

**VERİ ARTIRMA TEKNİĞİ KULLANIMININ ARAÇ SÜRÜŞ
KARARLILIĞINA ETKİSİNİN İNCELENMESİ**

FURKAN ŞEN



T.C.
BURSA ULUDAĞ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**VERİ ARTIRMA TEKNİĞİ KULLANIMININ ARAÇ SÜRÜŞ
KARARLILIĞINA ETKİSİNİN İNCELENMESİ**

Furkan ŞEN
0000-0003-4661-7957

Prof. Dr. Güneş YILMAZ
(Danışman)

YÜKSEK LİSANS TEZİ
ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

BURSA – 2023
Her Hakkı Saklıdır

TEZ ONAYI

Furkan ŐEN tarafından hazırlanan “VERİ ARTIRMA TEKNİĐİ KULLANIMININ ARAÇ SÜRÜŐ KARARLILIĐINA ETKİSİNİN İNCELENMESİ” adlı tez alıŐması aŐađıdaki jüri tarafından oy birliĐi ile Bursa UludaĐ Üniversitesi Fen Bilimleri Enstitüsü Elektronik MühendisliĐi Anabilim Dalı’nda **YÜKSEK LİSANS TEZİ** olarak kabul edilmiŐtir.

DanıŐman: Prof. Dr. GüneŐ YILMAZ

- Başkan** : Prof. Dr. GüneŐ YILMAZ İmza
0000-0001-8972-1952
Bursa UludaĐ Üniversitesi,
Mühendislik Fakültesi,
Telekomünikasyon Anabilim Dalı
- Üye** : Dr. Öğr. Üyesi Arif BAŐGÜMÜŐ İmza
0000-0002-0611-3220
Bursa UludaĐ Üniversitesi,
Mühendislik Fakültesi,
Telekomünikasyon Anabilim Dalı
- Üye** : Dr. Öğr. Üyesi Ekrem DÜVEN İmza
0000-0003-4957-6126
Bursa Teknik Üniversitesi,
Mühendislik ve DoĐa Bilimleri Fakültesi,
Kontrol Sistemleri Anabilim Dalı

Yukarıdaki sonucu onaylarım

Prof. Dr. Ali KARA
Enstitü Müdürü

.././.....

B.U.Ü. Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada;

- tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- ve bu tezin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

beyan ederim.

07/08/2023

Furkan ŞEN

TEZ YAYINLANMA FİKRİ MÜLKİYET HAKLARI BEYANI

Enstitü tarafından onaylanan lisansüstü tezin/raporun tamamını veya herhangi bir kısmını, basılı (kâğıt) ve elektronik formatta arşivleme ve aşağıda verilen koşullarla kullanıma açma izni Bursa Uludağ Üniversitesi'ne aittir. Bu izinle Üniversiteye verilen kullanım hakları dışındaki tüm fikri mülkiyet hakları ile tezin tamamının ya da bir bölümünün gelecekteki çalışmalarda (makale, kitap, lisans ve patent vb.) kullanım hakları tarafımıza ait olacaktır. Tezde yer alan telif hakkı bulunan ve sahiplerinden yazılı izin alınarak kullanılması zorunlu metinlerin yazılı izin alınarak kullandığını ve istenildiğinde suretlerini Üniversiteye teslim etmeyi taahhüt ederiz.

Yükseköğretim Kurulu tarafından yayınlanan “**Lisansüstü Tezlerin Elektronik Ortamda Toplanması, Düzenlenmesi ve Erişime Açılmasına İlişkin Yönerge**” kapsamında, yönerge tarafından belirtilen kısıtlamalar olmadığı takdirde tezin YÖK Ulusal Tez Merkezi / B.U.Ü. Kütüphanesi Açık Erişim Sistemi ve üye olunan diğer veri tabanlarının (Proquest veri tabanı gibi) erişimine açılması uygundur.

Prof. Dr. Güneş YILMAZ
07/08/2023

Furkan ŞEN
07/08/2023

İmza

Bu bölüme kişinin kendi el yazısı ile okudum
anladım yazmalı ve imzalanmalıdır.

İmza

Bu bölüme kişinin kendi el yazısı ile okudum
anladım yazmalı ve imzalanmalıdır.

ÖZET

Yüksek Lisans Tezi

VERİ ARTIRMA TEKNİĞİ KULLANIMININ ARAÇ SÜRÜŞ KARARLILIĞINA ETKİSİNİN İNCELENMESİ

Furkan ŞEN

Bursa Uludağ Üniversitesi
Fen Bilimleri Enstitüsü
Elektronik Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Güneş YILMAZ

Bu tez çalışması kapsamında, zorlu çevre şartlarında araç sürüş kararlılığını incelemek için İleri Sürücü Destek Sistemlerinde (ADAS) kullanılan çeşitli sensör teknolojilerinin ayrıntılı değerlendirmesi ve karşılaştırmalı analizi yapılmıştır. Yapılan analiz ultrasonik mesafe sensörleri, radar, lidar, kamera gibi araç görüş sistemlerine dahil olan bir dizi teknolojiyi içermektedir. Bu çalışma, görüş sensörlerinin çalışma prensiplerini ve bileşenlerini inceleyerek, belirli avantaj ve dezavantajlarının net bir şekilde anlaşılmasını sağlamaktadır. Kalman filtreleri, Genişletilmiş Kalman filtreleri ve Koksuz Kalman filtreleri gibi tekniklerin incelemesi eşliğinde sensör füzyonunun önemi vurgulanmaktadır.

Tez çalışmasının temeli, KITTI veri setini kullanarak İleri Sürücü Destek Sistemleri (ADAS) uygulamaları için zorlu çevre şartlarında üç boyutlu nesne tanımlama modellerinin kapsamlı bir şekilde incelenmesinde yatmaktadır. Değerlendirme kriterleri, çeşitli durumlarda araçların, yayaların ve bisikletlilerin doğru tespiti ve tanınmasının yanı sıra hesaplama etkinliğinin analizini de içermektedir. Bunun yanı sıra, zorlu koşulları içeren ortamlarda genelleme sürecini çevreleyen karmaşıklıklar ve aracın bu durumdaki sürüş kararlılığı kapsamlı bir şekilde incelenmiştir.

Elde edilen bulgularda, PointPillars modeli olağanüstü hassasiyet gösterdiğini ortaya koymuş ve böylece doğruluk odaklı uygulamalardaki etkinliğini doğrulamıştır. Bu model üstün hesaplama verimliliği göstererek gerçek zamanlı faaliyetler için uygun bir seçim olabileceğini ispatlamıştır. Özetle bu çalışma, İleri Sürücü Destek Sistemleri (ADAS) için sensör füzyonuna ilişkin bilinçli kararlar vermenin önemini destekleyen kanıtlar sunmakta ve bunun çok çeşitli araç güvenliği uygulamaları için etkileri bulunmaktadır.

Anahtar Kelimeler: İleri Sürücü Destek Sistemleri (ADAS) teknolojileri, araç güvenliği, sensör füzyonu, zorlu çevre şartları

2023, x + 96 sayfa.

ABSTRACT

Master's Thesis

INVESTIGATING THE EFFECT OF USING DATA AUGMENTATION TECHNIQUE ON VEHICLE DRIVING STABILITY

Furkan ŞEN

Bursa Uludağ University
Graduate School of Natural and Applied Sciences
Department of Electronics Engineering

Supervisor: Prof. Dr. Güneş YILMAZ

In this thesis, a detailed evaluation and comparative analysis of various sensor technologies used in Advanced Driver Assistance Systems (ADAS) to study vehicle driving stability under harsh environmental conditions has been carried out. The analysis includes a range of technologies involved in vehicle vision systems such as ultrasonic distance sensors, radar, lidar, camera. This study examines the operating principles and components of vision sensors, providing a clear understanding of their specific advantages and disadvantages. The importance of sensor fusion is emphasized through a review of techniques such as Kalman filters, Extended Kalman filters and Unscented Kalman filters.

The basis of the thesis work lies in a comprehensive investigation of three-dimensional object recognition models under harsh environmental conditions for Advanced Driver Assistance Systems (ADAS) applications using the KITTI dataset. The evaluation criteria include accurate detection and recognition of vehicles, pedestrians and cyclists in various situations, as well as analysis of computational efficiency. In addition, the complexities surrounding the generalization process in harsh environments and the driving stability of the vehicle in this situation have been extensively studied.

In the findings, the PointPillars model demonstrated exceptional accuracy, thus validating its effectiveness in accuracy-oriented applications. This model demonstrates superior computational efficiency, proving that it can be a suitable choice for real-time activities. In summary, this study provides evidence to support the importance of making informed decisions regarding sensor fusion for Advanced Driver Assistance Systems (ADAS), with implications for a wide range of vehicle safety applications.

Key words: Advanced Driver Assistance Systems (ADAS) technologies, vehicle safety, sensor fusion, harsh environments

2023, x + 96 pages.

TEŐEKKÜR

Bu tez alıőmasının gerekleőtirilmesi srecinde, destekleriyle ve katkılarıyla bu alıőmanın baőarılı bir Őekilde tamamlanmasına yardımcı olan herkese teőekkrlerimi sunarım.

İlk olarak, Prof. Dr. Gneő YILMAZ hocama en iten teőekkrlerimi iletmek istiyorum. Sabrı, rehberlięi ve deęerli grŐleri sayesinde, bu alıőma srecinde nemli ilerlemeler kaydedebildik. Sizin uzmanlıęınız ve rehberlięiniz olmadan, bu tez alıőmasının bu seviyeye gelmesi mmkn olmazdı.

Ayrıca, ailem ve dostlarıma bu sre boyunca saęladıkları motivasyon ve destek iin minnettarlıęımı ifade etmek istiyorum. Sizlerin anlayıŐı ve yardımı olmadan, bu alıőmayı tamamlamak ok daha g olurdu.

Son olarak, tez alıőmasının gerekleőtirilmesinde emeęi geen tm ęretim yelerine, kaynak saęlayıcılara ve bu srete yardımcı olan herkese teőekkr etmek istiyorum. Sizin katkılarınız sayesinde bu alıőma daha da zenginleőtti.

Furkan ŐEN
07/08/2023

İÇİNDEKİLER

Sayfa

ÖZET.....	i
ABSTRACT.....	ii
TEŞEKKÜR.....	iii
SİMGELER ve KISALTMALAR DİZİNİ.....	vi
ŞEKİLLER DİZİNİ.....	ix
ÇİZELGELER DİZİNİ.....	x
1. GİRİŞ.....	1
2. KAYNAK ARAŞTIRMASI.....	3
3. MATERYAL ve YÖNTEM.....	9
3.1. Ultrasonik Sensör.....	9
3.2. Ultrasonik Sensörün Kullanılma Nedenleri.....	10
3.3. Kızılötesi Sensörlerin Optik Tabanlı Algılama Yöntemleriyle Kıyaslanması.....	10
3.4. Ultrasonik Sensörün Sistem Bileşenleri.....	11
3.5. Radar.....	13
3.6. Otomotiv Radar Sistemlerinin Prensipleri.....	15
3.7. Otomotiv Radar Mimarisi.....	18
3.7.1. Verici.....	19
3.7.2. Alıcı.....	21
3.7.3. Anten ve anten dizisi.....	22
3.8. Lidar Görüntülemenin Temelleri.....	23
3.9. Lidar Ölçüm Prensipleri.....	25
3.9.1. Darbeli yaklaşım.....	25
3.9.2. Sürekli dalga genlik modülasyonlu (AMCW) yaklaşım.....	27
3.9.3. Sürekli dalga frekans modülasyonlu (FMCW) yaklaşım.....	29
3.10. Araç Görüş Sistemleri.....	33
3.10.1. Monoküler kameralar.....	34
3.10.2. Stereo kameralar.....	35
3.10.3. IR (Infrared) kameralar.....	36
3.11. İleri Sürücü Destek Sistemleri (ADAS) ve Araçlardaki Uygulamaları.....	37
3.12. Otonom Araç Sürüş Seviyeleri.....	38
3.13. ADAS Teknoloji Tabanlı Sensörler.....	39
3.13.1. İleri çarpışma uyarısı.....	39
3.13.2. Kilitlenmeyi önleyici fren.....	40
3.13.3. Adaptif hız sabitleyici.....	41
3.13.4. Şerit takip asistanı ve şerit değiştirme asistanı.....	42
3.14. Otomotiv Güvenlik Sistemlerinde ADAS Teknolojisinde Kullanılan Sensörlerinin Uygulamaları.....	44
3.14.1. Radar sensörünün otomotivdeki uygulamaları.....	46
3.14.2. Lidar sensörünün otomotivdeki uygulamaları.....	46
3.14.3. Ultrasonik mesafe sensörünün otomotivdeki uygulamaları.....	47
3.14.4. Optik kamera sensörlerinin otomotivdeki uygulamaları.....	48
3.15. Sensör Füzyonu.....	50
3.16. Sensör Füzyonu için Yaklaşımlar.....	53
3.17. Sensör Füzyon Teknikleri ve Algoritmaları.....	54
3.17.1. Kalman filtresi.....	57
3.17.2. Genişletilmiş kalman filtresi.....	59

3.17.3. Koksuz kalman filtresi	60
3.18. Güvenli ve Güvenilir Çevre Algısı için Sensör Füzyonunun Zorlukları	61
3.19. 3B Nesne Algılama Modelleri	64
3.19.1. PointPillars modeli	64
3.19.2. SECOND modeli.....	66
3.19.3. PointRCNN modeli	67
3.20. Zorlu Ortamlarda Nesne Algılama Analizi için Lidar Işık Saçılımı Artırma (LISA) Veri Setinin Kullanımı.....	68
3.21. Model Değerlendirmesi için Ortalama Hassasiyet (AP) Metriklerinin Hesaplanması	70
4. BULGULAR ve TARTIŞMA	72
4.1. 3B Nesne Algılama Modellerinin Performans Karşılaştırması.....	74
4.1.1. Veri kümesi hazırlama	75
4.1.2. Değerlendirme ölçütleri	75
4.1.3. Temel veri kümeleri üzerindeki sonuçlar.....	75
4.1.4. Artırılmış veri kümeleri üzerindeki sonuçlar	76
4.1.5. Tartışma ve çıkarımlar	77
4.2. Zorlu Koşulları İçeren Ortamları Genelleme	77
4.2.1. Veri kümesi tanımı.....	78
4.2.2. Değerlendirme ölçütleri	78
4.2.3. Zorlu koşulları içeren ortam veri kümesi üzerindeki performans.....	78
4.2.4. Tartışma.....	79
4.3. Hesaplama Verimliliği	79
4.3.1. Deney düzeneği.....	80
4.3.2. Çıkarım süresi karşılaştırılması.....	80
4.3.3. Tartışma.....	81
4.4. Doğruluk ve Hesaplama Verimliliğinin Karşılaştırılması.....	81
4.4.1. Performans puanı	82
4.4.2. Karşılaştırmalı analiz	82
4.4.3. Tartışma.....	83
4.5. Kararlılık Analizi	83
4.5.1. Gürültü işleme.....	84
4.5.2. Aydınlatma koşulları.....	84
4.5.3. Hava koşulları	85
4.5.4. Tartışma.....	85
4.6. Hesaplama Verimliliği	86
4.6.1. Bellek kullanımı	86
4.6.2. Tartışma.....	87
5. SONUÇ	89
KAYNAKLAR	91
ÖZGEÇMİŞ	96

SİMGELER ve KISALTMALAR DİZİNİ

Simgeler	Açıklama
BW	Bant Genişliği
c	Serbest Uzaydaki Işık Hızı
d	Ultrasonik Mesafe
D	Kat Edilen Toplam Mesafe
$\Delta\phi$	Faz Kayması
ΔR	Radarın Menzil Çözünürlüğü
$f(t)$	Gönderilen Sinyal Frekansı
f_d	Doppler Frekansı
f_M	Sinyalin Genliğinin Modülasyon Frekansı
f_r	Vuruş Frekansı
H	Radar Verileri Ölçüm Fonksiyonu
k_M	Modülasyon Frekansıyla İlişkili Dalga Sayısı
$r(t)$	Yankı Sinyali
$r_b(t)$	Temel Bant İşareti
R	Ölçüm Gürültüsü Kovaryansı
R_{max}	Maksimum Menzil
R_x	Alicı Anten
t_{max}	Maksimum Zaman Aralığı
t_{oF}	Uçuş Süresi
t_r	Darbe Sinyalinin Yükselme Süresi
T	Darbe Periyodu
T_x	Gönderici Anten
U	Durum Geçiş Gürültüsü
V_s	Ses Hızı
Q	Süreç Gürültüsü Kovaryansı

Kısaltmalar	Açıklama
2D	Two-Dimensional
3D	Three-Dimensional
ACC	Adaptive Cruise Control
ADAS	Advanced Driver Assistance Systems
AEB	Autonomous Emergency Braking
AMCW	Amplitude-Modulated Continuous Wave
AP	Average Precision
BW	Bandwidth
CFV	Cross-View Fusion
CL	Camera-Lidar
CLR	Camera-Lidar-Radar
CNN	Convolutional Neural Network
CR	Camera-Radar
CTRV	Constant Turn Rate and Velocity
CW	Continuous Wave
DL	Deep Learning

EIRP	Effective Isotropic Radiated Power
FCW	Forward Collision Warning
FFT	Fast Fourier Transform
FL	Fuzzy Learning
FMCW	Frequency-Modulated Continuous Wave
FN	False Negative
FP	False Positive
GB	Giga Byte
HLF	High-Level Fusion
IC	Integrated Circuit
IR	Infrared
ISM	Industrial, Scientific, and Medical
ITU	International Telecommunication Union
KITTI	Karlsruhe Institute of Technology and Toyota Technological Institute
LCA	Lane Change Assist
LCD	Liquid Crystal Display
LED	Light Emitting Diode
LIDAR	Light Detection and Ranging
LISA	Lidar Light Scattering Augmentation
LKS	Lane Keeping System
LLF	Low-Level Fusion
LO	Local Oscillator
LRR	Long Range Radar
MB	Mega Byte
MCU	Microcontroller Unit
ML	Machine Learning
MLF	Mid-Level Fusion
MRR	Medium Range Radar
OEM	Original Equipment Manufacturer
PLL	Phase-Locked Loop
PointPillars	Point-based Pillars
PointRCNN	Point-based Region Proposal Network and Multi-View 3D Object Detection
PS	Performance Score
RADAR	Radio Detection and Ranging
RGB	Red Green Blue
RL	Reinforcement Learning
RNN	Recurrent Neural Network
RPN	Region Proposal Network
SAE	Society of Automotive Engineers
SDF	Spatial Data Fusion
SECOND	Sparse and Evenly Distributed Clusters of Points for real-time Object Detection
SLAM	Simultaneous Localization and Mapping
SNR	Signal-to-Noise Ratio
SRR	Short Range Radar
SSD	Single Shot MultiBox Detector
TCSPC	Time-Correlated Single Photon Counting

TOF	Time of Flight
TSR	Traffic Sign Recognition
TP	True Positives
UWB	Ultra-Wideband
V2V	Vehicle-to-Vehicle
V2X	Vehicle-to-Everything
VOC	Visual Object Classes
YOLO	You Only Look Once

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 3.1.	Ultrasonik uçuş süresi ölçümü 9
Şekil 3.2.	Ultrasonik sensörün sistem bileşenleri şeması 11
Şekil 3.3.	İdeal ve gürültülü ultrasonik yankı sinyalleri (Wu vd., 2014) 12
Şekil 3.4.	Ölçüm aralığının şematik diyagramı 13
Şekil 3.5.	Bir araç üzerindeki tipik bir radar konfigürasyonu 14
Şekil 3.6.	Radar ölçümü için küresel koordinat sistemi 17
Şekil 3.7.	Basitleştirilmiş tek kanallı radar mimarisi..... 18
Şekil 3.8.	Farklı dalga biçimi türleri..... 21
Şekil 3.9.	Yama anten örnekleri (Peng vd., 2017) (a) 3 elemanlı seri beslemeli yama anten ve (b) 5 elemanlı seri beslemeli yama anten 23
Şekil 3.10.	Darbeli uçuş süresi (TOF) ölçüm prensibi 25
Şekil 3.11.	Sürekli dalganın genlik modülasyonu (AMCW) sensörlerinde kullanılan TOF faz ölçümü prensibi..... 28
Şekil 3.12.	Frekans modülasyonlu sürekli dalga (FMCW) yönteminde frekans modülasyonu ve algılama 30
Şekil 3.13.	Zaman ve bağlantılı genlik sinyal değişimi ile üçgen frekans modülasyonu zaman alanı 31
Şekil 3.14.	Hareketli bir hedef için üçgen modülasyon frekans sinyali ve vuruş frekansı 32
Şekil 3.15.	(a) Monoküler kamera, (b) Stereo kamera 34
Şekil 3.16.	Monoküler kameranın araç üzerine entegrasyonu..... 35
Şekil 3.17.	Stereo kameranın araç üzerine entegrasyonu 36
Şekil 3.18.	IR kameranın araç üzerine entegrasyonu 37
Şekil 3.19.	Destekli sürüş için mevcut teknolojiler 38
Şekil 3.20.	Otonom sürüş seviyeleri 39
Şekil 3.21.	İleri çarpışma uyarısı (FCW) sistemi 40
Şekil 3.22.	Kilitlemeyi önleyici fren (AEB) teknolojisi 41
Şekil 3.23.	Adaptif hız sabitleyici (ACC) teknolojisi..... 42
Şekil 3.24.	Şerit takip sistemi (LKS) teknolojisi 43
Şekil 3.25.	Şerit Değiştirme Asistanı (LCA) teknolojisi 44
Şekil 3.26.	ADAS teknolojisi taksonomisi 45
Şekil 3.27.	Lidar (Vlacic vd., 2001) 47
Şekil 3.28.	Ultrasonik mesafe sensörü..... 48
Şekil 3.29.	Füzyon işleminin temelleri 51
Şekil 3.30.	Füzyon sistemlerinin sınıflandırılması 53
Şekil 3.31.	Kamera, lidar ve radardan alınan yüksek seviyeli nesne verilerinin Kalman filtresi ile tahmin edilmesi..... 57
Şekil 3.32.	Sigma noktalarını kullanarak, doğrusal olmayan durum geçiş fonksiyonu $f(x)$ ve ardından ölçüm fonksiyonu $h(x)$ üzerinden geçerek $k+1$ 'deki durumu tahmin edilmesi..... 61
Şekil 3.33.	PointPillars genel bakış 65
Şekil 3.34.	SECOND modelinin yapısı (Mao vd., 2018) 66
Şekil 3.35.	PointRCNN modelinin yapısı (Shi vd., 2018)..... 68
Şekil 4.1.	Simülasyon akış diyagramı 74

ÇİZELGELER DİZİNİ

	Sayfa
Çizelge 3.1. Otomotiv radar frekans bantları.....	19
Çizelge 3.2. Çevresel algı için ana teknolojilerin karşılaştırılması	49
Çizelge 3.3. Belirli parametreler için sensör füzyonu kıyası.....	52
Çizelge 4.1. 3B nesne algılama modellerinin temel veri kümesi üzerindeki performans ölçütleri.....	76
Çizelge 4.2. 3B nesne algılama modellerinin artırılmış veri kümeleri üzerindeki performans ölçütleri (LISA yöntemi)	76
Çizelge 4.3. Zorlu koşulları içeren ortam veri kümesi üzerindeki performans	79
Çizelge 4.4. Çıkarım süresi karşılaştırması	80
Çizelge 4.5. Performans puanı karşılaştırması	82
Çizelge 4.6. Gürültü işleme performansı.....	84
Çizelge 4.7. Aydınlatma durumu performansı	84
Çizelge 4.8. Hava durumu performansı.....	85
Çizelge 4.9. Ortalama çıkarım süresi karşılaştırması	86
Çizelge 4.10. MB cinsinden bellek kullanımı karşılaştırması	87

1. GİRİŞ

Otomotiv teknolojileri, İleri Sürücü Destek Sistemlerinin (ADAS) sektördeki uygulamasının günden güne artmasıyla mobilitayı yeniden tanımlayarak ulaşımda dönüştürücü bir çağa yol açmıştır. Sensör teknolojilerinden oluşan bu sistemler, araç güvenliğini ve otonomisini artırmada çok önemli bir rol oynamaktadır. Ultrasonik sensörler, radar, lidar ve kamera gibi araç görüş sistemlerinin kademeli entegrasyonu, otomotiv güvenliğinde yeni bir çağın habercisidir. Bu gelişmeler, otonom araçların hayata geçirilmesinin önünü açmakta ve yol güvenliğinin sınırlarını genişletmektedir.

İleri Sürücü Destek Sistemlerinin geliştirilmesi söz konusu olduğunda, sensörlerin seçimi ve kombinasyonu önemli zorluklar ortaya çıkarmaktadır. Bu sistemlerin etkinliği, dinamik çevre koşullarını algılama, analiz etme ve bunlara yanıt verme kapasitelerine bağlıdır. Bu nedenle, kapsamlı araştırma ve değerlendirme yapmak, bu sensör teknolojilerinin karmaşıklıklarını ve hata oranını azaltma, yayaları koruma ve karmaşık yol senaryolarında aracın güvenlik potansiyellerini ortaya çıkarmak için vazgeçilmezdir.

Bu tez çalışmasında, ADAS sensör teknolojileri, bunların altında yatan ilkeler, bileşenler ve uygulamalar incelenmiştir. Ultrasonik mesafe sensörlerinin, radarın, lidarın ve araç görüş sistemlerinin kendine özgü nitelikleri, artı ve eksilerinin kapsamlı bir şekilde anlaşılmasını sağlamak için ayrıntılı olarak analizler yapılmıştır. Otomotiv endüstrisi hızla ilerlediğinden, çeşitli sensör modalitelerinin kolektif gücünü kullanmak için bir köşetaşı olarak sensör füzyon tekniklerinin potansiyelini değerlendirmek kritik önem taşımaktadır.

Bu çalışmanın temel amacı, İleri Sürücü Destek Sistemleri (ADAS) bağlamında zorlu çevre koşullarında aracın sürüş kararlılığını incelemek, 3B nesne algılama modellerinin performansını değerlendirmek ve karşılaştırmaktır. Bu çalışmanın diğer amacı, bu modellerin güçlü ve zayıf yönlerini analiz ederek optimum sensör seçimi ve sistem mimarisi tasarımına yardımcı olacak faydalı bilgiler sağlamaktır.

Tezin içeriğinde, PointPillars, SECOND ve PointRCNN gibi üç önemli 3B nesne algılama modeline odaklanılmaktadır. Odaklanılan bu modeller doğruluk, sağlamlık, hesaplama verimliliği ve farklı ortamlara uyarlanabilirlik açısından incelenmiştir.

2. KAYNAK ARAŞTIRMASI

Araç dinamiği ve stabilite analizi alanındaki çok sayıda araştırma, sürüş koşulları, çevresel faktörler ve araç performansı arasındaki karmaşık etkileşimi anlamayı amaçlamıştır. Bu çalışmalar toplu olarak, olumsuz veya zorlu koşullar altında araç dengesini anlamanın ve iyileştirmenin son derece önemli olduğunu vurgulamaktadır. Zorlu ortamlarda araç dinamiklerini analiz etmek elektronik mühendisliği, kontrol teorisi, sensör teknolojisi ve veri füzyon metodolojilerini kapsayan multidisipliner bir yaklaşım gerektirir. Araştırmacılar, en yeni sensörlerden, hesaplama tekniklerinden ve gelişmiş kontrol stratejilerinden yararlanarak olumsuz koşullarda optimum sürüş dengesini korumanın karmaşık zorluğuna yenilikçi çözümler bulmaya çalışmışlardır. Doğrulama için fiziksel deneyler gerekli olsa da simülasyonlar sürüş dinamiklerinin karmaşık sınırlarını çözmek ve bilinçli kararlar almak için paha biçilmez araçlardır. Temel doğrulama ve hesaplamalı araştırmanın entegre edilmesi, çeşitli bağlamlarda araç davranışının daha iyi anlaşılmasını sağlayarak, zorlu çevre şartlarında bile sürüş dengesini sağlayabilen sağlam sistemlerin geliştirilmesini kolaylaştırır.

Kalman filtresi, Kalman (1960) tarafından zorlu çevre koşullarında araçların sürüş stabilitesini incelemek için temel bir kavram olarak tanıtılmıştır. Kalman filtresinin doğrusal filtreleme ve tahminde uygulanması, belirsizlik ve gürültünün yarattığı zorlukları ele alır ve bu da onu öngörülemeyen arazilerde istikrarlı navigasyonu sürdürmek için değerli bir araç haline getirir. Bu kaynağın durum tahmini ve öngörüsüne katkısı, aracın değişen yol koşullarına ve harici bozukluklara uyum sağlama yeteneğini geliştirir. Bu da sonuçta sürüş stabilitesinin ve güvenliğinin iyileştirilmesine yol açar. Bu çalışma, Kalman filtresinden yararlanan tahmin ve kontrol sistemlerinin hava koşullarının ve zorlu arazilerin araç dengesi üzerindeki olumsuz etkilerini nasıl azaltabileceğine dair bilgiler sunmaktadır.

