Akıllı ulaşım yönetimi: Algılama verileri, büyük veri analizi ile birleştirilerek trafik modellemesi, yol planlaması ve ulaşım politikalarının geliştirilmesinde kullanılabilir.

Algılama teknolojileri, akıllı ulaşımın temel bileşenlerinden biri olarak trafik akışını iyileştirme, enerji verimliliğini artırma ve sürdürülebilir ulaşım sistemleri oluşturma amacıyla geniş bir şekilde kullanılır.

Kooperatif Akıllı Ulaşım Sistemleri (K-AUS), farklı ulaşım araçları ve altyapı elemanlarının birbiriyle iletişim kurarak trafiği daha güvenli, akıcı ve etkili hale getirmeyi amaçlayan bir akıllı ulaşım yaklaşımını ifade eder. Bu sistemler, araçlar arasında ve araçlar ile altyapı arasında gerçek zamanlı veri paylaşımını sağlayarak trafik yönetimini optimize eder ve trafik akışını iyileştirir. Ayrıca karayolu ulaşımında özellikle taşımacılığın verimliliğini, güvenliğini ve çevresel performansı artırmaya yönelik imkanlar sunan yenilikçi teknolojilerden birisi olarak ifade edilebilir (Anonim 2023f). Kooperatif Akıllı Ulaşım Sistemleri'nin temel bileşenleri şunlar olabilir:

Araçlar arası iletişim (V2V / Vehicle-to-Vehicle): Araçlar arasındaki iletişimi ifade eder. Araçlar, diğer araçların konumunu, hızını, yönünü ve diğer verileri paylaşabilir. Bu sayede trafik kazalarını önleme, trafik sıkışıklığını azaltma ve trafik akışını iyileştirme amacıyla kullanılabilir (Anonymous 2023b).


Araç-altyapı iletişimi (V2I / Vehicle-to-Infrastructure): Araçlar, trafik ışıkları, yol işaretleri, yol kenarındaki sensörler gibi altyapı elemanlarıyla iletişim kurabilir. Bu iletişim sayesinde sürücülere trafik durumları, hava koşulları ve yol yapım çalışmaları gibi bilgiler sunulabilir.

Merkezi kontrol merkezi: Trafik yönetim merkezi, tüm verileri toplar, analiz eder ve trafik durumunu izler. Acil durum yönetimi, trafik sıkışıklığı tahmini, yol planlaması gibi işlevleri gerçekleştirir.

Güvenlik uygulamaları: K-AUS, acil frenleme uyarıları ve şerit değiştirme uyarıları gibi güvenlik önlemlerini sürücülere ileterek trafik kazalarını azaltabilir.

Trafik yönetimi ve akışı iyileştirme: Gerçek zamanlı trafik verileri ile trafik sıkışıklığı tahminleri yapabilir ve alternatif rotaları önererek trafik akışını daha akıcı hale getirebilir.

K-AUS, IoT teknolojisi ile birleşerek daha güvenli, verimli ve sürdürülebilir bir ulaşım ağı oluşturmayı hedefler. Bu sistemler gelecekteki şehirlerin ulaşım ihtiyaçlarını karşılamak ve trafik sorunlarını çözmek için önemli bir rol oynayabilir (Anonim 2023f). K-AUS'un çalışma prensibini özetleyen animatör resim Şekil 3.32'de sunulmaktadır.



Şekil 3.32. Kooperatif akıllı ulaşım sistemleri (Anonoim 2023f)

3.10.2. AUS uygulamaları

Bilişim ve haberleşme teknolojilerinin gelişimi ve yapay zekâ tabanlı çözüm önerilerinin gelişmesi AUS uygulama alanlarını artırmaktadır. Kalabalık kentleşme neticesinde meydana gelen olumsuzlukları en düşük seviyeye indirmek açısından AUS uygulamaları hayati öneme sahiptir. Operasyonel yönetim, sürücü destek sistemleri, ücret toplama, seyahat bilgileri, trafik yönetimi, güvenlik ve talebe duyarlı taşımacılık gibi ana başlık altında birçok AUS uygulaması mevcuttur (Anonim 2018). Mevcut durumda yapılan AUS çalışmaları ve gelecekte yapılması ön görülen bazı uygulama türlerine bu kısımda yer verilmiştir.

Bir servis olarak hareketlilik (MaaS), farklı ulaşım seçeneklerini tek bir entegre platformda birleştiren ve kullanıcılara kapsamlı bir ulaşım deneyimi sunmayı amaçlayan bir konsepttir. MaaS, geleneksel olarak bireylerin sadece bir taşıma aracını kullanmasından ziyade farklı taşıma modları arasında esnek bir şekilde geçiş yapmalarını ve seyahatlerini daha verimli hale getirmelerini sağlamak için tasarlanmıştır.

3. MATERYAL VE YÖNTEM

MaaS'ın temel amacı, kullanıcılara bir uygulama veya platform aracılığıyla ulaşım hizmetlerini entegre bir şekilde planlama, rezervasyon, ödeme ve yönetme imkanı sunmaktır. Bu kapsamda MaaS platformları genellikle aşağıdaki hizmetleri içerebilir:

Ulaşım planlama: Kullanıcıların gitmek istedikleri yere en uygun ve etkili ulaşım seçeneklerini sunan bir plan oluşturma.

Rezervasyon ve bilet alma: Otobüs, tren, metro, taksi, bisiklet paylaşımı gibi farklı taşıma modları için rezervasyon yapma ve bilet satın alma.

Ödeme entegrasyonu: Tüm ulaşım seçenekleri için tek bir ödeme platformu kullanarak ödeme yapma.

Gerçek zamanlı bilgi: Gerçek zamanlı trafik, sefer saatleri, gecikmeler ve diğer seyahat bilgilerine erişim.


Kişisel tercihlere göre öneriler: Kullanıcının tercihlerine ve ihtiyaçlarına dayalı olarak en iyi ulaşım rotalarını ve seçeneklerini önerme.

MaaS'ın hedeflerinden biri, bireyleri özel araç kullanımından uzaklaştırmak, trafik sıkışıklığını azaltmak, çevresel etkileri minimize etmek ve ulaşım sistemlerini daha sürdürülebilir ve etkili bir şekilde kullanılabilir hale getirmektir. Bu kapsamda MaaS, şehirlerde daha akıllı ve entegre ulaşım çözümlerinin geliştirilmesine katkı sağlamayı amaçlamaktadır (Anonim 2023g). MaaS çalışma prensibi Şekil 3.33'de özetlenmiştir.



Şekil 3.33. MaaS çalışma ağ yapısı (Anonoim 2023j)

Maas uygulama yönetimi düşünüldüğü kadar kolay olmayıp güçlü bir altyapı ve planlama organizasyonuna ihtiyaç duymaktadır. Ayrıca kuşak farklılıkların getirdiği bazı özel durumlar MaaS'a yaklaşımı sınırlandırmaktadır. Cox Automotive tarafından mobilite üzerine yapılan bir araştırmada özel araç sahipliğinin zorunluluğu hakkında çıkan sonuçların MaaS uygulama süreci üzerinde anahtar rol oynamaktadır. Şekil 3.34'de farklı kuşaklara ait otomobil isteğinin gerekliliği hakkında bilgiler mevcuttur. Z kuşağının çoğu otomobil sahipliğinin zorunlu olmadığına inanmaktadır. Ancak diğer kuşakların bu fikre sıcak olmadığı ortadır.



Şekil 3.34. Kuşaklara göre özel araç sahipliğinin gereksizliği (Anonoim 2023j)

Araç paylaşımı, bireylerin veya grupların, ihtiyaç duyduklarında bir aracı kısa süreliğine kullanmak üzere kiralamalarını veya paylaşmalarını sağlayan bir ulaşım hizmetidir. Bu hizmet, bireylerin sahip olmadıkları araçlara erişim sağlamak, toplu taşıma alternatiflerine ek olarak kullanmak veya özel araç sahipliğini azaltmak isteyenler için bir seçenek olarak ortaya çıkmıştır (Sprei et al. 2019; Kaya et al. 2022). Araç paylaşımı genellikle aşağıdaki şekillerde gerçekleşir:

Teknoloji tabanlı paylaşım: Mobil uygulamalar veya web platformları aracılığıyla kullanıcılar, yakınlarındaki paylaşımlı araçları arayabilir, rezerve edebilir ve kiralayabilirler. Bu yaklaşım, hızlı ve kullanıcı dostu bir deneyim sunar.

Üye tabanlı sistemler: Bu tür sistemlerde, kullanıcılar belirli bir araç paylaşım hizmetine üye olurlar ve belirli saatlerde veya günlerde araçları kullanmak için

3. MATERYAL VE YÖNTEM

rezervasyon yaparlar. Üyelik ücreti genellikle kullanımı kolaylaştırmak ve ödemeleri düzenlemek amacıyla alınabilir.

Kurumsal araç paylaşımı: Şirketler, çalışanlarının araçları paylaşmasını sağlamak veya kendi araçlarını diğer çalışanlarla paylaşmalarına izin vermek amacıyla araç paylaşımı programları oluşturabilir.

Araç paylaşımının avantajları şunlar olabilir:

Çevresel etkilerin azaltılması: Daha az araç sahipliği, trafik sıkışıklığını ve hava kirliliğini azaltabilir.

Maliyet tasarrufu: Araç sahipliği yerine ihtiyaç duyulduğunda araç kiralama, yakıt ve bakım masraflarını azaltabilir.

Alan kullanımı: Birden fazla kişi tarafından paylaşılan araçlar, park alanlarının daha etkili kullanılmasını sağlayabilir.

Esneklik: Kullanıcılar, ihtiyaçlarına göre farklı türde araçları kiralamak veya paylaşmak konusunda esneklik kazanırlar.

Ancak araç paylaşımı da bazı zorlukları beraberinde getirebilir, örneğin:

Kullanılabilirlik sorunları: Yoğun talep dönemlerinde uygun araç bulma zorluğu yaşanabilir.

Temizlik ve bakım: Paylaşılan araçların temizlik ve bakımı, kullanıcılar arasında sorumluluk paylaşımı gerektirebilir.

Güvenlik ve gizlilik: Kullanıcıların kişisel eşyalarının güvende olması ve gizlilik endişeleri önemli olabilir.

Araç paylaşımı, kentsel hareketlilik ve ulaşım sisteminin daha sürdürülebilir ve verimli hale getirilmesine yönelik bir adım olarak değerlendirilir.

Yolculuk paylaşımı, bireylerin aynı güzergâhta seyahat etmeyi tercih eden kişilerin araçlarını paylaşarak seyahat etmelerini sağlayan bir ulaşım modelidir. Bu modelde, sürücüler yolculuk yapmak isteyen kişilere boş koltuklarını sunar ve yolculuk masraflarını paylaşırlar. Yolculuk paylaşımı, hem sürücülerin hem de yolcuların faydalandığı bir sistem olarak öne çıkar (Hu et al. 2021; Luo et al. 2022).

Yolculuk paylaşımının bazı temel özellikleri şunlar olabilir:

Paylaşılan masraflar: Yolculuk paylaşımında, sürücü yolculara araçlarını kullanma imkânı sunar ve yolculuk sırasında masrafları paylaşırlar. Bu masraflar arasında yakıt, park ücretleri ve araç bakımı yer alabilir.

Uygulama tabanlı platformlar: Teknoloji tabanlı platformlar, sürücülerin ve yolcuların bir araya gelmelerini ve yolculuklarını düzenlemelerini sağlar. Bu platformlar sayesinde kullanıcılar kolayca yolculuk talepleri oluşturabilir veya seyahat edecekleri zamanları belirleyebilirler.

Ortak güzergâh kullanımı: Yolculuk paylaşımı, sürücülerin ve yolcuların aynı güzergâhta seyahat etmelerini teşvik eder. Bu, trafik sıkışıklığını azaltabilir ve ulaşım sisteminin daha etkin kullanılmasına katkı sağlayabilir.

Sürdürülebilirlik ve trafik azaltma: Yolculuk paylaşımı, bireysel araç kullanımını azaltarak trafik sıkışıklığını ve hava kirliliğini azaltmaya yardımcı olabilir. Daha az araç kullanımı çevresel etkileri azaltabilir.

Sosyal interaksyon: Yolculuk paylaşımı, farklı insanların tanışmasını ve sosyal etkileşimi teşvik edebilir. Aynı güzergâhta seyahat eden kişiler arasında iletişim kurma fırsatı oluşabilir.

Yolculuk paylaşımı, sürücüler için ek gelir sağlama ve yolcular için daha ekonomik bir seyahat seçeneği sunma gibi avantajlar sunabilir. Ayrıca, kentlerde trafik yoğunluğunu azaltmak ve çevresel etkileri minimize etmek gibi genel ulaşım hedeflerine de hizmet edebilir. Teknoloji tabanlı uygulamaların yaygınlaşmasıyla birlikte, yolculuk paylaşımı daha erişilebilir hale gelmiş ve daha fazla insan tarafından kullanılan bir seçenek haline gelmiştir.

Araç havuzu, bir grup insanın aynı güzergâhta seyahat etmek üzere araçlarını paylaştığı bir ulaşım modelidir. Bu modelde, bireyler kendi araçlarıyla seyahat ediyor olabilirler veya rotalarına uygun bir araçla katılımcılar bir araya getirilir. Araç havuzu, bireysel araç kullanımını azaltmayı ve trafik yoğunluğunu düşürmeyi amaçlayan sürdürülebilir bir ulaşım alternatiftir.

Araç havuzunun temel özellikleri şunlar olabilir:

Masrafların paylaşımı: Araç havuzunda yer alan katılımcılar, araç masraflarını paylaşırlar. Bu masraflar arasında yakıt, otoyol ücretleri, park ücretleri ve araç bakımı yer alabilir. Bu sayede katılımcılar seyahat masraflarını azaltabilirler.

Sosyal ve çevresel faydalar: Araç havuzu, trafik sıkışıklığını azaltmak ve çevresel etkileri minimize etmek için kullanılan bir yöntemdir. Aynı güzergâhta seyahat eden kişilerin araçlarını paylaşarak daha az araç kullanımı sağlanabilir.

Güzergâh uygunluğu: Katılımcılar, benzer veya aynı güzergâhta seyahat eden kişilerle bir araya gelirler. Bu sayede seyahat edilen yol daha etkili bir şekilde kullanılır.

İşbirliği ve paylaşım: Araç havuzunda yer alan katılımcılar, ulaşım konusunda işbirliği yaparlar ve araçlarını paylaşarak diğer insanlarla yardımlaşırlar.

Ulaşım seçeneklerinin artırılması: Araç havuzu, toplu taşıma seçeneklerinin eksik olduğu bölgelerde veya belirli rotalarda daha fazla ulaşım seçeneği sunar.

Araç havuzu, topluluklar ve iş yerleri arasında popüler bir ulaşım modeli olarak kullanılabilir. Ayrıca, teknoloji tabanlı platformlar sayesinde insanlar kolayca uygun araç havuzlarına katılabilir ve seyahatlerini daha verimli hale getirebilirler. Bu tür paylaşım modelleri, trafik sıkışıklığını azaltmak, enerji tüketimini düşürmek ve ulaşım sistemlerini daha sürdürülebilir hale getirmek gibi çeşitli faydalar sağlayabilir.

Park Et Devam Et, genellikle şehirlerdeki trafik sıkışıklığını azaltmak ve toplu taşıma kullanımını teşvik etmek amacıyla kullanılan bir ulaşım stratejisidir. Bu konseptte, sürücüler özel araçlarıyla şehir merkezine gelirler, burada park ederler ve daha sonra toplu taşıma araçlarına geçerek seyahatlerine devam ederler (Anonim 2023h).

Park Et Devam Et sisteminin temel özellikleri şunlar olabilir:

Park alanları: Şehir merkezi veya yoğun trafiğe sahip bölgelerde, toplu taşıma duraklarına yakın park alanları oluşturulur. Bu alanlar, sürücülerin araçlarını güvenli bir şekilde bırakabilecekleri yerlerdir.

Toplu taşıma entegrasyonu: Park Et Devam Et sistemlerinde, toplu taşıma araçları (otobüs, metro, tren) park alanlarına yakın bir şekilde duraklar bulundurulur. Bu sayede sürücüler, araçlarını park ettikten sonra hızlı ve kolay bir şekilde toplu taşıma araçlarına geçebilirler.

Trafik azaltma: Park Et Devam Et sistemi, şehir merkezindeki trafiği azaltmayı hedefler. Sürücüler araçlarıyla doğrudan merkeze gitmek yerine park alanlarına bırakarak toplu taşıma araçlarına geçerler, bu da trafik yükünü azaltır.

Çevresel etkiler: Daha fazla insanın toplu taşıma kullanması, hava kirliliğini ve sera gazı emisyonlarını azaltabilir. Özel araç kullanımının azalması çevresel etkileri olumlu şekilde etkileyebilir.

Kolay erişim: Sürücüler için kolay park etme imkânı ve hızlı toplu taşıma erişimi sunar. Bu da daha az stresli ve daha verimli bir seyahat deneyimi sağlayabilir.

Park Et Devam Et sistemi, şehirlerde sürdürülebilir ulaşım stratejileri arasında önemli bir yer tutar. Bu yaklaşım, bireyleri özel araç kullanımından vazgeçmeye teşvik ederken toplu taşıma kullanımını artırabilir. Ayrıca, trafik sıkışıklığına, otopark sorunlarına ve çevresel sorunlara çözüm oluşturabilir.

Alan Trafik Kontrolü, bir bölge içindeki trafik akışını optimize etmek ve düzenlemek için kullanılan bir ulaşım yönetimi ve trafik kontrol stratejisidir. Bu yaklaşım, trafik ışıkları, trafik işaretleri, sinyalizasyon sistemleri, kameralar ve sensörler gibi teknolojik altyapıları kullanarak trafik akışını daha akıcı hale getirmeyi amaçlar.

Alan Trafik Kontrolünün temel amacı şunlardır:

Trafik akış optimizasyonu: Alan içindeki trafik sıkışıklığını azaltmak ve trafik akışını daha verimli hale getirmek için trafik ışıklarını senkronize etmek ve trafik yönlendirmesini optimize etmek.

Trafik sıkışıklığının azaltılması: Akıllı trafik yönetimi, trafik sıkışıklığını azaltarak seyahat sürelerini ve trafik yavaşlamalarını minimize etmeye yardımcı olabilir.

Çevresel etkilerin azaltılması: Daha akıcı trafik akışı, yakıt tüketimini ve emisyonları azaltabilir böylece çevresel etkileri minimize edebilir.

Trafik güvenliği ve kazaların azaltılması: Akıllı trafik yönetimi, trafik işaretleri ve trafik ışıkları gibi unsurları entegre ederek trafik güvenliğini artırabilir ve kazaların sayısını azaltabilir.

Kamu hizmeti geliştirme: Alan Trafik Kontrolü, topluluklara ve şehir yönetimlerine daha etkili ve sürdürülebilir bir trafik yönetimi hizmeti sunarak halk hizmetini geliştirebilir.

Bu tür sistemler genellikle trafik yönetimi merkezleri tarafından izlenir ve kontrol edilir. Sensörler ve kameralar, trafik durumunu gerçek zamanlı olarak izlemek ve trafik

yoğunluğu hakkında veri toplamak için kullanılır. Toplanan verilere dayanarak, trafik ışıkları ve yönlendirmeler dinamik olarak ayarlanabilir böylece trafik akışı optimize edilir. Alan Trafik Kontrolü, şehirlerdeki trafik sorunlarını çözmek ve ulaşım sistemini daha verimli hale getirmek için kullanılan önemli bir araçtır. Teknoloji ilerlemesiyle birlikte daha akıllı ve entegre trafik yönetimi sistemleri geliştirilerek trafik sıkışıklığı ve çevresel etkilerin azaltılması hedeflenmektedir.

Sıkışıklık Ücretlendirme, trafik sıkışıklığını azaltmak ve şehir içi trafiği yönetmek amacıyla kullanılan bir ulaşım yönetimi stratejisidir. Bu yöntemde, yoğun saatlerde veya belirli bölgelerde araç kullanımını düzenlemek ve teşvik etmek amacıyla sürücülerden belirli bir ücret alınır (Çodur ve Harun 2018).

Sıkışıklık ücretlendirmesi, genellikle şehir merkezindeki yoğun trafik bölgelerinde uygulanır ve aşağıdaki şekillerde çalışır:

Ücret alanı belirleme: Şehir merkezi veya yoğun trafik bölgeleri belirlenir ve bu bölgelere giren araçlardan bir ücret alınması planlanır.

Zaman aralığı: Sıkışıklık ücreti, yoğun trafiğin olduğu belirli saatlerde veya günlerde geçerli olabilir. Bu, özellikle iş saatlerinde trafiği azaltmaya yardımcı olabilir.

Ücret miktarı: Giriş ücreti, belirli bir miktar veya trafik yoğunluğuna bağlı olarak değişen bir ücret olabilir. Yoğun saatlerde ücret artabilirken, düşük trafik saatlerinde daha düşük olabilir.

Ödeme ve denetleme: Araç sahipleri genellikle ödeme yapmak veya bir etiket veya elektronik sistemi kullanmak zorundadır. Denetim kameraları veya sensörler, ödeme yapmayan araçları tespit edebilir.

Sıkışıklık ücretlendirmesi, aşağıdaki avantajları sağlayabilir:

Trafik sıkışıklığının azalması: Ücretlendirme, sürücüleri şehir merkezine gitmek veya belirli bölgeleri kullanmak konusunda daha düşünerek hareket etmeye teşvik edebilir.

Toplu taşıma kullanımının artması: Ücretlendirme, toplu taşıma kullanımını teşvik ederek, toplu taşımanın daha çekici hale gelmesini sağlayabilir.

Çevresel etkilerin azalması: Daha az araç trafiği, hava kirliliğini ve sera gazı emisyonlarını azaltabilir.

Şehir içi yaşam kalitesi: Daha az trafik sıkışıklığı, gürültü ve stresi azaltabilir böylece şehir içi yaşam kalitesini artırabilir. Ancak sıkışıklık ücretlendirmesi bazı zorlukları da beraberinde getirebilir, örneğin:

Ekonomik etkiler: Sürücüler, ücretlerin ekonomik yüküne karşı çıkabilir ve bunun ekonomik etkileri olabilir.

Eşitsizlik endişeleri: Sıkışıklık ücretlendirmesi, düşük gelirli veya zorunlu olarak araç kullanmak zorunda olan kişilere karşı eşitsizlik yaratabilir.

Alternatif yolların kullanımı: Sürücüler, ücretleri ödememek için alternatif yolları kullanabilir bu da trafik akışını değiştirebilir.

Sıkışıklık ücretlendirmesi, şehirlerde trafik yönetiminde etkili bir araç olarak kullanılırken, dikkatli planlama ve politika oluşturma gerektirir. Başarılı bir uygulama için toplumun geniş kesimleriyle işbirliği ve iletişim önemlidir.

Gelişmiş taksi uygulamaları, geleneksel taksicilik hizmetlerini modern teknolojiyle birleştirerek kullanıcılara daha iyi ve daha kolay bir taksi deneyimi sunmayı amaçlar. Bu uygulamalar, sürücüler ve yolcular arasındaki etkileşimi artırırken aynı zamanda hızlı ve güvenilir hizmet sunmayı hedefler. İşte bazı popüler gelişmiş taksi uygulamalarının örnekleri:

Uber: Uber, dünya genelinde en bilinen ve yaygın olarak kullanılan gelişmiş taksi uygulamalarından biridir. Kullanıcılar, akıllı telefonları üzerinden yakındaki sürücüleri bulabilir, talepte bulunabilir, fiyatları kontrol edebilir ve seyahatlerini kolayca planlayabilirler. Uber'in kullanıcı dostu ara yüzü ve ödeme kolaylıklarıyla bilinir (Anonymous 2023c).

Lyft: Lyft, ABD'de özellikle yaygın olan bir taksi hizmeti uygulamasıdır. Uber'e benzer şekilde, kullanıcılar uygun sürücüleri bulabilir, fiyatları görüntüleyebilir ve seyahatlerini planlayabilirler (Anonymous 2023d).

Didi Chuxing: Çin merkezli Didi Chuxing, Çin ve diğer bazı ülkelerde faaliyet gösteren büyük bir taksi hizmeti platformudur. Didi, farklı hizmet seviyeleri sunarak kullanıcıların tercihlerine daha iyi yanıt verme amacını taşır (Anonymous 2023e).

Grab: Güneydoğu Asya'da popüler olan Grab, Uber'in bu bölgedeki rakibi olarak faaliyet gösteriyor. Tek uygulama içinde taksi, motosikletli taşıma ve özel araç kiralama gibi farklı ulaşım seçeneklerini sunar (Anonymous 2023f).

Gelişmiş taksi uygulamaları genellikle aşağıdaki avantajları sağlar:

Kolay kullanım: Kullanıcı dostu ara yüzleri ve sezgisel navigasyonlarıyla kullanıcıların hızlıca hizmetleri kullanmalarını sağlar.

Hız ve verimlilik: Kullanıcılar yakındaki sürücüleri hızlıca bulabilir ve talep edebilirler, bu da hızlı ve verimli yolculukları teşvik eder.

Fiyat şeffaflığı: Kullanıcılar, yolculuk maliyetini önceden görebilirler böylece sürpriz ücretlerden kaçınabilirler.

Değerlendirmeler ve geri bildirimler: Kullanıcılar, sürücüler hakkında geri bildirimde bulunabilir ve bu geri bildirimler gelecekteki kullanıcılar için faydalı olabilir.

Ancak bu tür uygulamaların bazı zorlukları da vardır, örneğin:

Regülasyon ve yasal konular: Bazı bölgelerde, gelişmiş taksi uygulamalarıyla ilgili regülasyonlar ve yasal zorluklar olabilir.

Rekabet: Bu alanda yoğun bir rekabet vardır ve farklı hizmet sağlayıcıları arasında mücadele yaşanabilir.

Sürücü ve yolcu güvenliği: Uygulamanın sağladığı sürücü ve yolcu güvenliği kritik önem taşır.

Gelişmiş taksi uygulamaları, mobil teknolojinin ve paylaşım ekonomisinin bir parçası olarak günümüzde önemli bir role sahiptir. Yolculuk deneyimini geliştirme, trafik akışını etkileme ve daha iyi ulaşım seçenekleri sunma amacıyla sürekli olarak geliştirilmektedirler.

Yıkıcı ve yenilikçi teknolojiler, AUS’u temelde dönüştüren ve geleneksel ulaşım yöntemlerini radikal bir şekilde değiştiren teknolojilerdir. Bu teknolojiler, ulaşım sistemlerini daha etkili, verimli, güvenli ve sürdürülebilir hale getirmeyi amaçlar. AUS, dijitalleşme ve bağlantılı cihazlar sayesinde daha entegre ve bilgiye dayalı bir yaklaşım sunar. Yıkıcı ve yenilikçi teknolojilerin AUS’a etkisi şu şekillerde açıklanabilir:

Otonom araç teknolojileri: Otonom sürüş teknolojileri, sürücüsüz araçların geliştirilmesi anlamına gelir. Bu teknolojiler, AUS için büyük bir yıkıcı etki yaratır. Otonom araçlar, trafik kazalarını azaltabilir, trafik akışını daha akıcı hale getirebilir ve yolculukları daha güvenli ve verimli hale getirebilir.

Bağlantılı araçlar (V2V ve V2I): V2V ve V2I, trafik yönetimini ve güvenliğini büyük ölçüde artırabilir. Bu teknolojiler sayesinde araçlar anlık olarak bilgi alışverişi yaparak trafik sıkışıklığını önleyebilir, kazaları azaltabilir ve yolculuk sürelerini kısaltabilir.

Paylaşım ekonomisi ve mobil uygulamalar: Yıkıcı teknolojiler, paylaşım ekonomisini destekleyen mobil uygulamaların geliştirilmesine olanak tanır. Bu uygulamalar, sürücülerin ve yolcuların daha kolay bağlantı kurmasını, araç paylaşımını teşvik etmesini ve toplu taşıma kullanımını artırmasını sağlar.

Akıllı trafik yönetimi ve tahmin: Büyük veri analitiği, trafik akışını daha iyi yönetmek ve tahmin etmek için kullanılabilir. Bu sayede trafik sıkışıklığı önceden tahmin edilebilir ve alternatif rotalar veya seyahat saatleri önerilebilir.

Elektrikli ve otonom ulaşım: Elektrikli araçlar ve otonom taşıma modları, AUS'un sürdürülebilirliğini artırabilir. Elektrikli araçlar, çevresel etkileri azaltabilirken otonom taşıma modları, toplu taşıma sistemlerini ve trafik yönetimini optimize edebilir.

Mikro hareketlilik ve elektrikli scooterlar: Yenilikçi mikro hareketlilik araçları, kısa mesafe yolculuklarını daha hızlı ve çevre dostu hale getirebilir. Elektrikli scooterlar gibi araçlar, trafik yoğunluğunu azaltabilir ve şehir içi ulaşımın daha esnek hale gelmesini sağlayabilir.

Uzaktan ve esnek çalışma modelleri: Yıkıcı teknolojiler, uzaktan çalışma ve esnek çalışma modellerini destekler. Bu da yolculuk taleplerini azaltabilir ve trafik yoğunluğunu düşürebilir.

Sonuç olarak yıkıcı ve yenilikçi teknolojiler, AUS'u daha etkili, güvenli, çevre dostu ve verimli hale getirir. Bu teknolojiler geleneksel ulaşım paradigmasını değiştirerek daha sürdürülebilir ve akıllı bir ulaşım geleceğini şekillendirebilir. Ancak bu dönüşümün yönetilmesi ve düzenlemelerin yapılması önemlidir çünkü bu teknolojiler aynı zamanda regülasyon ve güvenlik zorlukları da beraberinde getirebilir.

