Şerit Takibi Yapan Bir Sürücü Güvenlik Destek Sistemi

Muhammed Doruk ÇAPRAZ

T.C.
BURSA ULUDAĞ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ŞERİT TAKİBİ YAPAN BİR SÜRÜCÜ GÜVENLİK DESTEK SİSTEMİ

Muhammed Doruk ÇAPRAZ
0000-0003-4114-2702

Doç. Dr. Ersen YILMAZ
0000-0002-6620-655X
(Danışman)

YÜKSEK LİSANS TEZİ
ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

BURSA– 2024
Her Hakkı Saklıdır.

ÖZET

Yüksek Lisans Tezi

ŞERİT TAKİBİ YAPAN BİR SÜRÜCÜ GÜVENLİK DESTEK SİSTEMİ

Muhammed Doruk ÇAPRAZ

Bursa Uludağ Üniversitesi
Fen Bilimleri Enstitüsü
Devreler ve Sistemler Anabilim Dalı

Danışman: Doç. Dr. Ersen YILMAZ

Trafikte aktif olarak kullanılan araç sayısının artışı ile trafik kazalarında da önemli ölçüde bir artış gerçekleşmiştir. Bu kazaların alt sebepleri incelendiğinde şerit ihlali kaynaklı kazaların oranının yüksek olduğu dikkat çekmektedir. Trafik kazalarının önlenmesi için akademide ve sanayide çeşitli çalışmalar yapılmaktadır ve uygulayıcı kuruluşlar da bu önleyici sistemleri araçlarda bulundurmayı zorunlu hale getirmektedirler. Bu sistemlerden biri de şerit tespit sistemidir.

Bu çalışma kapsamında SGDS (Sürücü Güvenlik Destek Sistemleri)'den biri olan araç içi kamera kullanılarak bir şerit tespit sistemi geliştirilmiştir. Bu sistemlerin önemli dezavantajlarından biri yolda meydana gelen bozulmalar ve çevresel etmenlerin yola etkisinin sistemleri yanıltmasıdır. Bazı durumlarda araç sürüş esnasında meydana gelen hatalı algılamaları neticesinde sürüşe müdahale ederek trafik güvenliğini riske atabilmektedir. Araç içi kameradan alınan veriler Hollanda ve Almanya otoyollarından toplanmıştır.

Bu çalışmada gri tonlamalı geçiş, Canny kenar algılama ve Hough dönüşümü gibi görüntü işleme teknikleri incelenmiş ve uygulama detaylarından bahsedilmiştir. Uygulanan algoritmalar sonucunda alınan yol verileri ile sistemin performans ölçümleri gerçekleştirilmiştir. Çalışma kapsamında uygulanan görüntü işleme tekniklerinin performansı günün farklı zaman dilimlerinde ve hava koşullarında test edilerek ölçülmüştür. Bu sonuçlar ışığında sistemin hangi koşullarda daha başarılı olduğuna dair çıkarımda bulunulmuştur.

Yapılan çalışmalar sonucunda önerilen SGDS'nin gündüz-gece ve yağışlı-yağışsız hava durumlarında yapılan testlerinde sistemin %88,67'lik bir doğrulukla çalıştığı tespit edilmiştir. Çevresel etmenlerin şerit takip sistemleri üzerine olan etkileri hakkında çıkarımda bulunulmuştur.

Anahtar Kelimeler: Sürücü güvenlik destek sistemi, Şerit tespiti, Kenar tespiti, Görüntü işleme, Bilgisayarla görme
2024, xiii + 79 sayfa.

ABSTRACT

MSc Thesis

A DRIVER SAFETY ASSISTANCE SYSTEM THAT FOLLOWS LANE

Muhammed Doruk ÇAPRAZ

Bursa Uludag University
Graduate School of Natural and Applied Sciences
Department of Circuits and Systems

Supervisor: Assoc. Prof. Dr. Ersen YILMAZ

With the increase in the number of vehicles actively used in traffic, there has been a significant rise in traffic accidents. When examining the underlying causes of these accidents, it is notable that a high proportion are due to lane violations. Various studies are being conducted in academia and industry to prevent traffic accidents, and implementing organizations are making these preventive systems mandatory in vehicles. One of these systems is the lane detection system.

In this study, a lane detection system has been developed using an in-vehicle camera, which is one of the Driver Safety Support Systems (DSS). One major disadvantage of these systems is that road deteriorations and environmental factors affecting the road can mislead the systems. In some cases, erroneous detections during driving can lead to interventions that jeopardize traffic safety. Data for the system was collected from highways in the Netherlands and Germany.

This study examines image processing techniques such as grayscale conversion, Canny edge detection, and Hough transformation, and discusses their application details. The performance of the system was measured using road data obtained through the implemented algorithms. The performance of the applied image processing techniques was tested and measured at different times of the day and under various weather conditions. Based on these results, inferences were made regarding the conditions under which the system is more successful.

The proposed DSS, as a result of tests conducted during day-night and rainy-clear weather conditions, was found to operate with 88,67% accuracy. Inferences were made regarding the effects of environmental factors on lane-tracking systems.

Key Words: Driver safety support system, Lane detection, Edge detection, Image processing, Computer vision
2024, xiii + 79 pages.

ÖNSÖZ ve TEŞEKKÜR

Bu tez çalışmasının tamamlanmasında desteğini hiçbir zaman esirgemeyen başta danışmanım Doç. Dr. Ersen Yılmaz, bölüm hocalarım, Tofaş ve DAF Trucks'tan iş arkadaşlarıma teşekkürlerimi sunuyorum.

Ayrıca hiçbir zaman beni yalnız bırakmayan ve fedakârca destek olan eşime teşekkür etmek istiyorum.

Son teşekkürümü de tüm hayatım boyunca beni bir gün bile yalnız hissettirmeyen ve destekleyen aileme etmek istiyorum…

Muhammed Doruk ÇAPRAZ

İÇİNDEKİLER

ÖZET
ABSTRACT ..... İX
ÖNSÖZ VE TEŞEKKÜR X
SİMGELER VE KISALTMALAR DİZİNİ ..... Xİİ
ŞEKİLLER DİZİNİ ..... Xİİİ
ÇİZELGELER DİZİNİ XV
1.GİRİŞ 1
2.KURAMSAL TEMELLER VE KAYNAK ARAŞTIRMASI 6
2.1. Şerit takip sistemlerinde kullanılan sensörler 6
2.2. Sürücü güvenlik destek sistemi olarak kamera 8
2.3. Bilgisayarla görme 11
2.4. Kenar algılama algoritmaları 14
2.4.1. Laplacian kenar algılama 16
2.4.2. Canny kenar algılama 19
2.4.3. Roberts kenar algılama 19
2.4.4. Prewitt kenar algılama 22
2.4.5. Sobel kenar algılama 23
2.4.6. Hough kenar dönüşümü 25
2.5. Kameranın pozisyonlaması 29
2.6. Kamera verisi toplanması 30
2.7. İlgi bölgesi(Region of Interest – ROI) 31
3. MATERYAL VE YÖNTEM 33
3.1 Donanım ve Yazılımlar 33
3.1.1 Donanım 33
3.1.2 Yazılım 36
3.2 Test verisi 37
3.3 Uygulama 46
3.3.1. Kamera konumlandırılması 48
3.3.2. Uygulama çıktıları 49
4.BULGULAR VE TARTIŞMA 55
5.SONUÇLAR 77

SİMGELER ve KISALTMALAR DİZİNİ

Simgeler	Açıklama
ρ	Başlangıç noktasından düz çizgiye en yakın nokta
σ	Standart Sapma