Vlacic ve diğerleri (2001), olumsuz koşullarda araç sürüş dengesinin incelenmesiyle doğrudan ilgili olan akıllı araç teknolojilerini araştırmıştır. Gelişmiş araç sistemleri ve teknolojilerine odaklanan kaynak, uyarlanabilir sistemlerin zorlu arazilerde dengeyi ve

güvenliđi nasıl artırabileceđine dair katkıda bulunmaktadır. Uyarlanabilir hız sabitleyici (ACC) ve ileri sürücü destek sistemleri (ADAS) gibi akıllı araç teknolojilerinin incelenmesi, bu teknolojilerin hızı ayarlayarak ve dinamik yol koşullarına yanıt vererek dengeli sürüşün sürdürülmesine nasıl yardımcı olabileceđi konusunda fikir vermektedir. Akıllı araç teknolojilerinin dengenin artırılması üzerindeki etkisini analiz eden bu çalışma, farklı ortamlarda araç güvenliđini ve dengesini artırmaya yönelik stratejiler hakkında bilgi vermektedir.

Visser'in (2006) çalışması, olumsuz koşullarda araç sürüş stabilitesinin incelenmesiyle doğrudan ilgili olan dizi ve faz dizi antenler hakkında bilgiler sunmaktadır. Bu kaynak, anten prensiplerini ve bu teknolojilerin zorlu arazilerde ve kötü hava koşullarında iletişim ve algılama sistemlerini nasıl geliştirebileceđini anlamaya katkılarını araştırmaktadır. Dizi ve aşamalı dizi antenler, sensör kapsama alanını ve sinyal güvenilirliđini geliştirerek kararlı navigasyonun sürdürülmesine önemli ölçüde katkıda bulunur. Araçlar, anten teknolojilerinden yararlanarak diđer araçlar ve altyapı ile iletişim kurma becerilerini geliştirebilir ve sonuçta olumsuz çevre koşullarında daha güvenli ve daha istikrarlı sürüşe katkıda bulunabilir. Bu kaynak, zorlu arazilerde sürüş stabilitesi için kilit faktörler olan araç iletişim ve algılama yeteneklerinin geliştirilmesinde anten tasarımının önemini vurgulayan kavramları tanıtmaktadır.

Coelingh ve diđerleri (2010), çarpışma uyarısı ve yaya algılama yoluyla araç sürüş dengesinin incelenmesinin pratik bir örneđini göstermiştir. Çarpışmadan kaçınmaya odaklanan bu kaynak, ileri sürücü destek sistemlerinin (ADAS) olumsuz koşullarda dengeyi nasıl geliştirebileceđine ışık tutmaktadır. Çarpışma uyarısı ve otomatik fren sistemlerini inceleyen çalışma, bu teknolojilerin kazaları önleyerek ve çarpışmaların etkisini azaltarak dengeli sürüşü nasıl desteklediđine dair fikir vermektedir. Çarpışma uyarısı ve otomatik fren sistemlerinin etkinliđini analiz eden bu çalışma, zorlu arazilerde ve olumsuz hava koşullarında araç dengesini ve güvenliđini artırmaya yönelik stratejiler hakkında bilgi vermektedir.

O'Connor (2012), zorlu kořullarda araç sürüş dengesini incelemek için yararlı bir teknoloji olan zamanla ilişkili tek foton sayımını (TCSPC) tanıtmıştır. Bu kaynağın foton sayma tekniklerine odaklanması, olumsuz hava kořullarında ve düşük görünüme sahip ortamlarda sensörlerin verimli çalışmasını anlamamıza yardımcı olmaktadır. TCSPC'nin foton emisyonlarının zaman aralıklarını ölçme yeteneğı, istikrarlı navigasyonu sürdürmek ve engellerden kaçınmak için çok önemli olan mesafe ve derinlik ölçümlerinin doğruluğunu artırır. Bu çalışma, TCSPC teknolojisini kullanarak sensörlerin olumsuz kořullara nasıl uyum sağlayabileceğine dair anlayışımızı geliřtirmekte ve nihayetinde aracın çevresini algılama ve bilinçli kararlar alma becerisini iyileřtirmektedir. Bu kaynakta tanıtılan kavramlar, zorlu arazilerde sürüş stabilitesi için kilit faktörler olan sensör doğruluğunu ve güvenilirliğini geliřtirmede foton sayma tekniklerinin önemini vurgulamaktadır.

Cabral ve Valdez (2013), mesafe ölçümü için havadan taşınan bir ultrasonik sensör düğümünü tanıtmıştır. Bu kaynak, zorlu çevre kořullarında araç sürüş dengesini korumak için ultrasonik teknolojilerin keřfedilmesine yönelik içgörüler sağlamaktadır. Çalışmanın mesafe ölçümüne odaklanması, kararlı navigasyonla doğrudan ilgilidir. Doğru mesafe tahmini, çarpışmalardan kaçınmak ve güvenli takip mesafeleri sağlamak için çok önemlidir. Ultrasonik sensör düğümünün önerilen mesafe ölçme kabiliyeti, aracın çevresi hakkındaki farkındalığına katkıda bulunarak zorlu arazilerde uyum sağlama ve tepki verme kabiliyetini artırır. Bu araştırma, ultrasonik teknolojiden yararlanarak, sensörlerin özellikle görsel ipuçlarının tehlikeye girebileceğı olumsuz hava kořullarında araç dengesini ve güvenliğini artırmada nasıl önemli bir rol oynayabileceğine dair değerli perspektifler sunmaktadır.

Wu ve diğeri (2014), tarafından başlangıç çıkarma ve faz kayması tespitine dayalı yüksek doğrulukta bir ultrasonik aralık belirleme yöntemi önerilmiştir. Bu teknoloji, zorlu ortamlarda araç sürüş dengesini incelemek için doğrudan uygulanabilir. Ultrasonik menzile odaklanan kaynak, aracın mesafeleri doğru bir şekilde ölçme yeteneğini geliřtirir, bu da olumsuz kořullarda istikrarlı navigasyon için çok önemlidir. Ultrasonik mesafenin doğruluğundaki iyileşmeyi vurgulayan çalışma, hassas mesafe ölçümleri ve güvenilir

engel tespiti sağlayarak dengeyi artırmaya yönelik stratejiler hakkında fikir vermektedir. Bu çalışma, ultrasonik sensörlerin gelişmiş sinyal işleme tekniklerinden yararlanarak olumsuz arazi ve hava koşullarında araç dengesini ve güvenliğini sağlamada nasıl önemli bir rol oynayabileceğinin anlaşılmasına katkıda bulunmaktadır.

Illade-Quinteiro ve diğerleri (2015), zorlu koşullarda bir aracın dengesini korumakla ilgili olan uçuş süresi sensörlerinin mesafe ölçümündeki hataları araştırmışlardır. Bu çalışmanın sensör doğruluğuna yaptığı vurgu, ölçümlerdeki hataların zorlu arazilerde istikrarlı navigasyonu nasıl etkileyebileceğini anlamamıza katkıda bulunmaktadır. Bu çalışmada atış gürültüsünün mesafe ölçüm doğruluğu üzerindeki etkisinin analizi, hataları hafifletmeye ve sensör verilerinin güvenilirliğini artırmaya yönelik stratejiler hakkında faydalı bilgiler sağlayabilir. Bu çalışma, hassas mesafe ölçümlerinin çok önemli olduğu zorlu ortamlarda araç dengesini ve güvenliğini artırmanın bir yolu olarak sensör doğruluğunu geliştirme zorluğunu ele almaktadır.

Liu ve diğerleri (2016), çeşitli ortamlarda araç sürüş stabilitesini araştırmak için kullanılabilir Tek Atışlı Çoklu Kutu Dedektörünü (SSD) sunmuştur. Nesne algılamaya odaklanmak, aracın çevresini algılama ve tepki verme kabiliyetini artırır; bu da zorlu arazilerde istikrarlı navigasyon sağlamak için gereklidir. Bu çalışmada SSD algoritmasının tanıtılması, elverişsiz hava koşullarında bile nesnelere hassas bir şekilde tespit edip konumlandırarak stabilizeyi ve güvenliğini artırmaya yönelik stratejiler hakkında fikir vermektedir. Bu çalışma, SSD'nin etkinliğinden ve hassasiyetinden yararlanmakta ve nesne algılama algoritmalarının aracın algılama ve karar verme yeteneklerini nasıl artırabileceğini anlamaya katkıda bulunarak farklı arazilerde ve hava koşullarında istikrarlı sürüşe yol açmaktadır.

Xu ve diğerleri (2018) yaptıkları çalışmada, 3B sınırlayıcı kutuları tahmin etmek için derin bir sensör füzyon yaklaşımı olan PointFusion'ı incelemişlerdir. Bu yaklaşım, karmaşık ortamlarda araç sürüş stabilitesinin incelenmesiyle doğrudan ilgilidir. Bu kaynakta sensör füzyonuna odaklanması, araçların birden fazla sensörden gelen verileri entegre etme becerisini geliştirmektedir; bu da farklı arazilerde istikrarlı navigasyonu

sürdürmek için çok önemlidir. Çalışmada PointFusion algoritmasının tanıtılması, zorlu hava koşullarında bile nesnelerin 3B sınırlayıcı kutularını doğru bir şekilde tahmin ederek kararlılığı ve güvenliği artırmaya yönelik stratejiler hakkında fikir vermektedir. Bu çalışma, derin sensör füzyon tekniklerinden yararlanarak, sensör entegrasyonunun araçların algılama ve karar verme yeteneklerini nasıl geliştirebileceğine dair anlayışımızı geliştirmekte ve sonuçta karmaşık arazilerde ve hava koşullarında istikrarlı sürüşe yol açmaktadır.

Uçtan uca nokta bulutu tabanlı bir 3B nesne algılama öğrenme yaklaşımı olan VoxelNet, Zhou ve Tuzel (2018) tarafından tanıtılmıştır. Bu yaklaşım, karmaşık ortamlarda araç sürüş dengesinin incelenmesine doğrudan uygulanabilir. Nokta bulutu tabanlı nesne algılama kaynağına odaklanmak, farklı arazilerde istikrarlı navigasyonu sürdürmek için gerekli olan aracın algısını ve çevresine verdiği tepkiyi geliştirir. VoxelNet'i inceleyen bu çalışma, zorlu hava koşullarında bile 3D uzaydaki nesnelere doğru bir şekilde tespit edip konumlandırarak stabilite ve güvenliği artırmaya yönelik stratejiler hakkında içgörüler sağlıyor. Uçtan uca öğrenme tekniklerinden yararlanılarak, nokta bulutu tabanlı nesne algılama algoritmalarının aracın algılama ve karar verme yeteneklerini nasıl geliştirebileceğinin anlaşılmasına katkıda bulunulmakta ve sonuçta karmaşık arazilerde ve hava koşullarında istikrarlı sürüşe katkıda bulunulmaktadır.

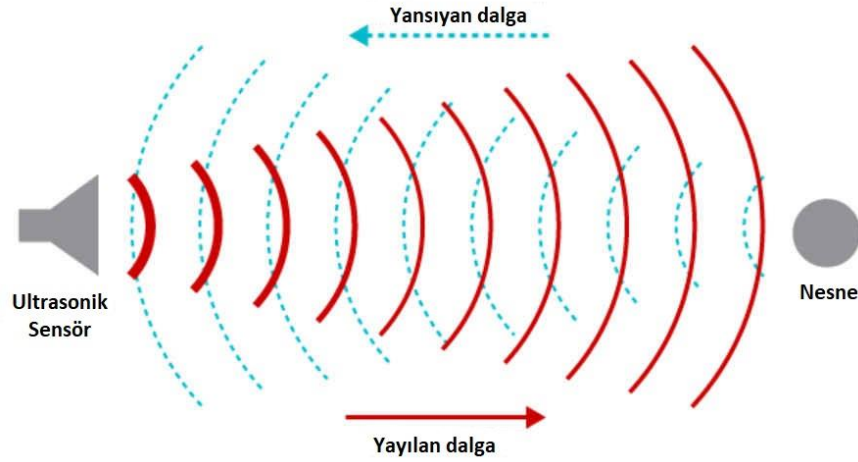
Zhao ve diğerleri (2020), olumsuz koşullarda araç sürüş stabilitesini incelemek için yüksek hassasiyetli bir ultrasonik mesafe ölçme sisteminin tasarımını ve deneysel çalışmasını gerçekleştirmiştir. Ultrasonik menzile odaklanmak, aracın mesafeleri doğru bir şekilde ölçme yeteneğini geliştirir ve bu da istikrarlı navigasyon için temel bir gerekliliktir. Bu çalışma, ultrasonik mesafe ölçümünde tasarım ve deneysel yaklaşımları kullanarak, zorlu arazilerde ve olumsuz hava koşullarında dengeyi artırmak için sensör teknolojisinin nasıl optimize edilebileceğine dair içgörüler sunmaktadır. Bu çalışma, doğru mesafe ölçümleri ve güvenilir engel tespiti sağlamak için gelişmiş sinyal işleme tekniklerinden ve deneysel doğrulamadan yararlanarak araç dengesini ve güvenliğini artırmaya yönelik stratejilere katkıda bulunulmaktadır.

Brena ve diğeri (2020), elverişsiz çevre koşullarında araç sürüş dengesini değerlendirmek için uygulanabilecek en uygun sensör füzyon tekniğini seçmek için bir makine öğrenimi yöntemini araştırmıştır. Bu kaynağın sensör füzyonuna yaptığı vurgu, sensör verilerinin entegrasyonunun zorlu arazilerde ve olumsuz hava koşullarında algıyı ve navigasyonu nasıl iyileştirebileceğinin anlaşılmasına yardımcı olmaktadır. Çalışmanın sensör füzyon tekniklerini seçmeye yönelik makine öğrenimi metodolojisi, çeşitli sensörlerden gelen verileri verimli bir şekilde entegre ederek dengeyi ve güvenliği artırmaya yönelik stratejiler hakkında fikirler sunmaktadır. Bu çalışma, farklı füzyon yöntemlerinin performansını analiz ederek, sensör entegrasyonunu optimize etmek ve zorlu koşullarda aracın navigasyonunu ve dengesini iyileştirmek için teknikler hakkında bilgi vermektedir. Bu kaynakta tartışılan kavramlar, zorlu arazilerde istikrarlı sürüş için kesin ve güvenilir bilgi sağlamada sensör füzyon tekniklerinin önemini vurgulamaktadır.

3. MATERYAL ve YÖNTEM

3.1. Ultrasonik Sensör

Ultrasonik sensörler, fiziksel temas gerektirmeden bir nesnenin varlığını belirlemek için mesafe ölçebilir. Bu olay, ultrasonik bir yankı üretmek ve izleyerek gerçekleştirilir. Havadaki etkili menzil, sensörün ve nesnenin özelliklerine bağlı olarak birkaç santimetre ile birkaç metre arasındadır. Ultrasonik sensörler (veya dönüştürücüler), bir nesnenin görüş alanı içindeyken sensöre geri yansıtılan ultrasonik darbeleri üretir ve yayar.



Şekil 3.1. Ultrasonik uçuş süresi ölçümü

Ultrasonik sensörler, piezoelektrik bir dönüştürücüdür bu nedenle mekanik titreşimleri elektrik sinyallerine dönüştürebilir. Böylece, ultrasonik sensör belirli frekanslarda hem mikrofon hem de hoparlör işlevi görmüş olur.

Alınan ve yayılan yankı arasındaki zaman farkını sensör algılayabilir. Ses hızı bilinen bir değişken olduğundan, sensör ile nesne arasındaki mesafeyi bulmak için yakalanan gidiş-dönüş süresi kullanılabilir. Ultrasonik mesafe hesaplaması Denklem 3.1'de gösterilmektedir.

$$d_0 = \frac{t_t v_s}{2} \quad (3.1)$$

Bu ultrasonik algılama yöntemi, sesin yayılma süresini kullanır. Ancak hava sıcaklığı da sesi hızlandırmaktadır. 20°C kuru havada ses hızı 343 m/s olarak kabul edilmektedir.

3.2. Ultrasonik Sensörün Kullanılma Nedenleri

Şekil, şeffaflık veya renkten bağımsız olarak, ultrasonik sensörler çeşitli malzemeleri algılayabilir. Hedef malzemenin katı veya sıvı olması ultrasonik algılama için tek şarttır. Bu nedenle, aşağıdaki malzemeler ultrasonik sensör tarafından kolaylıkla algılanabilir:

- Metal
- Plastik
- Cam
- Ahşap
- Kayalar
- Kum
- Yağ
- Su
- Diğer sert, ses emici olmayan malzemeler

Bu maddeler hava yoluyla sensöre sesi geri gönderebilir. Açılı yüzeyler veya sünger, köpük ve yumuşak giysiler gibi geçirgen hedefler yankı algılamayı zorlaştırabilir. Bunlar daha fazla ultrasonik enerji emer.

3.3. Kızılötesi Sensörlerin Optik Tabanlı Algılama Yöntemleriyle Kıyaslanması

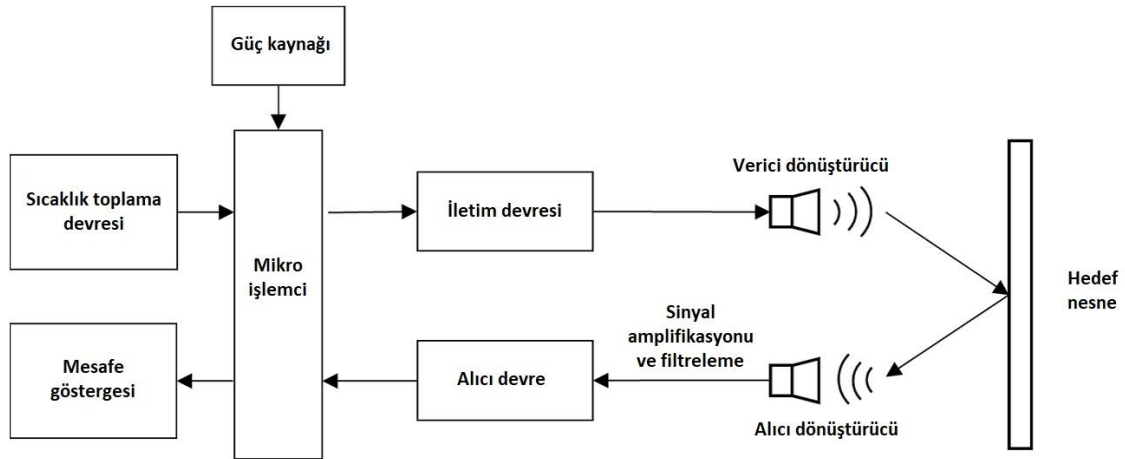
Kızılötesi (IR) sensörler, düşük maliyetli, yüksek çözünürlükleri ve hızlı tepki süreleri nedeniyle engelleri tespit etmek için kullanılabilir. Bununla birlikte, infrared sensörleri, doğrusal olmayan özellikleri ve yansıma özelliklerine bağımlılıkları nedeniyle uygulamadan önce yüzey özelliklerini öğrenilmelidir. Çeşitli yüzey malzemeleri IR enerjisini farklı şekillerde yansıtır ve emer, bu nedenle hedef malzemenin belirlenmesi gerekir.

Ultrasonik teknoloji ve optik tabanlı algılama teknolojilerinin temel prensipleri benzerdir. Bununla birlikte, optik teknoloji, ses dalgaları yerine ışık dalgaları yaymak ve uçuş zamanını belirlemek için LED (Işık Yayan Diyotlar)'ler kullanır. Bu, ışık hızı prensibine göre dönüştürülebilir. Optik tabanlı algılama, ultrasonik algılamadan daha hızlıdır çünkü ışık ses hızından çok daha hızlıdır. Bununla birlikte, parlak aydınlatma koşulları ve dumanlı veya sisli ortamlar, ışık reseptörünün yayılan ışığı algılamasını zorlaştırır. Optik algılama, su veya cam gibi berrak malzemeleri algılayamaz. Bu malzemelerin içinden geçerken ışık ultrasonik bir şekilde yansır.

Lidar ve radar tabanlı teknolojilerin amacı, tek bir uçuş süresini ölçmek yerine çok noktalı veri toplamaktır. Bu, ortamdaki çok küçük anları ve son derece hassas veri noktalarını haritalama ve ayırt etme yeteneğine olanak tanır.

3.4. Ultrasonik Sensörün Sistem Bileşenleri

Şekil 3.2 tipik bir ultrasonik mesafe ölçme sistemini göstermektedir. Bu sistem gönderici ve alıcı, güç kaynağı, gönderme ve alma devreleri, mikroişlemci, sıcaklık dengeleme modülü ve mesafe bilgisi içeren ekran modülü içerir (Zhao vd., 2020).




Şekil 3.2. Ultrasonik sensörün sistem bileşenleri şeması

Verici ve alıcı devreler, dönüştürücülerin bir parçasıdır. Alıcı devrenin ön yükselticisi, zayıf sinyalleri yükseltirken, verici devre programlanmış darbeleri, yüksek voltaj darbelerine yükseltir (Tai ve Zhang, 2019).

Ardından sinyal, girişim yapan gürültü sinyallerini çıkarmak ve alınan sinyallerin SNR'sini (Sinyal Gürültü Oranı) iyileştirmek için bant geçiren filtreden geçer. Yankı sinyalini dijitalleştirmek için bant geçiren örnekleme teorisi kullanılabilir (Cabral ve Valdez, 2013). Bu, donanım sistem gereksinimlerini azaltır.

Mikroişlemciler genellikle düşük güçlü ve yüksek performanslı bir mikro denetleyici birimi (MCU) kullanır (Lu vd., 2020). Verici sinyalin programlanması mikroişlemcinin görevidir. Aynı zamanda, ölçüm sonuçlarını ekran modülüne iletmek için sinyali işler ve ilgili bilgileri alır. Bu arada, menzil sisteminin çalışması, güç kaynağı modülünden kaynaklanmaktadır.

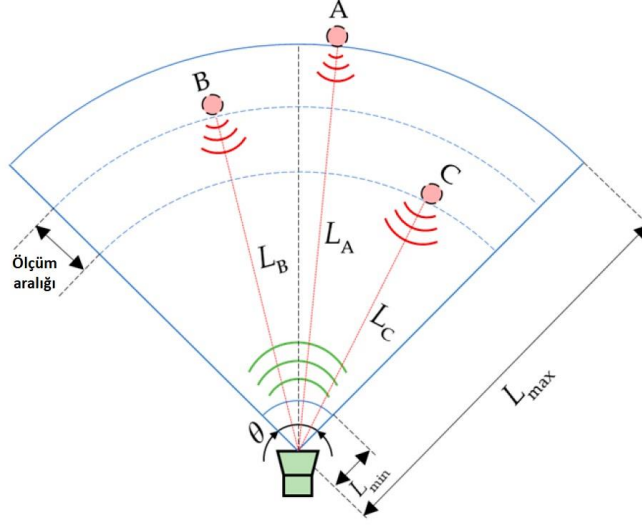
Şekil 3.3'te gösterildiği gibi, ideal ve gürültülü ultrasonik yankı sinyallerinin başlangıç zamanı olan T_1 , alınan sinyallerin mikroişlemci tarafından işlenmesinin önemli bir parçasıdır. Ek olarak, ölçülen sinyalin genliği alınan sinyalin genliği ile aynı değildir.



Şekil 3.3. İdeal ve gürültülü ultrasonik yankı sinyalleri (Wu vd., 2014)

Sıcaklık dengeleme modülü, ultrasonik dalgaların yayılma hızını azaltır. Ses hızı her 1 °C artışında yaklaşık 0,607 m/s artar (Sahoo ve Udgata, 2020). Bu sebeple devre sıcaklık sensörü ile donatılmıştır ve gerçek zamanlı olarak ultrasonik hız elde etmek için mikroişlemciye bağlanmıştır.

Bir mikroişlemci, ölçüm verilerini gerçek zamanlı görüntüleme için doğrudan bir sıvı kristal ekrana (LCD) bağlayabilir. Alternatif olarak, ölçüm verilerini doğrudan okuma zahmetinden kaçınmak için diğer mikrodenetleyicilerle kablosuz iletişim yoluyla iletilebilir. Şekil 3.4'te, ultrasonik mesafe sensörünün bir araçtaki ölçüm aralığı gösterilmiştir.



Şekil 3.4. Ölçüm aralığının şematik diyagramı

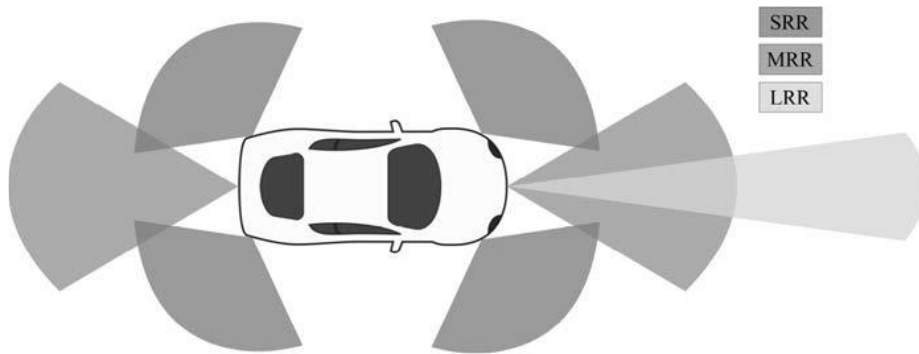
3.5. Radar

"Radar" terimi, radyo sinyallerini algılamak ve mesafenin uzunluğunu belirlemek için kullanılan bir terimdir. Radarlar, belirli bir alandaki nesnelere bulmak, izlemek ve tanımlamak için kullanılan elektromanyetik sistemlerdir. Radarlar, hedeflerden gelen yankıları takip etmek için elektromanyetik dalga gönderir. Hedefler; gemiler, uçaklar, otomobiller, astronomik cisimler vb. olabilir. Radar sistemleri, büyük boyutları ve yüksek maliyetleri nedeniyle ilk başta yalnızca askeri alanlarda kullanılıyordu. Modern minyatür radar sistemleri, yüksek frekanslı tümeşik devreler (IC) ve monolitik mikrodalga IC'ler sayesinde bir baskılı devre kartı veya hatta bir IC üzerinde gerçekleştirilebilir (Droitcour vd., 2004). Duvar ötesi algılama, iç mekan lokalizasyonu, biyomedikal uygulamalar ve

sürücü yardımı, radar sistemlerinin ticari uygulama alanlarıdır (Patole vd., 2017). Bu bölümün odak noktası radar teknolojisi ve otomobillerdeki uygulamalarıdır.

Modern araçların güvenliği için radar çok önemlidir. Otomotiv radarları, gelişmiş sürücü destek sistemlerinde (ADAS) kullanılan önemli sensörlerdir ve çarpışmadan kaçınma, kör nokta tespiti, şerit değiştirme yardımı, park yardımı vb. fonksiyonları için kullanılır. Bir araç üzerindeki tipik bir otomotiv radar konfigürasyonu Şekil 3.5'te gösterilmiştir. Uyarlanabilir hız sabitleyiciler genellikle aracın ön tarafına monte edilen uzun menzilli bir radar (LRR) kullanır. Ön ve arkaya monte edilen orta menzilli radarlar, LRR'den daha geniş bir kapsama alanı sunar ve çapraz trafik uyarısı ve şerit değiştirme yardımı için kullanılabilirler. Köşelere monte edilen kısa menzilli radarlar, kör nokta izlemeyi, engel/yaya algılamayı ve park yardımını sağlar.

Bu radarlar genellikle daha iyi algılama sonuçları sağlamak için birlikte çalışırlar. 24 GHz bantları, çalışma frekansı için eski otomobil sensörlerinde kullanılmaktadır. 77 GHz frekans bandı, Avrupa Telekomünikasyon Standartları Enstitüsü ve Federal İletişim Komisyonu tarafından geliştirilen spektrum düzenlemeleri ve standartları nedeniyle otomotiv radarları için yaygın olarak kullanılır. Ana akım otomobil radarı geliştirme süreci, radarın daha düşük form faktörüne ve daha yüksek çözünürlüğe sahip olmasını sağlayan 77 GHz frekans bandına taşınmasıyla sonuçlanmıştır.