Otonom araç teknolojileri, insan müdahalesi olmaksızın otomatik olarak hareket edebilen ve çevresel koşulları algılayarak kararlar verebilen araçlara atıfta bulunur. Bu araçlar, sensörler, kameralar, radarlar, lazer tarayıcılar ve yapay zekâ gibi teknolojileri kullanarak etraflarındaki nesneleri algılar, yorumlar ve buna göre tepki verirler.

3. MATERYAL VE YÖNTEM

Otonom araç teknolojileri, genellikle altı seviyeye ayrılan bir otonom sürüş ölçeğine dayanmaktadır:

Seviye 0 (Sürücü Destekli): Sürücü aracı tamamen kontrol eder ve otomasyon desteklenmez.

Seviye 1 (Kısmi Otomasyon): Araç, belirli görevleri (hız kontrolü veya şerit takibi) otomatik olarak gerçekleştirebilir ancak sürücü dikkatini korumalıdır.

Seviye 2 (Kısmi Otomasyon): Araç, belirli koşullar altında hız kontrolü, şerit takibi ve bazı manevraları gerçekleştirebilir ancak sürücü sürekli dikkatli olmalıdır.

Seviye 3 (Şartlı Otomasyon): Araç, belirli koşullarda tam otonom sürüş yapabilir ancak sürücü sistemin müdahale etmesi gereken durumları tespit etmeli ve gerektiğinde kontrolü ele almalıdır.

Seviye 4 (Yüksek Otomasyon): Araç, belirli koşullar altında tamamen otomatik olarak sürüş yapabilir ve sürücüye ihtiyaç duymaz ancak bazı özel koşullarda (zor hava koşulları) sürücü müdahalesi gerekebilir.

Seviye 5 (Tam Otomasyon): Araç, her türlü yol ve hava koşulunda tamamen otomatik olarak sürüş yapabilir ve sürücüye ihtiyaç duymaz.

Otonom araç teknolojileri, trafik güvenliğini artırabilir, trafik sıkışıklığını azaltabilir, seyahat sürelerini kısaltabilir ve engelli bireylere daha fazla bağımsızlık sağlayabilir. Ancak bu teknolojilerin yaygınlaşması ve entegrasyonu çeşitli teknik, etik, hukuki ve güvenlik zorlukları da beraberinde getirir. Yasal düzenlemeler, etik sorunlar ve teknik sorunlar gibi konuların çözülmesi, otonom araç teknolojilerinin gelecekteki kullanımını şekillendirecektir.

Sarmal arayüzler, kullanıcıların gerçek dünya ile dijital içeriği etkileşimde bulunurken daha doğal ve yoğun bir şekilde etkileşimde bulunmalarını sağlayan

teknolojilerdir. Bu tür arayüzler, artırılmış gerçeklik (AR), sanal gerçeklik (VR) ve karışık gerçeklik (MR) gibi teknolojileri içerebilir. AUS içinde sarmal arayüzlerin kullanımı, daha etkili ve verimli ulaşım deneyimleri sunma potansiyeli taşır.

Aşağıda, sarmal arayüzlerin AUS’da nasıl kullanılabileceğine dair bazı örnekler verilmiştir:

Artırılmış Gerçeklik (AR) Navigasyon: Sürücüler veya yolcular, AR gözlükleri veya akıllı telefonlar aracılığıyla gerçek dünyayı görmeye devam ederken navigasyon talimatlarını ve yol göstericileri görüntüleyebilirler. Örneğin, navigasyon işaretleri veya yönergeleri gerçek dünyada gösterilerek daha kolay ve güvenli bir yolculuk sağlanabilir.

Sanal gerçeklik (VR) Eğitim ve Simülasyon: Sürücüler, trafik eğitimi veya güvenli sürüş simülasyonları için VR teknolojilerini kullanabilirler. Bu, sürücülerin farklı koşullar altında nasıl tepki vereceğini öğrenmelerine yardımcı olabilir.

Yolcu eğlencesi ve bilgi: Yolcular, araç içinde VR gözlükleri veya AR cihazları kullanarak eğlence içeriğini (filmler, oyunlar, turistik bilgiler) deneyimleyebilirler.

Araç içi kontroller ve göstergeler: AR teknolojisi, araç içi kontrolleri ve göstergeleri sürücülerin görüş alanına yansıtarak daha kolay ve güvenli bir kullanım sağlayabilir.

Trafik ve yol durumu bilgileri: Yolcular, AR cihazları kullanarak gerçek zamanlı trafik ve yol durumu bilgilerini görsel olarak görebilirler.

Yolculuk planlaması ve rotasyon görüntüleme: Yolcular, sanal haritaları ve rota bilgilerini VR veya AR aracılığıyla görüntüleyerek daha iyi bir yolculuk planlaması yapabilirler.

Trafik ve araç güvenliği uyarıları: AR teknolojisi, sürücülere yol üstünde güvenlik uyarıları veya trafik işaretleri hakkında bilgi verebilir.

Sarmal ara yüzler, AUS'da daha fazla kişiselleştirme, etkileşim ve veri görselleştirmesi getirerek kullanıcı deneyimini geliştirebilir. Ancak bu teknolojilerin yaygınlaşması ve etkili bir şekilde entegre edilmesi teknik zorlukları ve kullanıcı kabulünü içerebilir. Ayrıca sürücülerin veya yolcuların sarmal ara yüzleri kullanırken dikkatlerini yoldan ayırmamaları ve güvenliği sağlamaları önemlidir.

Nesnelerin İnterneti (IoT) ve AUS, modern şehirlerde ulaşımın daha etkili, verimli, güvenli ve sürdürülebilir bir şekilde yönetilmesini sağlamak amacıyla bir araya getirilen teknolojilerdir. IoT, AUS'a büyük bir katkı sağlar ve ulaşım deneyimini hem sürücüler hem de yolcular için önemli ölçüde iyileştirir. İşte IoT ve AUS arasındaki ilişkiyi açıklayan bazı noktalar:

Trafik yönetimi ve akıllı sinyalizasyon: IoT sensörleri, trafik yoğunluğunu izleyebilir, trafik akışını analiz edebilir ve gerçek zamanlı trafik durumu hakkında veri toplayabilir. Bu veriler, trafik sinyalizasyon sistemlerini optimize etmek ve trafik sıkışıklığını azaltmak için kullanılabilir. Akıllı trafik ışıkları, trafik yoğunluğuna göre otomatik olarak ayarlanabilir ve trafik akışını optimize edebilir.

Park yönetimi ve bulma: IoT sensörleri, boş park yerlerini tespit edebilir ve sürücülere bu bilgiyi ileterek park yeri bulma sürecini kolaylaştırabilir. Bu, trafik sıkışıklığını azaltabilir ve zaman kaybını önleyebilir.

Toplu taşıma optimizasyonu: IoT cihazları, toplu taşıma araçlarının konumunu ve durumunu izleyebilir. Bu sayede toplu taşıma rotaları daha iyi planlanabilir, gerçek zamanlı güzergah ve tahmini varış saatleri sunulabilir.

Kaza ve acil durum izleme: IoT sensörleri ve veri analitiği, trafik kazalarını veya acil durumları hızlı bir şekilde tespit edebilir ve ilgili kuruluşa bildirebilir. Bu durum acil müdahale süreçlerini hızlandırabilir ve güvenliği artırabilir.

Akıllı araçlar ve otonom sürüş: IoT, araçlar arasında iletişim kurmayı ve yolculuk sırasında bilgi paylaşımını sağlar. Aynı zamanda otonom araçların güvenli bir şekilde

etkileşimde bulunmasına yardımcı olabilir. Araçlar, trafik ve yol durumu hakkında gerçek zamanlı verileri alabilir ve buna göre hareket edebilir.

Trafik akışı ve emisyon izleme: IoT sensörleri, hava kalitesi ve trafik emisyonlarını izleyebilir. Bu veriler, şehir yönetimlerine çevresel etkiler hakkında bilgi vererek çevre dostu ulaşım politikalarının oluşturulmasına yardımcı olabilir.

Yolculuk paylaşımı ve akıllı tarifeler: IoT tabanlı uygulamalar, yolculuk paylaşımını kolaylaştırabilir ve sürücüler ile yolcuları bir araya getirebilir. Ayrıca, akıllı tarife sistemleri, trafik yoğunluğuna ve talebe göre ücretlendirme yapabilir.

IoT ve AUS, daha iyi trafik yönetimi, enerji tasarrufu, çevre koruma ve yolculuk deneyimi sağlayarak şehirlerin daha sürdürülebilir ve yaşanabilir hale gelmesine katkıda bulunur. Ancak bu sistemlerin entegrasyonu ve güvenliği önemlidir. Çünkü büyük miktarda verinin doğru şekilde yönetilmesi gereklidir.

5.Nesil (5G) mobil ağlar, yüksek hızlı veri iletimi, düşük gecikme süreleri ve büyük cihaz yoğunluğu gibi özellikleriyle tanınan bir kablosuz iletişim teknolojisi neslidir. Bu teknoloji, AUS’u önemli ölçüde dönüştürebilir ve daha etkili, verimli ve güvenli bir ulaşım deneyimi sunabilir. İşte 5G teknolojisinin AUS’a etkisi:

Daha hızlı ve güvenilir veri iletimi: 5G, çok daha yüksek hızlarda veri iletimi sağlar. Bu süreç trafik yönetimi, araç-araċ iletişimi ve diğ̇er akıllı ulaşım uygulamaları için daha hızlı ve güvenilir veri akışını mümkün kılar.

Düşük gecikme süreleri: 5G, düşük gecikme süreleri sağlayarak neredeyse anında veri iletimi sağlar. Otonom araçlar gibi uygulamalar için hayati önem taşır çünkü gerçek zamanlı tepki gerektiren durumlarda çok kritik olabilir.

Yüksek cihaz yoğunluğu: 5G ağları, aynı anda çok sayıda cihazın bağlanabilmesine izin verir. Trafik sensörleri, otonom araçlar, akıllı kavşaklar ve diğ̇er akıllı ulaşım bileşenleri arasındaki etkileşimi artırabilir.

Araç-iletişimi (V2V ve V2I): 5G, V2V ve V2I'yı daha etkili ve güvenilir hale getirebilir. Bu sayede araçlar birbirleriyle ve çevreleriyle daha iyi iletişim kurabilir ve trafik akışını optimize edebilirler.

Otonom araçlar ve güvenlik: 5G'nin düşük gecikme süreleri, otonom araçların güvenli bir şekilde etkileşimde bulunmasına yardımcı olabilir. Araçlar, hızla değişen trafik durumu ve diğer araçların davranışları hakkında gerçek zamanlı bilgi alabilir ve buna göre tepki verebilirler.

Akıllı trafik yönetimi: 5G'nin yüksek veri hızları ve düşük gecikme süreleri, trafik akışını daha iyi izlemeyi ve yönetmeyi mümkün kılar. Trafik yönetim merkezleri, gerçek zamanlı veriye dayalı olarak trafik akışını tahmin edebilir ve alternatif rotaları önererek trafik sıkışıklığını azaltabilir.

Uzaktan bakım ve güncellemeler: 5G, araçların uzaktan teşhis ve bakımını sağlayabilir. Ayrıca, araç yazılımlarının güncellenmesi için daha hızlı ve güvenli bir iletişim kanalı sağlayarak araçların güncel kalmasını sağlayabilir.

Sonuç olarak, 5G teknolojisi, AUS'un daha etkili, verimli ve güvenli hale gelmesine olanak tanır. Bu teknoloji, akıllı şehirlerin geliştirilmesi ve geleceğin ulaşım ihtiyaçlarına cevap verilmesi için önemli bir bileşen olarak kabul edilir.

Bulut bilişim (cloud computing), internet üzerinden paylaşılan ve istemci cihazlarına sunulan bilgi işlem kaynaklarına erişim sağlayan bir teknoloji modelidir. Bulut bilişim sayesinde veri depolama, işleme, uygulama geliştirme, sunucu sağlama gibi kaynaklar, merkezi sunuculardan dağıtılan ve yönetilen hizmetler olarak sunulabilir. Bu teknoloji AUS için çeşitli avantajlar sunar:

Veri depolama ve yönetimi: AUS büyük miktarda veri üretmektedir (trafik akışı, sensör verileri, yol durumu). Bulut bilişim, bu verilerin etkin bir şekilde depolanmasını ve yönetilmesini sağlar. Veriler bulutta depolandığında, sistemler daha verimli çalışabilir ve geniş veri depolama kapasitesine erişim sağlanabilir.

Yüksek ölçeklenebilirlik: Bulut bilişim, AUS'un ihtiyaca göre ölçeklenmesini kolaylaştırır. Trafik yoğunluğu arttıkça veya yeni cihazlar sisteme eklendikçe bulut tabanlı altyapı kaynakları otomatik olarak genişletilebilir.

Veri analitiği ve yapay zekâ: AUS, büyük veri analitiği ve yapay zekâ kullanarak verileri işleyebilir ve anlamlı bilgiler üretebilir. Bulut bilişim, bu analitik işlemler için gerekli hesaplama gücünü sağlar.

Uygulama geliştirme ve dağıtımı: AUS uygulamaları ve hizmetleri bulutta geliştirilebilir ve dağıtılabılır. Yeni özelliklerin ve güncellemelerin daha hızlı bir şekilde sunulmasını sağlar.

Yedekleme ve kurtarma: Bulut bilişim, AUS verilerini yedekleyebilir ve felaket durumlarında veri kurtarma işlemlerini kolaylaştırabilir.

Uzaktan erişim ve yönetim: Bulut tabanlı AUS, uzaktan erişim ve yönetim yetenekleri sağlar. Bu sayede sistem yöneticileri herhangi bir yerden sistemleri izleyebilir, güncelleyebilir ve sorunları giderilebilir.

Maliyet tasarrufu: Bulut bilişim, donanım ve altyapı yatırımlarını azaltabilir. Gereksinimler doğrultusunda ölçeklendirilebilen bulut tabanlı hizmetler daha uygun maliyetli bir model sunabilir.

Bulut bilişim, AUS'un daha verimli çalışmasını sağlayarak trafik yönetimini, yol güvenliğini, sürdürülebilirliği ve yolculuk deneyimini geliştirebilir. Ancak, veri güvenliği ve gizliliği gibi önemli konuların ele alınması ve uygun güvenlik önlemlerinin alınması gereklidir.

Büyük veri, hacmi, hızı ve çeşitliliği nedeniyle geleneksel veri yönetim teknikleriyle işlenmesi zor olan büyük ve karmaşık veri kümelerini ifade eder. AUS, birçok farklı kaynaktan gelen büyük miktarda veri üretir ve işlemek, analiz etmek ve anlam çıkarmak açısından büyük veri teknolojilerine ihtiyaç duyar. Büyük veri, AUS'a önemli avantajlar sağlayabilir:

Trafik analizi ve tahminleri: Büyük veri analitiği, trafik akışını ve yoğunluğunu izlemek, analiz etmek ve tahmin etmek için kullanılabilir. Trafik modelleri oluşturulabilir, ani trafik sıkışıklıkları veya diğer olağandışı durumlar tespit edilebilir.

Yol güvenliği iyileştirmesi: Büyük veri, trafik kazalarının nedenlerini ve desenlerini analiz edebilir. Bu analizler, yol güvenliğini artırmak için önlemler alınmasına yardımcı olabilir.

Trafik yönetimi ve akıllı sinyalizasyon: Büyük veri analitiği, trafik sinyalizasyon sistemlerini optimize etmek için kullanılabilir. Gerçek zamanlı trafik verileri, trafik akışını yönlendirmek ve sıkışıklığı azaltmak için kullanılabilir.

Araç bakımı ve performans izleme: Araç sensörlerinden gelen veriler, araçların durumu ve performansı hakkında bilgi sağlayabilir. Araç bakımını daha etkili hale getirerek güvenlik ve verimlilik sağlayabilir.

Toplu taşıma iyileştirmesi: Büyük veri analitiği, toplu taşıma rotalarını ve tahmini varış saatlerini optimize etmek için kullanılabilir. Yolcuların daha iyi bir yolculuk deneyimi yaşamalarını sağlayabilir.

Yolculuk kişiselleştirmesi: Büyük veri, yolcuların tercihlerini ve geçmiş yolculuklarını analiz ederek kişiselleştirilmiş yolculuk önerileri sunabilir.

Altyapı geliştirme kararları: Büyük veri analizi, şehir planlamacılarına ve yöneticilere trafik altyapısını geliştirmek ve optimize etmek için önemli veriler sağlayabilir.

Çevresel sürdürülebilirlik: Büyük veri, trafik emisyonlarını ve çevresel etkileri izlemek ve değerlendirmek için kullanılabilir. Çevresel sürdürülebilirliği artırmaya yardımcı olabilir.

Büyük veri, AUS'un daha etkili, verimli ve güvenli hale gelmesine olanak tanır. Ancak büyük verinin doğru şekilde işlenmesi, analiz edilmesi ve güvenli bir şekilde saklanması için uygun altyapı ve veri yönetimi stratejileri gereklidir.

Açık veri, herkesin erişimine açık, kullanılabilir ve yeniden kullanılabilir verileri ifade eder. Bu veriler genellikle hükümetler, kamu kurumları, özel sektör ve diğer kuruluşlar tarafından toplanır ve paylaşılır. AUS için açık veri önemli avantajlar sunabilir ve ulaşım deneyimini geliştirmeye yardımcı olabilir:

Trafik bilgileri ve haritalar: Açık trafik verileri ve yol haritaları, sürücülere ve yolculara gerçek zamanlı trafik durumu hakkında bilgi sağlayabilir. Trafik sıkışıklığını önlemek veya alternatif rotalar bulmak için kullanılabilir.

Toplu taşıma bilgileri: Açık veri, toplu taşıma rotaları, tarifeler ve güzergah bilgilerini içerebilir. Toplu taşımayı kullanan yolcuların daha iyi bir şekilde planlama yapmalarını sağlayabilir.

Park yeri bilgileri: Açık park yeri verileri, sürücülere boş park yerlerini bulmaları konusunda yardımcı olabilir. Trafik sıkışıklığını azaltabilir ve zaman kazandırabilir.

Hava kalitesi ve çevre verileri: Açık çevre verileri, hava kalitesi ve çevresel faktörler hakkında bilgi sağlayabilir. Sürücülerin veya yolcuların daha temiz ve sağlıklı bir yolculuk yapmalarına yardımcı olabilir.

Kaza ve güvenlik bilgileri: Açık veri, trafik kazaları ve güvenlik olayları hakkında bilgi sağlayabilir. Trafik güvenliğini artırmak ve sürücülerin dikkatli olmalarını teşvik etmek için kullanılabilir.

Sosyal ve demografik veriler: Açık veri, nüfus yoğunluğu, demografik bilgiler ve sosyal faktörler hakkında bilgi sağlayabilir. Trafik yönetimi ve ulaşım planlamasında daha iyi kararlar almak için kullanılabilir.

Ulaşım analitikleri ve araştırmaları: Açık veri, ulaşım analitikleri ve araştırmaları için kullanılabilir. Ulaşım trendlerini anlamak, altyapı geliştirme kararları almak ve ulaşım politikalarını oluşturmak için önemlidir.

Açık veri, AUS'un daha şeffaf, verimli ve kullanıcı odaklı hale gelmesine yardımcı olabilir. Ancak veri gizliliği, güvenliği ve doğru kalitede veri sağlanması gibi konuların ele alınması önemlidir. Ayrıca bu verilerin etkili bir şekilde paylaşılması ve kullanılması için uygun platformlar ve araçlar sağlanmalıdır. Önerilen bu tez çalışması kapsamında açık veri kullanımı gerçekleştirilmiştir.

Dronlar, AUS'un bir parçası olarak çeşitli şekillerde kullanılabilen önemli teknolojilerden biridir. AUS için dronların potansiyel kullanım alanları şunlar olabilir:

Trafik izleme ve denetim: Dronlar, trafik akışını gerçek zamanlı olarak izlemek ve denetlemek için kullanılabilir. Trafik sıkışıklığı, kazalar veya yol durumu gibi bilgileri sağlayarak trafik yöneticilerine ve sürücülere yardımcı olabilir.

Yol ve altyapı izleme: Dronlar, yol durumu, asfalt kalitesi, kavşaklar ve köprüler gibi altyapı unsurlarının izlenmesi için kullanılabilir. Bu sayede erken uyarılarla bakım ve onarım ihtiyaçları tespit edilebilir.

Acil durum müdahalesi: Dronlar, trafik kazaları veya diğer acil durumlar sırasında hızla olay yerine ulaşarak hasarın boyutunu değerlendirebilir ve yardım ekiplerine gerçek zamanlı bilgi sağlayabilir.

Hava kalitesi izleme: Dronlar, hava kalitesi ve çevresel faktörler hakkında veri toplayabilir. Bu veriler, hava kirliliği seviyelerini izlemek ve hava kalitesiyle ilgili tedbirler almak için kullanılabilir.

Teslimat hizmetleri: Dronlar, paket teslimatlarını hızlandırmak ve trafik sıkışıklığını önlemek için kullanılabilir. Özellikle yoğun şehirlerde hızlı teslimatlar sağlayabilirler.

Haritalandırma ve navigasyon: Dronlar, haritalandırma ve navigasyon için kullanılabilir. Yeni yol rotalarının belirlenmesi, harita güncellemeleri ve navigasyon sistemlerine veri sağlama gibi işlemlerde kullanılabilirler.

Toplu taşıma ve yolcu bilgilendirme: Dronlar, toplu taşıma hatlarını izleyerek gecikmeleri tespit edebilir ve yolculara gerçek zamanlı bilgi sağlayabilirler.

Trafik sinyalizasyonu ve yönlendirmesi: Dronlar, trafik sinyalizasyonlarının etkinliğini değerlendirebilir ve trafik akışını yönlendirmek için gerektiğinde uyarılar gönderebilir.

Dronlar, AUS'un daha etkili, verimli ve güvenli hale gelmesine yardımcı olabilir. Ancak hava sahası yönetimi, güvenlik ve veri gizliliği gibi konuların dikkate alınması gereklidir.

3.10.3. AUS mimarisi ve Türkiye

AUS mimarisi, bir şehir veya bölgedeki ulaşım sistemlerinin entegre ve koordineli bir şekilde yönetilmesini, optimize edilmesini ve geliştirilmesini sağlamak için tasarlanmış bir yapı ve yaklaşımdır. Bu mimari, çeşitli ulaşım modları, teknolojiler, veriler ve hizmetler arasındaki etkileşimi düzenler ve yönetir. Amacı, trafik sıkışıklığını azaltmak, enerji verimliliğini artırmak, çevresel sürdürülebilirliği desteklemek ve kullanıcıların daha iyi bir ulaşım deneyimi yaşamalarını sağlamaktır (Anonim 2018).

Akıllı ulaşım mimarisi genellikle aşağıdaki ana bileşenleri içerir:

Altyapı ve ulaşım modları: Bu bileşen, karayolu, demiryolu, denizyolu, havayolu gibi farklı ulaşım modlarını ve bu modların fiziksel altyapısını kapsar. Aynı zamanda toplu taşıma sistemleri, bisiklet yolları, yaya yolları gibi ulaşım unsurları da bu bileşen altında yer alır.

3. MATERYAL VE YÖNTEM

Veri toplama ve sensörler: Trafik akışı, yol durumu, hava kalitesi, sürücü davranışı gibi verileri toplamak için kullanılan sensörler ve ölçüm cihazlarıdır. GPS, kameralar ve hava kalitesi sensörleri gibi cihazlar bu verileri toplar.

Veri iletişimi ve ağlar: Ulaşım araçları, altyapı unsurları ve diğer bileşenler arasındaki iletişimi sağlamak için kullanılan ağlar, sensör ağları ve iletişim protokolleri bu bileşeni oluşturur.

Veri depolama ve işleme: Toplanan verilerin depolandığı, işlendiği ve analiz edildiği merkezi veri tabanları veya bulut tabanlı sistemlerdir. Bu bileşen, veri analitiği, tahmin modelleri oluşturma ve karar destek sistemleri için kullanılır.

Karar destek sistemleri: Veri analitiği, yapay zekâ ve makine öğrenmesi tekniklerini kullanarak trafik yönetimi, yolculuk planlaması ve park yeri tahsisi gibi konularda akıllı kararlar almayı sağlar.

Kullanıcı arabirimleri: Yolcuların, sürücülerin ve diğer kullanıcıların etkileşimde bulunabileceği mobil uygulamalar, web siteleri veya diğer ara yüzler bu bileşeni oluşturur. Kullanıcılar, ulaşım bilgilerine erişebilir, bilet satın alabilir, rota planlaması yapabilir ve güzergâh bilgisi alabilir.

Toplu taşıma ve paylaşımlı ulaşım sistemleri: Toplu taşıma ağları, paylaşımlı ulaşım platformları ve diğer entegre ulaşım hizmetleri bu bileşenleri içerir. Bireylerin araçlarını paylaşmalarını veya toplu taşıma kullanmalarını teşvik eder.

Güvenlik ve gizlilik: Ulaşım sistemlerinin güvenliği, veri gizliliği ve siber güvenlikle ilgili önlemler bu bileşenin önemli bir parçasını oluşturur.

Çevre ve sürdürülebilirlik: Çevresel faktörlerin izlenmesi, emisyonların azaltılması, enerji verimliliğinin artırılması gibi çevre dostu stratejileri içerir.

Akıllı ulaşım mimarisi, bu bileşenlerin birbirleriyle etkileşimini ve entegrasyonunu sağlayarak daha iyi bir ulaşım sistemi oluşturmayı hedefler. Gelişmiş ülkelerde AUS uygulamaları sektörel rekabet haline gelmeye başladığında gelişmekte olan ülkeler AUS için stratejik hazırlıklar yapmaktaydı. Ülkemizde AUS ile ilgili olarak ilk yüzeysel etkileşim 2006 yılında gerçekleşmiştir. AUS stratejisine yol gösteren ilk belgeler aşağıdaki gibidir:

- Dokuzuncu Kalkınma Planı (2007-2013)
- Bilgi Toplumu Stratejisi ve Eki Eylem Planı (2006-2010)
- UDHB Stratejik Planı (2009-2013)
- Ulaşım ve İletişim Stratejisi Hedef 2023
- Ulusal İklim değişikliği ve Strateji Belgesi (2011-2020)
- Ulusal Bilim Teknoloji ve Yenilik Stratejisi ve Eki Eylem Planı (2011-2016)
- Trafik Güvenliği Eylem Planı (2011-2020)
- Enerji Verimliliği Strateji Belgesi (2012-2023)

Bu politika belgeleri ile AUS için ilk adımlar atılmış ancak AUS stratejisine yol göstermede ve vizyon sunmakta oldukça yetersiz kalmıştır. Bu durum AUS strateji belgesi hazırlanma zorunluluğunu beraberinde getirmiştir. Ayrıca ülkemizde kentleşmenin, motorlu taşıt sayısının, özel araç sahipliğinin ve hareketlilik isteğinin artması karayolu ulaşımında konfor, rahatlık ve güveni olumsuz etkilemektedir. Küresel nitelikte değerlendirilebilecek eğilimler ile bu sorunların ortadan kalkması ve AUS'un planlı ve sistemli yapıya kavuşturulması için AUS strateji belgesi kritik bir işleve sahip olacaktır.

Oluşturulan AUS strateji belgesi karayollarının geleneksel bakış açısını değiştireceği ve yeni bir yol haritası oluşturması bakımından birçok paydaşın fikri dikkate alınarak oluşturulmuştur. Eski ismi ile Ulaştırma, Denizcilik ve Haberleşme bakanlığı başkanlığında; KGM, İçişleri Bakanlığı, Bilim Sanayi ve Teknoloji Bakanlığı, Çevre ve Şehircilik Bakanlığı, TÜBİTAK, EGM, Belediyeler, Üniversiteler ve birçok ilgili sektör ve sivil toplum kuruluşlarından yaklaşık 220 temsilci ile bu belgenin hazırlanması tamamlanmıştır. İlk çalışmalar 2012 yılında başlatılarak “Akıllı Ulaşım Sistemleri

Çalıştayı” icra edilmiştir. Bu belge ile Türkiye’nin 2014-2023 dönemi vizyonu ve uygulanması gereken öncelikli politikalar uzman görüşleri ile belirlenmiştir. Oluşturulan belgenin eylem planı 2014-2016 yıllarını kapsamakta ve 38 eylem, 21 hedef ve 5 stratejik amaçtan oluşmaktadır. Hedeflenen eylemlerden 9 adedi bu sürede tamamlanırken geri kalanların belirtilen yıllarda tamamlanması hedeflenmektedir. Belgenin hazırlandığı tarih ile günümüz arasında bilgi ve iletişim teknolojileri bakımından büyük bir fark vardır. Özellikle ulaştırma sektörü bu gelişimden etkilenmiştir. Bağlantılı araçlar, otonom araçlar, hızlı lojistik ve yapay zekâ tabanlı çözümler ile K-AUS ciddi manada farklı boyutlar kazanmıştır. Bu gelişime ayak uydurmak ve toplumsal ihtiyaçların karşılanması zorunluluğu 2014 yılında hazırlanan stratejik belgesinin güncellenmesi ihtiyacını doğurmuştur.