Kısaltmalar	Açıklama
SGDS	Sürücü Güvenlik Destek Sistemi
UNECE	United Nations
ŞTU	Şerit Takip Uyarı
ŞAE	Şeritten Ayrılma Engelleme
STRADA	Swedish Traffic Accident Data Acquisition
COVID-19	Yeni koronavirüs hastalığı
LIDAR	Light Detection and Ranging
RADAR	Radio Detection And Ranging
LKAS	Lane Keep Assist System
SAE	Society of Automotive Engineers
GPU	Graphics Processing Unit
CPU	Central Processing Unit
IR	Infrared
FSDC	Full Self-Drive Capability
CSLP	Central Sensing Localization and Planning
MVC	Mono Video Camera
TB	Terabyte
GB	Gigabyte
Fps	Frame per second
MPEG	Moving Picture Experts Group
CAN	Controller Area Network
CAN FD	Controller Area Network Flexible Data-Rate
GPS	Global Positioning System
ROI	Region of Interes
RAM	Random Access Memory
LPDDR	Low-Power Double Data Rate
GPIO	General Purpose Input Output
Rpi	Rasperry Pi
LED	Light Emitting Diode
CSI	Camera Serial Interface
RGB	Red Green Blue
TP	True Positive
TN	True Negative
FP	False Positive
FN	False Negative

ŞEKİLLER DİZİNİ

Sayfa

Şekil 1.1.	SGDS komponentlerinin araç üstündeki yerleşimi (NMICPS TiHAN Foundation, 2022)	2
Şekil 1.2.	Mitsubishi sürücü destek sistem görselleri A) Ön kamera sistemi B) Lazer radar ünitesi C) Arka görüş kamerası (Mitsubishi Motors, 1995)	3
Şekil 1.3.	Araç şerit takip kamerası konumlandırma örneği (Toyota, 2022)	4
Şekil 2.1.	Tesla SGDS kamera pozisyonu ve rezistans (Tesla, 2024)	11
Şekil 2.2.	Şeritten ayrılma uyarı sistemi akış diyagramı (Pai et al., 2019)	13
Şekil 2.3.	Laplace operatörleri (A) 4 Komşulu Laplace Operatörü (B) 8 Komşulu Laplace operatörü	16
Şekil 2.4.	Piksel sınır belirleme (Gurusamy, 2017)	18
Şekil 2.5.	Canny kenar algılama algoritması uygulaması	19
Şekil 2.6.	Robert operatörü tarafından kullanılan maske	20
Şekil 2.7.	Giriş görseli	21
Şekil 2.8.	Roberts kenar algılama uygulaması	21
Şekil 2.9.	Prewitt filtresi uygulama örnekleri. A)x-ekseninde uygulanmış filtre örneği B) y-ekseninde uygulanmış filtre örneği C) x ve y eksenlerinde uygulanmış filtre örneği	23
Şekil 2.10.	Sobel filtresi	24
Şekil 2.11.	Sobel filtresi uygulanmış kalibrasyon görselleri A) x-ekseninde Sobel filtresi uygulanmış görsel (B)y-ekseninde Sobel filtresi uygulanmış görsel (C)x ve y ekseninde Sobel filtresi uygulanmış görsel	25
Şekil 2.12.	Kartezyen koordinat sistemi gösterimi	26
Şekil 2.13.	Kartezyen koordinatta elde edilen nokta	27
Şekil 2.14.	Birden fazla doğrunun oluşturduğu noktalar kümesi	27
Şekil 2.15.	Birden fazla doğrunun oluşturduğu noktalar kümesinin bölgelere ayrılmış gösterimi	28
Şekil 2.16	Hough uzayında oylama işlemi sonrası oluşan grafik	28
Şekil 2.17.	Sudoku üzerinde bir Hough dönüşümü denemesi (A) Sudoku görseli (B) Sudoku görseline Hough dönüşümü uygulaması (OpenCV, 2024)	29
Şekil 2.18.	Örnek bir araştırma aracı (Yurtsever vd., 2020)	30
Şekil 3.1.	Jetson Nano geliştirme kartı	34
Şekil 3.2.	Waveshare RPi camera (F) modeli (TinyTronics, 2024)	36
Şekil 3.3.	Program çıktıları klasör görünümü	40
Şekil 3.4.	Gece yağışlı hava deforme yol ekran çıktıları	41
Şekil 3.5.	Test videosu süreç akış şeması	47
Şekil 3.6.	Tez çalışmasında kullanılan aracın önden görüntüsü (A) Araç içinde Jetson nano yerleşimi (B) Test aracı içindeki kamera konumu (C) Test Aracı kamera çıktısı (D) Araç içi test ortamı (E)	49
Şekil 3.7.	Kalibrasyon görseli	49
Şekil 3.8.	Siyah beyaz dönüşümü uygulanmış kalibrasyon görseli	50
Şekil 3.9.	Gaussian filtresi uygulanmış kalibrasyon görseli	51
Şekil 3.10.	Canny kenar dönüşümü uygulanmış kalibrasyon görseli	51

Şekil 3.11. Matplotlib kütüphanesi ile kalibrasyon görselinin koordinat tespiti 52
Şekil 3.12. İlgi bölgesi üçgeni 53
Şekil 3.13. İlgi bölgesinin dışında kalan alanın kalibrasyon bölgesinden çıkarma uygulaması 53
Şekil 3.14. Hough dönüşümü uygulanmış kalibrasyon görseli 54
Şekil 3.15. Grafik üzerinde şeritten ayrılma tespiti (A) Sağ şeritten ayrılma (B) İdeal durum (C) Sol şeritten ayrılma 54
Şekil 4.1. Gündüz alınan ekran görüntüleri (A) Gündüz yağışlı hava (B) Gündüz yağışsız hava 55
Şekil 4.2. Gece alınan ekran görüntüleri (A) Gece yağışsız hava (B) Gece yağışlı hava 55
Şekil 4.3. Şerit çizgisi tespit algoritması değerlendirilecek program çıktıları (A) Doğru pozitif (B) Doğru Negatif (C) Yanlış pozitif (D) Yanlış negatif 57
Şekil 4.4. Şeritli yol hatalı tespit örnekleri (A) Şerit dışındaki bozucu etkiler (B) Şeritte meydana gelen genişlemeler (C) Yol kaplamasına çizilen şerit çizgisi dışı işaretler 63
Şekil 4.5. Gündüz yağışsız deforme yol örneği (A) Yolda meydana gelen yanıltıcı çizgi (B) Yolda zamanla meydana gelen deformasyon 70
Şekil 4.5. Gündüz yağışlı hava örnekleri (A) Yolda meydana gelen deformasyondan kaynaklanan hatalı tespit (B) Yol bariyerinin şerit olarak tespit edildiği bir örnek (C) Yol çalışması bölgesinde sonradan çizilen şerit çizgileri (D) Şeritsiz bölgede hatalı bir şekilde tespit edilen kaldırım 71
Şekil 4.6. Gece yağışlı hava örnekleri (A) Şeritsiz yolda yapılan yanlış pozitif örneği (B) Deforme olmuş olda yapılan yanlış pozitif örneği (C) Yol çalışması olan yolda tespit edilemeyen sağ şerit çizgisi 72
Şekil 4.7. Gece yağışsız hava örnekleri (A) Yol çalışmasında çizilen sarı çizgilerin etkisi (B) Şehir içinde yola yazılan ve çizilen şekilleri etkisi (C) İlgi bölgesi değişimlerinin etkisi 73