Şekil 3.5. Bir araç üzerindeki tipik bir radar konfigürasyonu

3.6. Otomotiv Radar Sistemlerinin Prensipleri

Bir radar sistemi, bir dizi anten kullanarak uzaya elektromanyetik enerji gönderir. Yayılan elektromanyetik enerji, yakındaki hedeflere "ışık verir". "Aydınlatılmış" hedefler, radar sistemine yayılan enerjinin bir kısmını keser ve bir kısmını geri yansıtır. Yansıyan enerjiyi algılamak için radar sistemi bir ya da daha fazla alıcı kanalını kullanır. Bu kanallar hedeflerin uzaklığını, hızını ve göreceli açılarını belirler.

Darbeleri ve sürekli dalga (CW) radarları, radar göndericisi tarafından yayılan dalga biçimlerine göre radar sistemlerini kategorize eder. Bir darbeleri radar, sık sık tekrarlanan kısa süreli darbelere sahiptir. Hedefin menzili, gönderilen darbe ile alınan darbe arasındaki süreye göre hesaplanır. Darbeleri radarlardan farklı olarak, CW radarları elektromanyetik dalgayı belirli bir süre boyunca sürekli olarak gönderir. Hedeflerin özellikleri, alınan işaret ve gönderilen işaretin bir kopyasını karşılaştırarak elde edilir. Birçok avantajı nedeniyle CW radar sistemleri otomobil uygulamalarında daha popülerdir. Darbeleri bir radarla karşılaştırıldığında, bir CW radarı düşük tepe gönderim gücüne sahiptir ve daha basit ve entegredir. Bu nedenle, özellikle otomotiv uygulamaları için çok çeşitli alanlarda kullanılabilir.

Otomobil radarları algılama, izleme ve görüntüleme özelliklerine sahiptir. Hedef belirlemede en önemli sorun, alıcı tarafından alınan yankının sadece gürültüden mi yoksa bir nesnenin yansımasından mı kaynaklandığını belirlemektir.

Bir CW radarında tespit kararı genellikle yankının işaret genliği ile önceden belirlenebilen ya da gerçek zamanlı olarak hesaplanabilen bir eşik değerinin karşılaştırılmasıyla verilir. Eşik değeri, sağlam bir radar sistemi için gerçek zamanlı radar verilerinden uyarlamalı olarak bulunmalıdır.

Bir hedefin uzaklığını belirlemek için bir CW radarında belirli modülasyonlar uygulanmalıdır. İşaret işleme yoluyla alınması gereken menzil bilgisini yankı işaretine kodlamak modülasyon olarak bilinir. Örneğin, bir doğrusal frekans modülasyonlu sürekli

dalga (FMCW) radarı, hedefin uzaklığını temel bant işaretinin frekansına kodlar. Faz modülasyonlu bir sürekli dalga radarında, menzil bilgisi bir faz kodu dizisi içinde kodlanır. Yankının korelasyonu, bu kod dizisi ile çıkarılabilir. Bir radarın menzil çözünürlüğü (ΔR), çeşitli modülasyon türlerine rağmen gönderilen işaretin bant genişliği Denklem 3.2'de de görülebileceği üzere (BW) ile ters orantılıdır.

$$\Delta R \propto \frac{1}{BW} \quad (3.2)$$

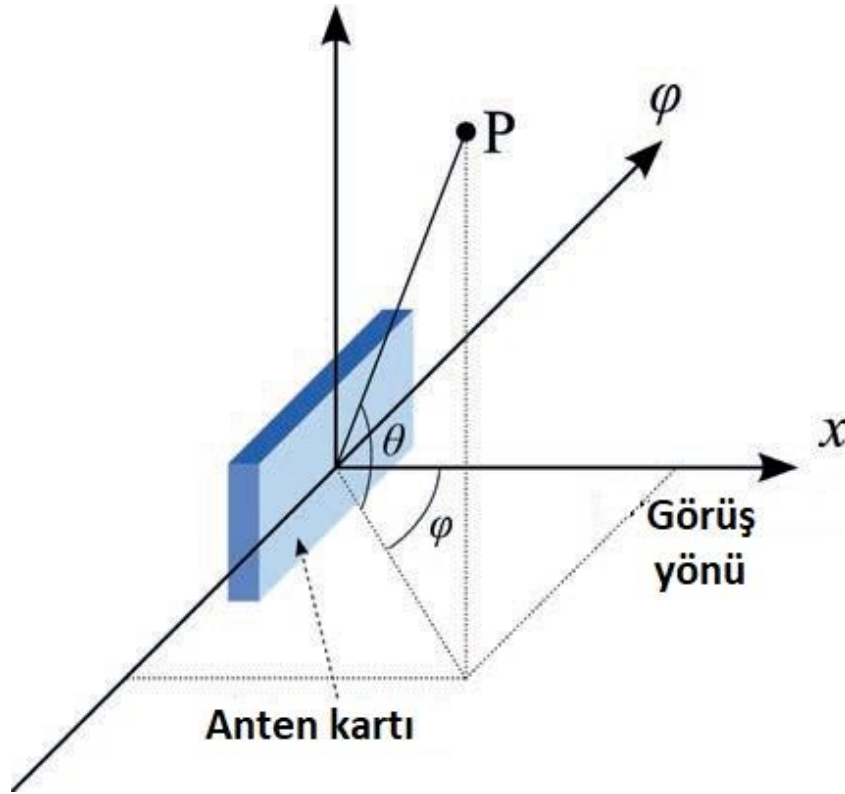
Otomotiv radar uygulamalarında, daha iyi menzil çözünürlüğü elde etmek için bant genişliği yüksek olan sinyaller kullanılır.

Doppler etkisini kullanarak bir radar, bir hedefin göreceli hızını elde edebilir. Lidar ve kameralar gibi otomotiv sensörleri ile karşılaştırıldığında, otomotiv radarının bu en önemli avantajlarından biridir. Doppler etkisi, bir elektromanyetik dalganın radara göre hareket ederken frekansında veya fazında meydana gelen değişiktir. Bu olguyu 1842 yılında tanımlayan Avusturyalı fizikçi Christian Doppler'den almıştır. Doppler etkisinin nedeni, hedef radara doğru hareket ederken, birbirini izleyen her elektromanyetik dalga tepesinin radara daha yakın bir konumdan yansmasıdır.

Sonuç olarak, her elektromanyetik dalga radara ulaşmak için biraz daha az zaman alır. Bu nedenle, birbirini izleyen elektromanyetik dalga tepelerinin radara varışları arasındaki süre kısalmış ve alınan elektromanyetik dalga fazı azalmıştır. Bununla birlikte, hedef radardan uzaklaştıkça, her elektromanyetik dalga radardan önceki elektromanyetik dalgadan daha uzak bir konumdan yansıtılır. Ardışık elektromanyetik dalgalar arasındaki faz ve varış süresi artar. Bir radar, bir hedefin göreceli hızını, hedeften gelen bir dizi sapma arasında gelişen fazı hesaplayarak elde edebilir.

Otomotiv uygulamaları için, bir hedefin göreceli menziline ve hızını elde etmek genellikle yetersizdir. Acil durum freni uygulamak gibi uygun bir karar vermek, aracın hedeflerin 3B uzaydaki konumlarının da farkında olması gerektirir. Otomotiv radarı, Şekil 3.6'da


gösterildiği gibi, bir hedefin (P) konumunu küresel bir koordinat sisteminde belirler. Genellikle radarın anten kartına dik olan görüş yönü, x-eksenidir. X ve Y düzlemi üzerindeki iki açı azimut ve yükseklik açılarıdır. Radar sistemlerinde hedeflerin azimut ve yükseklik açılarını belirlemek için çeşitli yöntemler kullanılabilir. Mekanik bir döndürücü, en yaygın kullanılan yöntemlerden biridir (Visser, 2006). Bu yöntem, çok küçük bir ışın demetine sahip bir radarı bir döndürücü üzerine monte ederek ortamı mekanik olarak taramaktır. Döndürücünün konumu, hedefin görece yüksekliğini ve azimut açılarını sağlar. Mekanik taramalı radar askeri uygulamalarda yaygın olarak kullanılmıştır; ancak, büyük boyutu nedeniyle, küçük ve ucuz otomotiv uygulamaları için uygun değildir. Faz dizisi, sayısal hüzmleme ve çoklu giriş ve çoklu çıkış gibi yöntemler de açı ölçümleri için kullanılabilir (Visser, 2006). Bu teknikler herhangi bir mekanik döndürme yapısı gerektirmez ve oldukça entegredir.



Şekil 3.6. Radar ölçümü için küresel koordinat sistemi

3.7. Otomotiv Radar Mimarisi

Genelleme yapmak gerekirse, temel bir otomotiv radarı gönderici, alıcı ve antenler olmak üzere üç parçadan oluşur. Basitleştirilmiş bir tek kanallı CW radar mimarisi Şekil 3.7’de gösterilmektedir (Peng vd., 2017). Bu mimari, CW radarların çoğuna uygulanabilir. Çeşitli dalga biçimi türlerine göre, radarın çeşitli parçalarının gerçek donanım gerçekleştirilmesi farklı olabilir. Gönderici (T_x), bir işaret sentezleyici kullanarak farklı dalga türleri oluşturur. Daha sonra oluşturulan dalga biçimi yükseltilir ve gönderici anteni ile iletilir. Alıcı, üretilmiş sinyalin bir kısmını alır ve yerel osilatör (LO) olarak çalışır. Alıcı anteni (R_x), hedeflerden yansıyan sinyalleri alır. İlk olarak, alıcı kanalında bir dizi yükseltme ve filtreleme yapılır ve bu, sinyallerin koşullandırılmasını sağlar. Bir karesel aşağı dönüştürücü, alınan sinyalleri LO ile karıştırarak temel bant sinyalini oluşturur. Aşağı dönüştürme tamamlandıktan sonra, temel bant sinyali daha fazla işlem yapmak için dijital alana aktarılır.



Şekil 3.7. Basitleştirilmiş tek kanallı radar mimarisi

Şekil 3.7’deki basitleştirilmiş mimari, farklı dalga konfigürasyonları nedeniyle tüm CW radarı tiplerine uygulanması beklenemez. Örneğin, çoklu kanalları geliştirmek için birçok

tasarım, alıcının farklı gönderici kanallarından gelen işaretleri ayırmasına yardımcı olmak için göndericide fazladan bir modülasyon içerir.

Bazı tasarımlar, verici kanallarında faz kaydırıcıları kullanarak hüzmelenmeyi destekler. Örnek olarak, alıcı tarafında dörtlü aşağı dönüştürücü her zaman gerekli değildir; bazı durumlarda tek kanallı doğrudan aşağı dönüştürücü de kullanılabilir.

3.7.1. Verici

Bir otomotiv radarının göndericisi, tüm sistemin hassasiyetini ve menzil çözünürlüğünü ölçmede çok önemlidir. Daha yüksek bir gönderim gücü ve yüksek kazançlı antenler kullanmak, sinyali iyileştirir ve radarın daha küçük bir hedefi daha uzun bir menzilde algılama kapasitesini artırır. Ek olarak, daha geniş bir BW gönderimi, radarın menzili yakın olan hedefleri belirleme yeteneğini artırır. Yetkililer, otomotiv radar vericileri tarafından kullanılan maksimum iletim gücü ve frekans bantları da oldukça sıkı bir şekilde kontrol etmektedir.

Uluslararası Telekomünikasyon Birliği (ITU), modern teknolojiye, özellikle de telekomünikasyonda elektromanyetik dalgaların yaygın olarak kullanılmasının bir sonucu olarak, elektromanyetik dalgaların üretimi ve iletimi için ulusal yasalar oluşturmuştur. Otomotiv radar uygulamaları için dünya çapında dört ayrı frekans bandı vardır. Otomobil radarları için mevcut frekans bantları Çizelge 3.1’de gösterilmektedir.

Çizelge 3.1. Otomotiv radar frekans bantları

Frekans	Bant genişliği	Bantın türü
24-24.25 GHz	250 MHz	ISM
21-26 GHz	5 GHz	UWB
76-77 GHz	1 GHz	Otomotiv LRR
77-81 GHz	4 GHz	Otomotiv SRR


24 ila 24.25 GHz arasındaki 250 MHz bant genişliğindeki ayrılmış endüstriyel, bilimsel ve tıbbi (ISM) bant hem lisanslı hem de lisanssız operasyonlar için kullanılabilir.

Paylaşılan bir bant olduğu için parazit riski yüksektir. 21 ila 26 GHz arasında 5 GHz ultra geniş bant (UWB), düşük iletim gücü gerektirdiği için kısa mesafedeki uygulamaları sınırlar. Genellikle çoğu ülke, uzun menzilli radar (LRR) için 76-77 GHz bandını ve kısa menzilli radar (SRR) için 77-81 GHz bandını tahsis etmiştir. Aşağıdaki avantajları nedeniyle bu iki yüksek frekans bandı otomotiv radarları için tercih edilmektedir.

4 GHz üzerinde bir BW ile 77 GHz frekans bandı 76 ila 81 GHz arasında değişir. Geniş BW, radarın yakın aralıklı hedefleri ayırt etme yeteneğini ve menzil çözünürlüğünü artırır. Daha kısa dalga boyu, daha yüksek frekans nedeniyle daha doğru ve çözünür bir hız ölçümü sağlar. Daha kısa dalga boyu otomotiv radarlarının anten boyutlarını da azaltır. 77 GHz bandı otomobil radar uygulamalarına tahsis edildiğinden, düzenleme daha yüksek gönderim gücüne izin vermektedir.

79 GHz'de otomotiv radarları için ortalama etkin izotropik ışınma gücü (EIRP) 55 dBm'dir ve en düşük EIRP spektral yoğunluğu -3 dBm/MHz'dir. 24 GHz bandında ise 20 dBm EIRP tepe sınırı vardır.

Bir otomotiv radarının en önemli parçalarından biri, dalga biçimi üretici olarak da bilinen sinyal sentezleyicidir. Sinyal sentezleyici çeşitli dalga biçimleri üretebilir. Şekil 3.8, yaygın olarak kullanılan dört dalga biçimi örneğini göstermektedir. Doppler radarlarında kullanılan ilk dalga biçimi, modüle edilmemiş bir sinüzoidal dalga olan tek tonlu bir işarettir. FMCW dalga biçimi, doğrusal modüle edilmiş bir sinyaldir ve frekansı zamanla doğrusal olarak değişmektedir. Kademeli frekanslı sürekli dalga biçiminde frekans artışları ve azalışları bir merdiven şeklindedir. Frekans kaydırmalı anahtarlama dalga biçiminde farklı frekanslar kullanılır. Bir faz kilitlemeli döngü (PLL) tarafından üretilmesinin kolaylığı ve temel banttan menzil bilgisinin elde edilmesinin yüksek verimliliği nedeniyle FMCW dalga biçimi otomotiv radarları için en yaygın seçimdir.



Şekil 3.8. Farklı dalga biçimi türleri

3.7.2. Alıcı

Alıcının temel amaçları, temel bant sinyalini elde etmek ve yankıyı düzenli olarak azaltarak iletmektir. Alıcı, alınan sinyali iki kanala ayırır. Temel bandın faz içi veya "I" kanalı, iletim sinyalinin bir kopyası olan LO sinyali ile kanallardan birine karıştırılır. Temel bandın dörtlü faz veya "Q" kanalı, 90 derece faz kaydırmalı LO sinyali ile karıştırıldığında elde edilir. Gönderilen sinyal $f(t)$ olduğunu varsayarsak, alınan yankı $r(t)$ şu şekilde yazılabilir:

$$r(t) = A \cdot f(t - \delta_t) \quad (3.3)$$

A işaret genliği, δ_t radar ile hedef arasındaki elektromanyetik dalganın gidiş-dönüş zaman gecikmesi ve t zamandır. Karıştırıcıdan sonra temel bant işareti $r_b(t)$ şu şekilde gösterilir:


$$r_b(t) = A \cdot f(t) \cdot f^*(t - \delta_t) \quad (3.4)$$

Burada * karmaşık sinyalin eşleniğini göstermektedir.

Temel bant işaretini modern otomotiv radarlarında işlemek için genellikle sayısal işaret işleme kullanılır. Sonuç olarak, analog temel bant işaretini sayısal bir gösterime çevirmek gerekir. Analogdan sayısal dönüşümde en önemli sorun, doğru örnekleme hızını seçmektir.

3.7.3. Anten ve anten dizisi

Bir radar sisteminde bir anten ya da bir dizi anten, duyarlılığı ve açısal çözünürlüğü belirlemede çok önemlidir. Radar sistemlerinde birçok farklı anten tipi kullanılır. Otomobil radarları için yama antenler, düşük profilleri ve kolay imal edilebilmeleri nedeniyle en yaygın antenlerdir. Yama antenlerin iki örneği Şekil 3.9'da gösterilmektedir (Peng vd., 2017). Şekil 3.9(a) üç elemanlı bir seri beslemeli yama anten ve Şekil 3.9(b) beş elemanlı bir seri beslemeli yama anten göstermektedir. Kazancı, demet genişliği ve yan lob seviyesi bir antenin en önemli özellikleridir.



Şekil 3.9. Yama anten örnekleri (Peng vd., 2017) (a) 3 elemanlı seri beslemeli yama anten ve (b) 5 elemanlı seri beslemeli yama anten

3.8. Lidar Görüntülemenin Temelleri

Lidar (Light Detection and Ranging) ışık darbeleri yardımıyla mesafeyi ölçen sensörler olarak bilinir. Nesnelere yansıyan lazer darbeleri, sensörlerin çevrelerindeki yapıları algılamalarını sağlar. Yansıyan ışık enerjisinin yardımıyla, lidar nesnelere olan mesafeleri ölçer ve çevrenin iki veya üç boyutlu bir temsilini oluşturur. Birçok sektörde, lidarlar algılama sistemleri için temel sensörlerdir. Lidarlar; nesne algılama, eşzamanlı konum belirleme ve haritalama (SLAM), yol planlama gibi 3B algılamaları mümkün kılar.

Lidar ile görüntüleme için kullanılan ölçüm yöntemi, bir kaynaktan yayılan ışıktaki olaylarda zaman gecikmelerinin sayılmasıyla derinliği ölçer. Uçuş zamanı olarak da bilinen TOF (Time of Flight), derinliği ölçmek için kullanılan ölçüm yöntemidir. Bu

nedenle lidar, optik bir sinyalin hedef olarak adlandırdığımız bir nesneye yansıtılması ve yansıyan veya geri saçılan sinyalin mesafesini belirlemek için algılanması ve işlenmesi yoluyla aktif, temassız bir menzil bulma yöntemidir. Bu teknik, birimin çevresinin bir kısmının 3B nokta bulutunu oluşturmasına izin verir. Bu nedenle, hedefe giden ışık dalgalarının gidiş-dönüş gecikmesi, R menziline veya hedefe olan mesafeye karar verir. Bu, iletilen sinyalin fazını, frekansını, yoğunluğunu ve/veya frekansını modüle ederek ve modülasyon modelinin alıcı tarafından algılanması için gereken süreyi ölçerek gerçekleştirilebilir. En basit olarak, hedefe doğru kısa bir ışık darbesi yayılır ve darbenin yankısının dedektöre varış süresi, mesafenin ne kadar uzun olduğunu belirler. Kullanılan nanosaniye darbeleri genellikle yüksek anlık tepe gücüne sahip olduğundan, bu darbeli lidar santimetre düzeyinde tek bir darbeye çözünürlük sağlayabilir. Bu, göz güvenliği sınırının altında tutarken uzun mesafeler kat etmeyi mümkün kılar.

İkinci bir yöntem, sürekli bir dalganın genlik modülasyonuna (AMCW) dayanan bir yöntemdir. Bu yöntem, yayılan ve geri saçılan tespit edilen dalgaların fazlarını karşılaştırarak mesafenin ölçülmesini sağlar. Darbeli yöntemle karşılaştırılabilir bir hassasiyet elde edilebilir, ancak frekans modülasyonundaki 2π belirsizliği nedeniyle yalnızca orta menzillerde elde edilebilir. Emisyon sürekli olduğundan, alıcıya uzak nesnelere yansıyan sinyal darbeli durumda olduğu kadar güçlü değildir. Bu nedenle, genlik her zaman göz için güvenli sınırın altında kalır. Geri yansıyan yoğunluk seviyelerini uzun mesafelerde hesaplamak da zordur. Son olarak, frekans modülasyonlu sürekli dalga (FMCW) teknikleri, frekans alanındaki sinyallerin doğrudan modülasyonu ve demodülasyonu yoluyla sağlanan üçüncü bir yöntemdir. Bu teknikler, yayılan ve tespit edilen dalganın tutarlı bir süperpozisyonu ile tespit edilmesini sağlar. FMCW, diğer yöntemlere göre iki önemli avantaj sağlar: menzil ölçümünde diğer yöntemlerden çok daha düşük çözünürlükler sağlar ve uzun mesafelerde 1 mikron hassasiyetle 150 mikrona kadar inebilir (Behroozpour vd., 2017). Asıl avantajı, Doppler etkisini kullanarak menzil verileriyle eşzamanlı olarak hız ölçümü sağlamaktır.

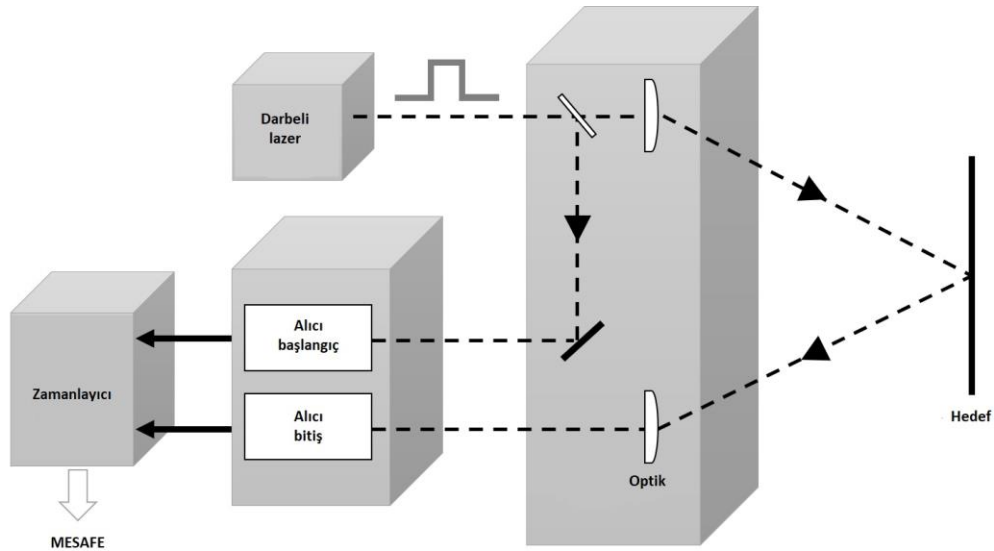
3.9. Lidar Ölçüm Prensipleri

3.9.1. Darbeli yaklaşım

Darbeli TOF teknikleri, aydınlatma ışınının en basit modülasyon prensibine dayanır. Bir ışık darbesinin bir ortamdaki ışık hızıyla hedefe olan mesafeyi kat etmesi için geçen sürenin çarpılması, mesafenin hesaplanmasına yardımcı olur. Aynı optik ortamda kaldığımız sürece, ışık hızı nesneye olan mesafeyle doğru orantılıdır. Işık hedefe doğru hem ileri hem de geri hareket ettiğinden, ölçülen zaman nesneye olan mesafenin açıkça iki katını gösterir. Bu nedenle, hedefe olan gerçek menzil değerini belirlemek için ışık hızı yarıya indirilmelidir (Sarbolandi vd., 2018).

$$R = \frac{c}{2} t_{oF} \quad (3.5)$$

R hedefe olan menzil, c serbest uzaydaki ışık hızı ($c = 3 \times 10^8$ m/s) ve t_{oF} enerji darbesinin yayıcıdan nesneye ve ardından alıcıya geri dönmesi için geçen süredir. Tipik bir uygulamanın basitleştirilmiş bir diyagramı Şekil 3.10'da gösterilmiştir. T_{oF} ölçümüne ilişkin daha fazla teknik ayrıntıya erişilebilir (Illade-Quinteiro vd., 2015).



Şekil 3.10. Darbeli uçuş süresi (TOF) ölçüm prensibi

Menzildeki elde edilebilen çözünürlük (ΔR_{\min}), mevcut zaman sayımındaki çözünürlükle doğru orantılıdır. Sonuç olarak, zaman sayma elektroniğindeki çözünürlük derinlik ölçümündeki çözünürlüğe bağlıdır. Zaman aralığı ölçümünün tipik çözünürlük değeri 0,1 ns'dir, bu da 1,5 cm derinlikte çözünürlük sağlar.

Zaman sayma elektroniğindeki gürültü ve titreşimler, bu değerleri mevcut referans olarak kabul edilebilir. İstatistik (O'Connor, 2012) kullanılarak çözünürlükte önemli iyileştirmeler elde etmek mümkündür, ancak bu, veri noktası başına çok sayıda zorluk gerektirir ve kare hızı veya uzamsal çözünürlük gibi temel yönlerden sensörün performansını azaltır.

Teorik olarak, elde edilebilecek maksimum menzil (R_{\max}), maksimum zaman aralığı (t_{\max}) ile sınırlıdır. Uygulamada, bu zaman aralığı yeterince geniş olduğundan, maksimum menzil diğer değişkenler tarafından sınırlanır. Özellikle, hareket sırasında lazer enerji kaybı, özellikle yayılan hedeflerde, algılama devresinin yüksek bant genişliği ile birleştiğinde, zayıf geri dönen sinyal ile elektronik gürültü arasında rekabet yaratır. Bu, sinyal-gürültü oranını (SNR) darbeli lidarlarda gerçek menzil sınırlayıcı unsur olarak oluşturur (Wehr ve Lohr, 1999). Darbeli yaklaşımda uçuş sırasında birden fazla eşzamanlı darbenin varlığıyla sınırlı olan ve lazerin darbe tekrarlama oranıyla ilişkili olan belirsizlik mesafesi, maksimum menzil ile ilgili olarak dikkate alınması gereken ek bir konudur. (bkz. Denklem 3.5) kullanılarak, MHz aralığına yakın lazer tekrarlama hızlarında bu belirsizlik değeri 150 m'ye ulaşabilir.

Darbeli prensip, bir hedef nesneden ışık darbesi emisyonu ve darbe yankısının geri dönüşü arasındaki gidiş-dönüş süresini doğrudan hesaplar. Sonuç olarak, darbelerin büyük optik güç ve hızlı yükselme ve düşme süreleri ile mümkün olduğunca kısa (genellikle birkaç nanosaniye) olması gerekir. Darbe ışınım gücü arka plan veya ortam ışınım gücünden çok daha yüksek olduğundan, bu tür bir yöntem dış mekanlarda (güneş arka planının yokluğunun yayılan güç gereksinimlerini azaltacağı iç mekan uygulamaları için de uygun olmasına rağmen), olumsuz çevresel koşullar altında iyi çalışır ve uzun mesafeli (birkaç metreden birkaç kilometreye kadar) ölçümler için kullanılabilir.

Bir ışık darbesi bir lazer tarafından yayıldıktan ve bir nesneye yansıtıldıktan sonra, dedektör yalnızca optik enerjinin bir kısmını geri alabilir. Hedefin optik bir difüzör olduğu varsayıldığında, bu enerji daha da çok saçılma yönü arasında bölünür. Bu enerji tipik olarak birkaç saçılma yönü arasında bölünür. Bu nedenle, darbeli yöntemler, düşük frekanslı çok hassas dedektörlere ihtiyaç duyar. Darbeli yöntemler genellikle doğrudan enerji ölçümleriyle uğraştıklarında tutarsız bir algılama ortaya çıkar (Wehr ve Lohr, 1999).