3.10.4. Ülkemizde AUS kapsamında yapılan çalışmalar

Ülkemizde yaygın olarak kullanılan AUS uygulamaları başlıca akıllı trafik yönetim merkezi, akıllı sinyalizasyon sistemleri, cep trafik uygulaması, trafik izleme sistemleri, tünel ve üst geçit izleme sistemleri, elektronik bariyer yönetimi, akıllı kavşaklar, toplu taşıma akıllı duraklar, elektronik ücret toplama sistemleri ve yolcu bilgilendirme sistemleridir. Bu uygulamalar neredeyse tüm illerde aktif olarak hizmet vermektedir. Ayrıca sadece karayolu ulaşımında değil diğer ulaşım modlarında da kullanılmaktadır. AUS çerçevesi kapsamında birçok kamu kurum ve kuruluşlar faaliyetlerini aktif şekilde yürütmektedir. AUS çok paydaşlı ve uygulama sahası geniş olan toplumsal ihtiyaçlara çözüm önerileri sunan bir sistem olarak ülkemizdeki kurum ve kuruluşların yapmış oldukları çalışmalar ve sahip oldukları yetenekler dikkat çekicidir.

Karayolları Genel Müdürlüğü; Karayolu ulaşım ağı içerisinde AUS uygulamaları oldukça geniş bir yelpazeye sahiptir. Bu uygulamalar arasında sinyalizasyon sistemleri, yol ve hava durum kontrol sistemleri, ücret toplama sistemleri, ağırlık ve boyut kontrol sistemleri, olay algılama sistemleri, tünel kontrol sistemleri, radyo yayın sistemleri, mobil uygulamalar ve değişken mesaj işaretleri bulunmaktadır. Bu faaliyetlerin yanı sıra trafik kontrol ve yönetim merkezleri kurulumu gerçekleştirilmekte, iletişim altyapısı ve sistem kurulumları hayata geçirilmekte ayrıca ulaşımın dair planlama faaliyetleri de titizlikle yürütülmektedir (Anonim 2023i).

Türkiye Cumhuriyeti Devlet Demiryolları; Sürüş güvenliğinin artırılması ve demiryolu güvenliğinin sağlanması amacıyla sinyalizasyon ve sürücü destek sistemleri önemli bir rol oynamaktadır. Bu çerçevede, demiryolu ağının sürekli gözlemlenmesi için kamera izleme sistemleri de kullanılmaktadır. Ayrıca, hareket kısıtlılığı olan bireylerin en iyi şekilde ulaşım hizmetlerinden yararlanabilmesi için gerekli altyapı tedbirleri araçlarda ve istasyonlarda sağlanmıştır. Yeni inşa edilen veya hizmete alınan demiryolu, metro ve tramvay araçları ile hatları ve istasyonlarında da AUS uygulamaları yaygın bir şekilde kullanılmaktadır.

Çevre ve Şehircilik Bakanlığı; 2014-2018 dönemi 10. Kalkınma Planı, 2016-2019 dönemi Ulusal e-Devlet Stratejisi ve Eylem Planı, 2015-2018 dönemi Bilgi Toplumu Stratejisi ve Eylem Planı ve 2017-2020 dönemi Ulusal Genişbant Stratejisi ve Eylem Planı gibi ulusal ölçekte hazırlanan strateji ve eylem planlarında akıllı kent stratejisinin ve programının oluşturulması görevini üstlenmiştir. Bu doğrultuda 24 Aralık 2019 tarihli ve 30988 sayılı Resmi Gazete'de yayımlanan 2020-2023 Ulusal Akıllı Şehirler Stratejisi ve Eylem Planı Genelgesi yürürlüğe girmiştir. Bu plan, akıllı şehirlerin geliştirilmesi ve uygulanması için belirli hedefler ve eylemleri içermektedir.

Sanayi ve Teknoloji Bakanlığı; Otomotiv sektöründeki üretimin uluslararası standartlara uygun bir şekilde gerçekleşebilmesi için Türkiye Otomotiv Sektörü Strateji Belgesi ve Eylem Planı (2016-2019), Sanayi ve Teknoloji Bakanlığı tarafından oluşturulmuştur (Anonim 2016). Bu belge, otomotiv sektörünün gelişimi ve sürdürülebilirliği için önemli bir rehber niteliğindedir. Ulaşım araçlarında yer alan sürücü destek sistemleri, acil durum fren sistemi, aktif hız sabitleme sistemi, şerit takip sistemi, e-Call ve benzeri AUS uygulamalarının ülkemizde de geliştirilmesi için gerekli uyumluluk çalışmaları, Sanayi ve Teknoloji Bakanlığı tarafından yürütülmektedir. Ülkemizde AUS kapsamında, girişimcilere, akademik personellere ve özel sektör firmalarına destek ve teşvikler verilmektedir. Bu teşviklerden bazıları, TÜBİTAK TEYDEB, KOSGEB, San-Tez ve Kalkınma Ajansları tarafından sağlanmaktadır. Bu destekler, inovasyon ve teknolojik gelişmeyi teşvik ederek ülkemizin AUS alanındaki yetkinliğini artırmayı hedeflemektedir.

İçişleri Bakanlığı İller İdaresi Genel Müdürlüğü; Ülkemizde farklı acil yardım çağrıları için (yangın, sağlık, asayiş) için farklı hizmet numaraları kullanılmaktaydı ve bu hizmet numaralarının tek bir numara (112) altında birleştirilmesi amacıyla 112 Acil Çağrı Merkezlerinin kurulum çalışmaları İller İdaresi Genel Müdürlüğü tarafından sağlanmıştır. Ayrıca AUS kapsamındaki diğer çalışmalar arasında Uyumlaştırılmış Araç İçi Acil Çağrı Sistemi Projesi, 112 Acil Çağrı Merkezi ve Engelsiz 112 Projesi gibi projeler de tamamlanmıştır. Bu projeler, acil durum iletişim sistemlerinin daha etkili ve hızlı bir şekilde çalışmasını sağlayarak vatandaşların güvenliğini ve sağlığını korumayı amaçlamaktadır (Anonim 2023k).

Emniyet Genel Müdürlüğü ve Jandarma Genel Komutanlığı; EGM ve Jandarma Genel Komutanlığı (JGK), karayolu güvenliğinin artırılması, ulaşım sistemi verimliliğinin yükseltilmesi ve işletme şartlarının iyileştirilmesi amacıyla elektronik denetleme sistemleri kurmaktadır. Yol sensörleri, trafik yoğunluk haritaları, trafik kural ihlali tespiti, plaka tanıma sistemleri, trafik eğitimi gibi bir dizi çalışmayla AUS'un gelişimine ve yaygınlaşmasına katkı sağlamaktadır. EGM ve JGK, trafiği düzenleme ve denetleme amaçları doğrultusunda şehir içi ve şehirlerarası yollarda Elektronik Denetleme Sistemi (EDS) uygulamalarını yaygınlaştırmak için çaba sarf etmektedir. Ayrıca KGM'ye bağlı otoyollarda pilot bölgelerde ortalama hız denetimi uygulamaları gerçekleştirilmekte ve bu uygulama otoyol dışındaki karayolu ağında da yaygınlaştırılması için EGM tarafından çalışmalar yürütülmektedir. JGK ise güvenlik amaçları doğrultusunda plaka tanıma sistemi uygulamasını ülke genelinde yaygınlaştırmak için çaba göstermektedir. Bu tür çalışmalar, trafik güvenliğini artırmak, trafik akışını düzenlemek ve sürücülerin trafik kurallarına uymasını teşvik etmek amacıyla gerçekleştirilmektedir.

Büyükşehir belediyelerinde bir dizi AUS uygulamalarına rastlanmaktadır. Bu uygulamalar trafik yönetimi, toplu taşıma, trafik güvenliği ve yolcu deneyimi gibi alanlarda çeşitli çözümler sunmaktadır.

Hız ihlal ve kırmızı ışık ihlal tespiti: Bu sistemler, sürücülerin hız limitlerine ve trafik kurallarına uymalarını sağlamak amacıyla kullanılır. Hız aşımaları ve kırmızı ışık ihlalleri otomatik olarak tespit edilir ve cezalar verilir. Ayrıca emniyet şeridi ihlali,

3. MATERYAL VE YÖNTEM

kırmızı ışık ihlali, koridor hız ihlali, ters yön ihlali, park ihlali ve tramvay yolu ihlali için tespit sistemleri de yerel yönetimler tarafından uygulanmaktadır.

Trafik yoğunluğu takibi: Trafik yoğunluğunun gerçek zamanlı olarak izlenmesi ve analiz edilmesi, trafik akışının daha etkin yönetilmesini sağlar. Özellikle İstanbul, Ankara gibi büyükşehirler bu konuda oldukça başarılı hizmetler sağlamaktadır. İBB trafik yoğunluk haritası kullanıcılara geniş ve anlamlı veri sağlamaktadır.

Otomatik plaka tanıma ve okuma sistemleri: Plakaların otomatik olarak tanınması ve okunması sayesinde trafik denetimi ve güvenliği artırılır.

Yolcu bilgilendirme sistemleri: Toplu taşıma kullanıcılarına gerçek zamanlı bilgiler sunarak yolculuk deneyimini geliştirir. Araç içi bilgilendirme, mobil yolcu bilgilendirme, durak bilgilendirme, anons ve haberleşme sistemleri sıklıkla kullanılan AUS uygulamalarıdır.

Elektronik ödeme sistemleri: Toplu taşıma ücretlerinin elektronik olarak ödenmesini sağlayarak hızlı ve kolay ödeme yöntemleri sunar. Son zamanlarda kredi kartı temassız özelliği de bu sisteme dâhil olarak nakit para alışverişinin tamamen ortadan kaldırılması ve yolcu veri tutarlılığı ile şeffaf toplu ulaşım amaçlanmıştır.

Akıllı kavşak ve duraklar: Trafik akışının daha verimli ve düzenli bir şekilde sağlanması için akıllı kavşak ve duraklar kullanılır.

Akıllı otopark bilgilendirme sistemleri: Boş otopark yerlerinin ve kapasitelerinin takip edilmesi, sürücülere yönlendirme sağlar.

Engelliler için özel tasarlanmış ulaşım çözümleri: Hareket kısıtlılığı olan bireylerin daha kolay ve güvenli şekilde ulaşımını sağlayan sistemler ve altyapı düzenlemeleri yapılır.

3. MATERYAL VE YÖNTEM

Mobil uygulamalar ve trafik kontrol merkezleri: Mobil uygulamalar sayesinde sürücülerin ve yolcuların gerçek zamanlı trafik bilgisine erişmesi sağlanırken, trafik kontrol merkezleri de trafiği etkin bir şekilde yönetmeye yardımcı olur.

Toplu taşıma kart sistemleri ve elektronik ücret toplama: Toplu taşıma ücretlerinin elektronik olarak toplanması ve yönetilmesi, hızlı ve kolay bir ulaşım deneyimi sunar.

Bu tür akıllı sistemleri, büyükşehir belediyelerinin ulaşım yönetimi ve hizmet kalitesini artırmalarına yardımcı olurken, trafik akışını düzenlemek, sürdürülebilirlik ve yolcu memnuniyetini artırmak amacıyla kullanılmaktadır.

Türkiye'deki üniversiteler ile AUS arasındaki ilişki oldukça önemli ve etkili bir şekilde gelişmektedir. Üniversiteler, akademik bilgi, araştırma yetenekleri ve öğrenci potansiyeli ile AUS alanında önemli katkılarda bulunmaktadır. Türkiye'deki üniversitelerin AUS ile olan ilişkisini detaylarıyla anlatan bazı noktalar:

Araştırma ve projeler: Birçok üniversite, AUS alanında çeşitli araştırma projeleri yürütmektedir. Bu projeler, trafik akışını optimize etmek, toplu taşıma sistemlerini geliştirmek, trafik kazalarını azaltmak gibi amaçlar doğrultusunda gerçekleştirilir. Üniversiteler, bu projelerle akıllı sensör teknolojileri, veri analitiği, yapay zekâ gibi ileri teknolojileri kullanarak çözümler üretmektedir.

Eğitim ve öğrenci yetiştirme: Üniversiteler, AUS alanında uzmanlaşmış öğrenciler yetiştirmek için lisans, yüksek lisans ve doktora programları sunmaktadır. Bu programlar, öğrencilere akıllı ulaşım teknolojileri, trafik yönetimi, toplu taşıma planlaması gibi konularda bilgi ve beceri kazandırmayı hedefler.

Laboratuvar ve merkezler: Birçok üniversite, AUS için özel laboratuvarlar ve araştırma merkezleri kurmuştur. Bu merkezlerde akademisyenler ve öğrenciler, gerçek zamanlı trafik izleme, veri analizi, simülasyonlar gibi çalışmalar yaparak çeşitli projeler geliştirir.

Uygulama ve pilot projeler: Üniversiteler, AUS kapsamında pilot projeler gerçekleştirerek, geliştirdikleri çözümleri sahada test ederler. Bu projeler, yerel yönetimler, ulaşım şirketleri veya diğer paydaşlarla işbirliği içerisinde yürütülebilir.

Strateji ve politika geliştirme: Üniversiteler, AUS alanında strateji ve politika geliştirme çalışmalarına katkı sağlayabilir. Bu çalışmalar, ülkenin ulaşım planlaması, trafik güvenliği, sürdürülebilirlik gibi alanlarda yol haritalarının oluşturulmasına yardımcı olabilir.

Toplumsal farkındalık ve eğitim: Üniversiteler, AUS faydalarını ve kullanımını topluma yaymak amacıyla seminerler, konferanslar ve etkinlikler düzenleyebilir. Bu tür etkinlikler, toplumsal farkındalığı artırarak AUS'un daha geniş kitlelere ulaşmasını sağlar.

İşbirlikleri ve projeler: Üniversiteler, yerel yönetimler, ulaşım şirketleri, teknoloji firmaları ve diğer sektör paydaşları ile işbirliği yaparak ortak projeler geliştirebilir. Bu işbirlikleri, akademik bilginin sahada uygulanmasına ve gerçek dünya sorunlarına çözüm üretilmesine yardımcı olur.

Türkiye'deki üniversiteler, AUS konusunda hem akademik çalışmalar yapmakta hem de bu alandaki uygulamaları desteklemektedir. Bu işbirliği, ülkenin ulaşım altyapısının geliştirilmesi ve sürdürülebilir ulaşım çözümlerinin yaygınlaştırılması için büyük önem taşımaktadır.

Türkiye'deki üniversitelerin AUS alanında gerçekleştirdiği bazı uygulama örnekleri aşağıda sıralanmıştır:

ODTÜ - Akıllı Trafik Yönetimi Sistemi (ATYMS): Orta Doğu Teknik Üniversitesi (ODTÜ), Akıllı Trafik Yönetimi Sistemi'ni geliştirmiş ve Ankara şehir merkezinde pilot uygulama gerçekleştirmiştir. Bu sistem, trafik sinyalizasyonlarının akıllı bir şekilde yönetilmesi ve trafik akışının optimize edilmesi amacıyla kullanılmaktadır.

Boğaziçi Üniversitesi - Toplu Ulaşım Odaklı Trafik Planlaması: Boğaziçi Üniversitesi, İstanbul'da toplu taşıma sistemlerinin daha etkin ve verimli bir şekilde yönetilmesi için trafik planlaması çalışmaları yapmıştır. Bu çalışmalar, toplu taşıma rotalarının optimize edilmesi ve trafik yoğunluğunun azaltılması amacını taşımaktadır (Anonim 2023l).

Yıldız Teknik Üniversitesi - Lokal Trafik Kontrol Merkezi: YTÜ, İstanbul şehir merkezinde bulunan binlerce kamera, sensör ve radar ile gerçek zamanlı olarak trafik takip edebilen bir Lokal Trafik Kontrol Merkezi kurmuştur. Bu merkez, trafik akışını izlemek ve yönlendirmek için kullanılmaktadır (Anonim 2023m).

Okan Üniversitesi - Akıllı ve Çevreci Ulaşım Araçları: Okan Üniversitesi, akıllı ve çevreci ulaşım araçları üzerine çalışmalar yapmıştır. Bu kapsamda elektrikli araçlar, otonom araçlar ve sürdürülebilir ulaşım konularında uygulamalar geliştirmiştir (Anonim 2023n).

Bandırma Onyediy Eylül Üniversitesi - İhtisas Üniversitesi Olarak Çalışmaları: Bandırma Onyediy Eylül Üniversitesi, AUS alanında Yüksek Öğretim Kurulu (YÖK) tarafından ihtisas üniversitesi olarak belirlenmiştir ve bu alanda çalışmalar yapmaktadır (Anonim 2023p).

Gebze Teknik Üniversitesi (GTÜ) - Akıllı Ulaşım Yönetim Sistemi (AUSYS): GTÜ, Gebze bölgesinde AUS'u içeren bir proje olan AUSYS'i geliştirmiştir. Bu sistem, trafik akışını izlemek, trafik kazalarını tespit etmek ve trafik güvenliğini artırmak amacıyla kullanılmaktadır.

Eskişehir Teknik Üniversitesi (ESTÜ) - Otonom Araç Geliştirme: ESTÜ, otonom araç teknolojileri üzerine çalışmalar yapmaktadır. Bu kapsamda otonom araçların navigasyon, sensörler ve kontrol sistemleri gibi alanlarda geliştirilmesine yönelik projeler yürütülmektedir (Anonim 2023r).

Bu örnekler, Türkiye'deki üniversitelerin AUS alanında yaptıkları çeşitli uygulama ve projelerin sadece bir kısmını temsil etmektedir. Üniversiteler, farklı

kentlerde trafik akışını iyileştirmek, toplu taşıma sistemlerini geliştirmek, trafik güvenliğini artırmak ve çevre dostu ulaşım çözümleri üretmek gibi amaçlarla çeşitli uygulamalar gerçekleştirmektedir. Üniversiteler, farklı alanlarda farklı projeler yürüterek ulaşımın daha güvenli, verimli ve sürdürülebilir hale getirilmesine katkı sağlamaktadır.

Türkiye'de özel sektör, AUS alanında önemli bir rol oynamaktadır. Özel sektör, teknolojik gelişmeleri takip ederek, inovasyon ve uygulama yeteneklerini kullanarak ulaşım sektöründe çeşitli akıllı çözümler üretmekte ve bu çözümleri hayata geçirmektedir (Anonim 2023s). İşte Türkiye'deki özel sektörün AUS'daki yeri ve katkılarına dair bazı önemli noktalar:

Uygulama Geliştirme ve Teknoloji Sağlama: Özel sektör, AUS için yazılım, donanım ve teknoloji altyapısı geliştirme konusunda etkin rol oynamaktadır. Mobil uygulamalar, trafik yönetim yazılımları, akıllı ödeme sistemleri, plaka tanıma teknolojileri gibi birçok alanda özel sektör firmaları uygulama ve teknoloji sağlamaktadır.

Donanım üretimi ve entegrasyonu: Özel sektör, trafik kameraları, sensörler, plaka tanıma cihazları gibi fiziksel donanımları üretme ve entegrasyonunda rol oynamaktadır. Bu donanımların trafik akışını izlemek, araçları takip etmek ve veri toplamak gibi amaçlarla kullanılmasını sağlamaktadır.

Trafik yönetimi ve veri analizi: Özel sektör firmaları, trafik verilerini toplayarak analiz edip yönetim konusunda çeşitli çözümler sunmaktadır. Trafik yoğunluğunun izlenmesi, trafik sinyalizasyonunun optimize edilmesi, trafik kazası analizleri gibi alanlarda özel sektörün katkısı önemlidir.

Toplu taşıma ve ödeme sistemleri: Özel sektör, toplu taşıma sistemlerinin yönetimi ve ödeme sistemlerinin geliştirilmesi konusunda da etkin rol oynamaktadır. Akıllı kartlar, ödeme uygulamaları, online bilet satış platformları gibi çözümler özel sektör tarafından geliştirilmekte ve işletilmektedir.

Araç teknolojileri ve otomotiv sektörü: Otomotiv sektörü, AUS entegrasyon ve otonom araç teknolojileri konularında çalışmalar yapmaktadır. Özel sektörün bu alandaki gelişmeleri, trafik güvenliği, sürüş deneyimi ve verimlilik açısından önem taşımaktadır.

Trafik güvenliği ve acil durum çözümleri: Özel sektör, trafik güvenliğini artırmaya yönelik çözümler üretmekte ve acil durum sistemleri geliştirmektedir. Kazadan kaçınma sistemleri, araç içi acil çağrı sistemleri gibi uygulamalar bu alanda yer almaktadır.

Yatırımlar ve işbirlikleri: Özel sektör, AUS alanında yatırımlar yaparak, üniversitelerle işbirliği içinde Ar-Ge projeleri gerçekleştirmekte ve yeni teknolojileri geliştirmektedir.

Tüm bu alanlarda özel sektörün katkıları, AUS'un gelişmesi ve yaygınlaşmasında önemli bir rol oynamaktadır. İnovasyon ve teknoloji odaklı çözümler, ulaşım sektörünün daha verimli, güvenli ve çevre dostu hale gelmesine yardımcı olmaktadır.

Türkiye'deki sivil toplum kuruluşları (STK), AUS alanında farklı şekillerde etkin rol oynamaktadır. Bu kuruluşlar, toplumun çeşitli kesimlerini temsil ederek, ulaşımın daha verimli, güvenli, çevre dostu ve erişilebilir hale gelmesi için çalışmaktadır. İşte Türkiye'deki STK'ların AUS alanındaki rol ve katkılarına dair bazı örnekler:

Bilinçlendirme ve eğitim faaliyetleri: STK'lar, sürücüleri, yayaları ve toplumu AUS ve trafik güvenliği konusunda bilinçlendirmek amacıyla seminerler, eğitim programları ve kampanyalar düzenleyebilir. Bu tür etkinliklerle trafik kurallarına uyumu artırarak trafik kazalarının azaltılmasına katkı sağlanabilir.

Engelli ve hareket kısıtlılığı olan bireyler için çözümler: Engelli ve hareket kısıtlılığı olan bireylerin ulaşım ihtiyaçlarına yönelik çözümler üretmek ve öneriler sunmak amacıyla STK'lar çalışmalar yapabilir. AUS'un bu kesimin ihtiyaçlarını karşılayacak şekilde tasarlanması ve uygulanması konusunda katkı sağlanabilir.

Trafiğin düzenlenmesi ve çevre dostu ulaşım için savunuculuk: STK'lar, trafik akışının düzenlenmesi, bisiklet ve yaya yollarının geliştirilmesi gibi çevre dostu ulaşım çözümleri için savunuculuk faaliyetleri yürütebilir. Bu tür çözümlerin toplumsal farkındalığını artırarak destekleyici politikaların oluşturulmasına katkı sağlayabilirler.

Veri toplama ve analiz: STK'lar, trafik verilerinin toplanması ve analiz edilmesi konusunda rol oynayarak trafik akışının ve sorunlarının anlaşılmasına yardımcı olabilirler. Bu veriler, daha etkin ulaşım politikalarının oluşturulmasında kullanılabilir.

Hukuki süreç ve politika geliştirme: STK'lar, trafik güvenliği ve AUS konusunda hukuki düzenlemelerin yapılmasını veya güncellenmesini destekleyebilirler. Aynı zamanda, yerel ve ulusal düzeyde ulaşım politikalarının oluşturulması ve iyileştirilmesine katkı sağlayabilirler.

Lobiler ve işbirlikleri: STK'lar, ilgili paydaşlarla işbirliği yaparak ulaşım konularında lobi faaliyetleri yürütebilirler. Kamu kurumları, özel sektör, üniversiteler ve diğer STK'larla işbirliği yaparak daha etkili çözümler üretilebilir.

Trafik güvenliği ve istatistiklerin izlenmesi: STK'lar, trafik güvenliği istatistiklerini izleyerek riskli bölgeleri belirleyebilir ve çözüm önerileri sunabilir. Bu sayede trafik kazalarının azaltılması ve trafik güvenliğinin artırılması hedeflenebilir. Türkiye'deki sivil toplum kuruluşları, AUS alanında toplumun farklı kesimlerinin ihtiyaçlarına yönelik çalışmalar yaparak, ulaşımın daha etkin ve sürdürülebilir hale gelmesine katkı sağlamaktadır.

Türkiye'de AUS alanında faaliyet gösteren ve aktif olan birçok sivil toplum kuruluşu bulunmaktadır. Bu STK'lar, trafik güvenliği, çevre dostu ulaşım, toplu taşıma, sürdürülebilir ulaşım ve benzeri konularda çalışmalar yürüterek toplumsal farkındalığı artırmaya ve çözümler sunmaya çalışmaktadırlar. Türkiye Akıllı Ulaşım Sistemleri Derneği (AUSDER) bu alanda en yetkin STK olarak ön plana çıkmaktadır (Anonim 2023t).

3.10.5. Türkiye AUS stratejisi

Ulusal AUS Strateji Belgesi ve 2020-2023 Eylem Planı kapsamında belirtilen hedef ve amaçlara ulaşmak için yol haritası belirlenirken diğer dünya ülkeleri ile bu alanda yarışabilir konuma gelmenin arayışı mevcuttur. Uygulanması planlanan adımların hangi kurum ve kuruluş tarafından yapılacağı kapsamlı şekilde bu rapor ile detaylandırılmıştır (Anonim 2018).

Ulaşım, bir ülkenin ekonomik büyümesinin önemli bir itici gücüdür ve AUS bu alanda büyük bir potansiyele sahiptir. AUS, ulaşımın verimli bir şekilde yönetilmesini sağlayarak insanların ve yüklerin daha hızlı, güvenli ve sürdürülebilir bir şekilde hareket etmelerine olanak tanır. Bu da ekonomik büyümeye ve rekabet edebilirliğe olumlu etkiler sağlar. AUS'un ekonomik yönden önemli bir kaldıraç etkisi olduğu aşikârdır. İşte bu bağlamda AUS'un ekonomik faydalarından bazıları:

Verimlilik artışı: AUS, trafik akışını optimize ederek trafik sıkışıklığını azaltabilir ve yolculuk sürelerini kısaltabilir. Bu durum, işgücünün verimliliğini artırabilir ve ticaretin daha hızlı gerçekleşmesine olanak tanır.

Enerji tasarrufu: Akıllı trafik yönetimi ve taşıma optimizasyonu, yakıt tüketimini azaltabilir ve çevre dostu ulaşım modlarının teşvik edilmesine yardımcı olabilir. Enerji tasarrufu sağlar ve çevresel sürdürülebilirliği artırır.

Maliyet azaltımı: Daha etkin trafik yönetimi ve taşıma planlaması, işletmelerin lojistik maliyetlerini düşürebilir. Aynı zamanda trafik kazalarını ve zaman kayıplarını azaltarak maliyetleri minimize eder.

Yeni iş alanları ve istihdam olanakları: AUS'un geliştirilmesi ve uygulanması, yeni teknolojilerin ve hizmetlerin doğmasına yol açar. Bu da yeni iş alanlarının oluşturulmasına ve istihdamın artmasına katkı sağlar.


Ulaşım sektöründe büyüme: AUS'un uygulanması, ulaşım sektöründe teknolojik ve inovasyonel gelişmelere olanak tanır. Bu da sektörün büyümesine ve rekabet gücünün artmasına yol açar.

Kent planlaması ve yaşam kalitesi: AUS, şehirlerin daha iyi planlanmasına ve ulaşımın daha etkin bir şekilde yönetilmesine olanak tanır. Bu da yaşam kalitesini artırır ve çekici yaşam alanları oluşturur.

Gelişmiş ülkeler, AUS'un ekonomik ve sosyal faydalarını tanıyarak bu alana yatırımlar yapmaktadır. Bu yatırımlar, ülkenin sürdürülebilir büyümesine, rekabet edebilirliğine ve vatandaşların yaşam kalitesine olumlu katkılar sağlar. Bu durumlar dikkate alınarak ülkemiz için stratejik amaçlar, uzun dönem hedefleri ve eylemler uzman görüşleri ile belirlenmiştir.

3.10.6. Araç içi bilgi ve haberleşme sistemi

Araç İçi Bilgi ve Haberleşme Sistemi (ABHS), trafik ve sürüş güvenliği, sürücü bilgilendirmesi, araç ve yol durumu verilerinin toplanması, elektronik ücret tahsilatı, trafik akışının optimize edilmesi, enerji verimliliği, seyahat sürelerinde azalma ve konforlu sürüş gibi K-AUS hizmetlerinin otomobillerde kullanılması amacıyla sunulan bir teknoloji sistemidir (Anonim 2023u). ABHS, araç içindeki donanım ve yazılım bileşenlerinin bir araya geldiği bir yapıyı ifade eder. ABHS sayesinde insan sürücülü araçlarda sürücüler tehlikeli veya olağandışı durumlar hakkında bilgilendirilebilirken, otonom araçlarda ise uzaktan kontrol ve durum farkındalığı artırma gibi özellikler sağlanabilir. Bu amaçları yerine getirebilmek için ABHS, araçta bulunan V2X iletişim radyo birimi ve ilgili yazılımlar aracılığıyla diğer araçlar ve altyapı ile sürekli iletişim halinde olarak bilgi alışverişi gerçekleştirir.



Şekil 3.35. ABHS ve bileşenleri (Anonoim 2023u)

Şekil 3.35’de ABHS ve bileşenlerinin araç içinde konumlandırılması görselleştirilmiştir. ABHS'nin temel bileşenlerinden biri, çevredeki araçlarla ve diğer K-AUS unsurlarıyla iletişimi sağlayan araç üstü birim (OBU) olarak adlandırılır. Araç üzerindeki LIDAR, radar ve GNSS gibi çeşitli sensörlerden elde edilen bilgiler, Elektronik Kontrol Ünitesi (ECU) aracılığıyla araç içi ağı iletilir ve bu sayede çeşitli ABHS uygulamalarının kullanılabilir hale gelmesi sağlanır. Bu uygulamalar, elde edilen bilgilerin değerlendirilmesiyle üretilen sonuçları OBU aracılığıyla paylaşılabilir hale getirir. Bu uygulamalar çift yönlü bir şekilde işler. Benzer şekilde, diğer K-AUS bileşenleri (diğer araçlar, altyapı bileşenleri vb.) tarafından paylaşılan bilgiler de OBU aracılığıyla bu uygulamalar tarafından erişilebilir hale getirilir.