ÇİZELGELER DİZİNİ

Çizelge 3.1.	Gündüz yağışsız veri seti kare sayıları	41
Çizelge 3.2.	Gündüz yağışlı veri seti kare sayıları	42
Çizelge 3.3.	Gece yağışsız veri seti kare sayıları	42
Çizelge 3.4.	Gece yağışlı veri seti kare sayıları	43
Çizelge 3.5.	Hata matrisi	43
Çizelge 3.6.	Sektör profesyonellerine iletilen veri seti bilgisi	45
Çizelge 4.1.	Algoritmanın genel performans ölçümleri	57
Çizelge 4.2.	Algoritmanın performans metrikleri	58
Çizelge 4.3.	Yağışlı havada ölçülen performans metrikleri	58
Çizelge 4.4.	Yağışsız havada ölçülen performans metrikleri	59
Çizelge 4.5.	Gündüz ölçülen performans metrikleri	60
Çizelge 4.6.	Gece ölçülen performans metrikleri	60
Çizelge 4.7.	Yol koşullarının karmaşıklık matrisi elemanlarına dağılımı	62
Çizelge 4.8.	Gündüz yağışsız hava tüm değerlendirmecilerin değerlendirme sonuçları	65
Çizelge 4.9.	Gündüz yağışsız hava tüm değerlendirmecilerin performans metrikleri sonuçları	65
Çizelge 4.10.	Gündüz yağışlı hava tüm değerlendirmecilerin değerlendirme sonuçları	66
Çizelge 4.11.	Gündüz yağışlı hava tüm değerlendirmecilerin performans metrikleri sonuçları	66
Çizelge 4.12.	Gece yağışsız hava tüm değerlendirmecilerin değerlendirme sonuçları	67
Çizelge 4.13.	Gece yağışsız hava tüm değerlendirmecilerin performans metrikleri sonuçları	67
Çizelge 4.14.	Gece yağışlı hava tüm değerlendirmecilerin değerlendirme sonuçları	68
Çizelge 4.15.	Gece yağışlı hava tüm değerlendirmecilerin performans metrikleri sonuçları	68
Çizelge 4.16.	Hata analizi	73

1. GİRİŞ

Teknolojinin ve üretim teknolojisinin gelişmesi ve dünyadaki tedarik ağının hızla gelişmesi sayesinde kullandığımız ekipmanlar günden güne daha akıllı hale gelmektedir. Ulaşım için kullandığımız araçlar da bu gelişmelerden olumlu anlamda etkilenmektedir. Yeni geliştirilen sistemler bize konforun yanı sıra güvenlik de vaat etmektedir. Bu bağlamda, otomobiller, otobüsler, kamyonlar, hava ve deniz araçları yenilikçi güvenlik ekipmanları ile donatılmaktadır (Zam ve Yılmaz, 2019).

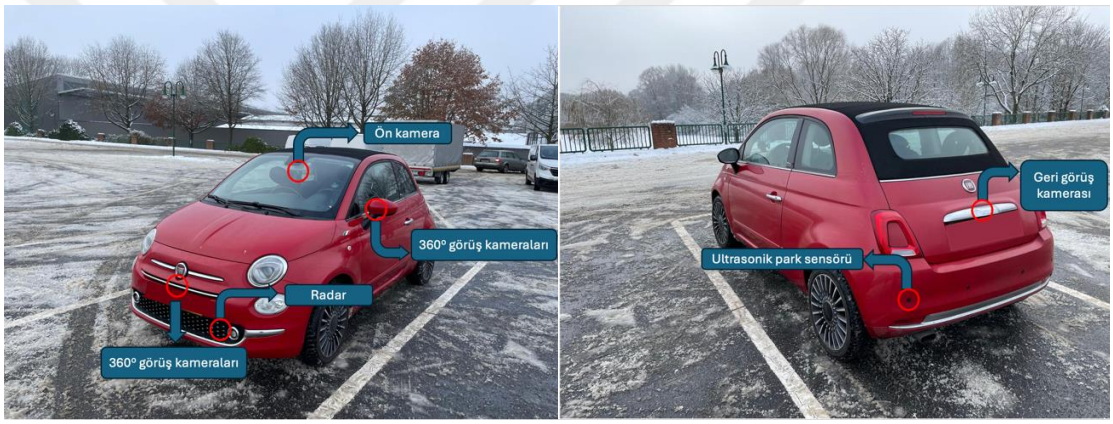
Trafik güvenliği günden güne daha çok önem kazanmakta ve bu alanda regülasyonlar ile araç üreticileri Sürücü Güvenlik Destek Sistemlerini (SGDS) ürettikleri araçlarda bulundurma zorunluluğu ile karşı karşıyadır. Trafikte insan hatasından kaynaklanan kazaların önüne geçmek için Birleşmiş Milletler Avrupa Komisyonu (United Nations Economic Comission for Europe[UNECE])'nun getirdiği bazı zorunluluklar ile birlikte Avrupa Birliğinde bulunan araçlarda 'Ön Kameralar' zorunlu hale gelmektedir. Şerit Takip Uyarı (ŞTU), Şeritten Ayrılma Engelleme (ŞAE), Tabela Algılama ve Nesne Algılama gibi özelliklere sahip olmayan araçlar trafiğe çıkmaya uygun bulunmayacaktır.

2022 yılının ilk yarısında Türkiye'de meydana gelen trafik kazalarını istatistikleri incelendiğinde, yaralanmalı ve ölümlü kazaların %86,29'u sürücü kaynaklı hatalardan kaynaklanmaktadır. Sürücü sebepli hataların kırınımına bakıldığı zaman, kazaların %10,47'lik bir oranının şerit izleme ve kurallara uymama kaynaklı olduğu görülmektedir (Emniyet Genel Müdürlüğü, 2022). Bu tarz kazaların önüne geçebilmek adına eklenen sistemlerin faydaları Cicchino (2018) tarafından incelenmiştir. Aynı marka ve model araçlardan ŞTU sistemi olan ve olmayan versiyonlarının incelenmesi sonucunda, 2009-2015 yılları arasında ABD'de meydana gelen kazalarda kazaların %18 azaldığı, yaralanmaların %24 azaldığı ve ölümlerin %86 oranında azaldığı tespit edilmiştir (Çapraz ve Yılmaz, 2024).

Bir başka çalışmada İsveç ülkesinde aynı marka ve model araçlarda ŞTU ve ŞAE sistemlerinin varlığı ve yokluğunun etkileri incelenmiştir. İsveç Trafik Kaza Veri

tabanından (STRADA) alınan verilere göre, sürücülerin yaralandığı kazalarda araçların 146'sında ŞTU sisteminin olduğu, 11'inde ŞAE sisteminin olduğu tespit edilmiştir. 1696 araç ise ŞTU veya ŞAE sistemlerine sahip değildir (Sternlund et al., 2017).

Dünyada trafik kazalarının önüne geçmek için çalışmalar sürmekte ve bu bağlamda SGDS'den fayda sağlanmaktadır. Gelişen kamera, radar ve lidar teknolojisi ile otomobil ve ticari taşıtlarda görev yapan yüksek performanslı donanımlar ile şerit algılama, tabela algılama, nesne algılama, yaya algılama işlemleri yapılabilmektedir. Bu sistemler yalnız başına çalıştığı gibi birbirleri ile de haberleşerek korelasyon ile de çalışabilmektedir. Bu sistemler sürüş güvenliğini artırmasının yanı sıra, yakıt ekonomisine de olumlu anlamda katkı sunmaktadır (Qian et al., 2020).