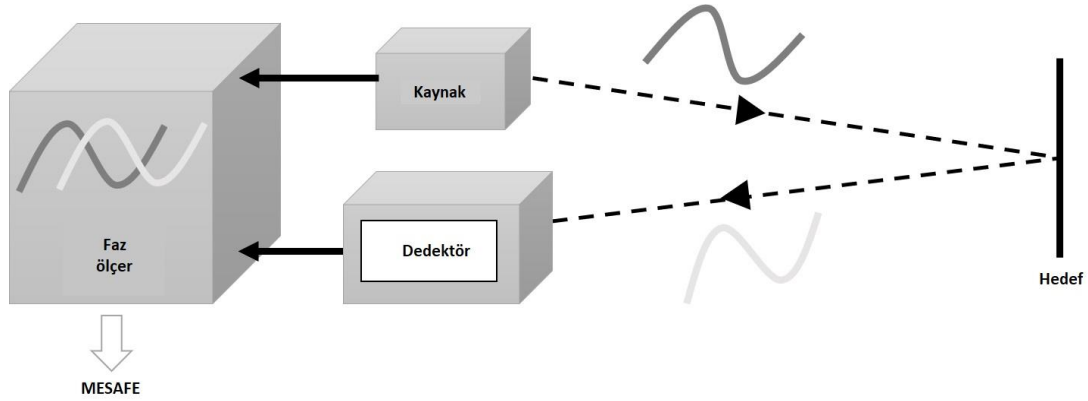
Darbeli yaklaşımın avantajları arasında uçuş zamanının doğrudan ölçümüne dayanan basit bir ölçüm prensibi, uzun belirsizlik mesafesi ve yüksek enerjili lazer darbelerinin kullanılması nedeniyle arka plan aydınlatmasının sınırlı etkisi vardır. Bununla birlikte, ölçüm sinyal-gürültü oranı (SNR) ile sınırlıdır ve algılama aralığına bağlı olarak pahalı olabilen çok hassas dedektörlerin kullanılması gerekir, böylece göz güvenliği sınırlarının korunması gerekir. Yüksek frekans oranları, algılamadaki önemli amplifikasyon faktörleri nedeniyle elektronik aksamda önemli ölçüde karmaşıktır. Darbeli yaklaşım, bu kısıtlamalara rağmen basitliği ve açık havada iyi çalışabilmesi nedeniyle şu anda otonom araçlar için lidar görüntüleme sistemleri üreticileri tarafından en yaygın seçimdir.

3.9.2. Sürekli dalga genlik modülasyonlu (AMCW) yaklaşım

Daha önce bahsedilen lazer darbeleri yerine AMCW yaklaşımı, sürekli bir ışık dalgasının yoğunluk modülasyonunu kullanır. Faz ölçümü, CW modülasyonu veya genlik modülasyonlu sürekli dalga (AMCW) bu prensiptir. Menzili hesaplamak için yoğunluk modülasyonlu periyodik bir sinyalde meydana gelen faz kaymasını kullanır. Optik güç genellikle MHz'in onda biri kadar olan sabit bir f_M frekansıyla modüle edilir; bu nedenle, f_M frekansında yayılan ışın kare veya sinüzoidal bir dalgadır. Hedeften yansıma gerçekleşikten sonra, bir dedektör ışık sinyalini toplar. R mesafesi, yayılan ve yansıyan sinyaller arasında meydana gelen $\Delta\phi$ faz kaymasından hesaplanır (Horaud vd., 2016):

$$\Delta\phi = k_M d = \frac{2\pi f_M}{c} 2R \Rightarrow R = \frac{c}{2} \frac{\Delta\phi}{2\pi f_M} \quad (3.6)$$

Bu durumda, R ve c yine hedefe olan menzil ve boş uzaydaki ışık hızlarıdır; k_M modülasyon frekansı ile ilişkili dalga sayısıdır, d kat edilen toplam mesafedir ve f_M sinyalin genliğinin modülasyon frekansıdır. Geleneksel bir AMCW sensörü Şekil 3.11 'de gösterilmiştir.



Şekil 3.11. Sürekli dalganın genlik modülasyonu (AMCW) sensörlerinde kullanılan TOF faz ölçümü prensibi

Alınan sinyali demodüle etmek ve ondan faz bilgisini çıkarmak için çeşitli yöntemler kullanılabilir. Örneğin, faz ölçümü, karıştırıcılar ve alçak geçiren filtreler kullanılarak sinyal işleme teknikleriyle veya daha yaygın olarak, hedefte geri saçılan örneklenmiş sinyalin bir dizi sabit faz ofsetiyle kaydırılmış ilk modüle edilmiş sinyalle çapraz korelasyonu ile elde edilebilir (Sarbolandi vd., 2018). Alınan modüle edilmiş sinyali dört aşamada örnekledikten sonra, referans sinyali ile karıştırıp sinyal totalde dört aşamada örneklenmiş olur. Değişken karmaşıklıkta elektronik devreler genellikle farklı faz ölçer türlerini kullanır.

AMCW yaklaşımı, gerçek aralık sinyalinin frekansı (f_M) ve elektronik tarafından sabitlenen faz ölçerin çözünürlüğünü belirler. Faz ölçerdeki çözünürlük sabit olduğunda, f_M 'nin artırılmasıyla birlikte çözünürlük de artırılır.

Ancak daha büyük f_M frekansları daha kısa kesin aralık değerleri sağlar. Bu nedenle, dönüş sinyalinin faz değeri, farklı aralık değerlerinde 2π kadar faz yer değiştirdikten sonra tekrar kendini yenilemeye başlar. Bu nedenle, ölçümün çözünürlüğü ile maksimum belirsiz olmayan aralık arasında önemli bir fark vardır. MHz'in birkaç onda biri aralığında genellikle modülasyon frekansları bulunur. Modülasyon frekansını düşürmeden belirsizlik mesafesini uzatmak için modüle edilmiş yoğunluk sistemlerinde çoklu frekans yöntemlerinin kullanılması önerilir (Wehr ve Lohr, 1999).

Ayrıca, optik alanda doğrudan algılamanın hassasiyeti azaldığından, faz ölçümü bazı alanlarda tutarlı olsa bile tekniğin hassasiyeti sınırlıdır. Derinlik doğruluğuyla da ilgili olan SNR açısından bakıldığında, kabul edilebilir bir sinyal oranı elde etmek için nispeten uzun bir entegrasyon süresi gereklidir. Bu nedenle, hareketli nesnelerin varlığında hareket bulanıklığı meydana gelir. Bu uzun entegrasyon süreleri, yüksek deklanşör hızları veya kare hızları elde etmeyi zorlaştırmaktadır (Hansard vd., 2012).

Ek olarak, AMCW modülasyonu genellikle lazerler yerine LED'ler üzerinde uygulanır. Bu, mevcut gücünü ve dolayısıyla sinyalin SNR'sini ve belirsizlik mesafesini daha da sınırlar. Ayrıca, sinyalin genliği varış noktasında güvenilir bir şekilde ölçülür ve bazı teknikler tarafından uygun yoğunluk seviyelerinde sayısallaştırılır. Sonuç olarak, TOF kameralar, özellikle büyük nesneler için iç mekanlarda mükemmel performans göstermesine rağmen, görsel-işitsel, arayüz ve video-oyun gibi çeşitli endüstriye uygulanmış olmalarına rağmen dış mekanlarda çok az kullanılır (Hansard vd., 2012). Ayrıca, sürücü veya yolcu algılama ve araç arayüzü gibi çeşitli amaçlarla araçlarda kullanılmıştır.

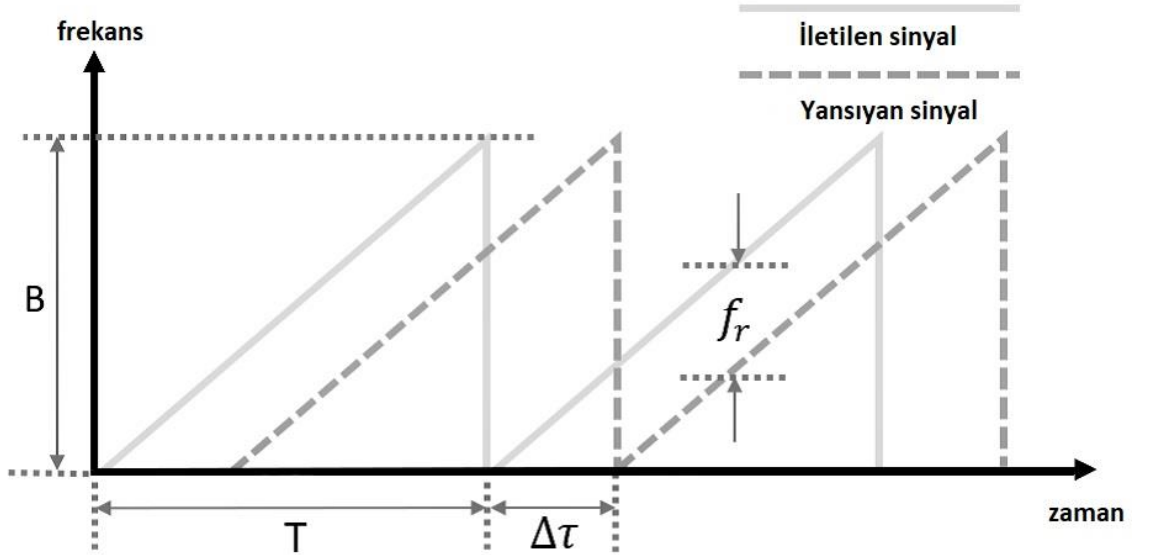
3.9.3. Sürekli dalga frekans modülasyonlu (FMCW) yaklaşım

FMCW yaklaşımı için, yayılan anlık optik frekans sürekli olarak kaynağa uygulanan güç değiştirilerek kaydırılır. Yayılan kaynakla karıştırıldığında, yayılan sinyal bir atım frekansı oluşturur (Jha et al., 2016). Tutarlılık için kaynak tipik olarak bir diyot lazerdir. Daha sonra hedefe gönderilir ve t_{0F} seyahat süresinden sonra alıcıya ulaşan yansıyan

sinyale yayıcı çıkışından gelen bir referans sinyali karıştırılır. Referans ve toplanan ışık arasındaki gecikme, karıştırılan ışıklardan sabit bir frekans farkına veya vuruş frekansına neden olur. Anlık frekansın doğrusal olarak değişmesine izin verildiğinde, f_r doğrudan t_{oF} ile orantılıdır ve bu nedenle hedef aralığı ile de orantılıdır (Agishev vd., 2006). Aşağıdaki formül, f_r 'nin doğrudan t_{oF} ile orantılılığı ile ilgili olduğunu göstermektedir:

$$f_r = \frac{B}{T} t_{oF} = \frac{B}{T} \frac{2R}{c} \Rightarrow R = f_r \frac{cT}{2B} \quad (3.7)$$

B frekans taramasının bant genişliğini, T rampanın periyodunu, c ise ışık hızını temsil etmektedir. Bu parametreler Şekil 3.12'de gösterilmektedir.




Şekil 3.12. Frekans modülasyonlu sürekli dalga (FMCW) yönteminde frekans modülasyonu ve algılama

Uygulamada, giden ve gelen bileşenler arasındaki frekans farkı periyodik bir faz farkına çevrilir. Bu, f_r frekansında bir vuruş sinyali üreten alternatif bir yapıcı ve yıkıcı girişim modeline neden olur. Vuruş frekansının tepe noktası, zaman alanındaki vuruş sinyalini frekans alanına çevirmek için frekans Hızlı Fourier Dönüşümü (FFT) kullanılarak kolayca mesafeye çevrilebilir.

Genel olarak, üçgen frekans modülasyonu yerine rampa kullanılır (Şekil 3.13). Bu durumda modülasyon frekansı f_m 'dir. Bu nedenle, frekans değişim oranı $2 f_m B$ (Aulia vd., 2015) olarak tanımlanabilir ve vuruş frekansı aşağıdaki gibi verilir:

$$f_r = \frac{4Rf_m B}{c} \quad (3.8)$$




Şekil 3.13. Zaman ve bağlantılı genlik sinyal değişimi ile üçgen frekans modülasyonu zaman alanı

Bu tür bir algılamanın önemli bir avantajı, aynı sinyali kullanarak hedefin hızını ve işaretini ölçme yeteneğidir. Hedefin hareket etmesi durumunda, vuruş frekansı hem R ile hem de hedefin sensöre göre hızı ile ilişkili olacaktır. Doppler frekansı f_d , hız katkısı nedeniyle vuruş frekansının aşağı veya yukarı taranmasını etkiler (Şekil 3.14). Bu nedenle, vuruş frekansı bileşenleri f_r 'ye eklenir:

$$f^+ = f_r + f_d \quad (3.9)$$

$$f^- = f_r - f_d \quad (3.10)$$



Şekil 3.14. Hareketli bir hedef için üçgen modülasyon frekans sinyali ve vuruş frekansı

Aralığın elde edildiği Denklem 3.11’de gösterilmiştir:

$$R = \frac{cT}{4B} (f^+ + f^-) \quad (3.11)$$

Doppler etkisi kullanılarak hesaplanan hız ve yön bilgisi Denklem 3.12’de gösterilmiştir:

$$v_r = \frac{\lambda}{2} f_d = \frac{\lambda}{4} (f^+ - f^-) \quad (3.12)$$

FMCW, Fourier spektrumlarının özelliklerini kullanarak bağıl hızı ve menzili aynı anda ölçülebilir (Aulia vd., 2015).

FMCW, optik alanın geniş frekans bant genişliğinden yararlanarak menzil sensörünün performansını artırır. Son olarak, teknolojinin çözünürlüğü sinyalin toplam bant genişliği ile ilişkilidir. FMCW yöntemi, kilohertz seviyesinde frekans ölçümleri yaparak, milimetre ve hatta milimetre altı mesafelere eşdeğer olan piko saniye aralığındaki t_{oF} değerlerini belirleyebilir. Bu mükemmel bir şekilde rampa periyodu seçilmesine sebep olur. Bu durumun dezavantajı, kontrol akımının doğrusal bir modülasyonu olmadan

mükemmel bir doğrusal veya üçgen optik frekans taraması gerçekleştirilemiyor olmasıdır. Ek olarak, frekans-akım eğrisi genellikle doğrusal değildir, özellikle eğim değişim anına yakındır. Sonuç olarak, doğrusal rampadan sapmalar sıklıkla meydana gelir ve f_r 'de ilgili değişiklikler oluşturur. Ek olarak, aralık çözünürlüğü hem f_r 'nin ölçüm doğruluğuna hem de modülasyon eğiminin bilinen veya kontrol edildiği doğruluğa bağlıdır (Agishev vd., 2006).

FMCW yöntemi, önceki iki yöntemden önemli ölçüde farklıdır çünkü zaman sayımı veya faz ölçümü yaklaşımları için şimdiye kadar açıklanan tutarsız yoğunluk algılama şemaları yerine Fourier alanında tutarlı (homojen) yoğunluk algılama şemaları kullanılır (Behroozpour vd., 2017). FMCW, darbeleri ve AMCW yöntemlerine göre daha çözünürlüklü ve uzun vadeli değerlere sahip olduğu için dış ortamlarda faydalıdır. Otonom araçlar için en büyük avantajı, yönünü ve hızını aynı anda tüm menzili algılayabilmesidir. Bununla birlikte, iyi bir sıcaklık kararlılığına sahip ayarlanabilir lazerlerin varlığı, dış koşullar, modülasyon elektroniğinin doğruluğu veya lazerin yoğunluk-voltaj eğrisinin doğrusallığı gibi pratik sorunları ortaya çıkarır. Bu sorunlar otomotiv sistemlerin lidar kullanımı için gelişmiş sinyal işleme çalışmaları gerektirir.

3.10. Araç Görüş Sistemleri

Araçlarda en sık kullanılan sensör tabanlı görüş sistemleri kameralardır. ADAS, görüntüleri yakalamak için bir veya daha fazla kamera ve bunların içindeki nesnelere tespit etmek, analiz etmek ve izlemek için gömülü bir sistem kullanır. Üst düzey ADAS'larda, kameralar aracın içini ve dışını görüntüler. Düşük maliyeti ve kolay kurulumu nedeniyle, kameraların modern araçlara entegre edilmesi daha yaygın hale gelmiştir. 2018 Tüketici Elektroniği Fuarı'nda Mobileye, 2018'de milyonlarca arabaya akıllı kameralar ekleyeceğini açıkladı. Ek olarak, kamera entegrasyonu, 1 Mayıs 2018'den itibaren üretilen tüm araçların görüş tabanlı ADAS kullanmasını zorunlu kılan yasalarla desteklenecektir.


Kameralar, renk, kontrast ve doku gibi bilgileri kaydederek diğer sensörlere göre çok daha iyidir. Şekil 3.15'te görüldüğü gibi görüş tabanlı ADAS'larda tipik olarak monoküler ve stereo kamera olmak üzere iki tür kamera kullanılır.



Şekil 3.15. (a) Monoküler kamera, (b) Stereo kamera

3.10.1. Monoküler kameralar

Monoküler kamera sistemleri tek lenslidir. Bu sistemler, diğer kamera türlerine kıyasla daha az görüntü işleme gerektirdikleri için her zaman tek bir görüntü çıktısına sahiptirler. Bu kameralar, yayaların, şeritlerin, engellerin ve trafik işaretlerinin tespitine yardımcı olabilir. Ayrıca araç içindeki sürücüyü izlemek için de kullanılabilirler, örneğin yüz algılama, göz algılama ve baş duruşu analizi yapabilir (Morignot vd., 2014). Monoküler kameralar, derinlik bilgisine sahip olmadıkları için mesafe tahmini için güvenilir sensörler değildir. Kamera hareket halindeyken araç konumunu izleyerek ve yakalanan görüntü karesindeki temel özellikleri belirler ve bazı yaklaşım metotları araç ile cisim arasındaki mesafenin yaklaşık olarak hesaplanmasını sağlar.



Şekil 3.16. Monoküler kameranın araç üzerine entegrasyonu

3.10.2. Stereo kameralar


Stereo kamera sistemleri, her biri stereo tabanlı olarak bilinen, birbirinden aralıklı bir görüntü sensörüne sahip iki veya daha fazla mercekten oluşur. Stereo kameralar, stereo çiftleri (sol ve sağ sensör görüntüleri) eşleştirerek iki veya daha fazla iki boyutlu (2B) görüntüden üç boyutlu (3B) bilgi çıkarmak ve sahnenin göreceli derinliğini tahmin etmek için bir fark haritası oluşturmak için kullanışlıdır. Monoküler kameralara göre bu kameralar trafik sinyali algılama, şerit algılama, yaya ve engel algılama, mesafe tahmini gibi birçok amaç için çok daha yüksek doğrulukla kullanılabilir. Stereo sistemler, 30 metreye kadar mesafeyi ve derinliği doğru bir şekilde tahmin edebilir. Stereo kameraya sahip olarak üretilmiş araçların çoğu, hafifçe aşağı doğru açılı ve yola bakacak şekilde kameralara sahiptir.



Şekil 3.17. Stereo kameranın araç üzerine entegrasyonu

3.10.3. IR (Infrared) kameralar

İki çeşit IR (Infrared) kamera türü vardır. Aktif IR kameralar, 750 ila 1400 nm dalga boylu bir yakın IR ışık kaynağı (insan gözü tarafından görülemeyen) ve yansıyan ışığı yakalamak için normal bir dijital kamera sensörü kullanır. Pasif infrared kameralar, infrared sensöründeki her pikselin herhangi bir malzeme tarafından yayılan termal radyasyonu yakalayabilen bir sıcaklık sensörü olarak düşünülebilir. Pasif IR kameralar, aktif IR kameraların aksine sahnenin aydınlatılmasını gerektirmez. Yine de yaygın olan gece görüş sistemleri, düşük ışık koşullarında sürücülere video verilerini bir ekranda göstermek için aktif IR kameralar kullanır.



Şekil 3.18. IR kameranın araç üzerine entegrasyonu

3.11. İleri Sürücü Destek Sistemleri (ADAS) ve Araçlardaki Uygulamaları

Güvenlik sistemleri, otomotiv şirketleri tarafından sürekli olarak geliştirilmektedir. Bu güvenlik sistemleri iki kategoriye ayrılabilir: pasif güvenlik sistemleri ve aktif güvenlik sistemleri. Pasif güvenlik sistemleri, bir kaza durumunda yolcuların yaralanmasını azaltır. Örneğin, hava yastıkları ve emniyet kemerleri, binlerce insanın hayatını kurtarmış ve otomotiv endüstrisinde önemli bir rol oynamıştır. Bir aracı kontrol altında tutmaya ve kazaları önlemeye çalışan sistemler, aktif güvenlik sistemleri olarak bilinir (Lu vd., 2005). Gelecekte, aktif güvenlik sistemlerinin çarpışma öncesi uyarı konusunda daha fazla rol oynaması beklenmektedir. ADAS tarafından desteklenen her uygulama farklı sensörler gerektirir, bu nedenle yeni uygulamalar ek sensörler gerektirecektir.

Her sensörün gözlem yeteneği ve algılama özellikleri birbirinden farklıdır. Şekil 3.19'da gösterildiği gibi, aracın farklı noktalarında birçok ADAS teknolojileri bulunmaktadır. Örneğin, ADAS fonksiyonlarının işlevlerinden birini temsil eden lidar, radar veya görüş algılama gibi yöntemler aracın güvenli bir şekilde yol alabilmesine katkı sağlar (Shaout vd., 2011). Bu sistem, kritik sürüş koşullarında sürücüyü uyarır ve aktif olarak destekler ve gerekirse bir kazayı önlemek için otomatik olarak müdahale eder (Lu vd., 2005).















Şekil 3.19. Destekli sürüş için mevcut teknolojiler

3.12. Otonom Araç Sürüş Seviyeleri

Sürücülerin devreden çıkarılması, sürücü hatalarını azaltabilir, hatta ortadan kaldırabilir, bu da daha güvenli yollara yol açabilir. Sürücüsüz otomobiller, sürüş asistanı teknolojilerin gelişmesiyle kaza durumları en aza indirgenmiştir. Google'ın sürücüsüz otomobili binlerce kilometreyi kazasız bir şekilde geçtiği bilinmektedir ve birçok ülke şu anda sürücüsüz otomobillere izin veren yasaları değiştirmeye hazırlanmaktadır (Diels ve Bos, 2016).

Kilitlenmeyi önleyici frenler (AEB) ve ileri çarpışma uyarısı (FCW), şerit takip asistanı (LKS), şerit değiştirme asistanı (LCA) ve adaptif hız sabitleyici (ACC) dahil olmak üzere otomatik araç teknolojilerinin birkaç örneğidir (Diels ve Bos, 2016).

Society for Automotive Engineers (SAE, 2018) tarafından oluşturulan taksonomiye göre, özellikle de en popüler fikir olan otonom sürüş, otomobiller ve metrolar gibi raylı sistemler dahil olmak üzere ulaşım sektörünün her alanında kullanılabilir hale gelecektir. Şekil 3.20, otonom sürüş seviyelerini göstermektedir.

	S0	S1	S2	S3	S4	S5
Sürücü	<p>OTOMASYON YOK</p>  <p>Tüm sürüşten sorumlu</p>	<p>SÜRÜCÜ YARDIMI</p>  <p>Bazı durumlarda bazı temel yardımlarla tüm sürüşü yapmalı</p>	<p>KISMI OTOMASYON</p>  <p>Araç bazı temel sürüş görevlerini üstlendiğinde bile tetikte kalmalı</p>	<p>KOŞULLU OTOMASYON</p>  <p>Kendi kendine sürüş sistemleri devam edemediğinde belirli bir süre zarfında devralmaya hazır olmalı</p>	<p>YÜKSEK OTOMASYON</p>  <p>Kendi kendine sürüş sistemleri devam edemediğinde bildirimde bulunarak sürüşü devralabilecek bir yolcu olabilir</p>	<p>TAM OTOMASYON</p>  <p>İnsan sürücü gerekmez -direksiyon isteğe bağlı- Herkes 5. seviye bir araçta yolcu olabilir</p>
Aracı	<p>Sadece sürücüden gelen girdilere yanıt verir ama çevreyle ilgili uyarılar verebilir</p> 	<p>Otomatik acil frenleme veya şerit tutuş desteği gibi temel yardım sunabilir</p> 	<p>Sınırlı durumlarda otomatik sürebilir, hızlanabilir ve fren yapabilir</p> 	<p>Belirli koşullar altında direksiyon, hızlanma ve frenleme üzerinde tam kontrol sağlayabilir</p> 	<p>Sürücü dikkati olmaksızın neredeyse her koşulda tüm sürüş görevlerini üstlenebilir</p> 	<p>Tüm sürüşten sorumludur ve insan müdahalesine ihtiyaç duymadan tüm ortamlarda çalışabilir</p> 


Şekil 3.20. Otonom sürüş seviyeleri

3.13. ADAS Teknoloji Tabanlı Sensörler

ADAS teknolojisi, araçla ilgili fiziksel özellikler, çevredeki faktörler ve sürücü hakkında bilgi toplamalıdır (Sunehra ve Jhansi, 2015). Sensörler tarafından toplanmış verilere göre belirli ADAS işlevleri aşağıda sunulmaktadır.

3.13.1. İleri Çarpışma uyarısı

İleri Çarpışma Uyarısı (FCW) sistemi, sürücüye arkadan çarpışmayı önleme veya hafifletme konusunda yardımcı olmayı amaçlayan sesli, görsel ve/veya dokunsal uyarılar sağlar. FCW sistemleri, radar, lidar (lazer), kameralar ve diğer teknolojiler aracılığıyla araçları algılayabilir. FCW sistemi, düzeltici eylem yapılmadığı takdirde başka bir araçla çarpışmanın yakın olabileceği konusunda sürücüyü uyarır. Şekil 3.21’de İleri Çarpışma Uyarısı (FCW) sistemi görülmektedir.



Şekil 3.21. İleri çarpışma uyarısı (FCW) sistemi

3.13.2. Kilitlenmeyi önleyici fren

Kilitlemeyi önleyici fren (AEB) teknolojisi, oldukça kompleks ve akıllı bir sistemdir. AEB sistemi bazen Otomatik Acil Durum Freni (OADF) veya Otomatik Frenli Çarpışma Uyarısı (OFÇU) olarak da adlandırılır. Her iki isim de otomobil üreticisine göre değişir, ancak ana fikir aynıdır. Sürücü müdahalesi olmadan bu sistem otomatik olarak frenleme gücü uygulayabilir. AEB, aracın önündeki alanı sürekli olarak izler. Sistemler ciddi bir çarpışma olasılığını fark ettiğinde, sürücü fren yapmaya başlaması için uyarılır ve frenler önceden etkinleştirilir. Bazen, mümkün olduğunca uzun bir fren mesafesi kazanmak için az miktarda frenleme gücü kullanılır. Sürücü önemli bir mesafede frenlemeye başlamazsa, sistem aracı durdurur veya hızını düşürür ve kaza olasılığını azaltır (Coelingh vd., 2010).

Arkadan çarpmaların çoğu düşük hızda olur. Bir aracın arka tarafını izlemek için üreticiler uzun menzilli radar (radyo algılama ve aralık belirleme) veya kısa menzilli lidar (ışık algılama ve aralık belirleme) sensörleri kullanmaktadır.

Kısa menzilli lidar daha ucuzdur ve 50 km/saate kadar hıza ulaşır. Uzun menzilli radar sensörü, kritik durumları algılayabildiği ve 200 km/saate kadar hızlarda çalışabildiği için uyarlanabilir hız sabitleyici için gereklidir. Kontrol ünitesi bu sensörlerden gelen verileri yorumlar ve uygun eylemleri yapar (Coelingh vd., 2010).



Şekil 3.22. Kilitlemeyi önleyici fren (AEB) teknolojisi

3.13.3. Adaptif hız sabitleyici

Adaptif Hız Sabitleyici (ACC), sürücülerin gaz veya fren pedallarını kullanmadan hızlarını ve öndeki araçla arasındaki mesafeyi ayarlamalarını sağlayan basit bir sistemdir. Bu, sürücünün beklenmedik bir tehlikeye geç tepki vermesi veya paniğe kapılması nedeniyle kazaya neden olmasının bir sonucu olabilir. Kötü hava koşulları, ACC sistemlerinin ilk versiyonları üzerinde önemli bir etkiye sahipti. Ayrıca ıslak veya yansıtıcı olmayan zeminlerde öndeki aracın hızını ve konumunu algılamada sorunlar yaşadı. Bu nedenle, günümüzde çoğu ACC sistemi Uzun Menzilli Radar kullanımına sahiptir. Bu radar, yansıtıcı olmayan araçları daha geniş bir hava koşulları aralığında tanıyabilir. Normal Uzun Menzilli Radar 200 metreye kadar görür ancak sınırlı bir aralıktadır.

Otomobil üreticileri, daha uzun mesafeleri kapsamak için Uzun Menzilli Radar (LRR) ve Kısa Menzilli Radar (SRR) veya ikisini birleştiren optik bir sistem kullanırlar.

Düşük hızlarda boşluklar daha küçük olduğundan, daha uzun bir menzil gereklidir. Başka türler de dahil olmak üzere, bir araç otomatik olarak tamamen duramaz ve yolculuğuna devam edemez. Bu tür ACC sistemleri, 50 km/sa ile 200 km/sa arasında hızlanabilen dur ve kalk özelliğini desteklemeyen daha ucuz sistemlerden oluşur. Daha gelişmiş ACC sistemleri, düşük hızda çalışan ve daha kesin sonuçlar üreten kısa menzilli ultrasonik sensörlere sahiptir. Trafik sıkışıklığında yavaş sürüş gibi durumlarda, bu sistemler sürüş sırasında otomatik olarak durabilir ve devam edebilir (Viktorová ve Šucha, 2019).