Dünya genelinde, ABHS üzerine yapılan çalışmalar, diğer teknolojilerde olduğu gibi farklı bölgeler arasında benzerlikler ve farklılıklar gösterebilmektedir. Uluslararası uyumluluk ve birlikte çalışabilirlik, her yeni teknolojiye olduğu gibi ABHS’de de önemli bir gerekliliktir. Ancak mevcut sistemler, yasal düzenlemeler, gereksinimler, öncelikler ve uygulanabilirlik durumu, coğrafi bölgelere göre farklılık göstermektedir. Bu farklılıklar, yaklaşımların ve uygulama aşamalarının da bölgelere özgü olarak değişmesine neden olabilir. Mevcut mevzuatların kısıtlamaları veya eksiklikleri, birçok nedenden ötürü düzenlemelerin, stratejik çalışmaların ve eylem planlarının hazırlanmasını gerektirmiştir. Sorumluluk paylaşımı, büyük ölçekli saha uygulamaları için önceden yapılan iyi ve nitelikli ön çalışmaların gerekliliği, kaynakların etkin kullanımı, mevcut sistemlere kolay ve doğru bir şekilde entegrasyonu, iş modellerinin doğru bir şekilde tanımlanması gibi faktörler bu gerekliliği şekillendiren unsurlardır. Bu

durum ABHS'nin benimsenmesi ve uygulanmasının, coğrafi, yasal ve teknik faktörlere bağlı olarak farklı bölgelerde farklılaşabileceği anlamına gelmektedir. Bu yüzden uluslararası düzeyde uyumlu ve işbirliğine dayalı yaklaşımların benimsenmesi, bu teknolojinin etkin ve sorunsuz bir şekilde yaygınlaştırılması için kritik bir öneme sahiptir.

Hala gelişimi süren ABHS, büyük şehirlerdeki trafik sorunları ve kazaları önleme potansiyeli taşımakla birlikte çevresel açıdan da önemli birçok soruna çözüm sunabilen bir teknolojidir. ABD, Avrupa Birliği, Japonya, Avustralya ve Güney Kore gibi ülkeler, ABHS teknolojisinin araştırılması, test edilmesi, geliştirilmesi ve uygulanması için çeşitli araştırma ve ticarileşme girişimleri yürütmektedir. Bu ülkeler, kentsel alanlarda yaşanan trafik sıkışıklığı ve kaza riskini azaltma amacıyla ABHS'nin potansiyelini değerlendirmekte ve bu teknolojinin çözüm getirebileceği çevresel zorluklara karşı bir çözüm olabileceğini görmektedir. Bu ülkeler, kendi bölgelerine özgü gereksinimleri ve mevzuatları göz önünde bulundurarak ABHS'nin uygulanabilirliğini araştırarak teknolojiyi geliştirme çabalarını yoğunlaştırmaktadır. ABHS'nin daha geniş bir kabul görmesi ve yaygınlaşması, trafik güvenliği, verimliliği ve çevresel sürdürülebilirlik gibi konularda önemli kazanımlar sağlayabilir. Bu ülkeler arası işbirliği ve deneyim paylaşımı, ABHS teknolojisinin daha etkin ve verimli bir şekilde geliştirilmesine katkı sağlamaktadır.

K-AUS, trafik verimliliği ve güvenliğini artırmada büyük bir potansiyele sahip olmasına rağmen, uygulama aşamasında çeşitli zorlukları barındıran karmaşık bir sistemdir. Bu karmaşıklık, iletişim teknolojilerinin kullanımı, büyük veri yönetimi, güvenlik ve emniyet gereksinimleri gibi faktörlerden kaynaklanmaktadır. Bu durum, farklı ülkelerdeki kamu kuruluşlarını ve yerel yönetimleri ile coğrafi olarak farklı bölgelerde bulunan endüstri kuruluşlarını işbirliği yapmaya yönlendirerek ortak bir teknolojik ilerleme hedefi oluşturmayı gerektirmektedir. Bu karmaşıklık, K-AUS'un uygulanması sırasında karşılaşılan meydan okumaları daha da vurgulamaktadır. Farklı ülkelerdeki yasal düzenlemeler, teknolojik gereksinimler ve altyapı durumları gibi faktörler, K-AUS'un benimsenmesi ve entegrasyonunu zorlaştırabilir. Bu nedenle kamu kuruluşları, yerel yönetimler ve endüstri oyuncuları arasında işbirliği ve bilgi paylaşımının teşvik edilmesi, bu teknolojinin geliştirilmesi ve uygulanmasının önündeki engelleri aşma konusunda kritik bir rol oynamaktadır. Ancak bu karmaşıklığa rağmen K-

AUS'un getirebileceği faydalar ve potansiyel, bu zorlukların üstesinden gelmeyi haklı çıkarmaktadır. Verimli trafik yönetimi, kazaların azaltılması, enerji tasarrufu ve çevresel sürdürülebilirlik gibi avantajlar, bu teknolojinin yaygınlaşmasının önemini vurgulamaktadır. Bu nedenle uluslararası işbirliği ve standartlar oluşturulması, K-AUS'un başarılı bir şekilde hayata geçirilmesi için kritik bir gerekliliktir.

Geniş çaplı ABHS uygulamaları, araçlar, altyapı ve ağlar arasında yoğun bir veri trafiğini beraberinde getirmektedir. Bu trafiğin içeriği yol emniyeti, trafik verimliliği, sürüş konforu ve araç-içi bilgi-eğlence sistemleri gibi uygulamaların iletişimi sonucu oluşmaktadır. Bu veri trafiği, kişiye özel bilgileri ve emniyet uygulamaları tarafından kullanılan emniyet-kritik parametreleri içerdiği gibi, aynı zamanda trafik verimliliği için hız, manevra gibi araç davranışlarını düzenlemeye yönelik bilgileri de içermektedir. Bu bilgilerin paylaşımı ve çeşitli uygulamalar tarafından kullanılması, ulaşımda büyük avantajlar sağlayabilir. Ancak, bu bilgilerin doğru bir şekilde gizlenmemesi ve üçüncü kişiler tarafından saldırıya açık hale gelmesi, trafik kullanıcılarının emniyetini ve kişisel bilgilerini riske atabilir. Bu nedenle, veri güvenliği ve gizliliği büyük önem taşır. Veri şifreleme, yetkilendirme ve kimlik doğrulama gibi güvenlik önlemleri, bu hassas bilgilerin sızmasını ve kötü niyetli saldırılara maruz kalmasını önlemek için gereklidir. Ayrıca, bu teknolojilerin geliştirilmesi ve uygulanması sırasında güvenlik standartlarına uyulması, kullanıcıların güvenliğini sağlamak açısından kritik bir adımdır. Büyük ölçekli ABHS uygulamalarının potansiyel faydalarını elde etmek için, bu teknolojilerin sağladığı verilerin korunması ve güvenliği sağlamak büyük bir önceliktir. Böylelikle hem trafik güvenliği ve verimliliği artırılabilir hem de bireysel kullanıcıların özel bilgileri korunabilir. Bu nedenle, aktarılan verinin ve kullanıcı bilgilerinin aşağıdaki hususları garanti altına alması gerekmektedir:

Yetkisiz üretim ve değişiklik engellenmesi: Verilerin yetkisiz kişiler tarafından üretilmesi veya değiştirilmesi önlenmelidir. Veri bütünlüğünü sağlamak ve güvenilirliği artırmak için gereklidir.

Yanıltıcı bilgi içermeme: Aktarılan veriler, yanıltıcı veya hatalı bilgiler içermemelidir. Doğru ve güvenilir verilerin kullanılmasını sağlamak amacıyla önemlidir.

3. MATERYAL VE YÖNTEM

Üçüncü kişiler tarafından takip edilememesi: Kullanıcıların ve verilerin üçüncü kişiler tarafından izlenmesi veya takip edilmesi engellenmelidir. Kullanıcı gizliliğini korumak için gereklidir.

Bu hedefleri gerçekleştirmek için, sadece veri transferi değil, aynı zamanda veri depolama sistemleri de özel verilerin gizliliğini sağlamalıdır. Üçüncü ve yetkisiz kişilerin bu verilere erişimini engellemek için güvenlik mekanizmaları gereklidir. Verilerin depolanması sırasında şifreleme ve anahtarlama gibi yöntemler kullanarak verilerin güvenliğini sağlamak önemlidir. Bu yöntemler, olası saldırı durumlarında verilerin açığa çıkmasını zorlaştırabilir. Tüm bu hususlar, veri transferi ve depolama süreçlerinin trafik güvenliğini tehlikeye atmayacak ve kişisel verilerin korunmasına yönelik düzenlemelere uygun şekilde olması gerektiğini vurgulamaktadır. K-AUS'un küresel bir eğilim olarak benimsenmesi ve uygulanması, güvenlik ve gizlilik önlemlerinin gözetilmesini gerektirir. Ülkemizde bu alanda yapılan çalışmalar Çizelge 3.11'de belirtilmiş olup aşağıdaki bölümlerde detaylı bir şekilde açıklanmıştır.

Çizelge 3.11. Türkiye’de yapılan ABHS girişimleri (Anonoim 2023u)

Kurumlar	ABHS'ye Yönelik Yönetmelik	ABHS'ye Yönelik Donanım ve Yazılım Ürünleri				ABHS Uygulamaları
		OBU	RSU	K-AUS Altyapı Ürünleri	Yazılım Ürünleri	
UAB	x					
STB	x					
KGM						x
BTK	x					
VeNIT Lab					x	x
ANADOLU ISUZU		x	x		x	
BigTRI					x	x
FORD OTOSAN		x	x		x	x
Intetra				x	x	x
NETAŞ		x	x		x	x
TOFAŞ		x	x		x	x
ULAK Haberleşme		x	x		x	
Yongatek		x	x		x	

4. MODEL EĞİTİMİ VE PERFORMANS ANALİZİ

Gerçekleştirilen çalışmanın bu bölümünde sekiz farklı ülkeye ait 10 farklı sınıfa ayrılmış yol kusurlarını algılama ve sınıflandırma analiz sonuçları yer almaktadır. Yol ağlarında meydana gelen yol kusurlarının algılanma ve sınıflandırma süreci YOLOv5, YOLOv7 ve YOLOv8 algoritmaları ile sağlanmıştır. Bu modellerin içerdiği farklı varyantlara ait analiz işlemleri de gerçekleştirilmiştir. Farklı kombinasyonlar ile gerçekleştirilen analiz süreçleri karşılaştırmalı olarak bu kısımda sunulmuştur. Elde edilen en iyi modele ait ağırlık dosyaları gerçek zamanlı olarak algılanma ve sınıflandırma sürecine dâhil edilmiştir.

4.1. YOLOv5 Analiz

YOLOv5, Hoher (2020) tarafından geliştirilmiş güçlü bir nesne algılama algoritmasıdır. Bu modelin yayınlanmış bir makalesi bulunmamaktadır. Online sayfa üzerinden literatüre girmiş ve hala günümüzde birçok araştırmacı tarafından kullanılmaktadır. Ortaya çıkış amacı gerçek zamanlı algılamada daha yüksek hızlı ve yüksek doğrulukla sonuçlar elde etmektir. YOLOv5, önceki versiyonlara kıyasla bazı küçük değişiklikler getirmiştir. Önceki sürümlerde bulunan odak yapısı değiştirilerek verimliliğin artması sağlanmıştır. YOLOv5, modelin performansını artırmak için birkaç gelişmiş eğitim stratejisi uygulamaktadır. Sonuç olarak YOLOv5, gerçek zamanlı nesne algılama modellerinin geliştirilmesinde önemli bir adımı temsil etmektedir. Çeşitli yeni özellikleri, geliştirmeleri ve eğitim stratejilerini birleştirerek performans ve verimlilikte YOLO ailesinin önceki sürümlerini performans olarak geride bırakıyor. Tüm bu yenilikler, YOLO modellerinin anahtarı olan yüksek hız derecesini korurken, nesne algılamının doğruluğunu ve verimliliğini önemli ölçüde artırır. YOLOv5 özellikle bazı araştırmacılar tarafından diğer YOLO ailesinin üyelerinden daha sık kullanılmaktadır. Bunun ana sebebi olarak algılama performansı ve hızında yüksek verim iken çalışma uyumunun fazla olması da gösterilmektedir.

Çalışma kapsamında sekiz farklı ülkeden elde edilen veri kümesinden tekrarlı görüntüler ve görüntü kalitesi düşük olanlar titizlikle ayıklanmıştır. Özellikle literatürden elde edilen görüntülerin birçoğu çalışma kapsamında değerlendirilmemiştir. Ayrıca bu

çalışmada yol kusur sınıf sayısı artırıldığından elde edilen veriler yeniden etiket ve sınıflama işleminden geçmiştir. Bu durum kullanılan verilerin kalitesini artırarak tekrar görüntülerden arındırmıştır. Çalışma kapsamında Türkiye ve Gürcistan ülkelerinden yaklaşık 10 bin adet görüntü elde edilmiş olup bu görüntülerden çalışma kapsamında 4.930 adeti kullanılmıştır. Farklı ülkelerden oluşan veri kümesi sayesinde küresel ölçekli yol kusuru algılama sisteminde ilk adım atılmıştır. Nesne algılama süreçlerinde algılanan nesnenin türü oldukça önemlidir. Özellikle yol kusurları gibi formu ve oluşumu değişken ve tahmin edilebilir olmayan nesneler için veri heterojenliği son derece önemlidir. Farklı yol görüntüsü ve kusur sınıfları sayısı arttıkça modelin sağlamlığında da artış olacaktır. Bu çalışma kapsamında üstün veri heterojenliği sağlanarak modelin algılamada karşılaçağı zorluklara karşı güçlendirilmesi gerçekleştirilmiştir.

Model eğitim aşamalarında görüntü boyutu, parti boyutu ve dönem sayısı değerleri çok önemlidir. Bu değerler eğitim verisine göre değişkenlik göstermek ile birlikte kullanılan bilgisayarın donanım durumuna da bağlıdır. Eğitim analizleri Google Colab Pro+'da gerçekleştirilmiştir. NVIDIA Tesla V100 GPU üzerinden eğitim işlemleri tamamlanmıştır. Sağlamış olduğu yüksek RAM ve GPU ile eğitim ve test analizleri gerçekleştirilmiştir. Eğitim sürecine başlamadan önce veri kümesini eğitim ve doğrulama kümelerine bölmek çok önemlidir. Eğitim, doğrulama ve test amacıyla bir veri kümesini farklı alt kümelere bölme işlemine genellikle derin öğrenme alanında veri bölme adı verilir. Veri bölme, modelin etkinliğini değerlendirme ve modelin eğitim verileri üzerindeki üstün performansı ve yeni, gözlemlenmemiş veriler üzerindeki düşük performansı ile karakterize edilen bir olgu olan aşırı uyum riskinin azaltılması şeklindeki ikili amaca hizmet eder. Bir modelin parametreleri eğitim verileri kullanılarak ayarlanırken hiper parametreler doğrulama verileri kullanılarak ince ayar yapılır. Hiper parametreler, öğrenme hızı, parti boyutu ve dönem sayısı ve bunlarla sınırlı olmamak üzere, eğitim algoritmasının davranışını belirleyen yapılandırılabilir parametreleri ifade eder. Hiper parametrelerin optimize edilmesi, modelin verilen veri kümesine yetersiz uyum ve aşırı uyum arasında uygun bir denge kurmasını sağlamada önemli bir adımdır. Son olarak, bir modelin yeni, gözlemlenmemiş veriler üzerindeki performansının değerlendirilmesi test verilerinin kullanılması yoluyla gerçekleştirilir. Modelin yeni verilere genelleme yeteneğine sahip olduğunu ve yalnızca eğitim için kullanılan verileri ezberlemediğini garanti etmek çok önemlidir. Verilerin uygun şekilde bölünmesi,

4. MODEL EĞİTİMİ VE PERFORMANS ANALİZİ

modelin yeni verilere etkili bir şekilde genelleştirme kapasitesini artıracak için bu çalışmada veri kümesi %70 eğitim ve %30 doğrulama olarak bölünmüştür.

YOLOv5 kendi içinde farklı varyantlara ayrılmıştır. Bunlar sırasıyla; YOLOv5n, YOLOv5s, YOLOv5m, YOLOv5l ve YOLOv5x olarak ifade edilmektedir. Bu varyantların AP değerleri, parametre sayıları ve çıkarım hızları değişkenlik göstermektedir. Bu çalışmada YOLOv5 için kullanılan parametre değerleri Çizelge 4.1’de verilmektedir.

Çizelge 4.1. YOLOv5 ve varyantlarının parametre değerleri

Parametre İsmi	Değer
Öğrenme Oranı (lr)	0,01
Optimizer	SGD
Ölçek (Scale)	0,5
Görüntü Boyutu	640
Ağırlık Gecikmesi (Weight decay)	0,0005
IoU eşik	0,5
Momentum	0,937
HSV-Ton (Hue)	0,015
HSV-Doygunluk (Saturation)	0,7
HSV-Değer (value)	0,4
Workers	8

Modelin verilen görevde en iyi performansı elde etmesi amacıyla eğitimden önce hiper parametrelerin titizlikle seçilmesi gerekmektedir. Yapılan eğitim süreçlerinde model üreticilerin sağlamış olduğu ilk değerler genel olarak korunmuştur. Ayrıca farklı kombinasyonlar ile en iyi algılama sonucuna ulaşan değerler belirlenmiştir. Birçok değişken olduğu göz önüne alındığında binlerce farklı oluşum meydana gelmekte ve hepsinin denenmiş sonuçlarını elde etmek çok uzun süreç gerektirecektir. Farklı görüntü boyutları olduğu için eğitim boyunca görüntü boyutları 640x640 olarak düzenlenmiştir. Ayrıca model varyantlarının çalıştığı görüntü boyutları açıktır. YOLOv5s ile eğitim işlemleri başlatılmıştır. İlk olarak parti boyutu 16 ve dönem sayısı 50 değerleri ile eğitim süreci başlatılarak farklı değerler ile devam edilmiştir. Ancak eğitim sürecinden sonra parti boyutu 32 ve dönem sayısı 100 değerlerinin daha iyi sonuçlar verildiği gözlemlenmiştir. YOLOv5s’e ait eğitim sonrası kusur sınıflarına ait hassasiyet (P), duyarlılık (R), mAP50 ve mAP50-95 değerleri Çizelge 4.2’de yer almaktadır. YOLOv5x

4. MODEL EĞİTİMİ VE PERFORMANS ANALİZİ

için parti boyutu 16, dönem sayısı 50 olacak şekilde eğitim tamamlanmış ve düşük performans sergilediği için bu kısımda yer verilmemiştir.

Çizelge 4.2. Doğrulama verileri ile değerlendirme kriterlerinin değerleri (YOLOv5s), (a); parti boyutu 16, dönem sayısı 50, (b); parti boyutu 32, dönem sayısı 50, (c); parti boyutu 32, dönem sayısı 75, (d); parti boyutu 32, dönem sayısı 100, (e); parti boyutu 64, dönem sayısı 100.

Kusur Sınıfları	Çıkarım	P	R	mAP50	mAP50-95	(a) Parti Boyutu 16- Dönem Sayısı 50 Eğitim süresi:94 Dk
D00	9.458	0,538	0,494	0,478	0,216	
D10	4.929	0,549	0,382	0,413	0,159	
D20	2.698	0,665	0,502	0,554	0,248	
D30	216	0,484	0,333	0,361	0,167	
D40	1.823	0,503	0,501	0,455	0,188	
D50	262	0,622	0,489	0,538	0,279	
D60	1.719	0,537	0,397	0,400	0,192	
D70	1.246	0,678	0,746	0,718	0,347	
D80	453	0,548	0,530	0,545	0,340	
D90	9	1	0	0	0	
Genel	22.813	0,613	0,437	0,446	0,214	

Kusur Sınıfları	Çıkarım	P	R	mAP50	mAP50-95	(b) Parti Boyutu 32- Dönem Sayısı 50 Eğitim süresi: 98 Dk
D00	9.458	0,514	0,514	0,480	0,216	
D10	4.929	0,533	0,398	0,412	0,159	
D20	2.698	0,652	0,527	0,554	0,250	
D30	216	0,474	0,343	0,349	0,171	
D40	1.823	0,502	0,496	0,457	0,186	
D50	262	0,646	0,473	0,536	0,273	
D60	1.719	0,510	0,410	0,401	0,195	
D70	1.246	0,647	0,750	0,722	0,353	
D80	453	0,600	0,496	0,530	0,330	
D90	9	1	0	0,00017	0,000119	
Genel	22.813	0,608	0,441	0,444	0,213	

Çizelge 4.2. (Devam)

Kusur Sınıfları	Çıkarım	P	R	mAP50	mAP50-95	(c) Parti Boyutu 32- Dönem Sayısı 75 Eğitim süresi: 178 Dk
D00	9.458	0,564	0,516	0,501	0,232	
D10	4.929	0,566	0,407	0,437	0,171	
D20	2.698	0,671	0,510	0,569	0,264	
D30	216	0,506	0,347	0,358	0,179	
D40	1.823	0,549	0,509	0,499	0,211	
D50	262	0,655	0,489	0,549	0,288	
D60	1.719	0,534	0,415	0,416	0,208	
D70	1.246	0,681	0,754	0,744	0,367	
D80	453	0,675	0,554	0,587	0,376	
D90	9	1	0	0,00052	0,000122	
Genel	22.813	0,64	0,45	0,466	0,23	

Kusur Sınıfları	Çıkarım	P	R	mAP50	mAP50-95	(d) Parti Boyutu 32- Dönem Sayısı 100 Eğitim süresi: 236 Dk
D00	9.458	0,551	0,531	0,510	0,239	
D10	4.929	0,578	0,411	0,443	0,177	
D20	2.698	0,661	0,543	0,572	0,268	
D30	216	0,433	0,273	0,313	0,160	
D40	1.823	0,569	0,525	0,510	0,222	
D50	262	0,688	0,512	0,577	0,321	
D60	1.719	0,526	0,430	0,429	0,213	
D70	1.246	0,674	0,764	0,740	0,376	
D80	453	0,647	0,614	0,636	0,437	
D90	9	1	0	0,00027	0,000159	
Genel	22.813	0,633	0,46	0,473	0,241	

Çizelge 4.2. (Devam)

Kusur Sınıfları	Çıkarım	P	R	mAP50	mAP50-95	(e)
D00	9.458	0,510	0,495	0,458	0,205	Parti Boyutu 64- Dönem Sayısı 100 Eğitim süresi: 204 Dk
D10	4.929	0,519	0,373	0,381	0,144	
D20	2.698	0,639	0,485	0,528	0,236	
D30	216	0,492	0,278	0,270	0,131	
D40	1.823	0,492	0,470	0,436	0,171	
D50	262	0,661	0,447	0,527	0,261	
D60	1.719	0,486	0,405	0,382	0,186	
D70	1.246	0,641	0,705	0,688	0,329	
D80	453	0,547	0,474	0,506	0,307	
D90	9	1	0	0	0	
Genel	22.813	0.599	0.413	0.418	0.197	

Sonuçlar incelendiğinde D90 kusur türünün görüntü sayısının az olması değerlendirme kriterlerinin oldukça düşük olmasına neden olmaktadır. Bu kusur türüne ait az görüntü sayısı çalışmanın en büyük zayıf yönü olarak ifade edilebilir. YOLOv5s’de sağlanan en yüksek mAP50 değeri 0,473 olarak elde edilmiştir. Diğer bir varyant olan YOLOv5n’ye ait analiz sonuçları Çizelge 4.3’de verilmektedir.

Çizelge 4.3. Doğrulama verileri ile değerlendirme kriterlerinin değerleri (YOLOv5n), (a); parti boyutu 32, dönem sayısı 75, (b); parti boyutu 32, dönem sayısı 100, (c); parti boyutu 64, dönem sayısı 100.

Kusur Sınıfları	Çıkarım	P	R	mAP50	mAP50-95	(a)
D00	9.458	0,512	0,469	0,445	0,194	Parti Boyutu 32- Dönem Sayısı 75 Eğitim süresi:152 Dk
D10	4.929	0,515	0,349	0,377	0,14	
D20	2.698	0,637	0,466	0,515	0,223	
D30	216	0,526	0,306	0,309	0,143	
D40	1.823	0,476	0,446	0,406	0,166	
D50	262	0,626	0,447	0,484	0,26	
D60	1.719	0,501	0,397	0,377	0,18	
D70	1.246	0,619	0,705	0,666	0,317	
D80	453	0,57	0,435	0,467	0,282	
D90	9	1	0	0	0	
Genel	22.813	0,598	0,402	0,405	0,19	

Çizelge 4.3. (Devam)

Kusur Sınıfları	Çıkarım	P	R	mAP50	mAP50-95	(b)
D00	9.458	0,51	0,495	0,458	0,205	Parti Boyutu 32- Dönem Sayısı 100 Eğitim süresi:236 Dk
D10	4.929	0,519	0,373	0,381	0,144	
D20	2.698	0,639	0,485	0,528	0,236	
D30	216	0,492	0,278	0,27	0,131	
D40	1.823	0,492	0,47	0,436	0,171	
D50	262	0,661	0,447	0,527	0,261	
D60	1.719	0,486	0,405	0,382	0,186	
D70	1.246	0,641	0,705	0,688	0,329	
D80	453	0,547	0,474	0,506	0,307	
D90	9	1	0	0	0	
Genel	22.813	0,599	0,413	0,418	0,197	

Kusur Sınıfları	Çıkarım	P	R	mAP50	mAP50-95	(c)
D00	9.458	0,519	0,493	0,463	0,208	Parti Boyutu 64- Dönem Sayısı 100 Eğitim süresi:195 Dk
D10	4.929	0,519	0,378	0,386	0,149	
D20	2.698	0,628	0,467	0,521	0,229	
D30	216	0,492	0,306	0,285	0,126	
D40	1.823	0,476	0,454	0,424	0,173	
D50	262	0,62	0,466	0,501	0,248	
D60	1.719	0,522	0,408	0,394	0,191	
D70	1.246	0,63	0,71	0,682	0,332	
D80	453	0,61	0,47	0,502	0,295	
D90	9	1	0	0	0	
Genel	22.813	0,601	0,415	0,416	0,195	

YOLOv5n için en iyi değerlere ulaşan parti boyutu 32 ve dönem sayısı 100 değeri olan eğitimidir. Bu eğitimde mAP50 0,418 değerine ulaşmıştır. YOLOv5m ve YOLOv1'e ait analiz sonuçları Çizelge 4.4 ve Çizelge 4.5'de verilmektedir.

Çizelge 4.4. Doğrulama verileri ile değerlendirme kriterlerinin değerleri (YOLOv5m)

Kusur Sınıfları	Çıkarım	P	R	mAP50	mAP50-95	(a)
D00	9.458	0,582	0,556	0,541	0,266	Parti Boyutu 32- Dönem Sayısı 100 Eğitim süresi:350 Dk
D10	4.929	0,584	0,477	0,498	0,213	
D20	2.698	0,685	0,581	0,61	0,304	
D30	216	0,549	0,433	0,406	0,214	
D40	1.823	0,597	0,57	0,579	0,266	
D50	262	0,671	0,607	0,625	0,359	
D60	1.719	0,536	0,469	0,459	0,24	
D70	1.246	0,708	0,774	0,77	0,408	
D80	453	0,707	0,638	0,661	0,496	
D90	9	0	0	0,00082	0,00245	
Genel	22.813	0,562	0,511	0,515	0,277	


Çizelge 4.5. Doğrulama verileri ile değerlendirme kriterlerinin değerleri (YOLOv5l)

Kusur Sınıfları	Çıkarım	P	R	mAP50	mAP50-95	(b)
D00	9.458	0,605	0,556	0,552	0,279	Parti Boyutu 32- Dönem Sayısı 100 Eğitim süresi:477 Dk
D10	4.929	0,612	0,463	0,513	0,223	
D20	2.698	0,716	0,591	0,633	0,318	
D30	216	0,53	0,407	0,399	0,216	
D40	1.823	0,647	0,572	0,592	0,274	
D50	262	0,662	0,595	0,628	0,372	
D60	1.719	0,561	0,45	0,47	0,251	
D70	1.246	0,734	0,793	0,787	0,417	
D80	453	0,698	0,653	0,684	0,52	
D90	9	1	0	0,00477	0,000379	
Genel	22.813	0,676	0,508	0,526	0,287	

En iyi performans sağlayan eğitim süreci YOLOv5l ile sağlanmıştır. Elde edilen en yüksek mAP değeri 0,526 olmuştur. Bu değerin 0,5 üzerinde olması modelin başarılı olduğunu göstermektedir. YOLOv5 modeli için bu analiz sonucu dikkate alınmıştır. Ayrıca diğer kusur sınıflarına ait sağlanan değerler kabul edilebilirdir. Tüm sınıflara ait hassasiyet 0,676, duyarlılık 0,508, mAP50 0,526 ve mAP050-95 ise 0,287 olarak belirlenmiştir. D90 kusur türü bu genel değerlerin düşük çıkmasına neden olmaktadır. Kusur sınıf sayısının yüksek olması ve farklı ülke verilerinden oluşan bir eğitim seti ile gerçekleştirilen analiz sonuçları oldukça başarılıdır. Yüksek sınıf sayısı her zaman

4. MODEL EĞİTİMİ VE PERFORMANS ANALİZİ


modelin genel performansında düşüklük gösterir. Eğitim analizinin detaylı gösterimleri aşağıda verilmiştir. Özellikle eğitim aşamasında kullanılan görüntülerde yer alan kusurların sınırlayıcı kutularına ait konum, genişlik ve yükseklik gibi değerlerin gösterimi Şekil 4.1’de sunulmuştur.