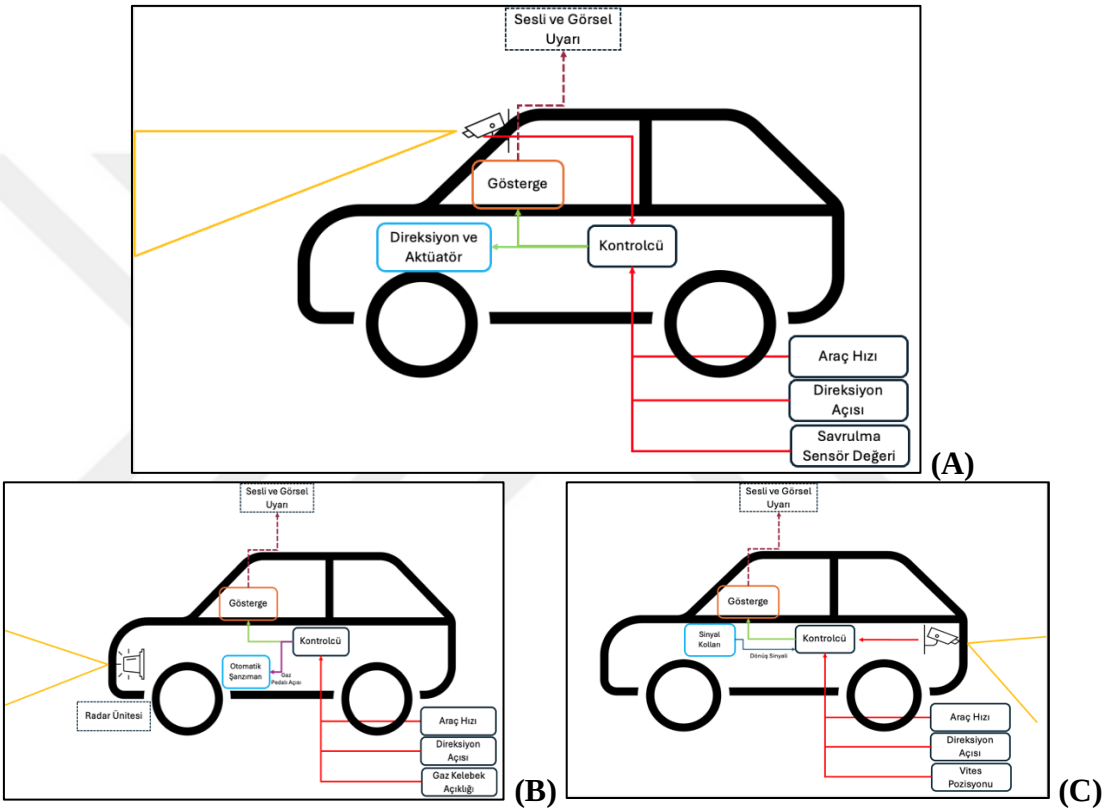
Şekil 1.1. SGDS komponentlerinin araç üstündeki yerleşimi

Şeritte kalma destek sistemlerinin geçmişi, araç otomasyonu ile ilgili ilk deneylerin başladığı 1990'lara kadar izlenebilir. O dönemde araştırmacılar, şerit işaretlerini algılamak ve bir aracı şeridinde tutmak için düzeltici direksiyon girdileri sağlamak üzere tasarlanmış şerit tutma sistemleri geliştirmeye başladılar.

Endüstriyel anlamda ilklerden biri olarak Mitsubishi Motor's 1998 yılında yaptığı basın açıklaması ile bir sürücü destek sistemi duyurdu. Sistem şeritten istem dışı ayrılan araç hakkında sürücüyü uyarmak ve aynı zamanda direksiyon müdahalesi ile aracı şeritte tutmak üzere tasarlanmıştır. Sistemin yapısı incelendiğinde iç ayna arkasına yerleştirilen bir kamera ile yol izlenerek şerit ihlali durumunda ilk olarak sesli ve görsel uyarı vererek

sürücüyü uyaracaktır. Direksiyon koluna takılan bir aktüatör ile de aracın şeritte kalması sağlanmaktadır.

Araç arkasına yerleştirilen bir kamera ile birlikte de sağ veya sol dönüş sinyali verilmesi durumunda araç arkasında kalan bölgelerin tespiti yapılmaktadır. Buna ek olarak araç ön tamponuna yerleştirilen bir lazer radar ile de öndeki aracın hızı ile iki araç arasındaki mesafe ölçülerek arkadan çarpmaların önüne geçilmesi hedeflenmiştir.



Şekil 1.2. Mitsubishi sürücü destek sistem görselleri **A)** Ön kamera sistemi **B)** Lazer radar ünitesi **C)** Arka görüş kamerası (Mitsubishi Motors, 1995)

Sonraki yıllarda, Toyota ve Volvo gibi diğer otomobil üreticileri de araçlarında şeritte kalma destek sistemlerini tanıttılar ve bazı sistemler aynı zamanda uyarlanabilir hız sabitleyici ve çarpışmadan kaçınma sistemleri gibi ek özellikler de içermektedir.



Şekil 1.3. Araç şerit takip kamerası konumlandırma örneği

Teknoloji geliştikçe, şeritte kalma destek sistemleri daha sofistike ve başarılı hale geldi. Son yıllarda birçok otomobil üreticisi, yalnızca şerit çizgilerini değil, aynı zamanda yoldaki diğer araçların konumunu ve hareketini, yayaları ve diğer potansiyel engelleri de algılayabilen gelişmiş sensörler ve algoritmalar kullandı.

SGDS komponentleri araç üstünde farklı pozisyonlara konumlandırılarak araç çevresindeki canlı ve cansız varlıkların konum, şekil, hız gibi bilgilerini çıkartmaktadır. Çıkartılan sonuçlar ışığında bu veriler işlenerek araç manevralarını yapılmaktadır. Araç otonomi seviyesine göre bu manevralar tamamen sürücüden bağımsız da yapılabilmektedir (Meyer et al., 2019).

Otomotivde otonomi seviyeleri Otomotiv Mühendisleri Topluluğu (SAE - Society of Automotive Engineers) tarafından L0 ilâ L5 arasında bir derecelendirmeye tabi tutulmaktadır. L0 tamamen manuel kontrolü, L1 “ayaklar serbest” şekilde hız sabitleme ile yolculuğu, L2 “eller serbest” şeklinde yolculuğu, L3 seviyesinde halen “eller serbest” yolculuk yapılırken araç aynı zamanda birçok güvenlik kritik müdahaleleri kendi kendine yapmayı taahhüt eder. L4 seviyesine çıkıldığında belirli bir alanda sürücüye ihtiyaç duymadan sürüşü gerçekleştirebilir, sürücü dilerse kontrolü tekrar ele alabilir. L5 seviyesi ise sürücüden tamamen bağımsız aracın tüm sürüşü kendi yaptığı senaryodur. Bu senaryo aynı zamanda ulaşması en güç olan seviyedir (SAE, 2021).

L2 seviyesi ile gelen “eller serbest” özelliğine sahip olabilmek için aracın çevreyi tarayarak kendini şeritte konumlandırması, hızını değiştirmesi, sürücüyü -ve mümkün olan donanımları ile- çevredeki araç ve yayaları uyarması gerekmektedir. Çevre kontrolü için, kameralar, ultrasonik sensörler, kısa-uzun menzilli radarlar ve lidarlardan faydalanılmaktadır.