Şekil 3.23. Adaptif hız sabitleyici (ACC) teknolojisi

3.13.4. Şerit takip asistanı ve şerit değiştirme asistanı


Şerit Takip Sistemi (LKS) ve Şerit Değiştirme Asistanı (LCA) sistemleri, özellikle ana yollarda ve otoyollarda yüksek hızlı çarpışmaları azaltmak ve yoldan çıkma kazalarını önlemek için geliştirilmiştir. Bu sistemler, beyaz çizgiler olmak üzere yol üzerindeki işaretleri optik olarak tanıır. Bu sistemler, optik tanımanın bir sonucu olarak yol

iřaretlerinin kalitesine ve hava kořullarının etkilerine karřı hassastır. Bu nedenle, yoęun yaęmur, kar veya guneřten kaynaklanan ařırı parlama durumunda bir hata yapma olasılıęı yuęsektir.

LKS, sũrũcũyũ řeritten ıkmaya bařlama konusunda uyararak kalmayan, aynı zamanda aracın yũnũ kontrol etmek iin direksiyonu evirebilen proaktif bir sistemdir. Bu, sũrũcũ tũm dikkatini vermedięinde kaza olasılıęını azaltır. ok fonksiyonlu monokũler veya ok fonksiyonlu stereo kameralar, otomobillerde yaygın olarak kullanılan sensũrlerdir. Stereo kamera, u boyutlu nesnelere, řeritlere ve hatta engelleri tanıyabilir (Lu vd., 2005). řerit Takip Sistemi (LKS) teknolojisi ve řerit Deęiřtirme Asistanı (LCA) řekil 3.24 ve 3.25'te gũsterilmektedir.



řekil 3.24. řerit takip sistemi (LKS) teknolojisi



Şekil 3.25. Şerit Değişirme Asistanı (LCA) teknolojisi

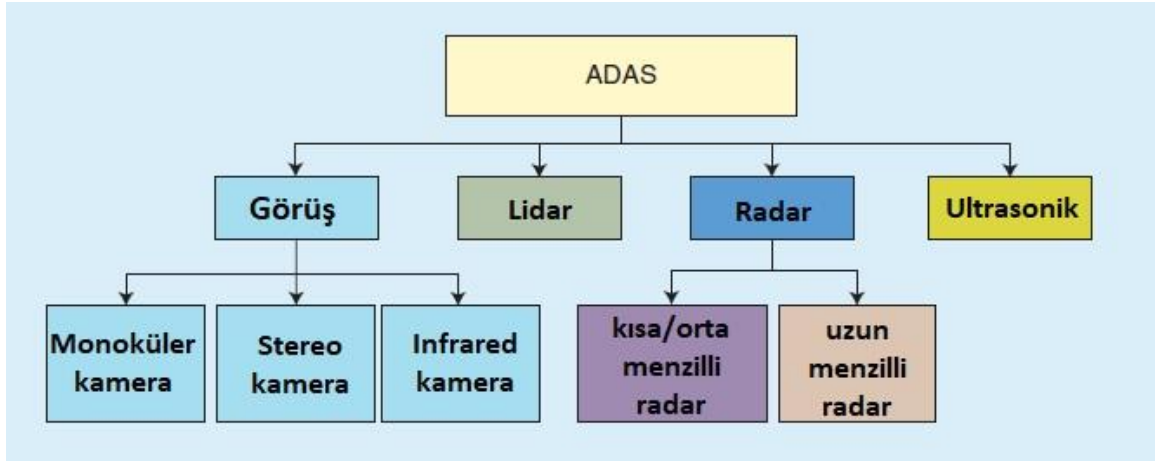
3.14. Otomotiv Güvenlik Sistemlerinde ADAS Teknolojisinde Kullanılan Sensörlerinin Uygulamaları

Son yıllarda otomobil sistemlerinin güvenliğini sağlamak oldukça önemli bir hale gelmiştir. Bu durumu çözmek için birçok Orijinal Ekipman Üreticisi (OEM), hem araç içindeki yolcuları hem de araç dışındaki insanların yaralanmasını önlemek için çeşitli güvenlik sistemleri geliştirmiştir. Bu sistemler iki kategoriye ayrılır: Aktif (proaktif) veya pasif (reaktif). Pasif güvenlik sistemleri; emniyet kemerleri, hava yastıkları ve yumuşak malzemeden üretilen gösterge panelleri gibi araç içindekileri bir kaza sonucunda yaralanmalardan korur. Tüketicilerin sürekli olarak daha güvenli araçlara olan talebi nedeniyle günümüz araçlarında aktif sistemler önemli ölçüde gelişmiştir.

Şerit takip, otomatik frenleme ve adaptif hız sabitleyici bu tür sistemlerden bazılarıdır. Bu sistemler, ADAS teknolojileri olarak bilinir ve otomobil üreticilerinin müşteri güvenliğini teşvik etmenin bir yolu olarak giderek daha popüler hale gelmesi beklenmektedir.

Dünya Sağlık Örgütü'nün son araştırmalarına göre, karayolu kazalarında yılda 1,25 milyon insan hayatını kaybetmektedir (Zambon vd., 2010). OEM'ler, yüksek ölüm oranları, mali kayıplar ve akıllı güvenlik sistemlerine yönelik artan talep nedeniyle ADAS teknolojilerini geliştirmeye başlamışlardır. Ek olarak, elektronik kontrol ünitelerinin artması ve çeşitli sensör türlerinin birleştirilmesi nedeniyle artık araçlarda ADAS teknolojilerini desteklemek için yeterli bilgi işlem kapasitesi mevcuttur. Birçok farklı ADAS teknolojisi; lidar, radar, kamera ve ultrasonik sensörler gibi çeşitli sensörlerin kullanılmasıyla mümkündür. Görüş tabanlı ADAS, kameraları görüş sensörleri olarak kullanan günümüz araçlarının çoğunda popülerdir. Şekil 3.26, son teknoloji ADAS özelliklerinin ve uygulanması için kullanılan sensörlerin bir listesini göstermektedir.

Günümüzde ADAS otonom araçlar için kritik teknolojilerdir. Bununla birlikte, ADAS'ların tasarımı, uygulanması ve işletilmesi sırasında karşılaşılan çeşitli zorlukların aşılması gerekmektedir. Bu zorluklardan bazıları olumsuz ve değişken hava koşullarına uyum sağlamak ve bu zorlu çevre koşullarında oluşabilecek potansiyel kazaların sayısını en aza indirgeyerek güvenliği sağlamaktır.



Şekil 3.26. ADAS teknolojisi taksonomisi

3.14.1. Radar sensörünün otomotivdeki uygulamaları

Radar, elektromanyetik (radyo) dalgaları kullanarak sabit nesnelerin mesafesini ve hareketli nesnelerin hızını ölçer. Radarlar 22-29 GHz ve 77-81 GHz'de kullanılır. Bunlar aşağıdaki gibidir:

- Kısa menzilli ve geniş açılı (tipik olarak 50 m'ye kadar, 130 derece görüş alanı).
- Orta menzilli ve geniş açılı (tipik olarak 100 m'ye kadar ve 30 dereceden fazla görüş alanı).
- Uzun menzilli ve dar açılı (tipik olarak 100 m ve 20 dereceden az görüş alanı).

Otomobil radarlarının hepsi Doppler tipidir. AEB veya ACC radar sensörleri genellikle iki verici ve dört alıcı veya bir verici ve iki alıcı olarak kullanılan daha ucuz alternatiflerdir (Zolock vd., 2016).

3.14.2. Lidar sensörünün otomotivdeki uygulamaları

Lidar'ın çalışma prensibi radarın çalışma prensibinin temeline dayanır, ancak iletilen bir lazer ışını yansıyan bir ışık olarak gönderir. Sürüş esnasında yaşanabilecek potansiyel tehlike esnasında aracın hızını ve önündeki nesnenin mesafesini ölçmek için benzer şekilde kullanılabilir, ancak düşük hızda görüş menzili 10 ila 20 metre arasında olabilir. 850 veya 900 nm dalga boyu olduğu için lidar, radardan daha kısa etkili menzile sahiptir. Lidar'lar, ACC teknolojisinde ilk olarak boyut olarak küçük oldukları için sensör olarak kullanılmıştır. Günümüzde, yüksek fiyat ve düşük çözünürlük nedeniyle tartışmalı da olsa radar veya kameralarla yer değiştirilmektedir (Vlacic vd., 2001). Örnek bir lidar Şekil 3.27'de gösterilmektedir.



Şekil 3.27. Lidar (Vlacic vd., 2001)

3.14.3. Ultrasonik mesafe sensörünün otomotivdeki uygulamaları

Ultrasonik sensörler, nispeten yakın mesafedeki bir nesnenin mesafesini ölçmek için ultrason dalgalarının yansımalarını kullanarak radara benzer. Belirli bir frekansta bir ses dalgası gönderir ve ardından ses dalgasının geri dönüşünü bekler. Bu, mesafenin ne kadar uzun olduğunu hesaplamak için yapılır. Bir sensör ile algılanan nesne arasındaki mesafeyi ($\text{mesafe} = \text{hız} \times \text{zaman}$) ve kaydedilen ses dalgası ile geri dönen ses dalgası arasında geçen süreyi bulmak için bir yöntem vardır. Araçlarda kullanılan ultrasonik sensör Şekil 3.28’de gösterilmektedir (Zolock vd., 2016).



Şekil 3.28. Ultrasonik mesafe sensörü

3.14.4. Optik kamera sensörlerinin otomotivdeki uygulamaları

Monoküler ve stereo kameralar gibi optik veya görüş sistemleri, bazı durumlarda araç çevresinde yaşanabilecek olası tehlikeleri etkili bir şekilde haritalamak için kullanılabilir. Çevreyi ölçmek için kullanılan kamera sistemlerinin insan görüşünde olduğu gibi avantaj ve dezavantajları vardır. Düşük güneş açısı, yoğun yağış ve sis gibi çevresel faktörler kamera sistemlerini potansiyel bir tehlikenin göreceli hızını doğrudan algılayamaz. Sonuç olarak, radar sensörleri ile birlikte kullanıldıklarında, radarın sınırlı açısal çözünürlüğünü ve görüş alanını tamamlarlar. Stereo kameralar, tehlikenin uzaklığını hesaplamak için kullanılabilir. Kameralar tipik olarak 100 metreden daha kısa mesafeleri algılayabilir. Modern görüntü işleme teknikleri ve özel görüntü işleme donanımı sayesinde, aracın çevresindeki nesnelere gerçek zamanlı olarak tanımlamada çok etkili olan kamera sistemleri geliştirilmiştir. Bir görüntü sistemi mükemmel yanal tahminler yapabilir, ancak uzunlamasına parametrelerin tahmininde yetersiz kalabilir. Sürücülerini izlemek için kameralar kullanılabilir. Baş hareketleri ve göz kırpması hızı bu kameralar tarafından kaydedilir. Sistem, sürücünün bu bilgilere tam olarak odaklanmadığını ve bu nedenle durması gerektiğini anlayabilir (Zolock vd., 2016).

Çizelge 3.2, radar, lidar, ultrasonik mesafe sensörü ve kameraların temel teknolojilerinin çevre algısı için temel özelliklerinin bir özetini içerir. Bu, kameranın nesnelere tek başına tespit edemediği bir durumdur, ancak görüntü işleme algoritmalarına bağlıdır. Görüldüğü gibi, bu teknolojilerin hiçbiri ideal değildir ve en iyi sonuçları elde etmek için iki veya daha fazla teknolojiyi birleştirmek akıllıca bir yaklaşımdır. Bu sebeple bu tezde bazı ADAS teknoloji sensörlerinin füzyonuna yer verilmiştir.

Çizelge 3.2. Çevresel algı için ana teknolojilerin karşılaştırılması

Kriter	Radar	Lidar	Kamera	Ultrasonik
0-1 m	Sadece SRR	Zayıf	Çok iyi	Çok iyi
0-30 m	Çok iyi	Çok iyi	İyi	Zayıf
30-100 m	Çok iyi	Orta	Zayıf	Hayır
Açı (<10 °)	İyi	Çok iyi	İyi	Zayıf
Açısal Çözünürlük	İyi	Çok iyi	İyi	Zayıf
Hız Ölçümü	Evet	Hayır	Hayır	Hayır
Kötü hava koşullarındaki performans	Çok iyi	Zayıf	Zayıf	İyi
Gece görüşü	Çok iyi	Çok iyi	Limitli	Çok iyi

3.15. Sensör Füzyonu

Günümüzde birçok araç üreticisi, gelişen teknoloji ile birlikte ilgili standartlara göre uygun güvenlik seviyesini sağlamak için birçok sensör kullanmaktadır. Ayrıca rekabet artıkça, otomotiv üreticileri araçların güvenlik seviyesini artırarak değişen pazar koşullarına uyum sağlamak zorundadırlar. Bu zorunluluk sensörlerin füzyon edilmesi konusunu oldukça önemli bir hale getirmektedir. Algılama belirsizliklerinin sayısını azaltmak ve bağımsız çalışan sensörlerin eksikliklerinin üstesinden gelmek için birden fazla algılama yönteminden elde edilen verileri birleştirir. Ek olarak, sensör füzyonu, farklı çevresel koşullarda çevreyi doğru bir şekilde algılayabilen tutarlı bir model oluşturmaya yardımcı olur. Örneğin, algılanan sahnede tespit edilen engellerin göreceli hızları ve yüksek çözünürlüklü görüntüler, radar ve kamera füzyonu kullanılarak sağlanabilir.

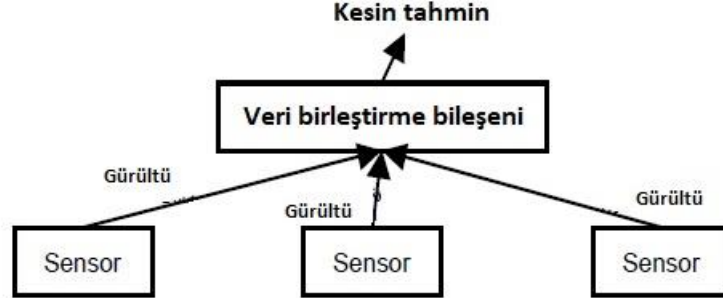
Bir aracın otonom olarak çalışması için öncelikle çevresini algılaması, sensörden gelen bilgileri işleme ve doğru kararlar vermesi gerekir. Bu algılama, işleme ve harekete geçme zincirinde dış çevre, kamera, radar ve lidar gibi sensörler tarafından algılanır. Bu sensörler, çevre sensörleri olarak da adlandırılabilir. Karar verme bloğuna bilgi sağlamak için çevre sensörleri ve aktüatörler gibi diğer sensörler de önemlidir. Örneğin, bir otomobilin çevre bilgileriyle birlikte direksiyon simidi açısı ve tekerlek hızı, doğru karar vermek için çok önemlidir. Bu nedenle sensörleri genel olarak aşağıdaki üç gruba ayırabiliriz.

Çevre sensörleri, bir aracın dış veya iç yüzeyine yerleştirilir ve çevre hakkında bilgi verir. Örnek olarak çevre sensörleri arasında radar, lidar, ultrasonik mesafe, kızılötesi kamera, IMU, GPS ve dijital harita gibi sensörler yer alır.

Araç odometri sensörleri araçların hareketini kaydeder. Örnek olarak, tekerlek hızı, ivme, sapma oranı, direksiyon simidi açısı ve diğer faktörlerden bahsedilebilir.

Aktüatörler, insan ve makine eylemlerini yönlendiren sensörlerdir. Kısıtlama aktüatörleri, tekerlek yayları, motor torkları bunlardan bazılarıdır.

Otomobil üreticileri, lidar, radar, kamera ve ultrasonik gibi çeşitli sensörler kullanarak aktif güvenlik özellikleri sağlar. Bunlar arasında ACC (Adaptif Hız Sabitleyici), LKA (Şeritte Kalma Yardımcısı), kör nokta algılamaları, ileri çarpışma uyarısı ve son zamanlarda AEB (Kilitlemeyi Önleyici Frenler) gibi en önemli ADAS fonksiyonları bulunmaktadır. Yakın zamanda sektör, lidar ve uydu bilgileri, araç ve altyapı (V2V ve V2X) gibi daha fazla sensör ve bilgi kullanarak bu güvenlik özelliklerinin güvenilirliğini artırmıştır. Bu sensörler tarafından sağlanan veriler büyük ölçüde tutarlıdır ve güvenilirlik dereceleri de değişmektedir. Örneğin, bir nesnenin uzaklığını belirlemek için hem kamera hem de radar sensörleri kullanılabilir, ancak radar sensöründen alınan bilgi kameradan daha güvenilirdir. Otonom sürüş sistemleri, Şekil 3.29'da gösterildiği gibi füzyon sürecini kullanarak güvenli bir karar vermek için çeşitli sensörlerden gelen bilgilerin iyi bir şekilde örtüşmesini gerektirir.



Şekil 3.29. Füzyon işleminin temelleri

Aşağıdaki Çizelge 3.3, algı tabanlı sensörlerin araçlarda yaygın olarak kullanılan teknik özelliklerine ve hava ve aydınlatma gibi diğer dış faktörlere dayalı olarak güçlü ve zayıf yönlerini niteliksel olarak özetlemektedir. Tik işareti; ilgili sensörün belirli şartlar altında veya belirli ADAS fonksiyonu durumlarında iyi bir şekilde performans göstereceğini belirtir. Tilda (~) işareti ise; ilgili sensörün belirli şartlar altında veya belirli ADAS fonksiyonu durumlarında orta düzeyde performans göstereceğini belirtir.

Ancak sensöre tam anlamıyla güvenmek yerine sensör füzyonunda bir birleşim elemanı olarak kullanmak gereklidir. Çarpı işareti ise, sensörün bu durumda uygun performans göstermeyeceği anlamına gelmektedir.

Çizelge 3.3. Belirli parametreler için sensör füzyonu kıyası

Parametreler	Kamera	Lidar	Radar	Füzyon
Menzil	~	~	✓	✓
Çözünürlük	✓	~	x	✓
Mesafe Doğruluğu	~	✓	✓	✓
Hız	~	x	✓	✓
Renk Algısı (Trafik Işıkları)	✓	x	x	✓
Nesne Tanıma	~	✓	✓	✓
Nesne Sınıflandırma	✓	~	x	✓
Şerit Takip	✓	x	x	✓
Engel Algılama	✓	✓	x	✓
Aydınlatma Koşulları	x	✓	✓	✓
Hava Koşulları	x	~	✓	✓

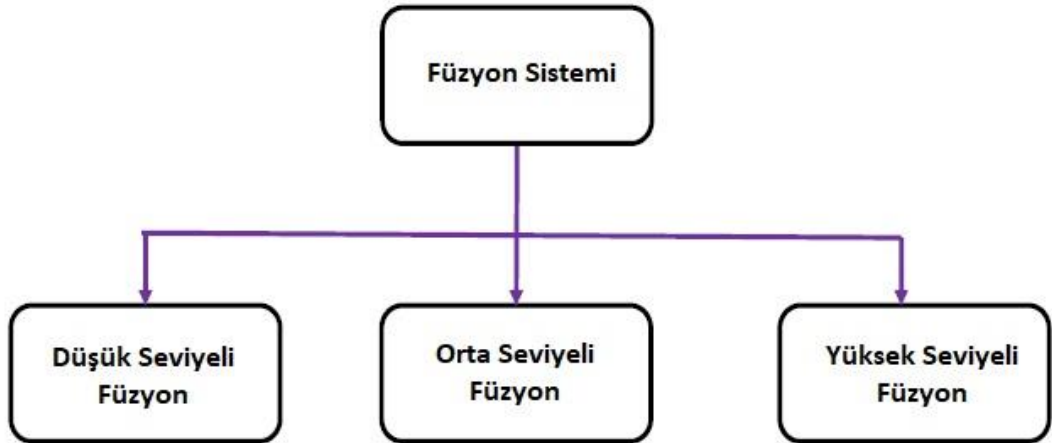
Çoklu sensör füzyon sistemleri kullanılarak çevre algısı ve nesne tespiti, hızla gelişen teknoloji ile birlikte otomotiv teknolojisinde yaygınlaşması beklenen bir konudur. Engel tespiti için şu anda literatürde üç ana sensör kombinasyonu bulunmaktadır: Kamera-Lidar (CL), Kamera-Radar (CR) ve Kamera-Lidar-Radar (CLR).

(Wang vd., 2020) tarafından aktarılan bir araştırma, çoklu sensör füzyon sistemlerinde çevre algısı için en yaygın CR sensör kombinasyonunun kullanıldığını göstermiştir. CLR ve CL ikinci sırada gelir. CR sensörleri yüksek çözünürlüklü görüntüler sunarken, çevredeki engellerin hız ve mesafe bilgilerini de elde eder. Örneğin, Tesla, aracın çevresini algılamak için CR sensörleri ve ultrasonik sensörler gibi diğer sensörleri kullanmaktadır. Benzer şekilde, CLR sensörlerin kombinasyonu, lidar nokta bulutları ve derinlik haritası verilerini kullanarak daha geniş bir aralıkta çözünürlük sağlayabilir ve

çevreyi tam olarak anlayabilir. Bu, genel otonom sistemin güvenliğini artırır. Örneğin, Waymo ve Navya araçlarda CLR sensörleri çevre algılama için kullanılmıştır.

3.16. Sensör Füzyonu için Yaklaşımlar

Yüksek seviyeli füzyon (HLF), düşük seviyeli füzyon (LLF) ve orta seviyeli füzyon (MLF) (Banerjee vd., 2018), MSDF (Çoklu Sensör Veri Birleştirme) çerçevelerinde çeşitli algılama modalitelerinden gelen duyuşsal verileri birleştirmek için üç temel yaklaşım vardır. HLF yaklaşımında, her sensör kendi nesne algılama veya izleme algoritmasını kullanır ve ardından füzyon yapar. Örneğin, (Shahian Jahromi vd., 2019) referansında, işlenmiş verileri (radar sinyallerini ve lidar nokta bulutlarını) bağımsız olarak birleştirmek için HLF yöntemi kullanılmıştır. Daha sonra, yol takibi ve engelleri belirlemek için doğrusal olmayan bir Kalman filtresi yöntemi kullanılmıştır. HLF ve LLF yaklaşımlarına göre daha düşük göreceli karmaşıklık nedeniyle HLF yaklaşımları sıklıkla tercih edilmektedir. Ancak, HLF yaklaşımının yetersiz bilgi sağlaması durumunda çok sayıda engel üst üste bindiği için daha düşük güven değerine sahip sınıflandırmalar seçilir.



Şekil 3.30. Füzyon sistemlerinin sınıflandırılması

LLF yaklaşımı, bunun aksine, her bir sensörden gelen verileri en düşük soyutlama seviyesinde birleştirir veya entegre eder. Sonuç olarak, tüm veriler korunur ve bu da engel tespitinin doğruluğunu artırabilir. (Yoo vd., 2020) üç boyutlu engel algılama için iki aşamalı bir yaklaşım olan 3B-çapraz görünüm füzyonu (3B-CVF) önermektedir. İkinci aşamada, 3B ilgi bölgesi (RoI) tabanlı bir havuzlama yöntemi kullanarak, ilk aşamadan elde edilen ortak kamera-lidar özellik haritasını düşük seviyeli kamera ve lidar özellikleriyle birleştirmek için LLF yaklaşımı kullanılmıştır. Önerilen yöntemi KITTI ve nuScenes veri kümeleri üzerinde test edilmiş ve KITTI liderlik tablosunda bulunan en gelişmiş 3B nesne algılayıcılardan daha iyi olduğu keşfedilmiştir. LLF yaklaşımının uygulaması konusunda çok sayıda zorlukla karşılaşmaktadır. Çevre algılamalarını doğru bir şekilde birleştirmek için sensörlerin dışsal kalibrasyonunu hassas bir şekilde yapmak gerekir. Ek olarak, sensörler zamansal olarak kalibre edilmeli ve ego hareketini (bir sistemin ortam içindeki 3B hareketi) dengelemelidir (Banerjee vd., 2018).

Sensör füzyonu, lidar ve radarın konum bilgileri gibi ilgili sensör verilerinden (ham ölçümler) renk bilgilerini birleştirir ve ardından birleştirilmiş çoklu sensör özelliklerini tanımlar ve sınıflandırır. Sınırlı iletişim kapasitesine sahip dinamik bir arka plan ortamında hedefleri belirlemek için özellik düzeyinde bir sensör füzyon çerçevesi, (Yue Li vd., 2015) tarafından önerilmiştir. Bu öneride, birkaç kızılotesi sensörden düşük boyutlu özellikleri çıkarmak için Sembolik Dinamik Filtreleme (SDF) algoritmasını kullanılmıştır.

3.17. Sensör Füzyon Teknikleri ve Algoritmaları

Son yıllarda, sensör füzyon teknikleri ve algoritmaları kapsamlı bir şekilde araştırılmıştır ve literatürde kapsamlı bir yere sahiptir. Bununla birlikte, yakın zamanda yapılan bir çalışma (Brena vd., 2020), literatürde önerilen füzyon algoritmalarının çok disiplinli ve çeşitli olması nedeniyle, mevcut en son füzyon tekniklerini ve algoritmalarını elde etmenin zorlu ve zorlu bir görev olduğunu göstermiştir. (Fayyad vd., 2020), klasik sensör füzyon ve derin öğrenme sensör füzyon algoritmaları olarak iki kategoriye ayırmıştır. Bir yandan, bilgi tabanlı yöntemler, istatistiksel yöntemler ve olasılıksal yöntemler gibi klasik

sensör füzyon algoritmaları, sensör verilerini birleştirirken yanlışlık ve belirsizlik gibi teoriler kullanır. (Ali vd., 2020), nesnelere bulmak için önerilen bir "lazer simülasyonu" ve bilgi tabanlı Bulanık Mantık (FL) algoritmasının bir kombinasyonunu kullanan gerçek zamanlı bir döner kavşak algılama ve navigasyon sistemi önermektedir.

Ayrıca, derin öğrenme sensör füzyon algoritmaları, otonom araçlar için kentsel bir ortamda nesne algılama gibi zorlu ve akıllı görevleri yerine getirmek için çeşitli çok katmanlı ağlar oluşturmak için ham verileri işlemelerini ve özellikleri çıkarmalarını sağlar. Evrimsel Sinir Ağı (CNN) ve Tekrarlayan Sinir Ağı (RNN) gibi algoritmalar, sanal gerçeklik (AR) algılama sistemlerinde en çok kullanılanlardır. (Kim vd., 2019), You Only Look Once (YOLO) olarak bilinen bir ağırlıklı ortalama CNN algoritmasını, RGB kamera ve lidar nokta bulutu verilerini birleştirerek nesne algılamanın gerçek zamanlı performansını artırmak için geliştirmiştir. YOLO dedektörü ilk olarak 2016 yılında kuruldu ve son yıllarda çok gelişti (Redmon vd., 2016). Sınırlayıcı kutuları tahmin eder ve tek bir sinir ağında (yalnızca bir değerlendirme için) güven puanları ve sınıf olasılıkları oluşturur. YOLO tabanlı model, VOC (Görsel Nesne Sınıfları) 2007 veri kümesi için %59,2 ortalama hassasiyetle (AP, nesne algılama veya bilgi alma modeli performanslarını ölçen bir değerlendirme ölçütü) 45 FPS'lik hızlı algılama hızı sağlar (Redmon vd., 2016). Ek olarak, YOLOv4, bir NVIDIA® Tesla® V100 Grafik İşlem Birimi (GPU) üzerinde %43,5 AP (ve %65,7 AP50-IoU %50'nin üzerinde) ve yaklaşık 65 FPS MS COCO veri kümesinde gerçek zamanlı hızda son teknoloji ürünü sonuçlar sağlar. (Lee vd., 2018)'da yazarlar, yakın kızılötesi ışık ve termal kameralar kullanarak duyguları kullanarak agresif sürüş davranışlarını belirlemek için CNN tabanlı bir teknik önermişlerdir. Tespit doğruluğunu artırmak için, yakın kızılötesi ışık görüntülerinden ve termal görüntülerden elde edilen CNN çıktı puanlarını kullanarak puan düzeyinde füzyon gerçekleştirmişlerdir. Önerdikleri yöntem, duyguların yüksek bir sınıflandırma doğruluğuna ulaşmış ve geleneksel yöntemlerden daha iyi duygu tespiti sağladığını göstermiştir.