Şekil 4.1. Sınıf etiketlerinin dağılımı, x - y koordinatları ve yükseklik-genişlik arasındaki korelasyon.

En çok var olan kusur türünün D00 olduğu net olarak görülmektedir. Yol ağlarında boyuna ve enine çatlak kusur türü genel olarak her coğrafyada sıklıkla görülmektedir. Kusurların y(0,50) ve üstünde olması görüntülerin toplanma açısından kaynaklıdır. Alt kısımda aracın kaput kısmının olması ve o bölgede kusur olmadığı en net göstergesi x-y yoğunluk grafiğinden görülmektedir. Sınırlayıcı kutuların genişlik ve yükseklik değerlerinin ise 0,2-0,2 aralığında yoğunlaştığı görülmektedir. Bu grafiksel gösterimde sunulan veriler, araştırmacıların modelin eğitim sürecini daha doğru

anlamalarını kolaylaştırır ve böylece üstün performans elde etmek için modeli özelleştirmelerine yardımcı olur.




Şekil 4.2. İşlenen veri kümesinin etiketlerinin korelogramı

Şekil 4.2’de işlenmiş veri seti etiket korelogramını göstermektedir. Korelogramlar korelasyon matrislerini gösterir. Bu araç değişkenler arasındaki korelasyon katsayılarını gösterir. Korelasyon matrisi, veri kümesi değişkenler arası korelasyonları tablolastırır. Korelogram, korelasyon katsayılarını ızgara formatında görselleştirmek için renkleri veya gölgelemeyi kullanır. Korelogramlar, birçok değişken içeren büyük veri kümelerindeki kalıpları ve ilişkileri bulmaya yardımcı olur. Bu varlıklar, araştırmacıların tahmine dayalı modelleme veya veri analizi için ilgili faktörleri ve ilişkileri bulmalarına yardımcı olabilir. Korelogramlar, bir veri kümesinin korelasyon modelini görselleştirmenin basit ve etkili bir yoludur ve temel veri analizine yardımcı olabilir.

Şekil 4.3’deki modelin grafiksel gösterimi, eğitim süreci sırasında sınırlayıcı kutu tahmini, nesnellik tahmini ve sınıflandırma tahmini için kayıp değerlerinde bir azalmayı


4. MODEL EĞİTİMİ VE PERFORMANS ANALİZİ

temsil etmektedir. Bu eğilim her dönemde gözlemlenmekte ve bu da yüksek düzeyde bir hassasiyete işaret etmektedir.




Şekil 4.3. Eğitim boyunca gerçekleşen performans analizi (YOLOv5l)

Ayrıca doğrulama verilerinde de düşüş düzenli olarak devam etmektedir. Bu durum yetersiz uyum olmadığını göstermektedir. Ayrıca bazı dönemlerde doğrulamada var olan dalgalanma aşırı uyum olmadığını da ifade etmektedir. Yetersiz uyum, makine öğrenimi ve derin öğrenmede yaygın bir sorundur ve model, eğitim verilerindeki temel kalıpları yakalayamaz. Yetersiz uyum, modelin aşırı derecede karmaşık olduğu ve eğitim veri kümesindeki yabancı bilgileri yakaladığı aşırı uyumun antitezidir. Yetersiz uyum, aşırı derecede basit bir modelin kullanılması veya modelin yeterli sayıda dönem için yetersiz eğitimi gibi çeşitli faktörlerden dolayı ortaya çıkabilir. Yetersiz eğitim verileri veya gürültülü ve tutarsız veriler de bunun oluşmasına neden olabilir. Yetersiz uyum sorununu azaltmak için ek katmanlar ekleyerek veya her katmandaki nöron sayısını artırarak modelin karmaşıklığını artırmak mümkündür. Kısacası, modelin karmaşıklığı, verilerde mevcut olan temel kalıpları etkili bir şekilde ayırt etmek için yetersiz olduğunda, derin öğrenme bağlamında yetersiz uyum sorunu sıklıkla ortaya çıkar. Sorunun önlenmesi, model karmaşıklığının artırılması, eğitim verilerinin artırılması veya hiper parametrelerin değiştirilmesi yoluyla sağlanabilir. Buna ek olarak doğrulama veri setinden yararlanılarak modelin etkinliğinin değerlendirilmesi de önemlidir.



Şekil 4.4. Eğitilen modelin doğrulama kümesindeki performans değerlendirmesi, (a) Hassasiyet, (b) Duyarlılık (YOLOv5l).



Şekil 4.5. Eğitilen modelin doğrulama kümesindeki performans değerlendirmesi, (a) PR eğrisi, (b) F1 Puanı (YOLOv5l).

Şekil 4.4 ve Şekil 4.5’de yer alan diyagramlar doğrulama görüntülerinin performans eğrilerinin görsel bir temsilini sağlamaktadır. Modelin performans değerlendirilmesi yapılırken kullanılan değerlendirme parametrelerinin eşitlikleri aşağıda yer almaktadır.

$$\text{Hassasiyet (Precision)} = \frac{TP}{TP+FP} \quad (4.1)$$

$$\text{Duyarlılık (Recall)} = \frac{TP}{TP+FN} \quad (4.2)$$

$$\text{F1 puanı} = 2 \times \frac{(\text{Precision} \times \text{Recall})}{(\text{Precision} + \text{Recall})} \quad (4.3)$$


$$\text{mAP} = \frac{1}{n} \sum_{i=1}^n AP_i \quad (4.4)$$

$$\text{IoU} = \frac{\text{bölge } (P_b \cap G_b)}{\text{bölge } (P_b \cup G_b)} \quad (4.5)$$

Eşitliklerde yer alan ifadeler; TP (Gerçek Pozitif), doğru şekilde tespit edilen yol kusurlarının sayısını temsil eder, FP (Yanlış Pozitif), yol kusuru olarak tespit edilen diğer nesnelerin sayısını temsil eder ve FN (Yanlış Negatif), tespit edilemeyen/kaçırılan yol kusurlarının sayısını temsil etmektedir.

Modelin doğrulama veri kümesi üzerindeki performansını gösteren eğriler Şekil 4.4 ve Şekil 4.5'de sunulmaktadır. Bu şekil sırasıyla hassasiyet eğrisini, duyarlılık eğrisini, hassasiyet-duyarlılık eğrisini ve F1 puanı eğrisini göstermektedir. Bu eğriler, ikili sınıflandırma görevlerinde yaygın olarak kullanılan performans değerlendirme ölçümleridir. Bu eğrilerin yapısı, bir sınıflandırıcının karar eşiğinin durumunu içerir; ilgilenilen metriğin elde edilen değerleri, yanlış pozitif orana (hassasiyet) veya yanlış negatif orana (duyarlılık) karşı çizilir. F1 puanı eğrisi, F1 puanı ile karar eşiği arasındaki ilişkiyi gösterir. F1 puanı, sağlanan bir veri kümesindeki pozitif ve negatif örneklerin miktarı arasında dengesizliğin olduğu senaryolarda yaygın olarak kullanılan bir ölçümdür. F1 puanı, hassasiyet ve duyarlılık harmonik ortalamasından türetilir ve sınıflandırma modellerinin etkinliğini değerlendirmek için yaygın olarak yararlı bir ölçüm olarak kabul edilir. Hassasiyet eğrisi, hassasiyet ile karar eşiği arasındaki ilişkiyi gösterir. Hassasiyet, gerçek pozitiflerin, gerçek pozitiflerin ve yanlış pozitiflerin toplamına oranını ölçen istatistiksel bir ölçümdür. Gerçekten pozitif olan tahmin edilen pozitiflerin oranını ölçerek pozitif tahminlerin doğruluğunun bir göstergesi olarak hizmet eder. Duyarlılık eğrisi, duyarlılık ile karar eşiği arasındaki ilişkiyi gösteren grafiksel bir

gösterimdir. Duyarlılık ölçüsü, gerçek pozitif örneklerin tanımlanmasının doğruluğunu ölçmek için kullanılır ve gerçek pozitiflerin sayısının, gerçek pozitiflerin ve yanlış negatiflerin toplamına bölünmesiyle hesaplanır. Hassasiyet ve duyarlılık eğrisi, değişen karar eşiklerinin bir fonksiyonu olarak hassasiyet ve duyarlılık arasındaki ilişkiyi gösteren grafiksel bir temsildir. Hassasiyet ve duyarlılık eğrisi, hassasiyet ve duyarlılık arasında bir denge sunduğundan, veri kümesinin dengesizlik gösterdiği durumlarda sınıflandırıcıları değerlendirmek için değerli bir araç sunar. Genel olarak yukarıda bahsedilen eğriler, doğruluk gibi tek başına bir performans ölçütüne kıyasla bir sınıflandırıcının etkinliği hakkında daha kapsamlı bir bakış açısı sunar. Bunlar, belirli bir göreve göre bir sınıflandırıcının karar eşikini ayarlamak ve çeşitli sınıflandırıcıların etkinliğini değerlendirmek ve karşılaştırmak için kullanılabilir. Bu deneyde güven düzeyi %36,1 olarak ayarlandığında F1 puanı maksimum değeri olan % 54'e ulaşmaktadır. Bulgular, güven düzeyleri %92,3 ve %0 olarak ayarlandığında hassasiyet ve duyarlılık yüzdelерinin sırasıyla %100 ve %79'lük mükemmel bir değere ulaştığını göstermektedir. Şekil 4.6'de modelin karışıklık matrisi yer almaktadır.




Şekil 4.6. Doğrulama görüntülerinden sınıfların tahminine ilişkin Karışıklık Matrisi (YOLOv5l).

Karışıklık matrisinin kullanılması, bir modelin performansının etkinliğini değerlendirmede önemli bir tekniktir. Karışıklık matrisinin kullanılması, derin öğrenme alanında sınıflandırma modellerinin etkinliğini değerlendirmek için yaygın bir uygulamadır. Bilgiler tablo formatında görüntülenir. Bir modelin belirli bir veri kümesi üzerindeki etkinliğinin değerlendirilmesi, doğru pozitif, doğru negatif, yanlış pozitif ve yanlış negatif tahminlerin sayısına göre belirlenir. Karışıklık matrisi, bir modelin etkinliğinin kapsamlı bir analizini sağlayan değerli bir araçtır. Bu, geliştiricilerin tahmin edilen sınıfların kesinliğini değerlendirmesine olanak tanır. Toplanan bilgiler modeli optimize etmek ve doğruluğunu artırmak için kullanılabilir. Karışıklık matrisinden türetilebilecek önemli bir ölçü, sınıflandırma doğruluğudur. Yukarıda bahsedilen ölçüm, model tarafından oluşturulan kesin tahminlerin genel oranını değerlendirir. Derin öğrenme alanında, karışıklık matrisi, sınıflandırma modellerinin etkinliğini değerlendirmek için değerli bir araç olarak hizmet eder. Modellerin iyileştirilmesini ve geliştirilmesini yönlendirmek için kullanılabilir. Ayrıca F1 puanı, hassasiyet ve duyarlılık değerleri karışıklık matrisi yardımı ile hesaplanmaktadır.

Şekil 4.6'da sunulan bulgulara göre, eğitilen model, doğrulama görüntüleri üzerinde D00, D10, D20, D30, D40, D50, D60, D70, D80 ve D90 sınıflarını tahmin ederken sırasıyla %64, %59, %67, %46, %64, %65, %53, %83, %67 ve %0 doğruluk sergiler. D00, D10, D20, D30, D40, D50, D60, D70, D80 ve D90 için yanlış negatif (FN) oranları sırasıyla %35, %40, %28, %35, %34, %33, %45, %15, %28, %78 ve %0'dır. Buna karşılık, D00, D10, D20, D30, D40, D50, D60, D70, D80 ve D90 için öngörücü yanlış pozitif (FP) oranları sırasıyla %47, %22, %8, %1, %7, %1, %8, %5, %2 ve %0'dır. Bu bulgu, belirtilen hiper parametrelerle eğitime tabi tutulan modelin dikkate değer bir performans sergilediğini göstermektedir.


Son olarak etiketli doğrulama verileri ile modelin tahmin ettiği görüntülerden oluşan karşılaştırmalı analiz sonuçları Şekil 4.7'de verilmektedir.

4. MODEL EĞİTİMİ VE PERFORMANS ANALİZİ




Şekil 4.7. Etiketli doğrulama verileri ve modelin tahmin ettiği kusur kutuları (YOLOv5l)

4. MODEL EĞİTİMİ VE PERFORMANS ANALİZİ



Şekil 4.7. (Devam)



Şekil 4.7. (Devam)

YOLOv5 algılama modelinde kapsamlı analizler gerçekleştirilmiştir. Elde edilen sonuçlar YOLOv5l varyantının daha üstün performans sergilediğini göstermiştir. Yüksek algılama sınıfı ve görüntü sayısının yanı sıra sınırlayıcı kutuların fazla olması ve bu kutuların birbirleriyle örtüşmesi modelin performansında düşüşe neden olmuştur. Ayrıca algılamada kaçırılan yani FN durumları gözlemlenmiştir. Bu durum algılanan nesne yani yol kusurlarının form yapısından kaynaklıdır. İç içe girmiş kusur oluşumları ve kusur formlarının her defasında değişmesi modelin algılamada kusur kaçırmasına neden olmaktadır. Ancak değerlendirme kriterleri göz önüne alındığında elde edilen 0,54 F1 puanının başarılı olduğu görülmektedir. IEEE GRDDC yol hasar yarışmasında ilk 12 sıralama incelendiğinde elde edilen F1 değeri ile 9. sıralamada yer aldığı görülmektedir. Ayrıca o yarışmalarda dört hasar sınıfı dikkate alınmıştır. Çalışma kapsamında kullanılan kusur sınıf sayısı ve F1 puanı birlikte değerlendirildiğinde YOLOv5 modelinin iyi performans sergilediği görülmektedir. Farklı ülkelere ait detaylı test sonuçları EK-1’de yer almaktadır.

4.2. YOLOv7 Analiz

YOLO ailesinin en son üyeleri arasında YOLOv7 ve YOLOv8 yer almaktadır. YOLOv7 diğer YOLO üyeleri ile karşılaştırıldığında çıkarım hızı ve doğruluk bakımından oldukça yüksek performans sergilemiştir. Özellikle gerçek zamanlı nesne algılama araştırma çalışmalarında çıkarım hızı son derece önemlidir. 5 FPS ile 160 FPS aralığında hem hız hem de doğruluk açısından tüm nesne dedektörlerinden daha iyi performans sergiler. YOLOv7'ye ait detaylı bilgiler önceki kısımlarda verilmiştir. Çıkarım hızı ve doğruluk arasındaki ilişkinin yüksek olması bu çalışmada kullanılmasının ana sebeplerinden bir tanesidir.

YOLOv7 kendi içinde farklı varyantlara ayrılmıştır. Bunlar sırasıyla YOLOv7, YOLOv7-X, YOLOv7-W6, YOLOv7-E6, YOLOv7-D6 ve YOLOv7-E6E olarak isimlendirilmiştir. Bu varyantların görüntü boyutları, AP değerleri ve çıkarım hızları değişkenlik göstermektedir. Bu değerler MS COCO'da yer alan veri kümelerine göre ortaya çıkmıştır. Ancak YOLOv7 ve YOLOv7-X dışındaki varyantların çalıştıkları görüntü boyutları büyük olup kullanılan veri setine uyum sağlamamaktadır. Ayrıca düşük FPS değeri sunmaları dolayısıyla analiz sürecine dâhil edilmemiştir. Çalışmada sunulan yol kusur veri kümesi ile bu varyantlara göre elde edilen analiz sonuçları bu kısımda detaylı olarak incelenmiştir. Nesne algılama modellerinin performansı çeşitli değer oluşumlarına bağlıdır. Kullanan araştırmacının yetkinliğine, verilerin kalite, çeşitlilik ve uygunluğuna, veri etiketleme kalitesine, kullanılan ekipmanlara ve modelin içsel parametrelerine bağlı olarak algılama modellerinin performansları değişkenlik gösterebilir. Yol kusur veri kümesinde veri ayıklama sürecinin gerçekleştiği ve etiketleme sürecinin titizlikle sürdürüldüğü bu çalışmada YOLOv7 için kullanılan parametre değerleri Çizelge 4.6'da verilmektedir.

Çizelge 4.6. YOLOv7 ve varyantlarının parametre değerleri

Parametre İsmi	Değer
Öğrenme Oranı (lr)	0,01
Optimizer	SGD
Ölçek (Scale)	0,5
Görüntü Boyutu	640
Ağırlık Gecikmesi (Weight decay)	0,0005
IoU eşik	0,5
Momentum	0,937
HSV-Ton (Hue)	0,015
HSV-Doygunluk (Saturation)	0,7
HSV-Değer (value)	0,4
Workers	8

Modelin verilen görevde en iyi performansı elde etmesi amacıyla eğitimden önce hiper parametrelerin titizlikle seçilmesi gerekmektedir. Bu çalışmada görüntü çoğaltma teknikleri kullanılmamıştır. Kullanılan yol kusur görüntüleri farklı ülkelerden ve farklı araştırmacılar tarafından toplanmıştır. Bu durum toplanma şekilleri, yükseklikleri ve açılarına göre değişiklik göstermiş olup farklı hava durumlarını içermektedir. Bu durumdan kaynaklı olarak görüntü sayı ve çeşitliliği yeterli görülmektedir. Model, Çizelge 5.6’da belirtilen parametreler kullanılarak eğitilmiştir. Eğitim süreci için her iki varyantta da 16’lık bir parti boyutu ve 50 dönem sayısı kullanılmıştır. Eğitim modeli 0,01 öğrenme oranıyla Stokastik Gradyan İnişi (SGD) kullanılarak optimize edildi. Her iki varyanta ait değerlendirme parametre sonuçları Çizelge 4.7 ve Çizelge 4.8’de verilmiştir.

Çizelge 4.7. Doğrulama verileri ile değerlendirme kriterleri değerleri(YOLOv7)

Kusur Sınıfları	Çıkarım	P	R	mAP50	mAP50-95	
D00	9.458	0,636	0,543	0,587	0,295	Parti Boyutu 16- Dönem Sayısı 50 Eğitim süresi:450 Dk
D10	4.928	0,637	0,471	0,545	0,232	
D20	2.697	0,690	0,584	0,636	0,314	
D30	216	0,600	0,431	0,471	0,260	
D40	1.823	0,655	0,572	0,619	0,294	
D50	262	0,633	0,634	0,640	0,374	
D60	1.717	0,589	0,476	0,513	0,279	
D70	1.244	0,734	0,803	0,794	0,432	
D80	453	0,677	0,687	0,739	0,578	
D90	9	1	0	0	0	
Genel	22.807	0,685	0,52	0,554	0,306	


Çizelge 4.8. Doğrulama verileri ile değerlendirme kriterleri değerleri(YOLOv7x)

Kusur Sınıfları	Çıkarım	P	R	mAP50	mAP50-95	
D00	9.458	0,62	0,556	0,591	0,301	Parti Boyutu 16- Dönem Sayısı 50 Eğitim süresi:487 Dk
D10	4.928	0,616	0,478	0,540	0,234	
D20	2.697	0,670	0,594	0,644	0,316	
D30	216	0,601	0,481	0,474	0,262	
D40	1.823	0,645	0,607	0,629	0,303	
D50	262	0,651	0,653	0,670	0,411	
D60	1.717	0,587	0,477	0,515	0,277	
D70	1.244	0,738	0,818	0,810	0,437	
D80	453	0,738	0,717	0,763	0,606	
D90	9	0	0	0	0	
Genel	22.807	0,587	0,538	0,564	0,315	

Sonuçlar incelendiğinde D90 kusur türünün görüntü sayısının az olması performans değerlerinin düşük çıkmasına neden olmaktadır. YOLOv5 model analizinde de aynı durum ile karşılaşmıştır. En iyi performans sağlayan eğitim süreci YOLOv7x varyantı ile sağlanmıştır. YOLOv7 modeli için bu analiz sonuçları dikkate alınmıştır. Ayrıca diğer kusur sınıflarına ait sağlanan değerler kabul edilebilirdir. Tüm sınıflara ait hassasiyet 0,587, duyarlılık 0,538, mAP50 0,564 ve mAP050-95 ise 0,315 olarak belirlenmiştir. Eğitim analizinin detaylı gösterimleri aşağıda verilmiştir.


Şekil 4.8'deki modelin grafiksel gösterimi, eğitim süreci sırasında sınırlayıcı kutu tahmini, nesnellik tahmini ve sınıflandırma tahmini için kayıp değerlerinde bir azalmayı temsil etmektedir. Bu eğilim her dönemde gözlemlenmekte ve bu da yüksek düzeyde bir hassasiyete işaret etmektedir.

4. MODEL EĞİTİMİ VE PERFORMANS ANALİZİ




Şekil 4.8. Eğitim boyunca gerçekleşen performans analizi (YOLOv7x)

Eğitim ve doğrulama verileri üzerinde kayıpların nesnellik tahmini kayıp harici düzenli olarak azaldığı görülmektedir. Nesnellik tahmini kayıp değeri 20 dönem sayısından sonra artmakta ve en iyi sınıf kutu seçiminde zorlanmaktadır. Sınıf tahmini kaybının daha küçük çıkmasının önünde D90 kusur türü yer almaktadır. D90 kusur sınıfının görüntü sayısının artırılması ile eğitim analizlerinin daha başarılı olması sağlanabilir. Ancak toplanması oldukça zor bir kusur türüdür. Bunun yanı sıra görüntüde belli olması ve etiketlenmesi de bir o kadar zordur.



Şekil 4.9. Eğitilen modelin doğrulama kümesindeki performans değerlendirmesi, (a) Hassasiyet, (b) Duyarlılık (YOLOv7x).




Şekil 4.10. Eğitilen modelin doğrulama kümesindeki performans değerlendirilmesi, (a) PR eğrisi, (b) F1 Puanı (YOLOv7x).

Şekil 4.9 ve Şekil 4.10'de yer alan diyagramlar doğrulama görüntülerinin performans eğrilerinin görsel bir temsilini sağlamaktadır. Hassasiyet eğrisi incelendiğinde yukarı doğru eğimli bir grafik sergilemektedir. Bu durum güven puanı arttıkça modelin görsel üzerinde boş tahmin yapmamasından kaynaklıdır. Yüksek güven sunduğu için sadece FP değerleri çok düşük olacaktır. D90 kusuru nerdeyse 0,01 güven

4. MODEL EĞİTİMİ VE PERFORMANS ANALİZİ

değerinden sonra algılanamayacağını da model bu grafik ile açıklamıştır. Duyarlılıkta ise grafik tam tersi olarak aşağı yönlü olarak evrilmiştir. Eğer güven puanı artarsa algılaması gereken kusurları bulamayacağı ve FN durumlarında artış olacağı açıktır. Hassasiyet-Duyarlılık grafiğinde ise grafik yine aşağı yönlüdür. Bu grafik hassasiyet ve duyarlılık değerlerinin modelin güven puanı eşiğinin bir fonksiyonu olarak meydana gelmektedir. Eğer güven puanı azalır ise daha fazla tahmin yapılır ve bu da daha az doğru tahmin yapılacağını göstermektedir. F1 puanı hassasiyet ve duyarlılığa bağlı olarak çizilen ve modelin temel doğrulama değeridir. Bu deneyde güven düzeyi %30,2 olarak ayarlandığında F1 puanı maksimum değeri olan % 54'e ulaşmıştır. Bulgular, güven düzeyleri %91,2 ve %0 olarak ayarlandığında hassasiyet ve duyarlılık yüzdelerinin sırasıyla %100 ve %83'lük mükemmel bir değere ulaştığını göstermektedir. IEEE GRDDC yol hasar yarışmasında ilk 12 sıralama incelendiğinde elde edilen F1 değeri ile 7. sıralamada yer aldığı görülmektedir. Ayrıca o yarışmalarda dört hasar sınıfı dikkate alınmıştır. Şekil 4.11'de modelin karışıklık matrisi yer almaktadır.




Şekil 4.11. Doğrulama görüntülerinden sınıfların tahminine ilişkin Karışıklık Matrisi (YOLOv7x).

4. MODEL EĞİTİMİ VE PERFORMANS ANALİZİ


Şekil 4.11'da sunulan bulgulara göre, eğitilen model, doğrulama görüntüleri üzerinde D00, D10, D20, D30, D40, D50, D60, D70, D80 ve D90 sınıflarını tahmin ederken sırasıyla %61, %55, %64, %54, %65, %65, %52, %84, %74 ve %0 doğruluk sergiler. D00, D10, D20, D30, D40, D50, D60, D70, D80 ve D90 için yanlış negatif (FN) oranları sırasıyla %37, %43, %31, %36, %33, %31, %47, %15, %24, %87 ve %0'dır. Buna karşılık D00, D10, D20, D30, D40, D50, D60, D70, D80 ve D90 için öngörücü yanlış pozitif (FP) oranları sırasıyla %45, %21, %10, %1, %8, %1, %8, %5, %2 ve %0'dır. Bu bulgu, belirtilen hiper parametrelerle eğitime tabi tutulan modelin dikkate değer bir performans sergilediğini göstermektedir.

Son olarak etiketli doğrulama verileri ile modelin tahmin ettiği görüntülerden oluşan karşılaştırmalı analiz sonuçları Şekil 4.12'de verilmektedir.




Şekil 4.12. Etiketli doğrulama verileri ve modelin tahmin ettiği kusur kutuları (YOLOv5l)

4. MODEL EĞİTİMİ VE PERFORMANS ANALİZİ



Şekil 4.12. (Devam)



Şekil 4.12. (Devam)

Farklı ülkelere ait detaylı test sonuçları EK-1’de yer almaktadır.

4.3. YOLOv8 Analiz

YOLO ailesinin son ve en iyi performans değerlerine ulaşan üyesi olan YOLOv8 araştırmacılar tarafından sıklıkla kullanılmaktadır. YOLOv8, önceki YOLO sürümlerinin başarısını temel alan, performansı ve esnekliği daha da artırmak için yeni özellikler ve iyileştirmeler sunan son teknoloji ürünü bir modeldir. YOLOv8 hızlı, doğru ve kullanımı kolay olacak şekilde tasarlanmıştır; bu da onu çok çeşitli nesne algılama ve izleme, örnek bölümlendirme, görüntü sınıflandırma ve poz tahmin görevleri için mükemmel bir seçim haline getirmektedir. Bu çok yönlülük, kullanıcıların çeşitli uygulamalar ve alanlarda YOLOv8’in yeteneklerinden yararlanmasına olanak tanımaktadır. Tüm bu olanakları yanı sıra gerçek zamanlı algılamadaki üstün performansı yol kusurlarının belirlenmesi sürecinde tercih edilmesine neden olmuştur. YOLOv7’de kullanılan veri kümesi, veri

4. MODEL EĞİTİMİ VE PERFORMANS ANALİZİ

bölümü ve model parametre değerleri aynı olup algılama performans değerleri incelenmiştir.

YOLOv8 beş farklı varyant olarak araştırmacılara sunulmuştur. Algılama hızı, doğruluğu ve parametre sayıları değişkenlik gösteren bu varyantlar sırasıyla YOLOv8n, YOLOv8s, YOLOv8m, YOLOv8l ve YOLOv8x olarak isimlendirilmiştir. Bu varyantlara ait değerlendirme parametre sonuçları verilmiştir. Güçlü bir GPU kullanılmasına rağmen eğitim süreleri oldukça uzundur. Ayrıca farklı kombinasyonların denenmesinde GPU yetersiz kaldığı için sonuç elde edilememiştir. Özellikle derin öğrenme tabanlı çalışmalarda altyapı imkânları önem arz etmektedir. Dolayısıyla gerçekleştirilen eğitim çıktıları yeterli altyapı olması durumunda daha da iyileştirilebilir. Varyantlara ait değerlendirme parametre sonuçları Çizelge 4.9 - Çizelge 4.13’de verilmiştir.