Kameralar bu alanda şerit takibi, şeritten çıkma algılama, nesne algılama, otomatik kısa-uzun far ayarı gibi fonksiyonlardan sorumludur. Bu sistemlerle birlikte trafik kazalarında azalma ve kazalarda meydana gelen yaralanmaları indirilmesi hedeflenmektedir.

Bu tez çalışması neticesinde Şerit tespiti yapan bir sürücü güvenlik destek sistemi geliştirilecek ve çevresel koşullar altında performansı incelenecektir. Görüntü işleme tekniklerinin alt alanlarından biri olan kenar tespiti algoritmaları kullanılarak geliştirilen sistem farklı yol koşullarında ve günün farklı dilimlerinde test edilecektir. Aynı algoritmalar farklı bilgisayar sistemlerinde koşturularak tutarlılıkları test edilecektir. Önerilen bu sistem ile bilgisayarla görü ile trafik güvenliğinin artırılmasına yönelik çalışmalara katkı yapılması hedeflenmiştir.

2. KURAMSAL TEMELLER VE KAYNAK ARAŞTIRMASI

Karayolları Genel Müdürlüğü, trafik güvenliği işaretleme şubesi müdürlüğünün yayınladığı karayolu trafik işaretleme standartları-1 dökümanına göre şerit, trafik kontrolünü sağlamak için yol kaplaması üzerine sınırları belirli ölçüler aralığında olmak şartı ile çizilen sınır çizgileri ile belirlenmiş alanlardır. Bu alanlar kenar çizgisi ve şerit çizgisi gibi iki farklı çizgi tipiyle tanımlanabilmektedir. Kenar çizgisi yolun sınırlarını belirlerken, şerit çizgisi diğer şeritler arasındaki sınır belirleyicidir. Bu çalışmanın amacı bu çizgileri tespit etmek olan bir sistem geliştirilmektir. Bundan dolayı kenar çizgisi ve şerit çizgisi tek bir isimle şerit çizgisi olarak adlandırılacaktır. (KGM, 2020)

Otonom sürüş özelliklerinin otoriteler tarafından zorunlu hale getirilmesiyle birlikte, üreticiler de bu sistemler için araştırma ve geliştirme çalışmalarına ağırlık vermişlerdir. Bu çalışmaların neticesinde, daha yüksek performanslı ve daha yüksek verimli ürünler ortaya çıkartılması hedeflenmektedir.

İşlemci Grafik İşlemci Biriminin (GPU) daha güçlü hale gelmesiyle birlikte yeni nesil işlemcilerle birlikte daha hızlı matematiksel işlem yapmanın yolları açılmıştır. CPU'dan farklı olarak, paralel işlem yapabilme yeteneği sayesinde anlık olarak CPU'ya kıyasla daha fazla veri işlenebilmektedir (Luo et al., 2008).

2.1. Şerit Takip Sistemlerinde Kullanılan Sensörler

SGDS'de kullanılan sensörler aşağıdaki gibi görülebilir.

1. Kameralar
2. LIDAR Sensörleri
3. Radar Sensörleri
4. Kızılötesi Sensörler
5. Ultrasonik Sensörler

Şerit algılama sistemleri, yoldaki şerit işaretlerini algılamak ve izlemek için tipik olarak çeşitli sensörlere güvenir. Kullanılan sensörler, sisteme ve araca göre değişebilir. Şerit tespiti için kullanılan bazı yaygın sensör türleri aşağıda açıklanmıştır.

Kamera Sensörleri: Monoküler veya stereo kameralar, şerit tespiti için en yaygın olarak kullanılan SGDS'den biridir. Bu kameralar aracın önündeki yolun görüntülerini yakalar. Şeritler, trafik işaretleri ve yol kullanıcıları gibi nesneleri anlamlandırmak için yakalanan görüntüleri araç üstü SGDS bilgisayarlarına aktarır. SGDS bilgisayarı, görme algoritmalarını kullanarak şerit, trafik işareti ve yol kullanıcıları işler ve aracın otonomi seviyesine göre sürücüye bilgi veya uyarı gönderebilir. İleri seviye otonom bir araçta ise kararlar alarak bunları eyler.

Kızılötesi Sensörler: Kızılötesi (IR) sensörler kızılötesi radyasyon yayar ve algılar. Yol yüzeyi ile şerit işaretleri arasındaki yansıtma farklılıklarını analiz ederek şerit işaretlerini tespit etmek için kullanılabilirler. Kızılötesi sensörler, özellikle düşük ışık koşullarında veya görüşün sınırlı olduğu durumlarda kullanışlıdır (Kukkala et al., 2018).

Lidar Sensörleri: Işık Algılama ve Menzil (LiDAR) sensörleri, mesafeleri ölçmek ve çevrenin ayrıntılı bir 3B haritasını oluşturmak için lazer ışınları yayar. LiDAR sensörleri, yol yüzeyinden ve yakındaki nesnelerden yansıyan lazer ışınlarını analiz ederek şerit sınırlarını algılayabilir. Bununla birlikte, LiDAR, kamera sensörlerine kıyasla şerit algılama için daha az kullanılır (Senapati et al., 2021).

Radar Sensörleri: Radar sensörleri, nesneleri ve mesafelerini algılamak için radyo dalgalarını kullanır. Yol yüzeyinden yansıyan radar sinyallerine dayalı olarak şerit işaretlerini belirlemek için şerit algılama sistemlerinde kullanılabilirler. Radar sensörleri, görüşün azalabileceği olumsuz hava koşullarında özellikle kullanışlıdır (Kim et al., 2018).

Bu tez çalışmasında araç içi ön kamera kullanılarak şerit tespiti yapıldığı için kameraların performans değerlendirmeleri yapılacaktır.

2.2. Sürücü Güvenlik Destek Sistemi Olarak Kamera

Son yıllarda bilgisayarla görme alanında hızlı gelişmeler yaşanmıştır. Bu alanda meydana gelen gelişmeler sonucunda birçok sektörde bilgisayarla görme teknolojisinden faydalanılmaya başlanmıştır. Belli başlı kullanım alanlarına bakacak olursak, otomotiv, savunma sanayi, tarım ve tıp örnek olarak gösterilebilir (Hassaballah et al., 2019).

Bu gelişmelerin sonucu olarak artan müşteri talepleri sebebiyle COVID-19 pandemisi sürecinde tüm dünyayı etkisi altına alan bir çip krizi meydana gelmiştir. Bu krizin meydana gelmesinde gelişen teknoloji ve hızlanan çiplerin ev eşyalarında kullanımının artması ve tüm dünya genelinde yüksek talep görmesi büyük rol oynamıştır. Bu krizden en çok etkilenen endüstrilerden biri de otomotiv sektörü olmuş, üretici firmalar aylarca üretimlerine ara vermek durumunda kalmıştır (Wassen et al., 2022).

Otomobil SGDS olarak kullanılacak ön kamera için minimum sistem gereksinimleri, ilgili kamera modeline ve kullanım amacına göre değişebilir. Bununla birlikte, genel olarak, modern bir otomobilde ön kamera için bazı ortak minimum sistem gereksinimleri şunlardır:

Kamera çözünürlüğü: Kameranın minimum çözünürlüğü 720p olmalıdır, ancak daha iyi görüntü kalitesi için daha yüksek çözünürlükler önerilir. Otomotiv üreticilerinin kullanmış olduğu kameralara örnek olarak aşağıdaki örnekleri inceleyebiliriz.

İşlemci: Kamera, görüntü verilerini gerçek zamanlı olarak işleyebilen bir işlemci ile donatılmalıdır. Bu genellikle en az 1 GHz saat hızına ve çoklu çekirdeğe sahip bir işlemci gerektirir.