Buna ek olarak, 3 boyutlu sensörlerin ve çevredeki araçların 3 boyutlu ortamını anlamaya yönelik çeşitli uygulamaların ortaya çıkmasıyla, 3 boyutlu nesne algılama üzerine çalışmalar yoğunlaşmaktadır. (Zhou ve Tuzel, 2018), daha önce önerilen VoxelNet

çerçevesini kullanarak RGB ve nokta bulutu verilerini 3B nesne algılama için birleştirmek için PointFusion ve VoxelFusion olarak bilinen iki özellik düzeyinde füzyon teknikleri sunmuştur. VoxelNet, özellik çıkarma ve sınırlayıcı kutu tahmin işlemlerini tek aşamalı, uçtan uca eğitilebilir bir derin ağda birleştiren genel bir 3B nesne algılama ağı olarak tanımlanmaktadır.

PointFusion, bilinen kalibrasyon matrisini kullanarak 3B noktaları bir görüntüye yansıtır. Ardından, önceden eğitilmiş bir 2B CNN'den görüntü özelliklerini çıkarır ve bunları nokta düzeyinde birleştirir. Daha sonra VoxelNet mimarisinden yararlanarak ortak özellikleri ve benzer noktaları birleştirir. Bununla birlikte, VoxelFusion yöntemi, VoxelNet tarafından oluşturulan boş olmayan üç boyutlu vokselleri (bir pikselin 3 boyutlu karşılığı) görüntüye yansıtırken, iki boyutlu ROI'lerde bulunan özellikleri çıkarır. Bu, voxel düzeyinde görüntü özelliklerini birleştirir.

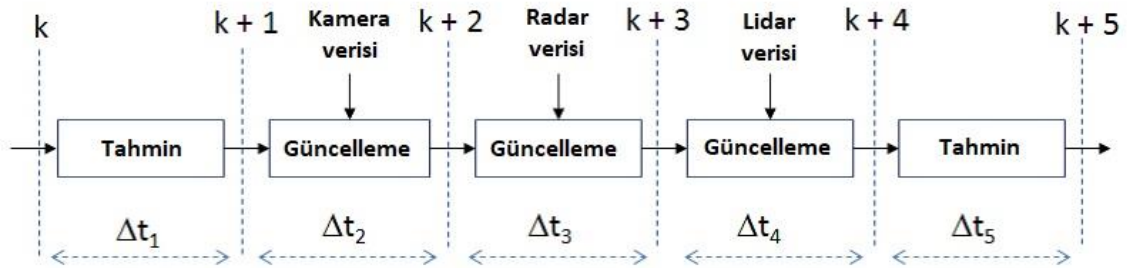
(Xu vd., 2018), 3B nesne tespiti için görüntü ve ham nokta bulutu verilerini kullanan bir PointFusion çerçevesi sağlar. Görüntü ve nokta bulutlarını bağımsız olarak işlemek için PointNet ve CNN mimarilerini kullanılmıştır. Ardından, çeşitli 3B kutu hipotezlerini ve bunlara ilişkin güvenilirlikleri tahmin etmek için elde edilen çıktılarını birleştirilmiştir. PointNet mimarisi, ham nokta bulutu verilerini işlemek için 3 boyutlu sınıflandırmadan sahne anlamsal ayrıştırmaya kadar çeşitli uygulamalar için birleştirilmiş bir mimari sunar. Başlıca derin öğrenme tabanlı sensör füzyon algoritması şunlardır:

Residual Networks olarak da bilinen ResNet, derin ağların eğitimini kolaylaştıran yeni bir öğrenme çerçevesidir (He vd., 2016).

Sınırlayıcı kutuları, özellik haritası konumu başına farklı boyutlara ve en boy oranlarına sahip bir dizi kutuya ayıran bir yöntemdir; bu, YOLO'nun değişken ölçekli nesne algılama doğruluğunun küçük ve değişken boyutlardaki nesnelere belirleme sınırlamasını ortadan kaldırır (Liu vd., 2016).

CenterNet sınırlayıcı kutuların merkez noktalarını bulmak için anahtar nokta tahmininden yararlanan son teknoloji bir monoküler kamera 3 boyutlu nesne algılama algoritmasını temsil eder (He vd., 2016). Bu algoritma, boyut, yönelim, poz ve 3 boyutlu konum gibi diğer nesne özelliklerine merkez noktalarını geriletir.

Sensör füzyonu yapılırken, düğümdeki nesnelere belirlemek için her sensörden gelen veriler bağımsız olarak işlenir ve ardından Kalman filtreleri kullanılır. Nesnelere, kamera, lidar ve radar verilerini kullanarak tespit edilebilir. Nesne tespitinin sensör verilerine zaten uygulandığı ve sensör füzyonu için en iyi tahminlerin hazır olduğu varsayılmaktadır. Gürültüye dayanıklı olmaları nedeniyle, Kalman filtreleri sensör füzyonu için yaygın bir seçimdir (Li vd., 2015). Ayrıca Kalman filtresi, bir nesnenin hareketini iki boyutlu veya üç boyutlu konum ve hız açısından simüle eden bir durum olarak tanımlanır. Farklı sensörlerden farklı zamanlarında veriler geldiğinde, takip edilen her nesnenin durumu tahmin edilir ve güncellenir. Şekil 3.31, yüksek seviye füzyonun temel akışı ile ilgili bilgileri göstermektedir.



Şekil 3.31. Kamera, lidar ve radardan alınan yüksek seviyeli nesne verilerinin Kalman filtresi ile tahmin edilmesi

3.17.1. Kalman filtresi

Tahmin ve güncelleme olmak üzere iki aşamadan oluşan Bayes filtreleri ailesinin bir parçası olan Kalman filtreleri (Thrun vd., 2005) 2B konum bilgisi P_x , P_y ve 2B hız bilgisi V_x , V_y gibi nesne parametrelerini modeller. Durum vektörü, sabit hız, ivme, dönüş hızı vb. nesne modeli seçimine bağlı olarak da modelleme yapılır. Denklem 3.13'de gösterildiği gibi, k+1 zamanında bir önceki nesne durumu x verildiğinde, durum geçiş

fonksiyonu F ile x 'in durumunu tahmin edebiliriz. Nesne kovaryansı P (Denklem 3.14) belirsizliği gösterir ve durum ortalama konum tahminini gösterir. Kalman filtreleri ayrıca durum geçiş gürültüsü u , süreç gürültüsü kovaryansı Q ve ölçüm gürültüsü kovaryansı R gibi gürültüyü modeller ve bunların hepsinin durum ve süreç kovaryansı üzerinde etkisi vardır. Bir sensörden alınan bir ölçümün H durumu, sensörün gerçek ölçüm değerine eşlik eder (Denklem 3.15). Gerçek ölçülen değer z ile tahmin edilen durum arasındaki farkı bulmak için Kalman kazancı K hesaplanır (Denklem 3.17). Daha sonra durumu (Denklem 3.18) ve süreç kovaryansını (Denklem 3.18) düzeltmek için kullanılır. Kalman filtresi nesneyi daha iyi takip edebilene kadar bu süreç tekrarlanır (Kalman, 1960).

Kalman filtresi tahmin denklemleri;

$$x' = Fx + u \quad (3.13)$$

$$P' = FPF' + Q \quad (3.14)$$

Kalman filtresi güncelleme denklemleri;

$$y = z - Hx' \quad (3.15)$$

$$S = HP'H^T + R \quad (3.16)$$

$$K = P'H^T S^{-1} \quad (3.17)$$

$$x = x' + Ky \quad (3.18)$$

$$P = (1 - KH)P' \quad (3.19)$$

Güncelleme adımı, sensör türüne (kamera, lidar veya radar) bağlı olarak değişir; tahmin adımı genellikle aynı kalır. Denklem 3.20'de gösterildiği gibi, kamera ve lidar kartezyen koordinat sisteminde veri sağladığından, ölçüm fonksiyonu doğrusal bir fonksiyondur.

Yine de radar, H'yi doğrusal olmayan bir fonksiyon haline getiren kutupsal koordinat sisteminde veri sağlar.

$$\begin{pmatrix} p_x \\ p_y \end{pmatrix} \xleftarrow{h(x')} \begin{pmatrix} p'_x \\ p'_y \\ v'_x \\ v'_y \end{pmatrix} \Rightarrow h(x') = \begin{pmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \end{pmatrix} \quad (3.20)$$

3.17.2. Genişletilmiş kalman filtresi

Beyaz gürültüden etkilenen verilerin normal dağılımına sahip olduğu varsayımı, standart Kalman süzgeci denklemlerini oluşturmak için kullanılmıştır. Radar verileri için ölçüm fonksiyonu H, kartezyen koordinatlardaki durumu p_x , p_y , v_x ve v_y kutupsal koordinatlara dönüştürür. Bu kutupsal koordinatlar, menzil, kerteriz ve radyal hızdır.

$$\begin{pmatrix} p \\ \phi \\ p' \end{pmatrix} \xleftarrow{h(x')} \begin{pmatrix} p'_x \\ p'_y \\ v'_x \\ v'_y \end{pmatrix} \Rightarrow h(x') = \begin{pmatrix} \sqrt{p_x'^2 + p_y'^2} \\ \arctan(p'_y / p'_x) \\ \frac{p'_x v'_x + p'_y v'_y}{\sqrt{p_x'^2 + p_y'^2}} \end{pmatrix} \quad (3.21)$$

Kalman Filtresi denklemleri, ölçüm fonksiyonu H doğrusal olmadığında geçersizdir. EKF yöntemi, doğrusal olmayan fonksiyonun doğrusal bir yöntemini kullanarak bu sorunu çözmek için çalışır. Denklem 3.22'de gösterildiği gibi, Taylor serisi açılımının birinci dereceden yaklaşımı, H_j (3x4) Jacobian matrisidir. Güncelleme denkleminde Jacobian H_j , ölçüm fonksiyonu H'yi değiştirir. Genel olarak kullanılan Kalman filtresinin kalan denklemleri aynıdır.

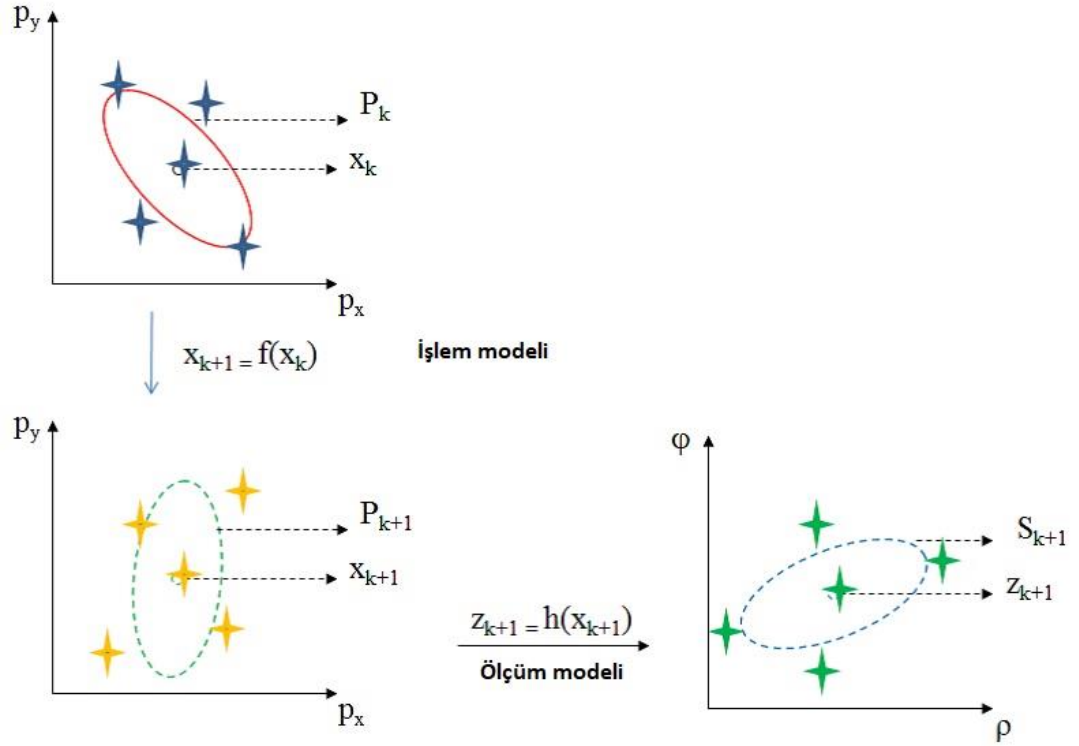
$$H_j = \begin{bmatrix} \frac{\partial p}{\partial p_x} & \frac{\partial p}{\partial p_y} & \frac{\partial p}{\partial v_x} & \frac{\partial p}{\partial v_y} \\ \frac{\partial \phi}{\partial p_x} & \frac{\partial \phi}{\partial p_y} & \frac{\partial \phi}{\partial v_x} & \frac{\partial \phi}{\partial v_y} \\ \frac{\partial p'}{\partial p_x} & \frac{\partial p'}{\partial p_y} & \frac{\partial p'}{\partial v_x} & \frac{\partial p'}{\partial v_y} \end{bmatrix} \quad (3.22)$$

Güvenli mesafe tutma özelliğine sahip otomatik seyir kontrolü uygulamaları genellikle genişletilmiş Kalman filtrelerini kullanır. Bu tür uygulamalarda, takip edilen nesnenin durumunu belirlemek için kullanılan yaygın modeller, sabit hız veya sabit ivme modelleridir.

Araçların kavşaklarda döndüğü kentsel koşullar veya otoyolda giden bir aracın bir çıkışa girmek için döndüğü durumlarda, sabit hız modeli gerçek ölçümleri aşacaktır. Bunun nedeni, dönüş sırasında aracın hızını düşürmesidir. Sabit Dönüş Hızı-Hız veya CTRV modeli bu tür durumlarda daha iyi çalışır.

3.17.3. Kokusuz kalman filtresi

Kokusuz Kalman filtresi, doğrusal olmayanlığı hesaplamak için sigma noktaları kullanır (Zhang vd., 2013). Şekil 3.32'de gösterildiği gibi, ortalama etrafında ve nesne durumunun kovaryans elipsi içinde seçilen N noktalardan oluşan bir küme, sigma noktaları olarak da bilinir. Tahmin adımını tamamlamak için bu noktaları durum geçiş fonksiyonu F 'den geçirdikten sonra yeni bir ortalama ve kovaryans bulunur. Güncelleme adımını tamamlamak için aynı sigma noktaları tekrar kullanılır ve yeni bir ortalama ve kovaryans üreten ölçüm fonksiyonu H 'den geçirilir.



Şekil 3.32. Sigma noktalarını kullanarak, doğrusal olmayan durum geçiş fonksiyonu $f(x)$ ve ardından ölçüm fonksiyonu $h(x)$ üzerinden geçerek $k+1$ 'deki durumu tahmin edilmesi

3.18. Güvenli ve Güvenilir Çevre Algısı için Sensör Füzyonunun Zorlukları

Kuşkusuz, derinlemesine araştırmalara dayanan çoklu sensör füzyon teknolojileri, insansı robotlardan otonom araçlara kadar uzanan otonom sistemlerde önemli faydalar sağlamıştır. Bu sistemler genellikle saatte çok sayıda veri üretebilen birkaç sensör içerir. Örneğin, bir otonom araç saati 383 GB'tan 5,17 TB'a kadar veri üretebilir. Sonuç olarak, bu bilgileri işlemek için çok sayıda hesaplama gücü gerekir. (Liu vd., 2017), SAE Seviye 4 otonom aracın bilgi işlem platformu uygulamasını ve otonom sürüş için mevcut birkaç işleme çözümünü incelemiştir. Ek olarak, güvenli, modüler, dinamik, enerji tasarruflu ve yüksek performanslı bir otonom sürüş bilgi işlem mimarisi ve yazılım paketi sunulmuştur.

Bir ARM Mobil Çip Üzerinde Sistem (SoC) kullanan bir mobil araç, tipik olarak 11 Watt (W) güce sahiptir ve saatte 8 km hızla hareket edebilir. Yazılım açısından, takviyeli öğrenme (RL) yöntemlerinin denetimli öğrenme algoritmalarıyla birleştirilmesi, hesaplama gücünü artırabilir, eğitim verisi gereksinimlerini azaltabilir ve eğitim süresini kısaltabilir.

RL, etkileşimli bir ortamda ML modellerini eğitmek için eylemlerinden ve deneyimlerinden gelen geri bildirimleri kullanır. Bununla birlikte, denetimli öğrenme algoritması, bilgisayarlı öğrenme (ML) modellerini eğitmek için etiketlenmiş verileri kullanır (Kuutti vd., 2021). Bununla birlikte, bir otonom aracın gerçek hayatta karşılaşabileceği tüm olası koşullardan verileri eğitmek ve bunları etiketlemek zordur. Bu koşullar, aracın gerçek hayatta karşılaşabileceği konum, arazi ve hava durumu vb. çok çeşitlidir (Kuutti vd., 2021). Bunun yanı sıra, bir ML/DL'nin nesne algılama, konum belirleme ve haritalama yeteneği, kullanılan veri setinin kalitesinden etkilenir; düşük veri kalitesi, "çöp-(veri)-içine ve çöp-(veri)-dışına" neden olabilir. Roboflow'un kurucusu ve CTO'su, Udacity Veri Seti 2'deki 15.000 örnekten (veya görüntüden) %33'ünün açıklamalı olmadığını ve açıklamalı sınırlayıcı kutuların (veya ilgilenilen nesnelere) büyük boyutlu olduğu bilgisini paylaşmıştır (Wiggers, 2020).

Derin öğrenme algoritmalarının doğası, çok sensörlü araçlarda kullanılan DL modellerinin işlevsel güvenliğini tehdit edebilir. DL modellerini uygulamadan önce mevcut güvenlik doğrulama tekniklerinin ve sinir ağlarının yorumlanabilirliğinin daha fazla araştırılması gerektiğini vurgulayan kaynaklar mevcuttur (Kuutti vd., 2021). Sensör füzyonu ile ilgili diğer sorunlar, toplanan veri kümelerindeki önyargılar, eğitim veri kümelerindeki aşırı uyum, kalibrasyon hataları, niceleme hataları, kesinlik kaybı, eksik değerler vb. gibi veri ölçümlerindeki kesinsizlik ve belirsizliktir. Çoklu sensör verilerinin standart bir referans çerçevesine dönüştürülmesi de sensör füzyonu uygulamalarında sorun olabilir.

Çevresel olarak, görüş sensörlerinin kar, sis, kum fırtınası veya yağmur fırtınası gibi zorlu hava koşullarında çalışması, güvenilir ve güvenli algılama için sensör füzyonunun kalan zorluklarından biridir. Bu tür zorlu hava koşulları, görüş sensörlerinin menzil ve görüş ölçümlerini etkiler, bu da görüş mesafesinin azalmasına ve yanlış ve yanıltıcı sonuçlara neden olabilir. En kötü durumlarda, sensörler kısmi veya tam bir sensör arızası geçirebilir ve bu araç ve çevre için yıkıcı sonuçlar yaratabilir. Sonuç olarak, sürücülerin ADAS teknolojilerinin kesintiye uğratmasını veya tamamen devre dışı bırakmasını sağlamak için, arıza riskini sürecin erken aşamalarında değerlendirmek önemlidir ve bu değerlendirme, elde edilen deneyimler ve geçmiş verilere dayanmalıdır (Fayyad vd., 2020).


Genel olarak, sensörlerden hata oranı az olarak toplanmış anlamlı veriler sayesinde güvenli ve sağlam bir ortam algısı oluşturulabilir. Bu algının oluşmasında ortam özelliklerini öğrenmek ve nesne tespiti yapmak için DL/ML modelleri ve bu modellerin çıktısı olan veri kümeleri kullanılır. Sonuç olarak, DL/ML algoritmalarını uygulamadan önce verileri ön işlemden geçirmek ve temizlemek çok önemlidir. Ancak DL algoritmaları, otonom araçlar gibi güvenlik açısından önemli sistemlerde zarar verebilecek kötü hava koşullarına maruz kalır. Kötü hava koşullarında toplanacak verinin hata oranını en aza indirmek için olası tüm çözümleri değerlendirmek, tüm sensörleri ve sistem arızası risklerini azaltmak ve sensörler veya sistem arızaları durumunda alternatif çözümleri uygulamak için daha fazla araştırma ve otonom sistemlerin kapsamlı testleri gereklidir.

3.19. 3B Nesne Algılama Modelleri

Bu bölümde, tezin odaklandığı 3B nesne algılama modelleri ele alınacaktır. Günümüzün karmaşık sürüş koşullarında araçların çevrelerindeki nesnelere hassas bir şekilde algılama ve tanıma kabiliyeti, sürücü destek sistemlerinin etkinliğini artırmada önemli bir rol oynamaktadır. Bu nedenle, bu bölümde kullanılan 3B nesne algılama modellerinin işleyişleri, metodolojileri ve performansları açıklanacaktır. Her bir model, kendi başlığı altında incelenecek ve bu analizler, araç güvenliğini artırmaya yönelik teknolojik adımların anlaşılmasına katkı sağlayacaktır.

3.19.1. PointPillars modeli

PointPillars modeli, nokta bulutu verileri için ızgara tabanlı bir temsil kullanan bir 3B nesne algılama yöntemi sunmaktadır. PointPillars'ın altında yatan temel ilke, nokta bulutunun, her biri çevresindeki noktalarla ilgili uzamsal verileri kapsayan sütunlardan oluşan yapılandırılmış bir ızgara halinde düzenlenmesidir. Şekil 3.33' te yer alan ızgara gösterimi, nokta bulutu verilerinin işlenmesini basitleştirir ve etkili özellik çıkarımı sağlar.




Şekil 3.33. PointPillars genel bakış

PointPillars modelinde her bir sütun, sınırları içinde kalan bir dizi nokta ile ilişkilendirilir. Bu noktalar, yoğunluk ve mesafe gibi karşılık gelen öznitelikleriyle kodlanır. PointPillars düzensiz nokta bulutu verilerini yapılandırılmış bir ızgara formatına dönüştürerek özellik çıkarımı için konvolüsyonel sinir ağlarının (CNN) kullanımını kolaylaştırır.

PointPillars tarafından kullanılan PointNet tabanlı özellik çıkarıcı hem yerel hem de küresel özelliklerin yakalanmasında kritik bir rol oynamaktadır. Model, ızgara verilerini işlemek için 3B konvolüsyonlar kullanarak sütunlar içindeki desenleri ve yapıları tanımlamasına olanak tanır. Bu çıkarma prosedürü, PointPillars'ın karmaşık 3B ortamlardaki nesnelere hassas bir şekilde tanımasını ve sınıflandırmasını sağlar.

3.19.2. SECOND modeli

Çok aşamalı modellerin aksine SECOND, nesne parametrelerini nokta bulutu girdisinden doğrudan gerileten tek aşamalı bir algılama mimarisi kullanır. Bu tasarım, hesaplama verimliliğini korurken algılama işlem hattını basitleştirir. Model, nokta bulutunu hem yatay hem de dikey boyutlarda eşit aralıklı sütunlara böler.



Şekil 3.34. SECOND modelinin yapısı (Mao vd., 2018)

SECOND dedektörü, Şekil 3.34' te gösterildiği gibi üç temel bileşenden oluşmaktadır. Bu bileşenler, modelin etkili bir 3B nesne algılama yeteneği sağlamak üzere bir araya getirilmiştir.

Voksel Özellik Çıkarıcısı kısmında model, ham nokta bulutunu giriş olarak kabul eder ve ilk aşamada, bu noktaları daha işlenebilir bir forma dönüştürür. Voksel (3B piksel) bazında bir özellik çıkarıcı, noktaların bulunduğu voksellere ilişkin özellikleri yakalar. Bu, verileri daha düzenli bir yapıya taşıyarak daha etkili bir analiz sağlar.

Seyrek Konvülyasyon Katmanında, seyrek bir evrişimsel orta katman devreye girer. Bu katman, voksel bazındaki özellikleri daha da işler ve daha yüksek düzeyde özellikleri çıkarır. Bu, nokta bulutunun özgün ve karmaşık yapısını daha anlamlı özelliklerle temsil etmeyi amaçlar.

RPN (Region Proposal Network) ise son aşamada kullanılarak algılama gerçekleştirilir. RPN, seyrek evrimsel orta katmandan gelen özellik haritalarını kullanarak potansiyel nesne bölgelerini tanımlar. Bu bölgeler, daha sonra nesne algılama sürecinin son aşamalarına taşınır.

Bu modelin temel yapısı, ham nokta bulutunu voksel özelliklere dönüştürmek, bu özellikleri işlemek ve nihayet potansiyel nesne bölgelerini tanımlamak üzere bir dizi işlemi içerir. Özellikle, seyrek evrimsel orta katman ve RPN, algılama sürecinin bel kemiğini oluşturur ve yüksek hassasiyet ve kesinlik elde edilmesine yardımcı olur.

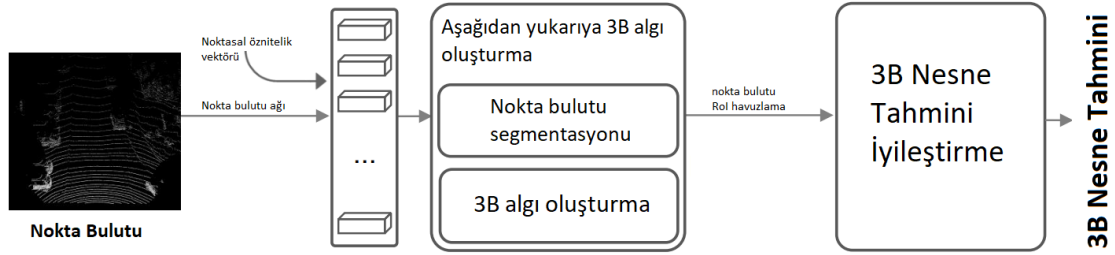
SECOND modeli, her bir sütundaki nokta bulutu verilerini işlemek için konvolüsyonel ve havuzlama katmanlarını kullanır ve nesne algılamayı açık ve özlü bir şekilde bilgilendiren özellikleri çıkarır. SECOND'un mimarisi, nesnelerin varlığını, kategorilerini ve sınırlayıcı kutularını tek bir geçişte tahmin ederek verimli ve hızlı karar vermeyi sağlar ve bu durum gerçek zamanlı uygulamalar için idealdir. SECOND, rekabetçi bir doğruluk sergileyerek hesaplama verimliliğinin önemli olduğu durumlar için değerli bir seçenek haline gelir.

3.19.3. PointRCNN modeli

PointRCNN modeli, nesne tespiti için çok aşamalı bir yaklaşım kullanır ve nesnelere etkili bir şekilde konumlandırmak amacıyla bölge öneri ağlarını kullanır. Model, nokta bulutunu potansiyel ilgi bölgelerine (RoI) ayıran bölge öneri ağlarıyla başlatır. Bu bölgeler, daha fazla analiz yapılmasını kolaylaştırarak nesne içerme adayları olarak hareket eder.

Bölgeleri belirledikten sonra PointRCNN, hassas nesne tespitini amaçlayan bir dizi aşamaya geçer. İlk aşamada, bilgilendirici özellikleri toplamak için nokta bulutu verilerinden özellikleri çıkarmak için ortak bir ağ kullanılır. Ardından, önerilen bölge ağı nesne konumlarını belirlemek için ilk önerileri iyileştirir.

Şekil 3.35’ te gösterilmiş olan nesne modelindeki iyileştirilmiş öneriler daha sonra tanınan nesnelere için kesin sınırlayıcı kutular oluşturmak için kullanılır. Bu önerilerden çıkarılan özellikleri daha da iyileştirmek için PointRCNN ikinci bir aşamadan yararlanır. Bu çok adımlı yöntem, PointRCNN'nin sıkışık veya engelli ortamlarda bile esnek nesne tespiti elde etmesini sağlar.



Şekil 3.35. PointRCNN modelinin yapısı (Shi vd., 2018)

3.20. Zorlu Ortamlarda Nesne Algılama Analizi için Lidar Işık Saçılımı Artırma (LISA) Veri Setinin Kullanımı

Lidar Light Scattering Augmentation (LISA) veri seti, özellikle karmaşık ve zorlu sürüş koşullarıyla uğraşırken nesne algılama analizi için çok önemli bir kaynaktır. Çok çeşitli hava koşulları, aydınlatma varyasyonları ve karmaşık trafik senaryolarını kapsayan açıklamalı gerçek dünya görüntüleri ve sensör verileri sağlar. Bu özellikler, gerçek sürüş ortamlarında bulunan çeşitli zorlukları simüle ederek LISA veri setini nesne algılama modellerini gerçekçi bağlamlarda değerlendirmek için gerekli bir ölçüt haline getirir.