Çizelge 4.9. Doğrulama verileri ile değerlendirme kriterleri değerleri (YOLOv8s)

Kusur Sınıfları	Çıkarım	P	R	mAP50	mAP50-95	
D00	9.458	0,644	0,506	0,557	0,300	Parti Boyutu 32- Dönem Sayısı 50 Eğitim süresi:562 Dk
D10	4.929	0,621	0,439	0,499	0,227	
D20	2.698	0,673	0,598	0,651	0,351	
D30	216	0,541	0,403	0,387	0,215	
D40	1.823	0,667	0,529	0,582	0,278	
D50	262	0,690	0,630	0,655	0,411	
D60	1.719	0,567	0,456	0,480	0,266	
D70	1.246	0,751	0,756	0,767	0,420	
D80	453	0,693	0,645	0,704	0,569	
D90	9	0	0	0	0	
Genel	22.813	0,585	0,496	0,528	0,304	

Çizelge 4.10. Doğrulama verileri ile değerlendirme kriterleri değerleri (YOLOv8n)

Kusur Sınıfları	Çıkarım	P	R	mAP50	mAP50-95	
D00	9.458	0,603	0,469	0,513	0,271	Parti Boyutu 32- Dönem Sayısı 50 Eğitim süresi:551 Dk
D10	4.929	0,585	0,405	0,462	0,207	
D20	2.698	0,655	0,579	0,622	0,338	
D30	216	0,529	0,287	0,336	0,189	
D40	1.823	0,584	0,469	0,498	0,235	
D50	262	0,675	0,603	0,623	0,383	
D60	1.719	0,543	0,419	0,429	0,242	
D70	1.246	0,717	0,724	0,742	0,392	
D80	453	0,652	0,618	0,642	0,513	
D90	9	0	0	0	0	
Genel	22.813	0,554	0,457	0,487	0,277	

Çizelge 4.11. Doğrulama verileri ile değerlendirme kriterleri değerleri (YOLOv8m)

Kusur Sınıfları	Çıkarım	P	R	mAP50	mAP50-95	
D00	9.458	0,650	0,535	0,582	0,322	Parti Boyutu 32- Dönem Sayısı 50 Eğitim süresi:643 Dk
D10	4.929	0,609	0,469	0,525	0,252	
D20	2.698	0,669	0,621	0,665	0,366	
D30	216	0,525	0,403	0,377	0,214	
D40	1.823	0,668	0,541	0,585	0,292	
D50	262	0,654	0,664	0,671	0,437	
D60	1.719	0,548	0,474	0,476	0,266	
D70	1.246	0,754	0,769	0,786	0,432	
D80	453	0,731	0,658	0,738	0,615	
D90	9	0	0	0	0	
Genel	22.813	0,581	0,513	0,54	0,32	

Çizelge 4.12. Doğrulama verileri ile değerlendirme kriterleri değerleri (YOLOv8l)

Kusur Sınıfları	Çıkarım	P	R	mAP50	mAP50-95	
D00	9.458	0,640	0,541	0,583	0,322	Parti Boyutu 16- Dönem Sayısı 50 Eğitim süresi:602 Dk
D10	4.929	0,616	0,492	0,537	0,258	
D20	2.698	0,671	0,619	0,670	0,368	
D30	216	0,533	0,407	0,415	0,235	
D40	1.823	0,666	0,576	0,606	0,292	
D50	262	0,621	0,622	0,661	0,420	
D60	1.719	0,568	0,481	0,506	0,285	
D70	1.246	0,767	0,776	0,793	0,439	
D80	453	0,701	0,698	0,753	0,632	
D90	9	0	0	0	0	
Genel	22.813	0,578	0,521	0,552	0,325	


Çizelge 4.13. Doğrulama verileri ile değerlendirme kriterleri değerleri (YOLOv8x)

Kusur Sınıfları	Çıkarım	P	R	mAP50	mAP50-95	
D00	9.458	0,647	0,527	0,582	0,322	Parti Boyutu 16- Dönem Sayısı 50 Eğitim süresi:664 Dk
D10	4.929	0,645	0,461	0,532	0,253	
D20	2.698	0,690	0,612	0,666	0,364	
D30	216	0,590	0,454	0,471	0,265	
D40	1.823	0,685	0,558	0,610	0,302	
D50	262	0,665	0,595	0,670	0,434	
D60	1.719	0,575	0,465	0,499	0,281	
D70	1.246	0,766	0,774	0,807	0,453	
D80	453	0,723	0,662	0,743	0,623	
D90	9	1	0	0	0	
Genel	22.813	0,699	0,511	0,558	0,330	

Sonuçlar incelendiğinde D90 kusur türünün görüntü sayısının az olması YOLOv5 ve YOLOV7’de olduğu gibi performans değerlerinin düşük çıkmasına neden olmaktadır. Varyantalar arasında en yüksek mAP değeri YOLOv8x ile elde edilmiştir. YOLOv8 modeli için bu analiz sonuçları dikkate alınmıştır. Ayrıca diğer kusur sınıflarına ait sağlanan değerler kabul edilebilirdir. Tüm sınıflara ait hassasiyet 0,699, duyarlılık 0,511, mAP50 0,558 ve mAP050-95 ise 0,33 olarak belirlenmiştir. Eğitim analizinin detaylı gösterimleri aşağıda verilmiştir.


4. MODEL EĞİTİMİ VE PERFORMANS ANALİZİ

Şekil 4.13'deki modelin grafiksel gösterimi, eğitim süreci sırasında sınırlayıcı kutu tahmini, nesnellik tahmini ve sınıflandırma tahmini için kayıp değerlerinde bir azalmayı temsil etmektedir. Bu eğilim her dönemde gözlemlenmekte ve bu da yüksek düzeyde bir hassasiyete işaret etmektedir. Kusur sınıflarına ait hassasiyet, duyarlılık, mAP50 ve mAO50-95 değerleri tüm varyantlar dikkate alınarak hesaplanmıştır. Performansı en yüksek varyanta ait gösterim bu kısımda yer almaktadır.




Şekil 4.13. Eğitim boyunca gerçekleşen performans analizi (YOLOv8x)

Şekil 4.13'de yer alan diyagramlar doğrulama görüntülerinin performans eğrilerinin görsel bir temsilini sağlamaktadır. Eğitim ve doğrulama kısımlarında gerçekleşen hata kayıpları modelde aşırı ve yetersiz olmadığını göstermektedir.



Şekil 4.14. Eğitilen modelin doğrulama kümesindeki performans değerlendirmesi, (a) Hassasiyet, (b) Duyarlılık (YOLOv8x).




Şekil 4.15. Eğitilen modelin doğrulama kümesindeki performans değerlendirmesi, (a) PR eğrisi, (b) F1 Puanı (YOLOv8x).

Genel olarak yukarıda bahsedilen eğriler, doğruluk gibi tek başına bir performans ölçütüne kıyasla bir sınıflandırıcının etkinliği hakkında daha kapsamlı bir bakış açısı sunar. Bu deneyde güven düzeyi %32,6 olarak ayarlandığında F1 puanı maksimum değeri olan %55'e ulaşmaktadır. Bulgular, güven düzeyleri %96,9 ve %0 olarak ayarlandığında hassasiyet ve duyarlılık yüzdelерinin sırasıyla %100 ve %78'lük mükemmel bir puana

4. MODEL EĞİTİMİ VE PERFORMANS ANALİZİ

ulaştığını göstermektedir. IEEE GRDDC yol hasar yarışmasında ilk 12 sıralama incelendiğinde elde edilen F1 değeri ile 8. sıralamada yer aldığı görülmektedir. Ayrıca o yarışmalarda dört hasar sınıfı dikkate alınmıştır. Nesne algılama sonuçlarının yorumlanması araştırmacıların amacına ve algıladığı nesneye göre değişkenlik göstermektedir. Özellikle hassasiyet ve duyarlılık değerleri bu amaca göre farklı önem kazanabilir. Örnek vermek gerekirse bir kanser hücresinin algılanması durumunda FN oluşumlarından kesinlikle kaçınmak gerekir. Bu algılama da FP'lerden kaçınmak daha yüksek bir önceliktir. Böyle bir algılamada duyarlılık değerimizin bir değerine oldukça yakın olması yani FN oluşumlarının sıfıra gitmesi gerekmektedir. Bu örnekten sonra YOLOv8x'den elde edilen karışıklık matrisi Şekil 4.16'de yer almaktadır.




Şekil 4.16. Doğrulama görüntülerinden sınıfların tahminine ilişkin Karışıklık Matrisi (YOLOv8x).

Şekil 4.16'da sunulan bulgulara göre, eğitilen model, doğrulama görüntüleri üzerinde D00, D10, D20, D30, D40, D50, D60, D70, D80 ve D90 sınıflarını tahmin

4. MODEL EĞİTİMİ VE PERFORMANS ANALİZİ


ederken sırasıyla %59, %54, %66, %50, %60, %63, %52, %81, %69 ve %0 doğruluk sergiler. D00, D10, D20, D30, D40, D50, D60, D70, D80 ve D90 için yanlış negatif (FN) oranları sırasıyla %39, %44, %30, %30, %38, %34, %47, %17, %28, %89 ve %0'dır. Buna karşılık, D00, D10, D20, D30, D40, D50, D60, D70, D80 ve D90 için öngörücü yanlış pozitif (FP) oranları sırasıyla %44, %21, %11, %1, %7, %1, %9, %4, %2 ve %0'dır. Bu bulgu, belirtilen hiper parametrelerle eğitime tabi tutulan modelin dikkate değer bir performans sergilediğini göstermektedir.

Son olarak etiketli doğrulama verileri ile modelin tahmin ettiği görüntülerden oluşan karşılaştırmalı analiz sonuçları Şekil 4.17'de verilmektedir.




Şekil 4.17. Etiketli doğrulama verileri ve modelin tahmin ettiği kusur kutuları (YOLOv8x).

4. MODEL EĞİTİMİ VE PERFORMANS ANALİZİ



Şekil 4.17. (Devam)



Şekil 4.17. (Devam)

Farklı ülkelere ait detaylı test sonuçları EK-1’de yer almaktadır.

4.4. YOLOv5, YOLOv7 ve YOLOv8 Modellerinin Karşılaştırılması

Üç farklı nesne algılama modelinin uygulanması ile yol kusurlarının algılanması ve sınıflandırılması için en doğru modeli tespit etmek amacıyla sonuçlar bu kısımda değerlendirilmiştir. Bu çalışmada modelin performansının değerlendirilmesi, açık veri kaynakları tarafından sunulan veriler ve yazar tarafından elde edilen yol kusur verileri ile gerçekleştirilmiştir. Sekiz farklı ülke ve 10 farklı yol kusur sınıfının değerlendirildiği bu çalışmada temel amaç, yol kusurlarının otomatik olarak tanımlama ve sınıflandırma yeteneğine sahip derin öğrenme tekniklerinin uygulanması ile katma değerli bir ürün elde edilmesidir.

Test veri setinde kullanılmak üzere Japonya, Hindistan, Çek Cumhuriyeti, Çin, ABD, Norveç ve Kuveyt ülkeleri yer almaktadır. Üç model için aynı test görselleri

üzerinde gerçekleşen algılama sonuçlarının ülke bazlı karşılaştırmalı hali EK-1’de sunulmuştur. Güven değeri 0,25 olarak tercih edilmiştir. Bu değer birçok deneme sürecinden sonra belirlenmiştir. Ayrıca test verilerinin görüntü boyutları farklı olduğu için aynı görüntü boyutlarına dönüştürülmemiştir. Özellikle FP ve FN durumunun en düşük seviye tutulduğu değerin bu olduğu kararlaştırılmıştır.

Çalışma kapsamında üç farklı algılama modeli ve onların varyantları farklı kombinasyonlar ile yol kusur veri seti ile eğitilmiştir. Kullanılan modellerin performans değerlerinin bir özeti Çizelge 4.14’da verilmiştir. Dört farklı değer dikkate alındığında modellerin sunduğu değerler değişkenlik göstermektedir. F1 puanı ve mAP değerleri incelendiğinde modellerin birbirlerine yakın sonuçlar vermekle birlikte en üstün değeri YOLOv7 ağ modeli vermektedir. Ayrıca çıkarım zamanlarının hesaplanması sadece Çin’e ait 14 adetlik test veri seti üzerinden gerçekleştirilmiştir. Aynı test seti üzerinden yapılan algılamada adet olarak en yüksek kusur yakalayan YOLOv8 olmaktadır. Bu ağ modelini sırası ile YOLOv7 ve YOLOv5 takip etmektedir. Test sürecinde görüntü başına sağlanan algılama süresinde ve kusur başına algılama süresinde YOLOv5 diğer modellere göre üstünlük sağlamaktadır. Üç modelin de farklı alanlarda üstünlükler sağladığı görülmektedir. Test seti içindeki görüntülerde en çok kusur algılayan YOLOv8, F1 puanı ve mAP değerlerinde YOLOv7 ve çıkarım zamanlarında en hızlı olan YOLOv5 olarak gözlemlenmiştir.

Çizelge 4.14. Modellere ait performans değerleri

	YOLOv5	YOLOv7	YOLOv8	Tesla V100-SXM2-16GB
Kusur algılama (adet)	38	51	64	
Çıkarım zamanı ms/görüntü	6,30	10,05	20,8	
Çıkarım zamanı ms/kusur	2,32	2,76	4,60	
F1 Puanı	0,540	0,560	0,550	
mAP50	0,526	0,564	0,558	

4. MODEL EĞİTİMİ VE PERFORMANS ANALİZİ

Bu çizelge değerlendirildiğinde YOLOv5, YOLOv7 ve YOLOv8 modellerinin yüksek düzeyde uygulanabilirlik ve hassasiyet gösterdiği ortaya çıkmaktadır. Bahsi geçen modellerin, görüntülerdeki kusurlu yolların sınıflandırılmasını tahmin etme yeteneğinde üstün performans sergilemektedir. Ancak bu değerlerin görüntü üzerinden hesaplandığı unutulmamalıdır. Çalışma kapsamında yol kusurlarının gerçek zamanlı olarak hesaplanması amaçlanmıştır. Özellikle YOLOv5 ve YOLOv8 modellerinin bu amaç doğrultusunda daha başarılı olacağı araştırmacılar tarafından ifade edilmektedir.



5. GÖMÜLÜ SİSTEM İNŞASI

Derin öğrenme modelleri, günümüzde çeşitli bilgisayar uygulamaları, grafik kullanıcı ara yüzleri ve yenilikçi birleşimler ile nesne algılamaya yönelik kullanımda dikkate değer bir artış yaşamaktadır. Nesne algılama süreci, belirli bir görüntü veya video akışı içindeki istenilen nesnelerin tanınmasını ve mekânsal olarak konumlandırılmasını hedeflemektedir. Deneysel kanıtlar, derin öğrenme modellerinin nesne algılama görevlerinde geleneksel bilgisayarlı görme yöntemlerini geride bırakarak üstün performans sergilediğini göstermektedir. Derin öğrenme modelleri, görsel verilerin karmaşık ve hiyerarşik temsillerini elde etme konusunda dikkate değer bir yeteneğe sahiptir ve bunları nesne algılama amacıyla oldukça uygun hale getirmektedir.

Bilgisayar tabanlı uygulamalarda nesne tespiti için derin öğrenme modelinin kullanılması çok sayıda fayda sunmaktadır. Derin öğrenme modelleri, kapsamlı veri kümeleri üzerinde eğitim alma ve böylece nesnelerin görsel özelliklerini tanıma becerisi kazanma yeteneğine sahip olması birçok sektörde sorunlara çözüm olarak tercih edilmektedir. Bu onların farklı koşullar ve ortamlardaki nesneleri yüksek doğruluk ile tespit etmelerini sağlamaktadır. Nesne algılamanın güvenilirliği ve doğruluğu, gözetleme sistemleri ve otonom araçlar da dâhil olmak üzere çeşitli uygulamalarda çok önemlidir. Geleneksel bilgisayarlı görme yöntemleri, yavaşlık ve yüksek hesaplama maliyetleri sergilediği için bu da onları gerçek zamanlı işlem gerektiren uygulamalar için kullanışsız hale getirmektedir. Derin öğrenme modelleri, çağdaş donanım üzerinde etkili çıkarımlar elde etmek için optimize edilebilir, böylece akıllı telefonlar veya gömülü sistemler gibi düşük güçlü cihazlarda bile gerçek zamanlı nesne algılaması kolaylaştırılabilir. Nesne tespiti için derin öğrenme modelinin uygulanması, şimdiye kadar ulaşamayan yeni uygulamaları ve kullanım senaryolarını kolaylaştırma potansiyeline sahiptir. Bu araştırma çalışmasında, yol ağlarında meydana gelen yol kusurlarını otomatik olarak belirleyen bir gömülü sistem elde edilmiştir.

5.1. Yol Kusurlarını Otomatik Olarak Algılayan ve Sınıflayan Sistem

Gömülü sistem, belirli bir işlev için tasarlanmış bilgisayar donanımı ve yazılımının birleşimidir. Gömülü sistemler daha büyük bir sistem içinde de çalışabilir.

Sistemler programlanabilir veya sabit bir işlevselliğe sahip olabilir. Endüstriyel makineler, tüketici elektroniği, tarım ve işleme endüstrisi cihazları, otomobiller, tıbbi ekipmanlar, kameralar, dijital saatler, ev aletleri, uçaklar, satış otomatları ve oyuncakların yanı sıra mobil cihazlar da gömülü sistem için olası konumlardır.

Gerçekleştirilen bu tez çalışmasında yol kusurlarını otomatik olarak belirleyen ve kusur konumlarını depolayabilen bir katma değerli ürün elde edilmiştir. Sistem inşası yazılım ve donanım olarak iki ana parçadan oluşmaktadır.

5.1.1. Yazılım

Algılama ve sınıflama süreçlerinde kullanılan YOLOv5, YOLOv7 ve YOLOv8 nesne algılama modelleri ile yol görüntülerinin eğitim analizleri tamamlanmıştır. Detaylı karşılaştırmalı analiz süreçleri, literatür incelemesi ve uzman araştırmacı görüşleri neticesinde gerçek zamanlı algılama sürecinde YOLOv8x'e ait en iyi ağırlık dosyası olan best.pt'nin kullanılmasına karar verilmiştir.

Jetson Xavier NX geliştirme kiti Linux işletim sistemi tabanlıdır. Bu geliştirme kitini kullanmak için ilk olarak SD Card Image dosyanın indirilmesi gerekmektedir. Kullanılan bilgisayar türüne (Windows, Mac veya Linux) göre talimatlar izlenerek dosya microSD karta yazılmaktadır. Başlangıçta microSD karta format işlemi yapılmalıdır. Ardından SD Card Image dosyasını microSD kartına yazmak için Etcher programı kullanılmaktadır. MicroSD kartınız hazır olduktan sonra geliştirici kite takılarak kurma işlemi devam etmektedir. Gerekli bağlantılar ile kit bilgisayar ekranına bağlanmaktadır. Ayrıca kit ile işlemleri devam ettirmek için USB fare ve klavyede bağlanmalıdır. Kite ait güç kaynağı da takıldıktan sonra ekran otomatik olarak açılmaktadır.

Gerçek zamanlı algılama için YOLOv8x modeli kullanılacağı için geliştirme kitine YOLOv8 ilk olarak yüklenmiştir. Derin öğrenme tabanlı bir algılama modeli olduğundan birçok kütüphaneye ihtiyaç duymaktadır. Numpy, pandas, Pillow, PyYAML, scipy, psutil, tqdm ve imutils paketlerinin kurulumu sağlanmıştır. Geliştirme kitinin GPU'sunu kullanmak üzere PyCuda kurulumu sağlanmalıdır. Matplotlib kütüphanesini temel alan bir Python görselleştirme kütüphanesi olan Seaborn'de yüklenmelidir. Torch

ve torchvision kurulumu ile kütüphanelerin yüklenmesi tamamlanmıştır. Ardından ağırlık dosyası olan best.pt farklı işlemler ile .wts ve .engine uzantılı dosyalara dönüşmektedir. Herhangi bir video dosyası veya kamera üzerinde çıkarım yapmak için app.py'yi kullanarak algılama süreci yapılmaktadır. GPS modülü ile yol kusurlarının algılanması sağlanmıştır. YOLOv8'e ait detect.py dosyası içine konum algılama kodu gömülerek algılanan kusura ait konum bilgileri elde edilmiştir.

5.1.2. Donanım

Geliştirilen sistemde kullanılmak üzere Jetson Xavier NX geliştirme kiti, Arducam kamera modülü, GPS alıcı ve harici hafıza kartı kullanılmıştır. Bu teknik malzemeler sistemin donanım ekipmanlarıdır.


NVIDIA Jetson Xavier NX yüksek performans sağlama imkanı ile hızlandırılmış bilgi işlem, modern sinir ağlarını paralel olarak çalıştırmak ve birden fazla yüksek çözünürlüklü sensörden gelen verileri işlemek için gereken gücü sağlamaktadır. Yapay zekâ tabanlı sistemlerde sıklıkla kullanılmaktadır. Jetson Xavier NX; ticari robotlar, tıbbi cihazlar, akıllı kameralar, yüksek çözünürlüklü sensörler, otomatik optik inceleme, akıllı fabrikalar ve diğer IoT gömülü sistemler gibi yüksek performanslı yapay zekâ sistemleri için mükemmel bir araçtır. 70mm x 45 mm boyutlarında Jetson Xavier NX kompakt modül tasarımı ile olağanüstü performans ve güç avantajlarını bir araya getirmektedir.

Arducam B429 kamera'nın dijital video kamera geliştirme, gözetim için yüksek çözünürlüklü IP ağ kamera ve yüksek çözünürlüklü video konferans sağlama yeteneğine sahiptir. Elde ettiği görüntü boyutları 1920x1200 olarak belirtilmiştir. Özellikle Jetson Xavier NX ile uyumlu çalışması bu kamera modülünün seçilmesinde önemli rol oynamıştır. Araç içine entegre olacak sistemin yol kaplamasının taranması bu kamera modülü ile sağlanmıştır.

GPS alıcı, Jetson Xavier NX'e bağlantısı sağlanarak kusurların konum bilgileri elde edilmiştir. Özellikle yol ağında meydana gelen 10 adet kusur türünün konumsal bilgileri bu alıcı ile sağlanmıştır. Elde edilen bilgilerin depolanma için harici hafıza kartı

5. GÖMÜLÜ SİSTEM İNŞASI

kullanılmıştır. Kullanılan ürünlerin birleştirilmeden önceki görselleri Şekil 5.1’de sunulmuştur.




Şekil 5.1. Sistemin donanımsal ekipmanları (a) Jetson Xavier NX, (b) kamera modülü, (c) GPS alıcı, (d) harici hafıza kartı.

Donanım birleştirme işleminde dikkat edilmesi gereken en önemli süreç tüm parçaların birbiri ile uyumlu olarak çalışabilmesidir. Yazılım ve donanım süreçlerinin eksiksiz olarak birleştirilmesi neticesinde yol kusurlarını otomatik olarak algılayan ve sınıflayan katma değerli ürün çalışma kapsamında elde edilmiştir. Ürünün gerçek bir yol ağında test aşaması gerçekleştirilmiştir. Şekil 5.2’de elde edilen ürünün gerçek test aşamasında çekilmiş fotoğrafı yer almaktadır.



Şekil 5.2. Sistemin prototip hali

Bu gibi gömülü sistemler gerçek zamanlı algılama işlemlerinde zorluklar yaşamaktadır. Bunun ana sebebi olarak kullanılan geliştirme kitlerinin performans sınıflarıdır. Özellikle yapılan tez çalışmasında olduğu gibi yüksek algılama sınıfı ve algılanan nesnenin form değişikliği geliştirme kitleri üzerinde ağır yük oluşturmaktadır. Bu durum kamera ile elde edilen görüntü ile geliştirme kitinin bunu işlemesi arasında zorluklar meydana getirmiştir. Şekil 5.3’de yer alan görselde gerçek zamanlı olarak yapılan algılamadan örnekler içermektedir.




Şekil 5.3. Prototip sistemin gerçek zamanlı yol kusur algılaması

Erzurum Teknik Üniversitesi kampüsü içerisinde bulunan yol ağında prototip sistemin gerçek zamanlı olarak algılama süreci tamamlanmıştır. Algılanan kusurlara ait konum bilgileri enlem ve boylam olarak depolanmıştır. Yol ağında var olan kusurların konumsal bilgileri ArcMap ortamına aktarılmıştır. Nokta yoğunluk analizi yapılarak yol ağında meydana gelen kusurların yoğunluk haritası elde edilmiştir. Şekil 5.4’de yol kusurlarının kampüs yol ağı içerisindeki dağılım durumu görülmektedir.



Şekil 5.4. ETÜ kampüs yol ağında var olan kusurların konumsal gösterimi

Gerçek zamanlı olarak algılanma işleminin sürdürüldüğü kampüs yol ağı 2x2 olarak tasarlanmıştır. Her iki araç yönünde dikkate alınarak hem gidiş hem de dönüş olarak kampüs yol ağının kusur taraması gerçekleştirilmiştir. Ardından yol ağında bulunan kusurların noktasal olarak yoğunluk analizleri farklı hassasiyetlere göre gerçekleştirilmiştir. Şekil 5.5’de yol kusurlarına ait nokta yoğunluk analiz sonuçları yer almaktadır. Kusurların bazı bölgelerde daha fazla yoğunlaştığı net olarak görülmektedir.



Şekil 5.5. Kusurların meydana geliş yoğunluğu

Gerçekleştirilen tüm bu süreçlerin ardından manuel yaklaşım ile yol ağlarını kontrol etmeye çalışan ilgili kurumlar için yüksek doğruluk oranı, verimlilik ve düşük maliyet sağlayan sistem sağlanmıştır. Özellikle yerel belediyelere ait trafik yönetim merkezleri ile yol kusurlarının bulunduğu konum verilerinin paylaşılması ile V2I iletişim

5. GÖMÜLÜ SİSTEM İNŞASI

modelinin kurulması sağlanabilir. Mevcut çalışma, yol kusurlarını tespit etmeyi amaçlayan geniş bir teknoloji çerçevesini sunmakta ve sağladığı bazı faydalar kısaca özetlenmektedir.

Erken tespit: Yoldaki bozulmanın zamanında tespit edilmesi, kazaların azaltılmasına ve insan hayatının korunmasına katkıda bulunabilir. Trafik bileşenlerinin konfor ve güvenliğini artırabilir.

Yüksek doğruluk: Kullanılan nesne algılama modeli ile yol kusurlarının yüksek doğruluk değeri ile algılanması neticesinde kullanıcılara yüksek güven sağlayabilir.

Erişilebilirlik: Elde edilen ürünün karayolu kusur tespit yaklaşımlarına entegre edilmesi, birleştirilen teknolojinin devlet kurumlarını, yerel belediyelere ve bireysel kullanıcıları kapsayan çeşitli bir kullanıcı portföyünün oluşturulması yol kusurlarına erişilebilirliğini kolaylaştırılabilir.

Denetim: Bu yaklaşım, yolun kusurlu bölümünün incelenmesi ve belirlenmesi sürecinde olası insani karar hatalarının hariç tutulmasını sağlar. Doğruluk açısından yüksek veri sağlamanın yanında çalışan ve zaman tasarrufu imkânı sunabilir.

Maliyet: Yol kusurlarının tespitinde farklı yaklaşımlar olduğu ve genel olarak sorumluların manuel denetim sağladığı gözlemlenmiştir. Ayrıca diğer bir yaklaşım olan lazer ve özel kameralarda donatılmış araçların yüksek fiyat ile pazarlandığı bilinmektedir. Her iki yaklaşımda da yüksek maliyet olduğu ve özel olarak algılama sürecine dâhil edildiği açıktır. Ancak bu çalışma kapsamında elde edilen ürünün düşük maliyetle tam otomatik olarak yol kusurlarını algılaması maliyet ve verimlilik açısından uygundur.

Diğer teknolojilerle entegrasyon: Bu araştırmanın otonom araçlar gibi diğer teknolojilerle entegrasyonu güvenli ve konforlu ulaşımın sağlanmasını kolaylaştırabilir. Ayrıca otonom araç teknolojisinin giderek hızlandığı günümüzde özellikle D50 ve D60 kusur türlerinin çok hızlı şekilde onarılması gerekmektedir.

6. SONUÇ VE ÖNERİLER

Ulaşım altyapısı modern toplum çerçevesinde temel bir rol oynayarak insanlığın var oluşundan beri her zaman toplumların gelişmesindeki en önemli faktör olmuştur. Ulaşım altyapısındaki olumlu gelişmelerin sağladığı olanaklar toplumların ekonomik ve sosyal kalkınması üzerinde önemli bir etkiye sahiptir. Özellikle kamu hizmeti olan sağlık, eğitim, güvenlik gibi işleyişlere erişimin kaliteli bir yol ağı ile sağlanması gerekmektedir. Yol ağları toplumlar arasında köprü görevini üstelenerek birçok yönden etkileşimi artırmaktadır. Etkileşim sayesinde kültürel gelişim, bilgi ve fikir alışverişi, ticaret olanakları artmaktadır. Geçmişten günümüze kadar uzanan tarihsel süreçte ulaşım altyapısındaki gelişmeler toplumları her zaman olumlu etkilemiştir.

Karayolu ulaşımın gerçekleştiği yol ağlarının günümüzde farklı malzeme seçimi ve yöntemler ile tasarlandığı görülmektedir. Genel olarak yol ağları esnek, rijit ve kompozit kaplama olarak üç sınıfta inşa edilmekle birlikte esnek kaplama üstyapı tasarımlarında sıklıkla kullanılmaktadır. Trafik için elverişli yüzey sağlaması, trafik yükü altında oluşacak deformasyonlara direnç, kademeli inşaata uygunluk, bakım ve onarımın kolay olması ve yapımdan hemen sonra hizmete açılabilmesi esnek üstyapıların daha sık tercih edilmesinin ana sebepleridir. Esnek üstyapıya sahip yol ağları zaman içerisinde yapısal bozulmalar ile karşılaşmaktadır. Oluşan bozulmaların yol altyapısından, serilen malzemenin özellikleri, bölgenin iklim durumu, çalışan elemanın kalifiyesi, yol ağını kullanan trafik kompozisyonu, bakım ve onarımına kadar birçok nedenden etkilendiği açıktır.

Yol ağlarında oluşan yapısal bozulmalar yol hasarı olarak adlandırılmaktadır. Yanal çatlaklar, boyuna çatlaklar, timsah çatlağı ve çukurlar genel olarak tüm yol ağlarında zaman içerisinde meydana gelmektedir. Bu hasarların bakım ve onarım süreçleri son derece önemlidir. Yol bozulmalarının teşhis edilmesi, belirli bir bölgenin ekonomik canlılığının korunması, yerel halkın refahının sağlanması, güvenli ve yeterli ulaşım hedefine ulaşılması açısından kritik öneme sahiptir. Yol hasarlarının belirlenme süreci günümüzde daha çok manuel olarak yapılmakla birlikte özel ekipmanlar ile donatılmış, kamera ve lazer barındıran yüksek maliyetli araçlar ile de otomatik olarak yapılmaktadır.