- Tesla: Tesla'nın Otopilot sistemi, Tam Kendi Kendine Sürüş Bilgisayarı (FSDC) adı verilen özel yapım bir işlemci kullanır. FSDC, saniyede 2300 kareye ve saniyede 36 trilyon işleme kadar işleyebilen yapay zekaya özgü iki işlemciye sahiptir. Bu bilgisayar 3 farklı kamera ile beslenerek otonom sürüş özellikleri hayata geçirilir (Bannan et al., 2019).

- BMW: BMW'nin mevcut ön kamera sistemi, görüntü tabanlı gelişmiş sürücü destek sistemlerinde uzmanlaşmış bir Intel yan kuruluşu olan Mobileye'den bir işlemci kullanıyor. EyeQ4 işlemci saniyede 2,4 gigapiksel işleyebilir ve nesne algılama, şeritten ayrılma uyarısı ve yaya algılama özelliklerine sahiptir (Jaeseok Kim et al., 2014).
- Audi: Audi'nin Audi Pre Sense Front adlı ön kamera sistemi, Delphi'den Merkezi Algılama Yerelleştirme ve Planlama (CSLP) platformu adı verilen bir işlemci kullanır. CSLP platformu, nesneleri algılayıp sınıflandırmak ve sürüş kararları vermek için kameralardan, lidardan ve radardan gelen sensör verilerini analiz etmek için yapay zeka ve makine öğrenimi algoritmalarını kullanır.
- Mercedes-Benz: Mercedes-Benz'in Aktif Fren Yardımı adlı ön kamera sistemi, Bosch'un Mono Video Kamera (MVC) adlı bir işlemcisini kullanıyor. MVC, yayaları ve diğer araçları tespit edip sınıflandırabilir ve bir çarpışmayı önlemek için sürücüye frenlemede yardımcı olabilir.

Araba üreticilerinin kamera sistemleri için genellikle özelleştirilmiş veya tescilli işlemciler kullandığını belirtmek gerekmektedir. Bu nedenle teknik özellikler, üreticinin ürün gamında yer alan tüm araç serisinde değişiklik gösterebilir.

Depolama: Araç otonomi seviyesi arttıkça araç üstünde bulunan sensör miktarı artmakta ve bu sensörlerin ürettiği veri miktarı da artış göstermektedir. Günümüzde araç ön kamerası saat 70 GB'tan 300GB'a kadar veri üretebilmektedir. Çekilen görüntülerin kısa süreliğine de olsa saklanabilmesi için en az 2 TB ila 11 TB arasında depolama önerilir. Kaza veri kayıt sistemleri kaza öncesi ve sonrası bazı bilgileri kayıt altında tutarak kazanın sebeplerini aydınlatma için kullanılmaktadır. Saklama ihtiyacı olmayan veriler zaman aşımına uğrayarak araçtan silinecektir (Madhok et al., 2019).

Bir otomobil ön kamera sistemi için depolama gereksinimleri, kameranın çözünürlüğüne, kare hızına ve kaydedilen görüntüleri saklamak istediğiniz sürenin uzunluğuna bağlı olacaktır. Depolama için göz önünde bulundurulması gereken bazı genel yönergeler şunlardır:

- Kamera çözünürlüğü: Kameranın çözünürlüğü ne kadar yüksek olursa, kaydedilen görüntüleri saklamak için o kadar fazla depolama alanı gerekir. Örneğin, 1080p çözünürlükte bir kamera kaydı, 720p çözünürlükte bir kamera kaydından daha fazla depolama alanı gerektirecektir.
- Kare hızı: Kare hızı ne kadar yüksek olursa, kaydedilen görüntüleri saklamak için o kadar fazla depolama alanı gerekir. Saniyede 30 kare (fps) hızında kayıt yapan bir kamera, 15 fps hızında kayıt yapan bir kameradan daha fazla depolama alanı gerektirir (Dabral S. et al., 2014).
- Depolama süresi: Gereken depolama miktarı, kaydedilen çekimi ne kadar süre depolamak istediğinize bağlı olacaktır. Yalnızca birkaç günlük çekimi saklamak istiyorsanız, birkaç haftalık veya aylık çekimi depolamak istediğinizden daha az depolama alanına ihtiyacınız olacaktır.
- Sıkıştırma: Çoğu ön kamera sistemi, kaydedilen görüntüleri depolamak için gereken depolama miktarını azaltmak için bir tür sıkıştırma kullanır. Yaygın sıkıştırma formatları arasında H.264, H.265 ve MPEG-4 bulunur (Wang Y. et al., 2023).

Güç: Kamera, aracın elektrik sisteminde çalışabilmeli ve araç kapalıyken bile sürekli çalışmayı sağlamak için pil gibi bir yedek güç kaynağına sahip olmalıdır. Güncel araçlar bu enerjiyi araç bataryasından almaktadırlar.

Haberleşme: Kameranın yoldan topladığı görüntüleri işledikten sonra aracın gerekli aksiyonları alması için elde edilen verileri diğer elektronik kontrol ünitelerine iletmesi gerekmektedir. Bu iletişim için günümüzde en yaygın olarak kullanılan protokol CANBus (Controlled Area Network)'tır. Ancak verinin artması ve araçların otonom olma yolunda hızla ilerlemesi nedeniyle daha hızlı ve daha fazla veri taşıyabilen haberleşme protokollerine ihtiyaç doğmuştur. Bunun için CAN-XL ve CAN-FD gibi CAN tabanlı haberleşme protokolleri geliştirilmiştir. Ancak veri paketleri daha da büyükdükçe Flexray ve Ethernet gibi haberleşme protokollerine de ihtiyaç duyulmaktadır (Broux et al., 2022).

Montaj: Kamera aracın yolu net görebileceği bir noktada konumlandırılması gerekmektedir. Günümüzde ön kameralar yaygın olarak ön cam dikiz aynası arkasında

konumlandırılmaktadırlar. Bunun başlıca sebepleri, silecekler yardımıyla sürekli olarak temizlenebilmesi ve görüşü kaybetmemesi, konum olarak aracın en üst noktalarından biri olması sayesinde geniş bir görüş açısı sağlaması ve kaza durumunda ön tampona kıyasla daha az hasar görmesi verilebilir. Tüm bu sebeplerden dolayı araç kameraları aracın ön camında, camın ortasında yer bulmaktadır. Bazı modeller görüş kaybını en aza indirmek için kameranın olduğu bölüme rezistans koyarak camın buhar yapması nedeniyle görüş kaybı yaşamasını engellemektedirler. Şekil 2.1 buna bir örnek olarak verilebilir.



Şekil 2.1. SGDS kamera pozisyonu ve rezistans

Yukarıda açıklanan sistem gereksinimlerini karşılayan kameraların yaygınlaşması sonucunda otomotivde araçlarda kameraların SGDS olarak kullanımı hızla yaygınlaşmıştır. Kameraların ana görevi çevreyi gözlemlemek, nesneleri tanımlamak ve anlamlandırmak, şeritlerin tespitini yapmak ve diğer sensörler ile koordinasyon içinde çalışarak aracı ve çevreyi mümkün olan en yüksek koruma seviyesinde sürülebilir halde tutmaktır (Kocić J. et al., 2018).

2.3. Bilgisayarla Görme

Bilgisayarla görme, makine öğrenmesi ve yapay zekanın alt kategorilerinden biridir. Bilgisayarlar, insanlar bilgisayarları eğitmeye ve belirli girdiler yardımıyla kendi kendine öğrenmelerine uygun hale getirmeleri ile günlük problemlerin çözümünde yaygın olarak kullanılmaya başlanmıştır.