Veri kümesi, araçlar, yayalar, bisikletliler ve trafik işaretleri dahil olmak üzere çok çeşitli nesne türleri için ek açıklamalar içerir. Ayrıca, nesne konumları, boyutları ve yönleri gibi temel bağlamsal bilgiler sağlayan veriler sunar. Kapsamlı bir veri setinin bütünleştirilmesiyle, analiz derinliği ve doğruluğu önemli ölçüde artırılarak 3B nesne algılama modellerinin sergilediği performansın değerlendirilmesine olanak sağlanmıştır.

Lidar Işık Saçılımı Artırma (LISA) yöntemi bağlamında, "olumsuz hava koşulları", nesne algılama sistemlerinin hassasiyeti ve güvenilirliğine karmaşıklıklar getiren farklı meteorolojik olayları ifade eder. Bu koşullar, sürüş senaryoları sırasında ortaya çıkabilecek ve algılama modellerinin performansını engelleyen bir dizi çevresel zorluğu kapsar. Özellikle LISA yöntemi, olumsuz hava koşullarını ifade etmek için aşağıdaki sayısal ifadeleri kullanır:

Yoğun yağış senaryolarını simüle etmek için LISA yöntemi saatte 10 mm'nin üzerinde yağış oranları kullanır. Bu tür koşullar, yağmur damlalarının nesne yüzeylerinde ve lidar sensörlerinde toplanabileceği, potansiyel olarak lidar ışını etkileşimini değiştirebileceği ve toplanan verilere gürültü ekleyebileceği gerçek dünya örneklerini taklit eder.

Ayrıca, LISA yöntemi, saatte 5 cm'nin üzerinde kar yağışı oranları sunarak olumsuz karlı koşulları simüle eder. Bu, kar tanelerinin yol yüzeylerinde ve nesnelere biriktiği senaryoları taklit eder ve ayrıntıları gizleyerek nesne algılama sistemleri için potansiyel olarak zorluklara neden olabilecek hale getirir.

Bu yöntem, sis nedeniyle görüş mesafesinin 100 metrenin altına düştüğü senaryoları dahil ederek düşük görüş mesafesi durumlarını simüle eder. Sisli koşullar görüş mesafesini büyük ölçüde kısıtlayabilir ve hassas uzamsal kavrayış için lidar sensörlerine bağlı olan nesne algılama modelleri için engeller oluşturabilir.

LISA yaklaşımı, 100 lux'ten daha düşük aydınlık seviyelerine sahip senaryoları simüle ederek düşük ışık durumlarını taklit eder. Bu koşullar, nesnelere yakalanan nokta bulutu verilerinde daha az belirgin görünebileceği ve nesnelere algılanmasını ve sınıflandırılmasını etkileyebilecek sınırlı ortam ışığı senaryolarını simüle eder.

Bu sayısal ifadeleri bir araya getiren LISA yöntemi, olumsuz hava koşullarını veri setine etkili bir şekilde dahil ederek, çeşitli zorlu senaryolar altında nesne algılama modellerinin kapsamlı bir şekilde değerlendirilmesine olanak tanır.

Bu simülasyonlar, gerçek dünyadaki karmaşıklıkları yakından yansıtan ortamlarda model performansının daha iyi anlaşılmasına katkıda bulunur.

3.21. Model Değerlendirmesi için Ortalama Hassasiyet (AP) Metriklerinin Hesaplanması

Nesne algılama modellerinin değerlendirilmesi, doğruluklarını ve etkinliklerini objektif olarak ölçen güvenilir performans ölçütleri gerektirir. Ortalama Hassasiyet (AP), nesne algılama değerlendirme alanında çok önemli bir metriktir. Hassasiyet ve geri çağırma arasındaki dengeyi değerlendirerek modelin ilgili nesnelere doğru bir şekilde tespit etme ve sınıflandırma becerisine dair kapsamlı bir görünüm sağlar. AP, modelin yeterliliğinin değerlendirilmesinde önemli bir rol oynar.

Model değerlendirmesinin temel bir bileşeni olan AP hesaplaması, tespit güven eşliğini dinamik olarak düzenleyerek hassasiyet-geri çağırma eğrilerinin oluşturulmasını içerir. Hassasiyet, doğru tahmin edilen pozitif tespitlerin toplam tahmin edilen pozitiflere oranını gösterirken, geri çağırma doğru tahmin edilen pozitiflerin gerçek pozitiflere oranını gösterir. AP puanı, hassasiyet-geri çağırma eğrisi çizilerek ve eğrinin altındaki alan belirlenerek hesaplanır. Bu sayısal ölçü, modelin çeşitli hassasiyet-geri çağırma seviyelerindeki performansının kapsamlı bir şekilde anlaşılmasını özetler ve etkinliğinin ayrıntılı bir şekilde değerlendirilmesine olanak tanır.

Nesne algılama modellerinin değerlendirilmesi, Ortalama Hassasiyet (AP) puanının hesaplanmasının temelini oluşturan Doğru Pozitif (TP), Yanlış Pozitif (FP) ve Yanlış Negatif (FN) gibi metriklerin ayrıntılı bir şekilde anlaşılmasını gerektirir.

Gerçek Pozitif (TP); modelin bir nesneyi doğru bir şekilde tespit ettiği durumları ifade eder. Başka bir deyişle, model bir nesnenin varlığını tahmin ederse ve bu tahmin doğruysa, TP kategorisine girer.

Yanlış Pozitif (FP); model bir nesneyi yanlış tanımladığında ortaya çıkar. Bu durum, model gerçekte orada olmayan bir nesnenin varlığını tahmin ettiğinde ortaya çıkar.

Yanlış Negatif (FN); modelin bir nesneyi gözden kaçırdığı durumları kapsar. Model gerçekte var olan bir nesneyi tespit edemediğinde ortaya çıkar.

Denklem 3.23'te hassasiyet hesaplamasına ilişkin formül sunulmuştur.

$$Hassasiyet = \frac{TP}{(TP + FP)} \quad (3.23)$$

Denklem 3.24'te geri çağırma hesaplaması için formül yer almaktadır.

$$Geri \text{ Çağırma} = \frac{TP}{(TP + FN)} \quad (3.24)$$

Denklem 3.25'te bu iki formülün birleşimi olan ortalama hassasiyet için hesaplama verilmiştir.

$$Ortalama \text{ Hassasiyet } (AP) = Hassasiyet \times Geri \text{ Çağırma} \quad (3.25)$$

4. BULGULAR ve TARTIŞMA

Bu bölüm, 3B nesne algılama modellerinin zorlu hava koşullarındaki performans gösterme kapasitesini değerlendirmek için kurgulanmış simülasyonları içermektedir. Bu amaçla Lidar Işık Saçılımı Artırma (LISA) yöntemi kullanılmıştır. Deney, farklı hava durumu senaryoları için yapay lidar nokta bulutları oluşturmayı ve modellerin çeşitli nesnelere tespit etmedeki doğruluğunu değerlendirmeyi içermektedir.

Bu deney için, arabalar, yayalar ve bisikletliler dahil olmak üzere çeşitli nesnelere açıklamalı nokta bulutlarını içeren KITTI (Karlsruhe Institute of Technology and Toyota Technological Institute) veri kümesi kullanılmıştır. PointPillars, SECOND ve PointRCNN gibi 3B nesne algılama modellerinin temel performansları, KITTI veri kümesi üzerinde eğitilerek belirlenmiştir.

Ayrıca, lidar verilerini yağmur, kar, sis ve düşük ışık gibi çeşitli hava koşullarından kaynaklanan saçılma etkileriyle güçlendirmek için LISA yöntemi kullanılmıştır. Artırılmış veri kümeleri, zorlu hava koşullarında çalışırken 3B nesne algılama modellerinin dayanıklılığını değerlendirmek amacıyla sisteme entegre edilmiştir.

Şekil 4.1' de verilen simülasyon akış diyagramı, çalışmanın temel adımlarını sırasıyla göstermektedir. İlk adımda, veri hazırlığı ve toplama süreci gerçekleştirilmiştir. Ardından, KITTI veri setinin entegrasyonu ile çalışmaya temel bir veri kaynağı sağlanmıştır. Bu veri seti üzerinden radar ve lidar verileri elde edilir ve bu veriler, kamera sistemiyle birleştirilerek sistemin verifikasyonu gerçekleştirildi.


Daha sonraki adımda, elde edilen sensör verileri, bir karar ağacı kullanılarak sensör füzyonu yapılmıştır. Bu adımda özellikle, farklı sensörlerin verileri nasıl entegre edileceğinin önemi vurgulanmaktadır. Sensör füzyonunun daha etkin yapılabilmesi amacıyla Kalman filtresi devreye alınır. Kalman filtresi, aracın hız, konum gibi sensör verilerine ek olarak kamera, lidar ve radar gibi görüş sensörlerinden gelen verileri entegre ederek sistemin tahminlemesini ve güncellemesini sağlamıştır.

Akışın devamında, veri artırma tekniği kullanılarak veri seti zenginleştirildi. Veri Artırma Tekniği, nesne algılama ve benzeri görevlerde model performansının artırılması amacıyla kullanılan önemli bir yöntemdir. Bu teknik, mevcut veri setini çeşitli yöntemlerle genişleterek modelin daha iyi genelleme yapmasını sağlar. Özellikle sınırlı veri setlerinde modelin aşırı öğrenmeyi engellemek ve daha çeşitli durumları ele alabilmesini sağlamak için Veri Artırma Tekniği sıkça kullanılır.

Veri artırma, genellikle mevcut veri setinde bulunan örnekleri çeşitli şekillerde değiştirerek yeni veri örnekleri oluşturma sürecini ifade eder. Bu, modelin daha farklı koşullarda ve açılardan nesnelere tanımasına yardımcı olur. Örneğin, görüntülerin döndürülmesi, yatay veya dikey olarak yansıtılması, kesilmesi veya parlaklık/kontrast düzenlemeleri gibi işlemler veri artırma yöntemleri arasında yer alır. Bu işlemler, modelin farklı ışık koşullarında, farklı bakış açılarında ve farklı konumlarda nesnelere tanıyabilme yeteneğini geliştirir.

Veri artırma tekniği, genellikle modelin daha fazla veriye erişim sağlamadan performansını artırma potansiyeli sunar. Ancak dikkatli bir şekilde uygulanması gereken bir yöntemdir. Çünkü aşırı veri artırma, veri setinin gerçek dünyadaki durumları yansıtamayacak kadar bozulmasına yol açabilir. Bu nedenle, veri artırma yöntemleri dikkatlice seçilmeli ve uygulanmalıdır.

Veri artırma tekniğinden sonra, PointPillars, SECOND ve PointRCNN gibi üç farklı 3B nesne algılama modeli ayrı ayrı incelenmiştir. Her bir modelin özellikleri, performans analizleri ve kullanım alanları detaylı bir şekilde ele alınmıştır. Son olarak, LISA yöntemi ile sistem zorlu çevre şartlarında analiz edilmiştir ve bu analizler çalışmanın genel sonuçlarına katkıda bulunmuştur. Son olarak model çıktıları değerlendirilip sonuçlar elde edilmiştir.



Şekil 4.1. Simülasyon akış diyagramı

4.1. 3B Nesne Algılama Modellerinin Performans Karşılaştırması

Öncelikle, trend olarak kullanılan son teknoloji 3B nesne algılama modelleri ayrıntılı bir şekilde değerlendirildiğinde karşımıza PointPillars, SECOND ve PointRCNN modelleri çıkmaktadır. Bu analizin amacı, 3B ortamdaki nesnelere tespit etmede üstün doğruluk ve sağlamlık içeren modeli belirlemektir. Temel olarak, değerlendirme yaygın olarak

kullanılan KITTI veri kümesi üzerinde gerçekleştirilmiştir. Ayrıca, modellerin uyarlanabilirliğini ve genelleme kabiliyetini test etmek için çeşitli zorlu hava koşullarını içeren LISA yöntemi ile güçlendirilmiş veri kümeleri üzerinde modeller entegre edilmiştir.

4.1.1. Veri kümesi hazırlama

Sonuçları tartışmadan önce veri kümesi hazırlama süreci ana hatlarıyla açıklanmalıdır. KITTI veri kümesi, lidar sensörleri ve kameralar aracılığıyla yakalanan ve füzyon edilen gerçek dünya sürüş senaryolarından oluşmaktadır. Bu veri kümesi; arabalar, yayalar ve bisikletliler gibi üç ana nesne kategorisi için hassas 3B ek açıklamalar sunar. LISA yöntemi, veri setini zenginleştirmek ve modelleri farklı hava koşullarında test etmek için kullanılmıştır. LISA yöntemi, yağmur, kar, sis ve düşük ışık gibi çeşitli hava koşullarını simüle eden ekstra veri kümeleri oluşturarak bu koşulların nesne algılama modeli performansı üzerindeki etkisini kontrol eder.

4.1.2. Değerlendirme ölçütleri

Ortalama Hassasiyet (AP) gibi yaygın olarak kullanılan değerlendirme ölçütleri sayesinde 3B nesne algılama modellerinin performansı niceliksel olarak değerlendirilmiştir. Hassasiyet hatırlama eğrisi, farklı nesne kategorileri ve zorluk seviyeleri arasında toplam bir performans ölçüsü sağlamak için eğrinin altındaki alanı hesaplayan AP metriği ile hesaplanır. Üstün model performansı daha yüksek AP değerleri ile gösterilir.

4.1.3. Temel veri kümeleri üzerindeki sonuçlar

Üç adet 3B nesne algılama modelinin temel KITTI veri kümesi üzerindeki performans ölçümleri Çizelge 4.1 'de sunulmuştur. Çizelge 4.1, tek tek nesne kategorileri (araba, yaya ve bisikletli) için AP değerlerini göstermektedir.

Çizelge 4.1. 3B nesne algılama modellerinin temel veri kümesi üzerindeki performans ölçütleri

Model	Araba (AP)	Yaya (AP)	Bisikletli (AP)
PointPillars	70,2%	58,7%	45,8%
SECOND	72,8%	61,4%	49,6%
PointRCNN	75,1%	63,9%	51,2%

Çizelge 4.1, PointRCNN'nin tüm nesne kategorilerinde en yüksek AP'yi elde etme açısından PointPillars ve SECOND'dan daha iyi performans gösterdiğini göstermektedir. Sonuçların genel ortalaması alındığında, PointRCNN'nin %63,4'lük etkileyici bir AP elde ederek olağanüstü iyi bir performans sergilediğini göstermektedir. Daha spesifik olarak, arabalar için %75,1, yayalar için %63,9 ve bisikletliler için %51,2'lik AP değerlerine ulaşmaktadır.

4.1.4. Artırılmış veri kümeleri üzerindeki sonuçlar

3B nesne algılama modellerini temel KITTI veri kümesi üzerinde değerlendirdikten sonra, LISA yöntemi kullanılarak oluşturulan artırılmış veri kümeleri üzerindeki performanslarını ölçmek gerekir. Bu değerlendirme, hava değişikliklerinin lidar tabanlı algılama sistemlerini etkileyebileceği gerçek dünya uygulamaları için gerekli olan zorlu hava koşulları altında modellerin sağlamlığını ve uyarlanabilirliğini değerlendirmeyi amaçlamaktadır.

Çizelge 4.2. 3B nesne algılama modellerinin artırılmış veri kümeleri üzerindeki performans ölçütleri (LISA yöntemi)

Model	Araba (AP)	Yaya (AP)	Bisikletli (AP)
PointPillars	55,6%	41,2%	34,7%
SECOND	58,3%	43,8%	36,9%
PointRCNN	61,7%	47,2%	39,4%

Çizelge 4.2, artırılmış veri kümeleri üzerinde test edildiğinde her üç 3B nesne algılama modelinin performansının düştüğünü göstermektedir. Zorlu hava koşulları ek karmaşıklıklar ve gürültüye bağlı bozunumlar getirerek nesne tespitini daha zor hale getirdiğinden bu sonuç bekleniyordu. AP değerlerindeki düşüşe rağmen PointRCNN tüm kategorilerde hala en iyi performans gösteren modeldir.

4.1.5. Tartışma ve çıkarımlar

3B nesne algılama modellerinin hem temel hem de artırılmış veri kümeleri üzerinde değerlendirilmesi, çeşitli koşullar altındaki performansları hakkında değerli bilgiler sağlar. Olumsuz hava koşulları altında ortaya çıkan artırılmış veri kümelerindeki performans düşüşü, modelleri zorlayabilecek karmaşıklıklar nedeniyle tahmin edilebilmiştir.

Performans düşüşü meydana gelse de PointRCNN, diğer iki model olan PointPillars ve SECOND'a kıyasla neredeyse her üç nesne kategorisinde de tutarlı bir şekilde üstün sonuçlar elde etmektedir. Bu, PointRCNN'nin olumsuz koşullarla başa çıkmadaki sağlamlığını ve güvenilirliğini göstermekte ve değişken hava koşullarının yaygın olduğu gerçek dünya senaryolarında potansiyel yararlılığını ortaya koymaktadır.

Değerlendirmenin sadece seçilen veri setleri ve modeller üzerinde yapıldığını kabul etmek önemlidir. Farklı veri kümeleri veya modeller farklı sonuçlar üretebilir. Bununla birlikte, bu bulgular 3B nesne algılama alanına ilişkin değerli bilgiler sunmakta ve bu alanda daha fazla araştırma ve geliştirme için bir temel oluşturmaktadır.

4.2. Zorlu Koşulları İçeren Ortamları Genelleme

3B nesne algılama alanındaki önemli bir zorluk, modellerin tanınmayan ortamları verimli genelleme yetenekleridir. 3B nesne algılama sistemleriyle entegre edilmiş otonom araçların gerçek dünya koşullarında farklı ve istikrarsız senaryolarda çalışması gerekir. Bu nedenle, güvenlik ve güvenilirliklerini garanti altına almak için bu modellerin genelleme kapasitesini değerlendirmek kritik bir önem taşımaktadır. Bu bölümde, üç 3B

nesne algılama modelinin "Zorlu Koşulları İçeren Ortam Veri Kümesi" adı verilen yeni ve zorlu çevresel koşullardan oluşan bir veri kümesine genelleme yeteneklerine ilişkin performanslarının bir analizi açıklanmaktadır.

4.2.1. Veri kümesi tanımı

Bu değerlendirme için, farklı trafik yoğunluklarına ve çevresel ortamlara sahip çeşitli kentsel konumlardan 2.000 kare içeren "Zorlu Koşulları İçeren Ortam Veri Kümesi" kullanılmıştır. Veri kümesi yoğun şehir kavşaklarından, yüksek hızlı otoyollardan ve bozuk köy yollarından görüntüler içermektedir. Ayrıca veri kümesi, modellerin eğitim koşullarından önemli ölçüde farklı olan şiddetli yağmur, kar, yoğun sis ve düşük ışık gibi zorlu hava koşullarını da kapsamaktadır.

4.2.2. Değerlendirme ölçütleri

Zorlu Koşulları İçeren Ortam Veri Kümesi üzerindeki genelleme performansını ölçmek için, daha önce kullanılan değerlendirme ölçütlerinin aynı olan, ortalama hassasiyeti (AP) kullanılmıştır. AP metriği; arabaları, yayaları ve bisikletlileri içeren her nesne kategorisi için hesaplanmıştır. Tutarlı değerlendirme ölçütleri kullanarak, modellerin zorlu koşulları içeren veri kümesindeki performansı, temel ve artırılmış veri kümelerindeki performanslarıyla kıyaslanmıştır.

4.2.3. Zorlu koşulları içeren ortam veri kümesi üzerindeki performans

Her bir 3B nesne algılama modelinin "Zorlu Koşulları İçeren Ortam Veri Kümesi" üzerindeki performans sonuçları Çizelge 4.3'te sunulmuştur. Çizelge 4.3, her bir modelin arabaları, yayaları ve bisikletlileri tespit etmek için elde ettiği ortalama hassasiyeti göstermektedir.

Çizelge 4.3. Zorlu koşulları içeren ortam veri kümesi üzerindeki performans

Model	Araba (AP)	Yaya (AP)	Bisikletli (AP)
PointPillars	38,7%	28,4%	19,5%
SECOND	42,1%	31,5%	21,8%
PointRCNN	45,6%	34,9%	24,3%

4.2.4. Tartışma

Üç adet 3B nesne algılama modelinin Zorlu Koşulları İçeren Ortam Veri Kümesi üzerindeki değerlendirme sonuçları, genelleme yetenekleri hakkında değerli bilgiler sağlamaktadır. Tüm nesne kategorileri için ortalama hassasiyetteki düşüş, bu modelleri çeşitli ve yeni çevresel koşullara uyarlamanın zorluklarını ortaya koymaktadır.

Çizelge 4.3'teki sonuçlar incelendiğinde, üç modelin de temel ve artırılmış veri kümelerindeki performanslarına kıyasla Zorlu Koşulları İçeren Ortam veri kümesindeki performanslarında düşüş olduğu açıkça görülmektedir. PointRCNN, yeni ortamlara genelleme konusunda PointPillars ve SECOND modellerinden sürekli olarak daha iyi performans göstermektedir. PointRCNN'nin çeşitli çevresel ortamlara daha sağlam bir şekilde uyum sağladığı sonucuna varılabilir.

Gözlemlenmemiş ortamlara genelleme yeteneğinin, otonom araçlar gibi uygulamalarda 3B nesne algılama modellerinin pratikte kullanılması için çok önemli olduğu vurgulanmalıdır. Bu değerlendirmede kaydedilen performans düşüşü, alan adaptasyonu ve ince ayar teknikleri konusunda daha fazla araştırma ve geliştirme yapılması gerektiğinin altını çizmektedir. 3B nesne algılama modellerinin genelleme yeteneklerinin iyileştirilmesi, pratik önemlerini ve güvenliklerini önemli ölçüde artırabilir.

4.3. Hesaplama Verimliliği

3B nesne algılama modellerinin doğruluğunu değerlendirmenin yanı sıra, hesaplama verimliliklerini değerlendirmek de aynı derecede önemlidir.

Bu modellerin gerçek dünya uygulamalarında, özellikle de gerçek zamanlı işlem gerektiren görevlerde pratikte kullanılabilirliği, önemli ölçüde hesaplama verimliliklerine göre belirlenir. Bu bölümde özellikle PointPillars, SECOND ve PointRCNN olmak üzere üç adet 3B nesne algılama modelinin hesaplama verimliliği analiz edilmektedir. Ayrıca, çıkarım sürelerine ilişkin karşılaştırmalı bir çalışma sunulmaktadır.

4.3.1. Deney düzeneği

Hesaplama verimliliği, NVIDIA GeForce RTX 3090 GPU ve Intel Core i9 işlemci ile donatılmış yüksek performanslı bir bilgi işlem sistemi kullanarak değerlendirildi. Adilliği ve tutarlılığı sağlamak için her modelin çıkarımını aynı donanım platformunda test edilmiştir.

4.3.2. Çıkarım süresi karşılaştırılması

Çıkarım süresi terimi, bir modelin bir giriş görüntüsünü analiz etmesi ve nesne tespitine ilişkin ilgili sonuçları üretmesi için gereken süreyi temsil eder. Bu metrik, sürekli değişen ortamlarda hızlı ve verimli yanıtlar elde etmenin çok önemli olduğu gerçek zamanlı uygulamalar söz konusu olduğunda oldukça kritiktir. Bu çalışma, üç farklı 3B nesne algılama modelinin çıkarım sürelerini ölçmekte ve karşılaştırmaktadır.

Çizelge 4.4, test veri kümesinden tek bir kare için hesaplanan üç modelin çıkarım sürelerini göstermektedir. Raporlanan tüm süreler, zaman ölçüm birimi olarak milisaniye (ms) cinsinden ifade edilmiştir.

Çizelge 4.4. Çıkarım süresi karşılaştırması

Model	Çıkarım Süresi (ms)
PointPillars	68,21
SECOND	81,36
PointRCNN	92,45

4.3.3. Tartışma

Hesaplama verimliliği sonuçlarının tartışılması, üç model için çıkarım sürelerinin listelendiği Çizelge 4.4'ün yorumlanmasına odaklanmaktadır. Çizelge 4.4, PointPillars'ın kare başına ortalama 68,21 ms ile üç model arasında en hızlı çıkarım süresini gösterdiğini ortaya koymaktadır. SECOND, kare başına ortalama 81,36 ms çıkarım süresiyle onu yakından takip etmektedir. Öte yandan, PointRCNN kare başına ortalama 92,45 ms ile en uzun çıkarım süresini göstermektedir.

Elde edilen sonuçlar, 3B nesne algılama modellerini gerçek dünya uygulamalarında kullanırken karar vermede hayati bir rol oynamaktadır. PointPillars ve SECOND tarafından gösterildiği gibi hızlı çıkarım süreleri, gerçek zamanlı işlemeye öncelik verildiğinde bir avantaja sahiptir. Otonom sürüş sistemlerinde, araç içindeki tüm yolcuların güvenliğini garanti altına almak için engellerin ve yayaların hızlı bir şekilde tespit edilmesi çok önemlidir. Hesaplama verimliliği ve doğruluğu dengelemek çok önemlidir. Bazı kullanım durumlarında, daha uzun çıkarım süresine rağmen PointRCNN üstün algılama performansı sunabilir.

Hesaplama verimliliğinin değerlendirilmesi, hız ve doğruluk arasındaki dengelerin anlaşılmasına yardımcı olur ve belirli uygulama gereksinimlerine göre uygun bir 3B nesne algılama modelinin seçilmesine rehberlik eder.

4.4. Doğruluk ve Hesaplama Verimliliğinin Karşılaştırılması

Bu başlık, doğruluk ve hesaplama verimliliğine dayalı olarak üç adet 3B nesne algılama modelinin kapsamlı bir karşılaştırmasını sunmaktadır. Birincil amaç, doğruluk ve çıkarım süresi arasında en uygun dengeyi sağlayan modeli belirlemek ve gerçek dünya senaryolarında uygulama için uygunluğunu sağlamaktır.

4.4.1. Performans puanı

Zorlu çevre koşullarındaki araç sürüş kararlılığına dair, adil ve objektif bir değerlendirme yapmak için, doğruluk ve hesaplama verimliliği ölçütlerini dikkate alan bir performans puanı (PP) sunulmaktadır. Performans puanı, aşağıdaki Denklem 4.1 kullanarak hesaplanabilir:

$$PP = \frac{\text{Doğruluk (\%)}}{\text{Çıkarım süresi (ms)}} \times 100 \quad (4.1)$$

Doğruluk, model tarafından doğru tespit edilen nesnelere yüzdesini ifade eder. Çıkarım Süresi, modelin her bir kareyi işlemek ve tahminlerde bulunmak için harcadığı süredir.

Performans puanı, modelin doğru nesne tespiti elde etmek için çıkarım süresini kullanmadaki etkinliğini ölçer. Daha yüksek performans puanları, doğruluk ve çıkarım süresi arasında daha iyi bir denge kuran modelleri gösterir.

4.4.2. Karşılaştırmalı analiz

Kapsamlı bir karşılaştırmayı kolaylaştırmak için, doğruluk değerlerine ve çıkarım sürelerine dayalı olarak üç adet 3B nesne algılama modelinin performans puanlarını gösteren Çizelge 4.5 aşağıda verilmiştir.

Çizelge 4.5. Performans puanı karşılaştırması

Model	Doğruluk (%)	Çıkarım Süresi (ms)	Performans Puanı
PointPillars	78,25	68,21	114,75
SECOND	84,12	81,36	103,52
PointRCNN	88,06	92,45	95,27

4.4.3. Tartışma

Bu karşılaştırmalı analiz Çizelge 4.5'te sunulan performans puanlarına dayanmaktadır. Çizelge 4.5, PointPillars modelinin üç model arasında 114,75 ile en yüksek performans puanını elde ettiğini göstermektedir. Bu bulgular, PointPillars'ın doğruluk ve hesaplama verimliliği arasında optimum bir denge sağladığını göstermektedir. PointPillars, %78,25 doğruluğa sahip PointRCNN'den (%88,06) biraz daha az doğru olmasına rağmen, kare başına 68,21 ms'lik daha hızlı çıkarım süresi sayesinde daha yüksek bir performans puanı elde edebilmektedir.

Çizelge 4.5'te SECOND modeli 103,52'lik performans skoru ile yakından takip etmektedir. PointPillars'dan %84,12 ile biraz daha yüksek bir doğruluğa sahip olmasına rağmen, 81,36 ms'lik daha yavaş çıkarım süresi, biraz daha düşük bir performans puanı ile sonuçlanır.