Her iki sistemde de maliyet ve verim durumu bakımından karşılaştırıldığında elverişli bir sistem olmadığı görülmektedir.

Yapılan tez çalışmasında yol ağında meydana gelen kusurların küresel ölçekte otomatik olarak belirlenmesi ve sınıflandırılmasını sağlayan bir gömülü sistem inşa edilmiştir. Japonya, Hindistan, Çek Cumhuriyeti, Norveç, Çin, ABD, Gürcistan ve Türkiye olmak üzere sekiz farklı ülkeden yol görüntüleri elde edilmiştir. Gürcistan ve Türkiye'ye ait yol görüntüleri yazar tarafından akıllı telefon ile toplanmıştır. Ayrıca D00, D10, D20, D30, D40, D50, D60, D70, D80 ve D90 olmak üzere 10 farklı yol kusuru çalışmaya dâhil edilmiştir. Yol hasarı ve yol kusuru terimleri farklı anlamları ifade etmektedir. Her yol hasarı, kusur olarak algılanmakta ancak her yol kusuru, hasar olarak algılanmamaktadır. D00, D10, D20, D40 ve D90 yol hasarı olarak meydana gelirken diğerleri yol kusuru olarak nitelendirilmektedir.

Yol kusurlarını algılama ve sınıflama sürecinde tek dedektörlü algılama modellerinden YOLOv5, YOLOv7 ve YOLOv8 kullanılmıştır. Birçok kombinasyon ile eğitim süreçleri tamamlanmıştır. Modellerin test süreçlerinde Japonya, Hindistan, Çek Cumhuriyeti, ABD, Çin, Norveç ve Kuveyt ülkelerine ait yol görüntüleri kullanılmıştır. Bu ülkelere ait toplam 3.485 test görüntüsü içerisinde gün ışığı, güneş yansıması, bulutlu hava, yağmurlu hava, karlı hava ve gölgeli kesim gibi gerçek dünyada karşılaşılabilen farklı hava şartlarını içeren 84 görüntü test aşamasında kullanılmıştır. Altı ülkeye ait 14 adetlik farklı görüntülere ait test sonuçları EK-1'de yer almaktadır. Test işleminde 0,25 güven değeri dikkate alınmıştır. Bu değer 0-1 arasında değişkenlik göstermektedir. Farklı güven aralıklarında test işlemleri gerçekleştirilmiş olup TP oluşumlarının çok olduğu FP ve FN oluşumlarının az olduğu ideal değer elde edilmiştir. Üç modelinde kusur algılama, çıkarım zamanı, F1 puanı ve mAP değerleri bakımından birbirlerine üstünlükleri mevcuttur. F1 (0,56) puanı ve mAP (0,564) değerleri incelendiğinde modellerin birbirlerine yakın sonuçlar vermekle birlikte en üstün değerlere sahip olan YOLOv7 ağ modelidir. Ayrıca çıkarım zamanlarının hesaplanması sadece Çin'e ait test veri seti üzerinden gerçekleştirilmiştir. Aynı test seti üzerinden yapılan algılamada en yüksek kusur yakalayan (64 adet) YOLOv8 olmaktadır. Bu ağ modelini sırası ile YOLOv7 ve YOLOv5 takip etmektedir. Test sürecinde görüntü başına sağlanan algılama süresinde (6,3 ms) ve kusur başına algılama süresinde (2,32 ms) YOLOv5 diğer modellere göre

üstünlük sağlamaktadır. Üç modelin de farklı alanlarda üstünlükler sağladığı görülmektedir. Test seti içindeki görüntülerde en çok kusur algılayan YOLOv8, F1 puanı ve mAP değerlerinde YOLOv7 ve çıkarım zamanlarında en hızlı olan YOLOv5 olarak gözlemlenmiştir.

Algılama ve sınıflandırma analiz süreçlerinin tamamlanması ve kusur algılamadaki başarılı performansı dolayısıyla YOLOv8x'e ait ağırlık dosyası (best.pt) gömülü sistem inşasında kullanılmıştır. Donanım kısmında Jetson Xavier NX, Arducam kamera modülü, GPS alıcı, harici hafıza kartı ve bağlantı elemanları yer almaktadır. Donanım ve yazılım kısmını içeren bu sistemin test süreci Erzurum Teknik Üniversitesi kampüs yol ağlarında gerçekleştirilmiştir. Yaklaşık olarak 4,5 km uzunluğundaki yol ağı kusur bakımından gerçek zamanlı olarak taranmıştır. Taranan yol ağına 10 kusur sınıfından 9 adeti yol ağına gözlemlenmiştir. D00-517, D10-507, D20-50, D30-2, D40-48, D50-18, D60-343, D70-25 ve D80-9 adet olarak gömülü sistem tarafından gerçek zamanlı olarak algılanmıştır. Yol kusurlarının gerçek zamanlı olarak algılanma ve sınıflandırma süreci oldukça zorlu bir görevdir. Algılanan ve sınıflanan kusurların konum bilgileri sisteme entegre GPS modülü yardımıyla elde edilmektedir. Sisteme entegre bu modül ile modelin algıladığı kusur sınıflarının konum bilgileri de sağlanmaktadır. Kusurlara ait konum bilgileri ArcMap ortamında işlenerek nokta (point) yoğunluk analizine tabi tutulmuştur. Özellikle kampüs yol ağının kuzey-doğu ve güney kesimlerinde yol kusurlarının yoğunlaştığı görülmektedir. Bu bilgiler yol ağı sorumlularına ve kaplama serim işlemini sağlayan kurumlar için geri bildirim sağlamada oldukça önemlidir.

Gerçekleştirilen tüm bu süreçlerin ardından manuel yaklaşım ile yol ağlarını kontrol etmeye çalışan ilgili kurumlar için yüksek doğruluk oranı, verimlilik ve düşük maliyet sağlayan sistem tasarlanmıştır. Bu sistem ile kusurların erken tespit edilmesi ve trafik bileşenlerinin konfor ve güvenliğinin artırılması sağlanabilir. Bakım ve onarım süreçlerinde hızlanma neticesinde yol ağının hizmet ömründe uzama ve özellikle küçük tekerlekli mikro mobilite araçları sürücüleri için yüksek güvenlik sağlanabilir. Sistemin karayolu kusur tespit yaklaşımlarına entegre edilmesi, birleştirilen teknolojinin devlet kurumları ve yerel belediyelerce kullanılması durumunda yol kusurlarına erişilebilirliğini

kolaylaştırılabilir. Ayrıca son yıllarda gelişimini hızlı sürdüren otonom araç teknolojisi ile entegrasyonu durumunda sürecin hızlanması kolaylaştırılabilir.

Yol kusurları, oluşumları itibariyle sabit boyutlara sahip olmayan, iç içe geçmiş ve oluşumu tahmin edilemeyen özelliklere sahiptir. Ayrıca yol görüntülerin toplanma şekli, açısı, kalitesi, hava durumu ve iklim koşulları dikkate alındığında birçok parametre içermektedir. Tüm bu hususlar dikkate alındığında ve yol kusurlarının gerçek zamanlı algılanma durumunda üstün donanım ve yazılım ekipmanlarına ihtiyaç vardır. Sınırlı şartlar altında en iyi performansı sergileyen küresel ölçekli otomatik yol kusur tespit sistemi ile yol ağlarında meydana gelen yol kusurlarının algılanması ve sınıflandırması gerçekleştirilerek AUS uygulama biçimi olan araç-altyapı (V2I) iletişim modeli tez çalışması kapsamında sunulmuştur.

KAYNAKLAR

- Adeli, H. 2001. Neural networks in civil engineering: 1989-2000. *Computer-Aided Civil and Infrastructure Engineering*, 16(2), 126–142.
- Agarwal, S., Terrail, J. O. D. and Jurie, F. 2018. Recent advances in object detection in the age of deep convolutional neural networks. *Computer Vision and Pattern Recognition*, arXiv:1809.03193v2.
- Ağaçsapan, B. and Çabuk, S. N. 2020. Determination of suitable waste transfer station areas for sustainable territories: Eskisehir case. *Sustainable Cities and Society*, 52, 101829.
- Ağın, O. ve Malasli, M. Z. 2016. Görüntü işleme tekniklerinin sürdürülebilir tarımdaki yeri ve önemi: Literatür çalışması. *Journal of Agricultural Machinery Science*, 12(3), 199–206.
- Ahmed, H. E. 2018. AI advantages and disadvantages. *International Journal of Scientific Engineering and Applied Science (IJSEAS)*, 4(4), 22–25.
- Alamgeer, M., Alkahtani, H. K., Maashi, M., Othman, M., Hilal, A. M., Alsaid, M. I. and Alneil, A. A. 2023. Optimal fuzzy wavelet neural network based road damage detection. *IEEE Access*, 11, 61986–61994.
- Anaissi, A., Khoa, N. L. D., Rakotoarivelo, T., Alamdari, M. M. and Wang, Y. 2019. Smart pothole detection system using vehicle-mounted sensors and machine learning. *Journal of Civil Structural Health Monitoring*, 9(1), 91–102.
- Anonim, 2016. Türkiye otomotiv sektörü strateji belgesi ve eylem planı (2016-2019), 1-40.
- Anonim, 2018. Ulusal akıllı ulaşım sistemleri strateji belgesi (2014-2023) güncellemesi ve 2020-2023 eylem planı hazırlama projesi, 1-81.
- Anonim, 2019a. Web Sitesi: <https://www.esri.com/en-us/what-is-gis/overview>, Erişim Tarihi: 23.10.2021.
- Anonim, 2019b. Web Sitesi: <https://www.uab.gov.tr/uploads/pages/bakanlik-yayinlari/20221025-2053-ulasirma-ve-lojistik-ana-plani-tr.pdf>, Erişim Tarihi: 12.10.2022.
- Anonim, 2020. Ulusal Akıllı Ulaşım Sistemleri Strateji Belgesi ve 2020-2023 Eylem Planı, 1-133.
- Anonim, 2023a. Web Sitesi: <https://www.kgm.gov.tr/Sayfalar/KGM/SiteTr/Kurumsal/YolAgi.aspx>, Erişim Tarihi: 06.04.2023.
- Anonim, 2023b. Web Sitesi: <https://www.kgm.gov.tr/Sayfalar/KGM/SiteTr/Istatistikler/DevletvellYolEnvant.eri.aspx>, Erişim Tarihi: 22.04.2023.
- Anonim, 2023c. Web Sitesi: <https://www.teknofest.org/tr/>, Erişim Tarihi: 17.06.2023.
- Anonim, 2023d. Web Sitesi: <https://github.com/ultralytics/ultralytics>, Erişim Tarihi: 10.02.2022.

- Anonim, 2023e, Web Sitesi: <https://data.tuik.gov.tr/Kategori/GetKategori?p=nufus-ve-demografi-109&dil=1>, Eriřim Tarihi:06.02.2023.
- Anonim, 2023f. Web Sitesi: <https://hgm.uab.gov.tr/uploads/pages/akilli-ulasim-sistemleri-aus/k-aus-turkiye-mevcut-durum-analizi.pdf>, Eriřim Tarihi:13.02.2023.
- Anonim, 2023g. Web Sitesi: <https://alj.com.tr/perspective/transport-on-demand-how-mobility-as-a-service-could-revolutionize-the-way-we-travel/>, Eriřim Tarihi:20.09.2023.
- Anonim, 2023h. Web Sitesi: <https://ispark.istanbul/projeler/park-et-devam-et/>, Eriřim Tarihi:03.05.2023.
- Anonim, 2023i. Web Sitesi: <https://hgm.uab.gov.tr/akilli-ulasim-sistemleri-aus>, Eriřim Tarihi:10.09.2023.
- Anonim, 2023k. Web Sitesi: <https://www.112.gov.tr/>, Eriřim Tarihi:20.07.2023.
- Anonim, 2023l. Web Sitesi: <http://itslab.boun.edu.tr/projects>, Eriřim Tarihi:25.10.2023.
- Anonim, 2023m. Web Sitesi <http://www.guvenlik.yildiz.edu.tr/sayfa/1>, Eriřim Tarihi:25.10.2023.
- Anonim, 2023n.Web Sitesi: <https://www.okan.edu.tr/arastirma/sayfa/903/ulastirma-teknolojileri-ve-akilli-otomotiv-sistemleri-uyg-ve-arst-merkezi/>, Eriřim Tarihi:22.10.2023.
- Anonim, 2023p. Web Sitesi: <https://bausmer.bandirma.edu.tr/>, Eriřim Tarihi:22.09.2023.
- Anonim, 2023r. Web Sitesi: <https://mf.eskisehir.edu.tr/tr/Icerik/Detay/otonom-arac-takimi>, Eriřim Tarihi:10.09.2023.
- Anonim, 2023s. Web Sitesi: <https://www.issd.com.tr/>, Eriřim Tarihi:24.09.2023.
- Anonim, 2023t. Web Sitesi: <https://austurkiye.org.tr/>, Eriřim Tarihi:07.09.2023.
- Anonim, 2023u. Araç içi ve haberleşme Sisteminin (ABHS) teknik özelliklerinin belirlenmesi projesi mevcut durum analizi raporu, 1-201.
- Anonymous, 2021. Web Sitesi: <https://github.com/sekilab/RoadDamageDetector>, Eriřim Tarihi:12.09.2021.
- Anonymous, 2022a. Web Sitesi: <https://xenomatix.com/our-solutions/road-surveying/>, Eriřim Tarihi:15.09.2023.
- Anonymous, 2022b. Web Sitesi: <https://crddc2022.sekilab.global/>, Eriřim Tarihi:12.04.2023.
- Anonim, 2023a, Web Sitesi: <https://github.com/ultralitics/ultralitics>, Eriřim Tarihi:10.02.2022.
- Anonymous, 2023b. Web Sitesi: <https://www.car-2-car.org/about-c-its>, Eriřim Tarihi:20.09.2023.
- Anonymous, 2023c. Web Sitesi: <https://www.uber.com/tr/tr/>, Eriřim Tarihi:05.09.2023.
- Anonymous, 2023d. Web Sitesi: <https://www.lyft.com/>, Eriřim Tarihi:05.09.2023.

- Anonymous, 2023e. Web Sitesi: <https://web.didiglobal.com/>, Eriřim Tarihi:05.09.2023.
- Anonymous, 2023f. Web Sitesi: <https://www.grab.com/sg/>, Eriřim Tarihi:05.09.2023.
- Arslan, K. 2020. Eđitimde yapay zekâ ve uygulamaları. Batı Anadolu Eđitim Bilimleri Dergisi (BAEBD), 11(1), 71–88.
- Arya, D., Maeda, H., Ghosh, S. K., Toshniwal, D. and Sekimoto, Y. 2021. RDD2020: An annotated image dataset for automatic road damage detection using deep learning. Data in Brief, 36, 107133.
- Arya, D., Maeda, H., Ghosh, S. K., Toshniwal, D. and Sekimoto, Y. 2022. RDD2022: A multi-national image dataset for automatic road damage detection, arXiv:2209.08538v1.
- Arya, D., Maeda, H., Ghosh, S. K., Toshniwal, D., Mraz, A., Kashiyama, T. and Sekimoto, Y. 2021. Deep learning-based road damage detection and classification for multiple countries. Automation in Construction, 132, 1-18.
- Arya, D., Maeda, H., Ghosh, S. K., Toshniwal, D., Omata, H., Kashiyama, T. and Sekimoto, Y. 2022. Crowdsensing-based road damage detection challenge (CRDDC2022). Proceedings. Computer Vision and Pattern Recognition. arXiv:2211.11362v1.
- Arya, D., Maeda, H., Kumar Ghosh, S., Toshniwal, D., Omata, H., Kashiyama, T. and Sekimoto, Y. 2020. Global Road Damage Detection: State-of-the-art Solutions. 2020 IEEE International Conference on Big Data (Big Data), 10-13 December, 5533–5539, Atlanta, USA.
- Asci, G. and Karşligil, M. E. 2020. Road Damage Detection Via in Car Cameras. 2020 28th Signal Processing and Communications Applications Conference (SIU), 8-7 October, SIU 2020 - Proceedings, 1–4, Gaziantep, Türkiye.
- Aslan, M. 2022. Derin öğrenme tabanlı otomatik beyin tümör tespiti. Fırat Üniversitesi Mühendislik Bilimleri Dergisi, 34(1), 399–407.
- Atan, S. 2016. Veri, büyük veri işletmecilik. Balıkesir Üniversitesi Sosyal Bilimler Enstitüsü Dergisi, 19(35), 137–154.
- Baltacıođlu, K., Bařar, M. T., Karaaslan, M., Özer, Z., ve Öcal, S. 2023. Görüntü işleme yoluyla otonom tren - hayvan kazası önleme sistemi. Demiryolu Mühendisliđi, 18, 150–161.
- Bhavsar, M., Alfarrarjeh, A., Baranwal, U. and Kim, S. H. 2022. Country-Specific Ensemble Learning: A Deep Learning Approach for Road Damage Detection. 2022 IEEE International Conference on Big Data, 17-20 December, Proceedings-IEEE Big Data 2022, 6387–6394, Osaka, Japan.
- Bhbosale, S., Pujari, V. and Multani, Z. 2020. Advantages and disadvantages of artificial intelligence. Aayushi International Interdisciplinary Research Journal, 77, 227–230.
- Bochkovskiy, A., Wang, C.-Y. and Liao, H.Y. M. 2020. YOLOv4: Optimal speed and accuracy of object detection. Computer Vision and Pattern Recognition. arXiv:2004.10934v1.
- Borji, A., Cheng, M.-M., Hou, Q., Jiang, H. and Li, J. 2019. Computational visual media salient object detection: A survey. Computational Visual Media, 5, 117-150.

- Cai, Z. and Vasconcelos, N. 2018. Cascade R-CNN: Delving into high quality object detection. Computer Vision and Pattern Recognition, arXiv:1712.00726v1.
- Careem, 2023. Web Sitesi: <https://www.careem.com/>, Eriřim Tarihi:05.09.2023.
- Chun, C. and Ryu, S. K. 2019. Road surface damage detection using fully convolutional neural networks and semi-supervised learning. Sensors, 19(24), 1–15.
- Çetin, B., Barış, S., Saroğlu, S. 2011. Türkiye’de karayollarının gelişimine tarihsel bir bakış. Çankırı Karatekin Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 1(1), 123–150.
- Çodur, M. Y. ve Harun, C. 2018. Erzurum Cumhuriyet Caddesi trafik tıkanıklığı problemi için kordon bazlı tıkanıklık fiyatlandırılmasının uygulanabilirliğinin araştırılması. Harran Üniversitesi Mühendislik Dergisi, 3(3), 81–92.
- Dalal, N. and Triggs, B. 2005. Histograms of Oriented Gradients for Human Detection. 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 20-25 June, CVPR 2005, 886–893, San Diego, USA.
- Daoud, E., Khalil, N.a and Gaedke, M. 2022. Implementation of a one stage object detection solution to detect counterfeit products marked with a quality mark. Online/Virtual, 37-49.
- Dean, T., Ruzon, M. A., Segal, M., Shlens, J., Vijayanarasimhan, S. and Yagnik, J. 2013. Fast, Accurate Detection of 100,000 Object Classes on A Single Machine. 2013 IEEE Conference on Computer Vision and Pattern Recognition, 23-28 June, 1814–1821, Portland, USA.
- Deepa, D. and Sivasangari, A. 2023. ESSR-GAN: Enhanced super and semi supervised remora resolution based generative adversarial learning framework model for smartphone based road damage detection. Multimedia Tools and Applications. 1-31.
- Demesouka, O. E., Vavatsikos, A. P. and Anagnostopoulos, K. P. 2013. Suitability analysis for siting MSW landfills and its multicriteria spatial decision support system: Method, implementation and case study. Waste Management, 33(5), 1190–1206.
- Dhiman, T. and Mohammad, S. 2018. Object detection and recognition in image processing. SSRN Electronic Journal, 8, 24–30.
- Ding, W., Zhao, X., Zhu, B., Du, Y., Zhu, G., Yu, T. and Wang, J. 2022. An Ensemble of One-Stage and Two-Stage Detectors Approach for Road Damage Detection. 2022 IEEE International Conference on Big Data, 17-20 December, Proceedings-IEEE Big Data 2022, 6395–6400, Osaka, Japan.
- Ding, X., Chen, H., Zhang, X., Huang, K., Han, J. and Ding, G. 2022. Re-parameterizing your optimizers rather than architectures, Machine Learning, arXiv:2205.15242.
- Ding, X., Zhang, X., Ma, N., Han, J., Ding, G. and Sun, J. 2021. RepVgg: Making VGG-style ConvNets great again. Computer Vision and Pattern Recognition, arXiv:2101.03697.
- Doğan, F. ve Türkoğlu, İ. 2019. Derin öğrenme modelleri ve uygulama alanlarına ilişkin bir derleme. DÜMF Mühendislik Dergisi, 10(2), 409–445.

- Doshi, K. and Yilmaz, Y. 2020. Road Damage Detection Using Deep Ensemble Learning. 2020 IEEE International Conference on Big Data, 10-13 December, Proceedings-IEEE Big Data 2020, 5540–5544, Atlanta, USA.
- Duran, F. ve Teke, M. 2019. Akıllı yol durum sensörü tasarımı. International Journal of Engineering Research and Development, 11(1), 396–401.
- Eisenbach, M., Stricker, R., Seichter, D., Amende, K., Debes, K., Sesselmann, M. and Gross, H.M. 2017. How to Get Pavement Distress Detection Ready for Deep Learning? A Systematic Approach. 2017 International Joint Conference on Neural Networks (IJCNN), 14-19 May, 2039–2047, Alashka, USA.
- Eldem, A., Eldem, H. ve Palali, A. 2017. Görüntü işleme teknikleriyle yüz algılama sistemi geliştirme. Bitlis Eren Üniversitesi Fen Bilimleri Dergisi, 6(2), 44–48.
- Erbaş, M., Kabak, M., Özceylan, E. and Çetinkaya, C. 2018. Optimal siting of electric vehicle charging stations: A GIS-based fuzzy Multi-Criteria Decision Analysis. Energy, 163, 1017–1031.
- Eren, E. 2020. Farklı arazi kullanımlarına dayalı alternatif bisiklet paylaşım istasyonu yer seçimi için cbs tabanlı hibrit bir yaklaşım. Yüksek Lisans Tezi, Adana Alparslan Türkeş Bilim ve Teknoloji Üniversitesi, Fen Bilimleri Enstitüsü, İnşaat Mühendisliği Ana Bilim Dalı, 112, Adana.
- Felzenszwalb, P. F., Girshick, R. B., McAllester, D. and Ramanan, D. 2010. Object detection with discriminatively trained part-based models. IEEE Transactions on Pattern Analysis and Machine Intelligence, 32(9), 1627–1645.
- Gao, Y., Kong, B. and Mosalam, K. M. 2019. Deep leaf-bootstrapping generative adversarial network for structural image data augmentation. Computer-Aided Civil and Infrastructure Engineering, 34(9), 755–773.
- Gauen, K., Dailey, R., Laiman, J., Zi, Y., Asokan, N., Lu, Y. H. and Chen, S. C. 2017. Comparison of Visual Datasets for Machine Learning. 2017 IEEE International Conference on Information Reuse and Integration, 4-6 August, IRI, 346–355, San Diego, USA.
- Ghiasi, G., Lin, T. and Le, Q. V. 2019. NAS-FPN : Learning scalable feature pyramid architecture for object detection. Computer Vision and Pattern Recognition, arXiv:1904.07392.
- Girshick, R. 2015. Fast R-CNN. Computer Vision and Pattern Recognition, arXiv:1504.08083v2.
- Girshick, R., Donahue, J., Darrell, T. and Malik, J. 2014. Rich feature hierarchies for accurate object detection and semantic segmentation. Computer Vision and Pattern Recognition, arXiv:1311.2524v5.
- Gönen, S., Barışkan, M. A., Karacayılmaz, G., Alhan, B., Yılmaz, E. N. and Artuner, H. 2021. Gender detection via voice using artificial intelligence algorithms. Gazi Journal of Engineering Sciences, 8(3), 567–575.
- Güçlü, E., Aydın, İ., Şener, T. K. ve Akin, E. 2022. Çelik yüzeylerdeki kusurların tespiti için derin öğrenme tabanlı gömülü sistem tasarımı. EMO Bilimsel Dergi, 12(2), 27–33.
- Hascoet, T., Zhang, Y., Persch, A., Takashima, R., Takiguchi, T. and Ariki, Y. 2020. Faster R-CNN Monitoring of Road Damages: Competition and Deployment. 2020

IEEE International Conference on Big Data, 10-13 December, Proceedings-IEEE Big Data 2020, 5545–5552, Atlanta, USA.

He, K., Gkioxari, G., Dollár, P. and Girshick, R. 2017. Mask R-CNN. *Computer Vision and Pattern Recognition*, arXiv:1703.06870v3.

He, K., Zhang, X., Ren, S. and Sun, J. 2014. Spatial pyramid pooling in deep convolutional networks for visual recognition. *Computer Vision and Pattern Recognition*, arXiv:1406.4729.

He, K., Zhang, X., Ren, S. and Sun, J. 2016. Deep residual learning for image recognition. *Computer Vision and Pattern Recognition*, arXiv:1512.03385v.

Hegde, V., Trivedi, D., Alfarrarjeh, A., Deepak, A., Ho Kim, S. and Shahabi, C. 2020. Yet Another Deep Learning Approach for Road Damage Detection Using Ensemble Learning. 2020 IEEE International Conference on Big Data, 10-13 December, Proceedings-IEEE Big Data 2020, 5553–5558, Atlanta, USA.

Hocher, G. 2020. Web Sites: <https://github.com/ultralytics/yolov5/releases>, Erişim Tarihi: 12.12.2022.

Hoiem, D., Chodpathumwan, Y. and Dai, Q. 2012. Diagnosing Error in Object Detectors. 12th European Conference on Computer Vision, 7-13 October, Proceedings Part III, 340-353, Florence, Italy.

Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T. and Adam, H. 2017. MobileNets: efficient convolutional neural networks for mobile vision applications. *Computer Vision and Pattern Recognition*, arXiv:1704.04861v1.

Hu, S., Dessouky, M. M., Uhan, N. A. and Vayanos, P. 2021. Cost-sharing mechanism design for ride-sharing. *Transportation Research Part B: Methodological*, 150, 410–434.

Huang, G., Liu, Z., Van Der Maaten, L. and Weinberger, K. Q. 2017. Densely connected convolutional networks. *Computer Vision and Pattern Recognition*, arXiv:1608.06993v5.

Huang, J., Rathod, V., Sun, C., Zhu, M., Korattikara, A., Fathi, A. and Murphy, K. 2017. Speed/accuracy trade-offs for modern convolutional object detectors. *Computer Vision and Pattern Recognition*, arXiv:1611.10012v3.

Ibrahim, G. R. F., Rasul, A., Hamid, A. A., Ali, Z. F. and Dewana, A. A. 2019. Suitable site selection for rainwater harvesting and storage case study using Dohuk governorate. *Water*, 11(4), 864.

Ioffe, S. and Szegedy, C. 2015. Batch normalization: Accelerating deep network training by reducing internal covariate shift. *Machine Learning*, arXiv:1502.03167.

Jalil, F. and Voronkov, I. 2016. Object detection using image processing. *Computer Vision and Pattern Recognition*, arXiv:1611.07791v1.

Jana, S., Middya, A. and Roy, S. 2023. Mobile crowd sensing based road anomaly detection using Mask R-CNN, *Research Square*, 1-18.

Jena, R., Pradhan, B., Beydoun, G., Alamri, A. M., Ardiansyah, N. and Sofyan, H. 2020. Earthquake hazard and risk assessment using machine learning approaches at Palu, Indonesia. *Science of the Total Environment*, 749, 141582.