İnsan beyni nesneleri küçük yaşlardan itibaren görerek hafızasında saklamakta ve bu nesneleri tekrar görmesi durumunda hafızadan çağırarak anlamlandırmaktadır. Bilgisayarla görme teknolojisinde ise nesneler bilgisayara önceden öğretilerek (bir veri tabanına kaydedilme) tüm veri tabanı nesneleri ile benzerlikleri kontrol edilerek benzerliği yüksek nesneler eşleştirilerek sınıflandırma yapılmaktadır.

Bilim insanları günlük hayatta karşılaştığımız problemlerin çözümü için ise yüksek işlem kapasitesine sahip olan bilgisayarlardan faydalanmaya başlamıştır. Görü işlemini gerçekleştirmek için ise kameralardan faydalanılmaya başlanmıştır. Karşılaşılan problemin tipine göre, gerçek zamanlı olarak görüntüleme yapılarak bu görüntüler anlık olarak işlenerek çıktı elde edilebilmektedir. Bunun yanı sıra, daha önceden kaydedilen görüntüler ile daha sonra işlenerek anlamlandırılabilmektedir. Yapılacak işleme göre optimum seçime karar verilmektedir.

Bilgisayarla görme farklı alt alanlara ayrılmaktadır. Bunlar kenar tespiti, nesne algılama, yüz tanıma, hareket ve eylem algılama ve insan poz tahminidir (Voulodimos et al., 2018).

Bu çalışmada otonom araçlar için geliştirilen şerit takibi uygulamaları için bir Şerit Takip Sistemi tasarlanacaktır. Bu sistem için farklı kenar tespiti algoritmaları incelenecektir. Bu algoritmalar farklı deney donanımlarında test edilerek en yüksek doğruluğa sahip olan algoritma ve donanım tespit edilmeye çalışılacaktır.

Görüntü İşleme:

Görüntü işleme, dijital görüntüleri anlamlandırarak, çıkartılan anlam ışığında kullanılmaya hazır hale getirme işlemidir. Eldeki görüntüyü iyileştirme, bulanıklaştırma, görüntü içinde canlı cansız varlıkları arama gibi operasyonlar için kullanılabilmektedir. Örnekler çalışma alanına göre artırılabilir. Görüntü işlemenin kullanıldığı sektörlere bakılacak olursa, otomotiv, uzay ve savunma sanayii, tıp, endüstriyel üretim ve akıllı ev aletleri verilebilir. Başarılı bir görüntü işleme için gerekli olan süreç Şekil 2.2'de akış diyagramı şeklinde gösterilmiştir.



Şekil 2.2. Şeritten ayrılma uyarı sistemi akış diyagramı (Pai et al., 2019)

Giriş görüntüsü: Üzerinde çalışılan görüntünün kalitesi yapılan işlemlerin ardından alınacak çıktının anlamlandırılmasını kolaylaştıracaktır. Bundan dolayı uygulama için gereken minimum isterler belirlendikten sonra buna uygun bir görüntüleme cihazı tercih edilmelidir. İşlem bir kamera ile yapılacaksa mümkün olan en yüksek çözünürlüğe sahip kamera tercih edilmelidir. Tıbbi anlamda bir analiz gerekiyor ise yine görüntünün elde edildiği cihazdan en yüksek kalitede giriş görüntüsü alınmalıdır. Daha başarılı sonuçlar için bu hususlar göz önünde bulundurulmalıdır. İlgi bölgesi belirlemeye ilerleyen bölümde detaylıca değinilmiştir.

Ön görüntü işleme görüntü işlemenin temel adımlarından biridir. İçerisinde birden fazla işlemi barındırmaktadır. Bunlar, gürültü giderme, kontrast pekiştirme, renk düzeltme, segmentasyon ve özellik çıkarmadır.

Gürültü giderme: Giriş görüntüsünde gelen gürültüyü gidermek için uygulanan adımdır. Giriş görüntüsünde gürültü, sensörden, görüntü sıkıştırma işleminden veya düşük ışıktan kaynaklanabilmektedir. Bu adımdaki amaç, görüntüyü mümkün olan en yüksek seviyede koruyarak görüntüde yer alan gürültüyü ortadan kaldırmaktır. Bazı yaygın gürültü

giderme işlemlerine Gaussian blur, medyan filtreleme ve dalgacık gürültü giderme örnek olarak verilebilir (Flusser et al., 2016).

Kontrast pekiştirme: Bu teknik görüntüdeki farklı bölgeleri kontrastı yükselterek farklı bölgeler arasındaki farkı çoğaltarak ayırt edilebilir bir hale getirmek için kullanılmaktadır. Medikal görüntüleme gibi çalışmalarda faydalı olabilmektedir (Chitradevi et al., 2014).

Renk düzeltme: Görüntüdeki renk dengesini sağlayabilmek için kullanılmaktadır. Daha çok görüntü kalitesinin yüksek olması istenen alanlarda kullanılmaktadır. Fotoğrafçılık sektörü buna örnek olarak verilebilmektedir.

Görüntü segmentasyonu: Görüntü bölümleme, bir görüntünün renk, doku veya diğer özelliklerdeki benzerliklere dayalı olarak anlamlı bölgelere bölünmesini içerir. Bu, nesne algılama veya izleme gibi görevler için, medikal görüntülemede hastalıklı dokunun tespitinde, obje sayma görevlerinde yaygın şekilde kullanılmaktadır. Görüntü segmentasyon işlemine örnek olarak eşiklendirme, kenar tespiti ve bölge büyütme verilebilir (Cheng et al., 2000).

Özellik çıkarma: Giriş görselinden ilgilenilen bölgeleri tespiti ve tanımlanması işlemi özellik çıkarımıdır. Yaygın olarak nesne tanıma ve sınıflandırma işlemlerinde kullanılmaktadır. Kenar tespiti, köşe tespiti ve doku çözümlemesi örnek olarak verilebilir. (Kumar et al., 2014).

2.4. Kenar Algılama Algoritmaları

Nesne tespiti uygulamalarında kullanılan araçlardan biri kenar algılamadır. Bir görüntüde taranan piksellerde ani değişimlerin olduğu ve süreksizliklerin tespit edilmeye yönelik yapılan çalışma kenar tespitidir. Bu çalışmalarda görsel sisteme girdi olarak verilir. Ardından siyah-beyaz dönüşümü gerçekleştirilir. Bu dönüşümün ardından kenar tesit algoritması çalıştırılarak çıktılar elde edilir (Ansari et al., 2017).

Kenar tespiti için birçok farklı teknik mevcuttur. Bunlardan öne çıkanlar, Canny, Roberts, Prewitt ve Sobel'dir. Her bir algoritmanın ardında farklı matematik uygulamaları yatmaktadır (Sharif et al., 2002).