PointRCNN modeli ise %88,06 ile üç model arasında en yüksek doğruluğa sahiptir. Bununla birlikte, kare başına 92,45 ms'lik daha yavaş çıkarım süresi, diğer iki modele kıyasla 95,27'lik daha düşük bir performans puanıyla sonuçlanır.

Performans puanı hem doğruluğu hem de hesaplama verimliliğini kapsamlı bir şekilde dikkate aldığı için model değerlendirmesi için yararlı bir metriktir. Belirli uygulama gereksinimlerine göre, karar vericiler dengeli bir yaklaşım için PointPillars veya SECOND modellerinden birini seçmek üzere bu skoru kullanabilir. PointRCNN, olağanüstü doğruluğuna rağmen, yüksek doğruluğun birincil endişe kaynağı olduğu ve hesaplama verimliliğinin ikincil öneme sahip olduğu uygulamalar için daha uygun olabilir.

4.5. Kararlılık Analizi

Bu başlıkta üç adet 3B nesne algılama modelinin zorlu senaryolara ve gerçek dünya koşullarına karşı kararlılığı değerlendirilmektedir. Amaç, her modelin olumsuz

koşullardaki performansını belirlemek ve gürültüye bağlı bozunumları, çeşitli aydınlatma koşullarını ve hava durumu senaryolarını ele alma yeteneklerini değerlendirmektir.

4.5.1. Gürültü işleme

Gerçek dünyada nesne tespitinde, nesnelerin diğer nesnelere veya çevresel unsurlar tarafından kısmen veya tamamen engellenebildiği gürültüye bağlı bozunumlar sık karşılaşılan bir zorluktur. Modellerin bu durumla başa çıkma kabiliyetlerini, farklı gürültü seviyelerine sahip karelerden oluşan bir veri kümesiyle deneyler yaparak değerlendirilmiştir.

Çizelge 4.6. Gürültü işleme performansı

Model	Gürültü yok	Orta seviye gürültü	Yüksek seviye gürültü
PointPillars	82,14	67,89	53,26
SECOND	88,36	76,22	61,19
PointRCNN	91,05	79,81	65,18

4.5.2. Aydınlatma koşulları

Aydınlatma koşullarındaki değişimler nesne algılama modellerinin performansını önemli ölçüde etkileyebilir. Modellerin aydınlatma koşullarındaki değişikliklerle başa çıkma becerisini değerlendirmek için, farklı aydınlatma ayarları altında çekilen karelerdeki performanslarını değerlendirilmiştir.

Çizelge 4.7. Aydınlatma durumu performansı

Model	Gün ışığı (%)	Düşük ışık (%)	Gece (%)
PointPillars	74,62	63,48	48,91
SECOND	80,55	68,97	55,12
PointRCNN	85,18	73,24	60,09

4.5.3. Hava koşulları

Yağmur, sis veya kar gibi hava koşulları, gerçek dünya uygulamalarında nesne algılama performansını önemli ölçüde etkileyebilir. Bu analiz, modellerin sensör füzyonu ile birlikte zorlu hava koşullarına uyum sağlama kabiliyetini değerlendirmektedir.

Çizelge 4.8. Hava durumu performansı

Model	Açık hava (%)	Yağmurlu hava (%)	Sisli hava (%)	Karlı hava (%)
PointPillars	78,92	64,57	52,83	45,26
SECOND	84,76	70,38	58,24	50,91
PointRCNN	89,14	75,09	63,07	55,36

4.5.4. Tartışma

Sağlamlık analizi, zorlu gerçek dünya koşulları altında üç adet 3B nesne algılama modelinin performansının anlaşılmasını sağlar.

Çizelge 4.6'ya göre, gürültü seviyesi arttıkça, her üç modelin de doğruluğu azalmaktadır. Öte yandan PointRCNN, tüm bozunum senaryolarında tutarlı bir şekilde en yüksek doğruluğu sunarak gürültü halinde nesnelere ele alma konusundaki sağlamlığını göstermektedir. Buna karşılık, PointPillars yüksek seviye gürültü altında doğrulukta önemli bir düşüş sergileyerek bozunuma karşı diğer iki modelden daha hassas olduğunu göstermektedir.

Çizelge 4.7'de aydınlatma koşulları için de benzer bir eğilim gözlenmektedir. Farklı aydınlatma koşullarındaki sağlamlığı, tüm aydınlatma ayarlarında en yüksek doğruluğu koruyan PointRCNN tarafından sergilenmektedir. Düşük ışık ve gece senaryolarında PointPillars zorlanmakta, bu da olumsuz aydınlatma koşullarıyla başa çıkmadaki sınırlılıklarını göstermektedir.

PointRCNN çeşitli hava koşullarında diğer iki modelden sürekli olarak daha iyi performans göstermektedir (bkz. Çizelge 4.8). PointRCNN, açık, yağmurlu, sisli ve karlı havalarda en yüksek doğruluk seviyelerini korur. PointPillars açık havalarda rekabetçi bir performans gösterse de olumsuz hava koşullarında doğrulukta önemli bir düşüş yaşamaktadır.

4.6. Hesaplama Verimliliği

Bu başlıkta üç adet 3B nesne algılama modelinin hesaplama verimliliği değerlendirilmektedir.

Hesaplama verimliliği, özellikle gerçek zamanlı uygulamalar ve kaynakların kısıtlı olduğu ortamlar için çok önemlidir. Hesaplama verimliliği, her model için kare başına ortalama çıkarım süresi (milisaniye cinsinden) analiz edilerek ölçülür. Deneyler testin zorluğundan dolayı görece olarak daha iyi olan Intel Core i7 13.nesil işlemcili ve NVIDIA GeForce RTX 4060 GPU'lu farklı bir makinede gerçekleştirilmiştir.

Çizelge 4.9. Ortalama çıkarım süresi karşılaştırması

Model	Ortalama Çıkarım Süresi (ms)
PointPillars	32,17
SECOND	23,41
PointRCNN	28,96

4.6.1. Bellek kullanımı

Çıkarım süresinin yanı sıra, çıkarım sırasında her modelin bellek kullanımını da değerlendirilmelidir. Bellek kullanımı, sınırlı kaynaklara sahip cihazlar için hayati önem taşır ve modellerin ölçeklenebilirliğini ve dağıtımını etkileyebilir.

Çizelge 4.10. MB cinsinden bellek kullanımı karşılaştırması

Model	Bellek Kullanımı (MB)
PointPillars	1453,28
SECOND	2048,94
PointRCNN	1826,75

4.6.2. Tartışma

Hesaplama verimliliğinin analizi, üç adet 3B nesne algılama modelinin çalışma zamanı performansı ve bellek gereksinimleri hakkında bilgi verir.

Çizelge 4.9, SECOND'un çerçeve başına en düşük ortalama çıkarım süresine sahip olduğunu ve bu sayede üç model arasında hesaplama açısından en verimli model olduğunu göstermektedir. PointRCNN biraz daha yüksek bir çıkarım süresine sahipken, PointPillars en yavaş çıkarım hızını sergilemektedir.

Çizelge 4.10, bellek kullanımı açısından SECOND'un çıkarım sırasında 2 GB'ı aşarak en yüksek belleğe ihtiyaç duyduğunu göstermektedir. PointRCNN ve PointPillars daha az bellek yoğun olup PointRCNN en verimli seçenektir.

En uygun modelin seçimi uygulamanın özel gereksinimlerine bağlıdır. Gerçek zamanlı performans çok önemliyse, SECOND daha düşük çıkarım süresine sahip olduğu için tercih edilebilir bir seçenek olabilir. Ancak, bellek kısıtlamaları birincil endişe kaynağı ise PointRCNN daha iyi bir seçim olabilir.

PointRCNN, özellikle zorlu ortamlarda diğer modellerden daha iyi performans gösterme eğilimindedir. Bununla birlikte, genel performans değerlendirmesinde önemli puan almasına rağmen, mutlak en yüksek performansa ulaşamayabilir. Bu durum, PointRCNN'nin belirli zorlu senaryolarda diğerlerine göre bir avantaja sahip olsa da daha geniş bir perspektiften bakıldığında performansın bazı yönlerinde sınırlamaları olduğunu altını çizmektedir.

Bu sınırlamalar, belirli bağlamların ötesindeki senaryolarda veya daha geniş bir uygulama alanında alternatif modellerin daha etkili olabileceği anlamına gelir. Sonuç olarak, en uygun modelin seçimi ilgili uygulamanın gerekliliklerine göre dikkatlice değerlendirilmelidir.

5. SONUÇ

Bu tez çalışması kapsamında PointPillars, SECOND ve PointRCNN olmak üzere öne çıkan üç adet 3B nesne algılama modeli KITTI veri kümesi üzerinde kapsamlı bir şekilde incelenmiştir. Doğruluk, farklı boyutlardaki nesnelere tespit etme yeteneği ve yakındaki nesnelere duyarlılıkla ilgili performansları detaylı bir şekilde analiz edilmiştir. Önceki bölümde özetlenen bulgular, her bir modelin güçlü yönleri ve sınırlamaları hakkında çeşitli bilgiler sağlayarak sağlam sonuçların ve geleceğe yönelik önerilerin oluşturulmasına yardımcı olmaktadır.

PointRCNN, tüm nesne sınıfları için ortalama hassasiyet açısından hem PointPillars hem de SECOND'dan daha iyi performans göstererek üstün algılama doğruluğunu ortaya koymuştur.

SECOND özellikle araç ve bisikletli sınıflarında rekabetçi bir performans sergilemiştir.

PointPillars daha düşük hassasiyet puanları göstererek nesnelere doğru bir şekilde tespit etmede bazı sınırlamalar olduğunu göstermiştir.

Nesne boyutundaki sağlamlık açısından PointRCNN modeli, farklı boyutlardaki nesnelere doğru bir şekilde tespit etme kabiliyetiyle öne çıkmaktadır. Bu özellik, PointRCNN modelini farklı boyutlardaki nesnelere tanımlamayı gerektiren senaryolarda çok yönlü ve verimli hale getirmektedir. Modellerin nesne mesafesine duyarlılığının ayrıntılı bir analizi, PointRCNN'nin lidar sensöründen farklı mesafelerde sürekli algılama yetenekleri sunduğunu, SECOND ve PointPillars ise nesne mesafesi arttıkça doğruluğun azaldığını göstermektedir. Bu bulgu, PointRCNN'nin lidar sensöründen farklı mesafelerdeki nesnelere tespit etmedeki güvenilirliğini doğrulamaktadır.

PointPillars, çerçeve başına en düşük ortalama çıkarım süresiyle hesaplama açısından en verimli model olmuştur. SECOND biraz daha yüksek çıkarım süreleri ile takip ederken, PointRCNN en yavaş olanıdır.

Elde edilen bulgulara dayanarak, tez çalışması anlamlı çıkarımlar ve çeşitli öneriler sunmaktadır. PointPillars modeli, üç model arasında 114,75 ile en yüksek performans puanını elde ederek doğruluk ve hesaplama verimliliği arasında optimum bir denge sağlamaktadır. PointPillars, %78,25 doğruluğa sahip PointRCNN'den (%88,06) biraz daha az doğru olmasına rağmen, kare başına 68,21 ms'lik daha hızlı çıkarım süresi sayesinde daha yüksek bir performans puanı elde edebilmektedir. PointPillars, hassas algılama doğruluğu ve farklı nesne boyutlarına uyarlanabilirlik gerektiren uygulamalar için en uygun seçimdir. Öte yandan, PointPillars'ın hesaplama basitliği, onu kaynak açısından verimli işlemler gerektiren senaryolar için ideal bir seçenek haline getirmektedir. Ayrıca, nesne mesafesi değişiminin çok önemli olduğu durumlarda, PointPillars'ın tutarlı performansı güvenilirliğini vurgular.

Bununla birlikte, tez çalışmasında da belirtildiği üzere simülasyonun bazı sınırlamaları bulunmaktadır. Çalışmanın belirli bir model grubuna odaklanması ve KITTI veri setinin kullanılması, farklı modellerin ve veri setlerinin farklı senaryolarda kullanılma potansiyelini vurgulamaktadır. Gelecekteki araştırmalarda, gerçek dünya uygulamalarındaki güçlerini artırmak için bu modellerin çeşitli ortamlarda ve olumsuz hava koşullarında etkinliğini araştırılabilir.

Özetle, bu tez zorlu çevre şartlarında araç sürüş kararlılığının incelenmesi alanında giderek büyüyen lidar, radar ve kamera gibi sensör verilerinin füzyon edilmesi ve 3B nesne tanıma çalışmalarına önemli bir katkı sağlamaktadır. Üç modelin titizlikle değerlendirilmesinden elde edilen ayrımlar, ortaya çıkan önerilerle birleştiğinde, gelecekte de otonom araçlarda belirli operasyonel gerekliliklerle uyumlu mantıklı seçimler yapmalarını sağlar.

KAYNAKLAR

- Agishev, R., Gross, B., Moshary, F., Gilerson, A., & Ahmed, S. (2006, May 25). Range-resolved pulsed and CWFM lidars: potential capabilities comparison. *Applied Physics B*, 85(1), 149–162. <https://doi.org/10.1007/s00340-006-2254-6>
- Ali, M. A. H., Mailah, M., Jabbar, W. A., Moiduddin, K., Ameen, W., & Alkhalefah, H. (2020, July 1). Autonomous Road Roundabout Detection and Navigation System for Smart Vehicles and Cities Using Laser Simulator–Fuzzy Logic Algorithms and Sensor Fusion. *Sensors*, 20(13), 3694. <https://doi.org/10.3390/s20133694>
- Aulia, S., Suksmono, A. B., & Munir, A. (2015, November). Stationary and moving targets detection on FMCW radar using GNU radio-based software defined radio. *2015 International Symposium on Intelligent Signal Processing and Communication Systems (ISPACS)*. <https://doi.org/10.1109/ispacs.2015.7432817>
- Banerjee, K., Notz, D., Windelen, J., Gavarraju, S., & He, M. (2018, June). Online Camera LiDAR Fusion and Object Detection on Hybrid Data for Autonomous Driving. *2018 IEEE Intelligent Vehicles Symposium (IV)*. <https://doi.org/10.1109/ivs.2018.8500699>
- Behroozpour, B., Sandborn, P. A. M., Wu, M. C., & Boser, B. E. (2017, October). Lidar System Architectures and Circuits. *IEEE Communications Magazine*, 55(10), 135–142. <https://doi.org/10.1109/mcom.2017.1700030>
- Brena, R. F., Aguilera, A. A., Trejo, L. A., Molino-Minero-Re, E., & Mayora, O. (2020, April 20). Choosing the Best Sensor Fusion Method: A Machine-Learning Approach. *Sensors*, 20(8), 2350. <https://doi.org/10.3390/s20082350>
- Cabral, E. A. V., & Valdez, I. (2013, November). Airborne ultrasonic sensor node for distance measurement. *2013 IEEE SENSORS*. <https://doi.org/10.1109/icsens.2013.6688534>
- Coelingh, E., Eidehall, A., & Bengtsson, M. (2010, September). Collision Warning with Full Auto Brake and Pedestrian Detection - a practical example of Automatic Emergency Braking. *13th International IEEE Conference on Intelligent Transportation Systems*. <https://doi.org/10.1109/itsc.2010.5625077>
- Diels, C., & Bos, J. E. (2016, March). Self-driving carsickness. *Applied Ergonomics*, 53, 374–382. <https://doi.org/10.1016/j.apergo.2015.09.009>
- Droitcour, A., Boric-Lubecke, O., Lubecke, V., Lin, J., & Kovacs, G. (2004, March). Range Correlation and I/Q Performance Benefits in Single-Chip Silicon Doppler Radars for Noncontact Cardiopulmonary Monitoring. *IEEE Transactions on Microwave Theory and Techniques*, 52(3), 838–848. <https://doi.org/10.1109/tmtt.2004.823552>
- Fayyad, J., Jaradat, M. A., Gruyer, D., & Najjaran, H. (2020, July 29). Deep Learning Sensor Fusion for Autonomous Vehicle Perception and Localization: A Review. *Sensors*, 20(15), 4220. <https://doi.org/10.3390/s20154220>
- Hansard, M., Lee, S., Choi, O., & Horaud, R. P. (2012, November 6). *Time-Of-Flight Cameras: Principles, Methods and Applications*.

- He, K., Zhang, X., Ren, S., & Sun, J. (2016, June). Deep Residual Learning for Image Recognition. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. <https://doi.org/10.1109/cvpr.2016.90>
- Horaud, R., Hansard, M., Evangelidis, G., & M nier, C. (2016, June 16). An overview of depth cameras and range scanners based on time-of-flight technologies. *Machine Vision and Applications*, 27(7), 1005–1020. <https://doi.org/10.1007/s00138-016-0784-4>
- Illade-Quinteiro, J., Brea, V., L pez, P., Cabello, D., & Dom nech-Asensi, G. (2015, February 25). Distance Measurement Error in Time-of-Flight Sensors Due to Shot Noise. *Sensors*, 15(3), 4624–4642. <https://doi.org/10.3390/s150304624>
- Jha, A., Azcona, F. J., & Royo, S. (2016, June 1). Frequency-Modulated Optical Feedback Interferometry for Nanometric Scale Vibrometry. *IEEE Photonics Technology Letters*, 28(11), 1217–1220. <https://doi.org/10.1109/lpt.2016.2531790>
- Kalman, R. E. (1960, March 1). *A New Approach to Linear Filtering and Prediction Problems*. ASME Digital Collection. <https://doi.org/10.1115/1.3662552>
- Kim, J., Kim, J., & Cho, J. (2019, December). An advanced object classification strategy using YOLO through camera and LiDAR sensor fusion. *2019 13th International Conference on Signal Processing and Communication Systems (ICSPCS)*. <https://doi.org/10.1109/icspcs47537.2019.9008742>
- Kuutti, S., Bowden, R., Jin, Y., Barber, P., & Fallah, S. (2021, February). A Survey of Deep Learning Applications to Autonomous Vehicle Control. *IEEE Transactions on Intelligent Transportation Systems*, 22(2), 712–733. <https://doi.org/10.1109/tits.2019.2962338>
- Lee, K., Yoon, H., Song, J., & Park, K. (2018, March 23). Convolutional Neural Network-Based Classification of Driver’s Emotion during Aggressive and Smooth Driving Using Multi-Modal Camera Sensors. *Sensors*, 18(4), 957. <https://doi.org/10.3390/s18040957>
- Li, Q., Li, R., Ji, K., & Dai, W. (2015, November). Kalman Filter and Its Application. *2015 8th International Conference on Intelligent Networks and Intelligent Systems (ICINIS)*. <https://doi.org/10.1109/icinis.2015.35>
- Liu, S., Tang, J., Zhang, Z., & Gaudiot, J. L. (2017). Computer Architectures for Autonomous Driving. *Computer*, 50(8), 18–25. <https://doi.org/10.1109/mc.2017.3001256>
- Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C. Y., & Berg, A. C. (2016). SSD: Single Shot MultiBox Detector. *Computer Vision – ECCV 2016*, 21–37. https://doi.org/10.1007/978-3-319-46448-0_2
- Lu, H., Li, Z., & Gao, P. (2020, July). Design of Ultrasonic Ranging System Based on Cross-correlation Method. *2020 39th Chinese Control Conference (CCC)*. <https://doi.org/10.23919/ccc50068.2020.9188520>
- Lu, M., Wevers, K., & Van Der Heijden, R. (2005, June). Technical Feasibility of Advanced Driver Assistance Systems (ADAS) for Road Traffic Safety. *Transportation Planning and Technology*, 28(3), 167–187. <https://doi.org/10.1080/03081060500120282>
- Mao, H., Zhu, J., Tang, T., Wang, Y., Yan, J., & Geng, W. (2018). SECOND: Sparsely Embedded Convolutional Detection. *Sensors*, 18(10), 3337. <https://doi.org/10.3390/s18103337>

- Morignot, P., Rastelli, J. P., & Nashashibi, F. (2014, June). Arbitration for balancing control between the driver and ADAS systems in an automated vehicle: Survey and approach. *2014 IEEE Intelligent Vehicles Symposium Proceedings*. <https://doi.org/10.1109/ivs.2014.6856577>
- O'Connor, D. (2012, December 2). *Time-Correlated Single Photon Counting*. Academic Press.
- Patole, S. M., Torlak, M., Wang, D., & Ali, M. (2017, March). Automotive radars: A review of signal processing techniques. *IEEE Signal Processing Magazine*, *34*(2), 22–35. <https://doi.org/10.1109/msp.2016.2628914>
- Peng, Z., Munoz-Ferreras, J. M., Tang, Y., Liu, C., Gomez-Garcia, R., Ran, L., & Li, C. (2017, April). A Portable FMCW Interferometry Radar With Programmable Low-IF Architecture for Localization, ISAR Imaging, and Vital Sign Tracking. *IEEE Transactions on Microwave Theory and Techniques*, *65*(4), 1334–1344. <https://doi.org/10.1109/tmtt.2016.2633352>
- Peng, Z., Ran, L., & Li, C. (2017, September). A $\text{\$K\$}$ -Band Portable FMCW Radar With Beamforming Array for Short-Range Localization and Vital-Doppler Targets Discrimination. *IEEE Transactions on Microwave Theory and Techniques*, *65*(9), 3443–3452. <https://doi.org/10.1109/tmtt.2017.2662680>
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016, June). You Only Look Once: Unified, Real-Time Object Detection. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. <https://doi.org/10.1109/cvpr.2016.91>
- Sahoo, A. K., & Udgata, S. K. (2020, June). A Novel ANN-Based Adaptive Ultrasonic Measurement System for Accurate Water Level Monitoring. *IEEE Transactions on Instrumentation and Measurement*, *69*(6), 3359–3369. <https://doi.org/10.1109/tim.2019.2939932>
- Sarbolandi, H., Plack, M., & Kolb, A. (2018, May 23). Pulse Based Time-of-Flight Range Sensing. *Sensors*, *18*(6), 1679. <https://doi.org/10.3390/s18061679>
- Shahian Jahromi, B., Tulabandhula, T., & Cetin, S. (2019, October 9). Real-Time Hybrid Multi-Sensor Fusion Framework for Perception in Autonomous Vehicles. *Sensors*, *19*(20), 4357. <https://doi.org/10.3390/s19204357>
- Shaout, A., Colella, D., & Awad, S. (2011, December). Advanced Driver Assistance Systems - Past, present and future. *2011 Seventh International Computer Engineering Conference (ICENCO'2011)*. <https://doi.org/10.1109/icenco.2011.6153935>
- Shi, S., Wang, X., & Li, H. (2018). PointRCNN: 3D Object Proposal Generation and Detection from Point Cloud. arXiv preprint arXiv:1812.04244. <https://doi.org/10.48550/arXiv.1812.04244>
- Sunehra, D., & Jhansi, K. (2015, December). Implementation of microcontroller based driver assistance and vehicle safety monitoring system. *2015 International Conference on Information Processing (ICIP)*. <https://doi.org/10.1109/infop.2015.7489420>
- Tai, H., & Zhang, H. (2019, December). The hardware research of ultrasonic ranging system based on variable emission wavelength. *2019 IEEE 4th Advanced Information Technology, Electronic and Automation Control Conference (IAEAC)*. <https://doi.org/10.1109/iaeac47372.2019.8997922>

- Thrun, S., Burgard, W., & Fox, D. (2005, September 20). *Probabilistic Robotics*. <https://doi.org/10.1604/9780262201629>
- Viktorová, L., & Šucha, M. (2019, August). Learning about advanced driver assistance systems – The case of ACC and FCW in a sample of Czech drivers. *Transportation Research Part F: Traffic Psychology and Behaviour*, *65*, 576–583. <https://doi.org/10.1016/j.trf.2018.05.032>
- Visser, H. J. (2006, June 21). *Array and Phased Array Antenna Basics*. Wiley. <https://doi.org/10.1604/978047087119510.1002/0470871199>
- Vlacic, L., Parent, M., & Harashima, F. (2001, June 1). *Intelligent Vehicle Technologies*. <https://doi.org/10.1604/9780750650939>
- Wang, Z., Wu, Y., & Niu, Q. (2020). Multi-Sensor Fusion in Automated Driving: A Survey. *IEEE Access*, *8*, 2847–2868. <https://doi.org/10.1109/access.2019.2962554>
- Wehr, A., & Lohr, U. (1999, July). Airborne laser scanning—an introduction and overview. *ISPRS Journal of Photogrammetry and Remote Sensing*, *54*(2–3), 68–82. [https://doi.org/10.1016/s0924-2716\(99\)00011-8](https://doi.org/10.1016/s0924-2716(99)00011-8)
- Wiggers, K. (2020, February 14). *Roboflow: Popular autonomous vehicle data set contains critical flaws*. VentureBeat. <https://venturebeat.com/ai/report-popular-autonomous-vehicle-data-set-contains-critical-flaws/>
- Wu, J., Zhu, J., Yang, L., Shen, M., Xue, B., & Liu, Z. (2014, January). A highly accurate ultrasonic ranging method based on onset extraction and phase shift detection. *Measurement*, *47*, 433–441. <https://doi.org/10.1016/j.measurement.2013.09.025>
- Xu, D., Anguelov, D., & Jain, A. (2018, June). PointFusion: Deep Sensor Fusion for 3D Bounding Box Estimation. *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. <https://doi.org/10.1109/cvpr.2018.00033>
- Yoo, J. H., Kim, Y., Kim, J., & Choi, J. W. (2020). 3D-CVF: Generating Joint Camera and LiDAR Features Using Cross-view Spatial Feature Fusion for 3D Object Detection. *Computer Vision – ECCV 2020*, 720–736. https://doi.org/10.1007/978-3-030-58583-9_43
- Yue Li, Jha, D. K., Ray, A., & Wettergren, T. A. (2015, July). Feature level sensor fusion for target detection in dynamic environments. *2015 American Control Conference (ACC)*. <https://doi.org/10.1109/acc.2015.7171097>
- Zambon, F., Sethi, D., Kuznetsova, R., & Racioppi, F. (2010, September 1). Next steps for road safety: findings from the European status report on road safety. *Injury Prevention*, *16*(Supplement 1), A239–A240. <https://doi.org/10.1136/ip.2010.029215.853>
- Zhang, H., Dai, G., Sun, J., & Zhao, Y. (2013, October). Unscented Kalman filter and its nonlinear application for tracking a moving target. *Optik*, *124*(20), 4468–4471. <https://doi.org/10.1016/j.ijleo.2013.03.013>
- Zhao, X., Qian, P., Lu, N., & Li, Y. (2020, November 18). Design and Experimental Study of High Precision Ultrasonic Ranging System. *2020 5th International Conference on Intelligent Informatics and Biomedical Sciences (ICIIBMS)*. <https://doi.org/10.1109/iciibms50712.2020.9336393>

- Zhou, Y., & Tuzel, O. (2018, June). VoxelNet: End-to-End Learning for Point Cloud Based 3D Object Detection. *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. <https://doi.org/10.1109/cvpr.2018.00472>
- Zolock, J., Senatore, C., Yee, R., Larson, R., & Curry, B. (2016, April 5). The Use of Stationary Object Radar Sensor Data from Advanced Driver Assistance Systems (ADAS) in Accident Reconstruction. *SAE Technical Paper Series*. <https://doi.org/10.4271/2016-01-1465>

ÖZGEÇMİŞ

Adı Soyadı : Furkan ŞEN
Doğum Yeri ve Tarihi : İstanbul – 21.03.1997
Yabancı Dil : İngilizce

Eğitim Durumu
Lise : Bandırma Anadolu Öğretmen Lisesi, Balıkesir 2015
Lisans : Bursa Uludağ Üniversitesi, Bursa 2021

Çalıştığı Kurum/Kurumlar : Türk Prysmian Kablo ve Sistemleri A.Ş 2021 – 2022
Oyak Renault Otomobil Fabrikaları A.Ş 2022 – Halen

İletişim (e-posta) : furkansen97@gmail.com

Yayınları :

Şen, F., & Yılmaz, G. (2023, 15 Mayıs). Lidar sensor-based perception in autonomous driving: performance assessment under different weather conditions. *9. Uluslararası Mühendislik ve Teknoloji Yönetimi Kongresi*, 380-389.

Şen, F., & Sağlam, Y. (2023, 15 Mayıs). Araç elektroniği sistemlerinde hat direnci hesabı ve geliştirilen akıllı hesaplama yönteminin analizi. *9. Uluslararası Mühendislik ve Teknoloji Yönetimi Kongresi*, 390-400.

Şen, F., Yüksel, E., Altingöz, C., & Feyzioğlu, A. (2021, November). Development of CPR B2ca s1a d1 class signal cables. *Latin American Conference on Natural and Applied Sciences, Universidad Juarez Autonoma de Tabasco, Villahermose, Mexico, November 5-6, 2021.*