- Jeong, D. 2020. Road Damage Detection Using YOLO with Smartphone Images. 2020 IEEE International Conference on Big Data, 10-13 December, Proceedings-IEEE Big Data 2020, 5559–5562, Atlanta, USA.
- Jeong, D. and Kim, J. 2022. Road Damage Detection Using YOLO with Image Tiling about Multi-Source Images. 2022 IEEE International Conference on Big Data, 17-20 December, Proceedings-IEEE Big Data 2022, 6401–6406, Osaka, Japan.
- Jo, Y. and Ryu, S. 2015. Pothole detection system using a black-box camera. *Sensors*, 15(11), 29316–29331.
- Joseph, R. 2013. Web Sitesi: <https://pjreddie.com/darknet/>, Eriřim Tarihi: 08.06.2023.
- Kaçmaz, S., Aktaş, F. ve Sondař, A. 2022. Evcil hayvanlar için nesnelerin interneti tabanlı akıllı mama sisteminin geliştirilmesi. *European Journal of Science and Technology*, 45, 26–29.
- Kandemir, F. ve Azizođlu, F. 2023. Hemřirelikte yapay zekâ ve robot teknolojilerinin kullanımı, 27(2), 118–127.
- Karras, T., Aila, T., Laine, S. and Lehtinen, J. 2018. Progressive Growing of GANs for Improved Quality, Stability, and Variation. 6th International Conference on Learning Representations, April 30- May 3, ICLR 2018 - Conference Track Proceedings, 1–26.
- Kaya, Ö. ve Çodur, M. Y. 2022. Modern derin öğrenme tabanlı nesne algılama modellerinin incelenmesi, *Mühendislik Alanında Uluslararası Arařtırmalar - II*, C. Özalp ve E. Hürdoğan (Ed.), Serüven Yayınevi, 155–177, İzmir.
- Kaya, Ö., Alemdar, K. D., Atalay, A., Çodur, M. Y. and Tortum, A. 2022. Electric car sharing stations site selection from the perspective of sustainability: A GIS-based multi-criteria decision making approach. *Sustainable Energy Technologies and Assessments*, 52, 102026.
- Khan, N. U., Wan, W., Yu, S., Muzahid, A. A. M., Khan, S. and Hou, L. 2020. A Study of user activity patterns and the effect of venue types on city dynamics using location-based social network data. *ISPRS International Journal of Geo-Information*, 9(12), 733.
- Kortmann, F., Talits, K., Fassmeyer, P., Warnecke, A., Meier, N., Heger, J. and Funk, B. 2020. Detecting Various Road Damage Types in Global Countries Utilizing Faster R-CNN. 2020 IEEE International Conference on Big Data, 10-13 December, Proceedings-IEEE Big Data 2020, 5563–5571, Atlanta, USA.
- Krizhevsky, A. and Hinton, G. E. 2012. ImageNet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems*, 60(6), 1–9.
- Kumari Saha, P. and Sekimoto, Y. 2022. Road Damage Detection for Multiple Countries. 2022 IEEE International Conference on Big Data, 17-20 December, Proceedings-IEEE Big Data 2022, 6431–6438, Osaka, Japan.
- Lee, T., Chun, C. and Ryu, S. K. 2021. Detection of road-surface anomalies using a smartphone camera and accelerometer. *Sensors*, 21(2), 1–17.
- Lee, Y., Hwang, J. W., Lee, S., Bae, Y. and Park, J. 2019. An Energy and GPU-Computation Efficient Backbone Network for Real-Time Object Detection. 2019

IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), 16-17 June, 752–760, California, USA.

- Li, C., Li, L., Jiang, H., Weng, K., Geng, Y., Li, L. and Wei, X. 2022. YOLOv6: A single-stage object detection framework for industrial applications. *Computer Vision and Pattern Recognition*, arXiv:2209.02976.
- Li, J., Qin, Q., Ma, H. and Yuan, W. 2010. Study on Road Damage Assessment Based on RS and GIS. 2010 IEEE International Geoscience and Remote Sensing Symposium, 25-30 July, IGARSS 2010, 4534–4537, Hawaii, USA.
- Li, R. and Liu, C. 2021. Road Damage Evaluation Via Stereo Camera and Deep Learning Neural Network. 2021 IEEE Aerospace Conference, 6-13 March, Big Sky, 1-7, Montana, USA.
- Liang, H., Lee, S. C., Seo, S. 2022. Automatic recognition of road damage based on lightweight attentional convolutional neural network. *Sensors*, 22(24), 1-23.
- Lin, T., Goyal, P., Girshick, R., He, K. and Dollar, P. 2017. Focal loss for dense object detection. *Computer Vision and Pattern Recognition*, arXiv:1708.02002.
- Lin, T., Dollar, P., Ross, G., He, K. and Hariharan, B. 2016. Feature pyramid networks for object detection. *Computer Vision and Pattern Recognition*. arXiv:1612.03144v2.
- Liu, L., Ouyang, W., Wang, X., Fieguth, P., Chen, J., Liu, X. and Pietikäinen, M. 2020. Deep learning for generic object detection: A survey. *International Journal of Computer Vision*, 128(2), 261–318.
- Liu, S., Zhao, Q., Wen, M., Deng, L., Dong, S. and Wang, C. 2013. Assessing the impact of hydroelectric project construction on the ecological integrity of the Nuozhadu Nature Reserve, southwest China. *Stochastic Environmental Research and Risk Assessment*, 27(7), 1709–1718.
- Liu, S., Qi, L., Qin, H., Shi, J. and Jia, J. 2018. Path aggregation network for instance segmentation. *Computer Vision and Pattern Recognition*, arXiv:1803.01534.
- Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C.Y. and Berg, A. C. 2016. SSD: Single shot multibox detector. *Computer Vision and Pattern Recognition*, arXiv:1512.02325.
- Liu, Y., Zhang, X., Zhang, B. and Chen, Z. 2020. Deep Network for Road Damage Detection. 2020 IEEE International Conference on Big Data, 10-13 December, Proceedings-IEEE Big Data 2020, 5572–5576, Atlanta, USA.
- Lohia, A., Kadam, K. D. and Bongale, A. 2021. Bibliometric analysis of one-stage and two-stage object detection, *Library Philosophy and Practice (e-journal)* 4910.
- Luo, H., Li, C., Wu, M. and Cai, L. 2023. An enhanced lightweight network for road damage detection based on deep learning. *Electronics*, 12(12), 2583.
- Luo, K., Agarwal, C., Das, S. and Guo, X. 2022. The Multi-Vehicle Ride-Sharing Problem. *WSDM '22: Proceedings of the Fifteenth ACM International Conference on Web Search and Data Mining*, 21-25 February, 628–637, New York, United States.
- Ma, H., Lu, N., Ge, L., Li, Q., You, X. and Li, X. 2013. Automatic Road Damage Detection Using High-Resolution Satellite Images and Road Maps. *International*

Geoscience and Remote Sensing Symposium (IGARSS), 21-26 July, 3718–3721, Melbourne, Australia.

- Ma, N., Fan, J., Wang, W., Wu, J., Jiang, Y., Xie, L. and Fan, R. 2022. Computer vision for road imaging and pothole detection: A state-of-the-art review of systems and algorithms. *Transportation Safety and Environment*, 4(4), 1–16.
- Maeda, H., Kashiyama, T., Sekimoto, Y., Seto, T. and Omata, H. 2020. Generative adversarial network for road damage detection. *Computer-Aided Civil and Infrastructure Engineering*, 36(1), 47–60.
- Maeda, H., Sekimoto, Y., Seto, T., Kashiyama, T. and Omata, H. 2018. Road damage detection and classification using deep neural networks with smartphone images. *Computer-Aided Civil and Infrastructure Engineering*, 33(12), 1127–1141.
- Mandal, V., Mussah, A. R. and Adu-Gyamfi, Y. 2020. Deep Learning Frameworks for Pavement Distress Classification: A Comparative Analysis. 2020 IEEE International Conference on Big Data, 10-13 December, Proceedings-IEEE Big Data 2020, 5577–5583, Atlanta, USA.
- Miller, T. and Zaloshnja, E. 2009. On a Crash Course: The Dangers And Health Costs of Deficient Roadways, TRB Annual Meeting, 7-11 January, Accident Research Centre, 1-33, United States.
- Montgomery, R. A., Roloff, G. J. and Millspaugh, J. J. 2013. Variation in elk response to roads by season, sex, and road type. *Journal of Wildlife Management*, 77(2), 313–325.
- Mustakim, M. R. 2023. Road damage detection based on deep learning. Doctoral Thesis. Beijing Institute of Technology, School of Computer Science, 69, Beijing.
- Naddaf-Sh, S., Naddaf-Sh, M. M., Kashani, A. R. and Zargarzadeh, H. 2020. An Efficient and Scalable Deep Learning Approach for Road Damage Detection. Proceedings-2020 IEEE International Conference on Big Data, 10-13 December, 5602–5608.
- Niu, B., Liang, R., Zhang, S., Zhang, H., Qu, X., Su, Q. and Chen, Q. 2020. Epidemic analysis of COVID-19 in Italy based on spatiotemporal geographic information and Google Trends. *Transboundary and Emerging Diseases*, 68(4), 1–17.
- Okran, A. M., Abdel-Nasser, M., Rashwan, H. A. and Puig, D. 2022. Effective Deep Learning-Based Ensemble Model for Road Crack Detection. 2022 IEEE International Conference on Big Data, 17-20 December, Proceedings-IEEE Big Data 2022, 6407–6415, Osaka, Japan.
- Özdemir, Ş. ve Örsülü, S. 2019. Makine öğrenmesinde yeni bir bakış açısı : Otomatik makine öğrenmesi (AutoML). *Journal of Information Systems and Management Research*, 1(1), 23–29.
- Pei, Z., Lin, R., Zhang, X., Shen, H., Tang, J. and Yang, Y. 2020. CFM: A Consistency Filtering Mechanism for Road Damage Detection, 2020 IEEE International Conference on Big Data, 10-13 December, Proceedings-IEEE Big Data 2020, 5584–5591, Atlanta, USA.
- Pham, V., Nguyen, D. and Donan, C. 2022. Road Damage Detection and Classification with YOLOv7. 2022 IEEE International Conference on Big Data, 17-20 December, Proceedings-IEEE Big Data 2022, 6416–6423, Osaka, Japan.

- Pham, V., Pham, V. and Dang, T. 2020. Road Damage Detection and Classification with Detectron2 and Faster R-CNN. 2020 IEEE International Conference on Big Data, 10-13 December, Proceedings-IEEE Big Data 2020, 5592-5601, Atlanta, USA.
- Pierce, L. M., McGovern, G., Zimmerman, K. A. 2013. Practical guide for quality management of pavement condition data collection. U.S. Department of Transportation Federal Highway Administration, 1-170.
- Pirim, H. 2006. Yapay zekâ. Journal of Yaşar University, 1(1), 81-93.
- Pokrywka, J. 2022. Efficient GPU Training of A Diversified Model Ensemble for The Crowdsensing-Based Road Damage Detection Challenge (CRDDC2022). 2022 IEEE International Conference on Big Data, 17-20 December, Proceedings-IEEE Big Data 2022, 6424–6430, Osaka, Japan.
- Poyraz, G., Öztürk, F. and Kırıcı, P. 2021. Cancer detection with an image processing application. European Journal of Science and Technology, 28, 1442–1446.
- Redmon, J. and Angelova, A. 2015. Real-time grasp detection using convolutional neural networks. Robotics, arXiv:1412.3128.
- Redmon, J. and Farhadi, A. 2016. YOLO9000: Better, faster, stronger. Computer Vision and Pattern Recognition, arXiv:1612.08242.
- Redmon, J. and Farhadi, A. 2018. YOLOv3: An incremental improvement. Computer Vision and Pattern Recognition, arXiv:1804.02767.
- Redmon, J., Divvala, S., Girshick and R., Farhadi, A. 2015. You Only Look Once: Unified, real-time object detection. Computer Vision and Pattern Recognition, arXiv:1506.02640v5.
- Ren, S., He, K., Girshick, R. and Sun, J. 2017. Faster R-CNN: Towards real-time object detection with region proposal networks. IEEE Transactions on Pattern Analysis and Machine Intelligence, 39(6), 1137–1149.
- Rojo, M., Gonzalo-Orden, H., Linares, A. and Dell’Olio, L. 2018. Impact of a lower conservation budget on road safety indices. Journal of Advanced Transportation, 2018, (Special Issue), 1-9.
- Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S. and Fei-Fei, L. 2015. ImageNet large scale visual recognition challenge. International Journal of Computer Vision, 115(3), 211–252.
- Sabır, B. 2022. Esnek ve rijit kaplama parametrelerinin üstyapı türü seçimi üzerine etkileri. Yüksek Lisans Tezi, İskenderun Teknik Üniversitesi. Lisansüstü Eğitim Enstitüsü, İnşaat Mühendisliği Ana bilim Dalı, 79, Ankara.
- Sadeghi, M. A. and Forsyth, D. 2014. 30Hz Object Detection with DPM V5. Computer Vision, 6-12 S Proceedings Part I, 65–79, Zurich, Switzerland.
- Saha, P. K., Arya, D., Kumar, A., Maeda, H. and Sekimoto, Y. 2022. Road Rutting Detection Using Deep Learning on Images. 2022 IEEE International Conference on Big Data, 17-20 December, Proceedings-IEEE Big Data 2022, 1362–1368, Osaka, Japan.
- Salimans, T., Goodfellow, I., Zaremba, W., Cheung, V., Radford, A. and Chen, X. 2016. Improved techniques for training GANs. Machine Learning, arXiv:1606.03498v1.

- Sermanet, P., Eigen, D., Zhang, X., Mathieu, M., Fergus, R. and LeCun, Y. 2014. Overfeat: Integrated recognition, localization and detection using convolutional networks. Computer Vision and Pattern Recognition, arXiv:1312.6229.
- Shu, C., Liu, Y., Gao, J., Yan, Z. and Shen, C. 2021. Channel-Wise Knowledge Distillation for Dense Prediction. 2021 IEEE/CVF International Conference on Computer Vision (ICCV) ,10-17 October, 5291-5300, Montreal, Canada.
- Silva, L. A., Leithardt, V. R. Q., Lopez Batista, V. F., Gonzalez, G. V. and De Paz Santana, J. F. 2023. Automated road damage detection using UAV images and deep learning techniques. IEEE Access, 11, 62918-6293.
- Simonyan, K. and Zisserman, A. 2015. Very deep convolutional networks for large-scale image recognition. Computer Vision and Pattern Recognition, arXiv:1409.1556.
- Soyturk, M., Dogan, F., Sasmaz, E. ve Boyuk, S. 2014. Yol Yüzey Bozukklarının Tespit ve Analizi. 2014 22nd Signal Processing and Communications Applications Conference, 23-25 April, SIU 2014 - Proceedings, 1897–1901, Trabzon, Türkiye.
- Sprei, F., Habibi, S., Englund, C., Pettersson, S., Voronov, A. and Wedlin, J. 2019. Free-floating car-sharing electrification and mode displacement: Travel time and usage patterns from 12 cities in Europe and the United States. Transportation Research Part D: Transport and Environment, 71, 127–140.
- Sultana, F., Sufian, A. and Dutta, P. 2019. A review of object detection models based on convolutional neural network. Computer Vision and Pattern Recognition. arXiv:1905.01614v3
- Sun, D. J., Chen, S., Zhang, C. and Shen, S. 2016. A bus route evaluation model based on GIS and super-efficient data envelopment analysis. Transportation Planning and Technology, 39(4), 407–423.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D. and Rabinovich, A. 2015. Going deeper with convolutions. Computer Vision and Pattern Recognition, arXiv:1409.4842.
- Tan, M., Pang, R. and Le, Q. V. 2019. EfficientDet: Scalable and efficient object detection. Computer Vision and Pattern Recognition. arXiv:1911.09070v7.
- Tektaş, M. ve Tektaş, N. 2019. Akıllı ulaşım sistemleri (AUS) uygulamalarının sektörlere göre dağılımı. Akıllı Ulaşım Sistemleri ve Uygulamaları Dergisi, 2(1), 1-10.
- Tektaş, N. ve Tektaş, M. 2019. Dünyada akıllı ulaşım sistemlerinin gelecek hedefleri japonya örneğinin incelenmesi. Paradoks Ekonomi Sosyoloji ve Politika Dergisi, 15(2), 189–210.
- Telatar, Z., Tora, H., Arı, F. and Kalaycıoğlu, A. 2014. Sayısal görüntü işleme. Palme Yayıncılık, 954, Ankara.
- Tunç, A. 2004. Esnek kaplama malzemeleri elkitabı. Asil Yayın Dağıtım, 352, Ankara.
- Van Der Horst, B. B., Lindenbergh, R. C. and Puister, S. W. J. 2019. Mobile laser scan data for road surface damage detection. International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives, 42, 1141–1148.

- Verma, V. R. and Dash, U. 2020. Geographical accessibility and spatial coverage modelling of public health care network in rural and remote India. *PLoS ONE*, 15(10), 1–23.
- Viola, P. and Jones, M. 2001. Rapid Object Detection Using A Boosted Cascade of Simple Features. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 17-19 June, CVPR, 511-518, Kauai, USA.
- Viola, P. and Jones, M. 2004. Robust real-time face detection. *International Journal of Computer Vision*, 57, 137–154.
- Vishwakarma, R. and Vennelakanti, R. 2020. CNN Model Tuning for Global Road Damage Detection. 2020 IEEE International Conference on Big Data, 10-13 December, *Proceedings-IEEE Big Data 2020*, 5609–5615, Atlanta, USA.
- Wang, C. Y., Bochkovskiy, A. and Liao, H. Y. M. 2021. Scaled-yolov4: Scaling cross stage partial network. *Computer Vision and Pattern Recognition*, arXiv:2011.08036.
- Wang, C. Y., Mark Liao, H. Y., Wu, Y. H., Chen, P. Y., Hsieh, J. W. and Yeh, I. H. 2020. CSPNet: A New Backbone That Can Enhance Learning Capability of CNN. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), 14-19 June, 1571–1580, Seattle, USA.
- Wang, C. Y., Yeh, I. H. and Liao, H. Y. M. 2023. You only learn one representation: Unified network for multiple tasks. *Journal of Information Science and Engineering*, 39(3), 691–709.
- Wang, C., Bochkovskiy, A. and Liao, H. M. 2022. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors. *Computer Vision and Pattern Recognition*, arXiv:2207.02696.
- Wang, S., Tang, Y., Liao, X., He, J., Feng, H., Jiao, H. and Yuan, Q. 2022. An Ensemble Learning Approach with Multi-Depth Attention Mechanism for Road Damage Detection. 2022 IEEE International Conference on Big Data, 17-20 December, *Proceedings -IEEE Big Data 2022*, 6439–6444, Osaka, Japan.
- Wojnarowska, M., Ilba, M., Szakiel, J., Turek, P. and Sołtysik, M. 2021. Identifying the location of odour nuisance emitters using spatial GIS analyses. *Chemosphere*, 263, 128252.
- Wu, X., Sahoo, D. and Hoi, S. C. H. 2020. Recent advances in deep learning for object detection. *Neurocomputing*, 396, 39–64.
- Xie, S., Girshick, R., Dollar, P., Tu, Z. and He, K. 2017. Aggregated residual transformations for deep neural networks. *Computer Vision and Pattern Recognition*, arXiv:1611.05431.
- Xin, H., Ye, Y., Na, X., Hu, H., Wang, G., Wu, C. and Hu, S. 2023. Sustainable road pothole detection: A crowdsourcing based multi-sensors fusion approach. *Sustainability*, 15(8), 1–23.
- Xu, C., Zhang, Q., Mei, L., Shen, S., Ye, Z., Li, D. and Zhou, X. 2023. Dense multiscale feature learning transformer embedding cross-shaped attention for road damage detection. *Electronics*, 12(4), 898.

- Yan, J., Lei, Z., Wen, L. and Li, S. Z. 2014. The Fastest Deformable Part Model for Object Detection. IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 23-28 June, 2497–2504, Columbus, USA.
- Yang, L., He, H. and Liu, T. 2022. Road Damage Detection and Classification Based on Multi-Scale Contextual Features. 2022 IEEE International Conference on Big Data, 17-20 December, Proceedings-IEEE Big Data 2022, 6445–6453, Osaka, Japan.
- Yayla, N. 2011. Karayolu mühendisliği. Birsen Yayınevi, 285, İstanbul.
- Yıldız, A. 2022. Finans alanında yapay zeka teknolojisinin kullanımı: sistematik literatür incelemesi. Pamukkale Sosyal Bilimler Enstitüsü Dergisi, 57, 47–66.
- Yin, J., Qu, J., Huang, W. and Chen, Q. 2021. Road damage detection and classification based on multi-level feature pyramids. KSII Transactions on Internet and Information Systems, 15(2), 786–799.
- Zaidi, S. S. A., Ansari, M. S., Aslam, A., Kanwal, N., Asghar, M. and Lee, B. 2022. A survey of modern deep learning based object detection models. Digital Signal Processing: A Review Journal, 126, 1–18.
- Zalama, E., Gómez-García-Bermejo, J., Medina, R. and Llamas, J. 2014. Road crack detection using visual features extracted by gabor filters. Computer-Aided Civil and Infrastructure Engineering, 29(5), 342–358.
- Zarandi, S. M., Shahsavani, A., Nasiri, R. and Pradhan, B. 2021. A hybrid model of environmental impact assessment of PM2.5 concentration using multi-criteria decision-making (MCDM) and geographical information system (GIS)—a case study. Arabian Journal of Geosciences, 14(3), 1-20.
- Zhang, D., Zou, Q., Lin, H., Xu, X., He, L., Gui, R., Li, Q. 2018. Automatic pavement defect detection using 3D laser profiling technology. Automation in Construction, 96, 350–365.
- Zhang, H., Wang, Y., Dayoub, F. and Sünderhauf, N. 2021. VarifocalNet: An IoU-Aware Dense Object Detector. 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 20-25 June, 8510–8519, Nashville, USA.
- Zhang, S., Wen, L., Bian, X., Lei, Z. and Li, S. Z. 2017. Single-shot refinement neural network for object detection. Computer Vision and Pattern Recognition, arXiv:1711.06897.
- Zhang, X., Xia, X., Li, N., Lin, M., Song, J. and Ding, N. 2020. Exploring The Tricks for Road Damage Detection with A One-Stage Detector. 2020 IEEE International Conference on Big Data, 10-13 December, Proceedings-IEEE Big Data 2020, 5616–5621, Atlanta, USA.
- Zhang, Y., Sun, X., Chen, J. and Cheng, C. 2021. Spatial patterns and characteristics of global maritime accidents. Reliability Engineering and System Safety, 206, 107310.
- Zhao, Z. Q., Zheng, P., Xu, S. T. and Wu, X. 2019. Object detection with deep learning: A review. IEEE Transactions on Neural Networks and Learning Systems, 30(11), 3212–3232.
- Zou, Z., Shi, Z., Guo, Y. and Ye, J. 2019. Object detection in 20 years: A survey, Computer Vision and Pattern Recognition, arXiv:1905.05055v3.

EKLER

EK-1

1.1. YOLOv5l Modeli İçin Test Sonuçları


Tez çalışması kapsamında 3.435 adet yol görüntüsü test işlemleri için kullanılmıştır. Ancak bu sayıda görüntünün sonuçlarının metin içerisinde sunulması zordur. Bu durum da dikkate alınarak Japonya, Çek Cumhuriyeti, Hindistan, Norveç, ABD, Çin ve Kuveyt ülkelerinin hepsini içeren 14 adetlik yol görüntülerinin test sonuçları bu kısımda verilmiştir. 14 adetlik yol görüntüleri gerçek dünyayı temsil edecek şekilde seçilmiştir. Gün ışığı, karşıdan güneş yansıması, bulutlu hava, yağışlı hava, gölgeli yol kesimleri ve karlı yol kesimleri gibi farklı iklim koşullarını barındıran görsellerin olmasına özen gösterilmiştir. Test aşamasında birçok güven değeri ile test seti analiz edilmiştir. TP oluşumunun en fazla olduğu ve FN ve FP değerlerinin en düşük seviyede olduğu güven değeri 0,25 olarak belirlenmiştir. Test sürecinde kullanılan yol görselleri 0,25 güven değeri üzerinden test edilmiştir. YOLOv5l'ye ait test sonuçları ülkesel olarak Şekil EK-1.1 ve Şekil EK-1.7 arasında verilmektedir. Kuveyt ülkesine ait görsellerin görüntü boyutlarının ve elde edilme açısının farklı olması bazı görüntülerde kusurların yakalanamaması yani FN oluşumunu meydana getirmektedir. Bu durum nesne algılamanın hassas bir süreç olduğunun en büyük kanıtı durumundadır.




Şekil EK-1.1. ABD ülkesine ait kusur algılama sonuçları




Şekil EK-1.1. (Devam)




Şekil EK-1.1. (Devam)




Şekil EK-1.2. Çek Cumhuriyeti ülkesine ait kusur algılama sonuçları




Şekil EK-1.2. (Devam)




Şekil EK-1.2. (Devam)



Şekil EK-1.3. Çin ülkesine ait kusur algılama sonuçları




Şekil EK-1.3. (Devam)



Şekil EK-1.3. (Devam)




Şekil EK-1.4. Hindistan ülkesine ait kusur algılama sonuçları




Şekil EK-1.4. (Devam)




Şekil EK-1.4. (Devam)



Şekil EK-1.5. Japonya ülkesine ait kusur algılama sonuçları




Şekil EK-1.5. (Devam)




Şekil EK-1.5. (Devam)




Şekil EK-1.6. Kuveyt ülkesine ait kusur algılama sonuçları



Şekil EK-1.6. (Devam)




Şekil EK-1.6. (Devam)




Şekil EK-1.6. (Devam)



Şekil EK-1.7. Norveç ülkesine ait kusur algılama sonuçları



Şekil EK-1.7. (Devam)



Şekil EK-1.7. (Devam)



Şekil EK-1.7. (Devam)



Şekil EK-1.7. (Devam)

1.2. YOLOv7x Modeli İin Test Sonuları

Tez alıřması kapsamında 3.435 adet yol grnts test iřlemleri iin kullanılmıřtır. Japonya, ek Cumhuriyeti, Hindistan, Norve, ABD, in ve Kuveyt lkelerinin hepsini ieren 14 adetlik yol grntlerinin test sonuları bu kısımda verilmiřtir. 14 adetlik yol grntleri gerek dnyayı temsil edecek řekilde seilmiřtir. Gn ıřıėı, karřıdan gneř yansıması, bulutlu hava, yaėıřlı hava, glgeli yol kesimleri ve karlı yol kesimleri gibi farklı iklim kořullarını barındıran grsellerin olmasına zen gsterilmiřtir. Test ařamasında birok gven deėeri ile test seti analiz edilmiřtir. TP oluřumunun en fazla olduėu ve FN ve FP deėerlerinin en dřk seviyede olduėu gven deėeri 0,25 olarak belirlenmiřtir. Test srecinde kullanılan yol grselleri 0,25 gven deėeri zerinden test edilmiřtir. YOLOv7x'ye ait test sonuları lkesel olarak řekil EK-1.8 ve řekil EK-1.14 arasında verilmektedir.




Şekil EK-1.8. ABD ülkesine ait kusur algılama sonuçları



Şekil EK-1.8. (Devam)



Şekil EK-1.8. (Devam)




Şekil EK-1.9. Çek Cumhuriyeti ülkesine ait kusur algılama sonuçları




Şekil EK-1.9. (Devam)




Şekil EK-1.9. (Devam)




Şekil EK-1.10. Çin ülkesine ait kusur algılama sonuçları



Şekil EK-1.10. (Devam)



Şekil EK-1.10. (Devam)



Şekil EK-1.11. Hindistan ülkesine ait kusur algılama sonuçları



Şekil EK-1.11. (Devam)



Şekil EK-1.11. (Devam)




Şekil EK-1.12. Japonya ülkesine ait kusur algılama sonuçları



Şekil EK-1.12. (Devam)



Şekil EK-1.12. (Devam)



Şekil EK-1.13. Kuveyt ülkesine ait kusur algılama sonuçları



Şekil EK-1.13. (Devam)



Şekil EK-1.13. (Devam)



Şekil EK-1.13. (Devam)



Şekil EK-1.14. Norveç ülkesine ait kusur algılama sonuçları



Şekil EK-1.14. (Devam)



Şekil EK-1.14. (Devam)



Şekil EK-1.14. (Devam)



Şekil EK-1.14. (Devam)



Şekil EK-1.14. (Devam)



Şekil EK-1.14. (Devam)

1.2. YOLOv8x Modeli İin Test Sonuları

Tez alıřması kapsamında 3.435 adet yol grnts test iřlemleri iin kullanılmıřtır. Japonya, ek Cumhuriyeti, Hindistan, Norve, ABD, in ve Kuveyt lkelerinin hepsini ieren 14 adetlik yol grntlerinin test sonuları bu kısımda verilmiřtir. 14 adetlik yol grntleri gerek dnyayı temsil edecek řekilde seilmiřtir. Gn ıřıėı, karřıdan gneř yansıması, bulutlu hava, yaėıřlı hava, glgeli yol kesimleri ve karlı yol kesimleri gibi farklı iklim kořullarını barındıran grsellerin olmasına zen gsterilmiřtir. Test ařamasında birok gven deėeri ile test seti analiz edilmiřtir. TP oluřumunun en fazla olduėu ve FN ve FP deėerlerinin en dřk seviyede olduėu gven deėeri 0,25 olarak belirlenmiřtir. Test srecinde kullanılan yol grselleri 0,25 gven deėeri zerinden test edilmiřtir. YOLOv8x'ye ait test sonuları lkesel olarak řekil EK-1.15 ve řekil EK-1.21 arasında verilmektedir.




Şekil EK-1.15. ABD ülkesine ait kusur algılama sonuçları




Şekil EK-1.15. (Devam)




Şekil EK-1.15. (Devam)




Şekil EK-1.16. Çek Cumhuriyeti ülkesine ait kusur algılama sonuçları




Şekil EK-1.16. (Devam)




Şekil EK-1.16. (Devam)



Şekil EK-1.17. Çin ülkesine ait kusur algılama sonuçları



Şekil EK-1.17. (Devam)



Şekil EK-1.17. (Devam)




Şekil EK-1.18. Hindistan ülkesine ait kusur algılama sonuçları




Şekil EK-1.18. (Devam)




Şekil EK-1.18. (Devam)



Şekil EK-1.19. Japonya ülkesine ait kusur algılama sonuçları




Şekil EK-1.19. (Devam)




Şekil EK-1.19. (Devam)




Şekil EK-1.20. Kuveyt ülkesine ait kusur algılama sonuçları



Şekil EK-1.20. (Devam)




Şekil EK-1.20. (Devam)



Şekil EK-1.20. (Devam)




Şekil EK-1.21. Norveç ülkesine ait kusur algılama sonuçları




Şekil EK-1.21. (Devam)




Şekil EK-1.21. (Devam)



Şekil EK-1.21. (Devam)



Şekil EK-1.21. (Devam)



Şekil EK-1.21. (Devam)



Şekil EK-1.21. (Devam)