2.4.1. Laplacian Kenar Algılama

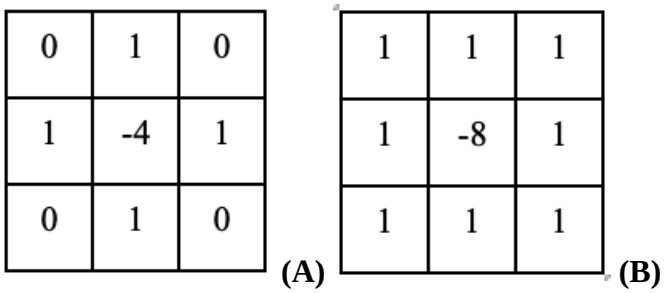
Laplace kenar algılayıcı, görüntü işlemde kenarları tespit etmek için kullanılan bir ikinci dereceden türev yöntemidir. Görüntüde yoğunluğun hızla değiştiği bölgeleri, yani kenarları veya sınırları belirler. Laplace, bir görüntünün ikinci türevini hesaplayan bir skaler diferansiyel operatördür. İki boyutlu bir görüntü *I(x,y)* için Laplace ∇^2 Denklem (1)'deki gibi ifade edilir. Aşağıdaki denklem x ve y yönlerinde ikinci türevleri toplar.

$$\nabla^2 I(x,y) = \frac{\partial^2 I(x,y)}{\partial x^2} + \frac{\partial^2 I(x,y)}{\partial y^2} \quad (1)$$

İkinci türev, Laplace tarafından temsil edilir ve yoğunluk değişikliklerine karşı oldukça hassastır. Bir görüntüdeki kenarlar, yoğunluğun önemli ölçüde değiştiği yerlere karşılık gelir, bu da ikinci türevde sıfır geçişlerine yol açar. Laplace, bu bölgeleri vurgulayarak kenarların tespit edilmesini kolaylaştırır. (Davies, 2012)

Laplace operatörü genellikle bir konvolüsyon maskesi veya çekirdek kullanılarak uygulanır. Ayrık bir görüntüde Laplace çekirdeği için en çok kullanılan matrisler Şekil 2.3'te gösterilmiştir. Aşağıdaki matrisler görüntüye konvolüsyon yapılarak Laplace sonucu elde edilmektedir. Elde edilen görüntü kenarları vurgular ve sıfır geçişlerinin tespiti ile kenarlar çıkartılabilir.

Tüm yönlerdeki kenarları bulabilmesi ve kolay uygulanabilir olması avantajları arasında sayılabilirken, gürültüye karşı hassas olması olumsuz yanlarındandır. Gürültüden daha az etkilenmesi için giriş görselinin filtre ile gürültüden arındırılması tavsiye edilmektedir.



Şekil 2.3. Laplace operatörleri **(A)** 4 Komşulu Laplace Operatörü **(B)** 8 Komşulu Laplace operatörü

2.4.2. Canny Kenar Algılama

Canny Kenar algılama John Canny tarafından 1983 yılında ileri sürülmüştür. Kenarları tespit etmeden önce resimdeki gürültüyü çıkarmak üzere tasarlanmıştır. Canny diğer metotlara göre kenar çıkarmada daha başarılı sonuçlar vermektedir. Bir görseldeki çok sayıdaki kenarı tespit ederek, resimdeki gürültüyü başarılı bir şekilde ortadan kaldırabilmektedir (Ansari et al., 2017).

Canny algoritmasını diğer algoritmalardan ayıran avantajları;

1. Hatayı minimize etmesi
2. Kenar tespitinde gerçek kenar noktasına en yakın tespiti yapması
3. Her bir gerçek kenar noktası için tek bir kenar tespiti yapması

Örnek olarak verilebilir.

Canny kenar algılama algoritması beş aşamada uygulanmaktadır.

1. Yumuşatma
2. Gradyan büyüklüğünün ve yönünün bulunması
3. Gradyan vektörü yönünde zayıf kenar noktalarını baskılama
4. İkili eşik değeri yöntemi ile kenarların birleştirilmesi
5. Histerezis ile kenar izleme

Bu işlemlerin açıklamasına bakacak olursak,

Yumuşatma;

Canny kenar algılama algoritması yumuşatma işlemini Gauss filtresi ile gerçekleştirmektedir. Gauss filtresi denklem (2)'de görülmektedir.

$$\mathrm{G}(\mathrm{x},\mathrm{y}) = \frac{1}{2\pi\sigma^2}\exp\left(-\frac{x^2+y^2}{2\sigma^2}\right) \tag{2}$$

Burada σ işareti standart sapmayı gösterir.

Gradyan Büyüklüğünün ve Yönünün Bulunması;

Görüntünün, Gauss fonksiyonun x ve y doğrultusunda birini dereceden türevinin alınması sürecidir. Bu işlemin ardından büyüklük değeri için denklem (3) ve yön için denklem (4)'ten faydalanılır.

$$|\mathrm{G}(\mathrm{x},\mathrm{y})| = \sqrt{(G_x\,(\mathrm{x},\mathrm{y})^2 + G_y\,(\mathrm{x},\mathrm{y})^2)} \tag{3}$$

$$\theta(\mathrm{x},\mathrm{y}) = \operatorname{arctg}\left(\frac{G_y\,(\mathrm{x},\mathrm{y})}{G_x\,(\mathrm{x},\mathrm{y})}\right) \tag{4}$$

Gradyan vektörü yönünde zayıf kenar noktalarını baskılama işlemi;

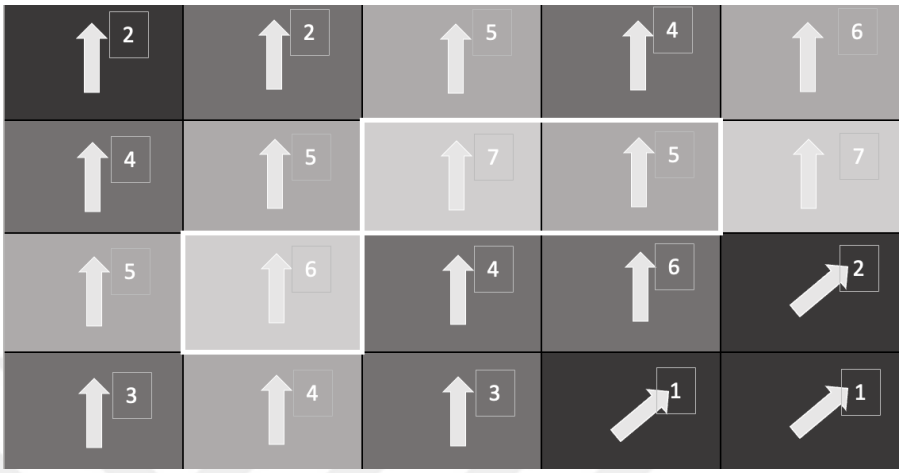
Üretilen görüntü bulanık kenarlarla sonuçlanır. İdeal olarak, son görüntünün ince ve keskin kenarları olmalıdır. Bu nedenle, görüntüde bir baskılama işlemi uygulanması gerekmektedir.

Baskılama işlemi tespit edilen kenarda maksimum değere sahip pikseli bularak çalışır. Bu pikseller korunarak bulanıklığa neden olan pikseller silinmektedir.

Bu işlem 3 adımda gerçekleştirilmektedir;

1. Maksimum değere sahip pikselin 8 bağlantılı komşusu θ gradyan yönüne en yakın 45^{o}'ye yuvarlanır.
2. İlgili pikselin kenar kuvveti pozitif ve negatif gradyan yöndeki piksellerin kenar kuvvetleriyle kıyaslanır. Gradyan yönü kuzey ise ($\theta = 90^0$) kuzey ve güney yönündeki pikseller kıyaslanır.
3. İlgili piksel kenar gücü en yüksek değere sahipse, kenar kuvvetinin değeri korunmalıdır. Değil ise bu piksel kaldırılmalıdır.

Böylece kenar pikselleri netleştirilirken bulanıklığa neden olan pikseller görselden uzaklaştırılacak ve net olarak kenarlar tespit edilmiş olacaktır.
Yukarıda açıklanan süreç Şekil 2.4'te gösterilmektedir.



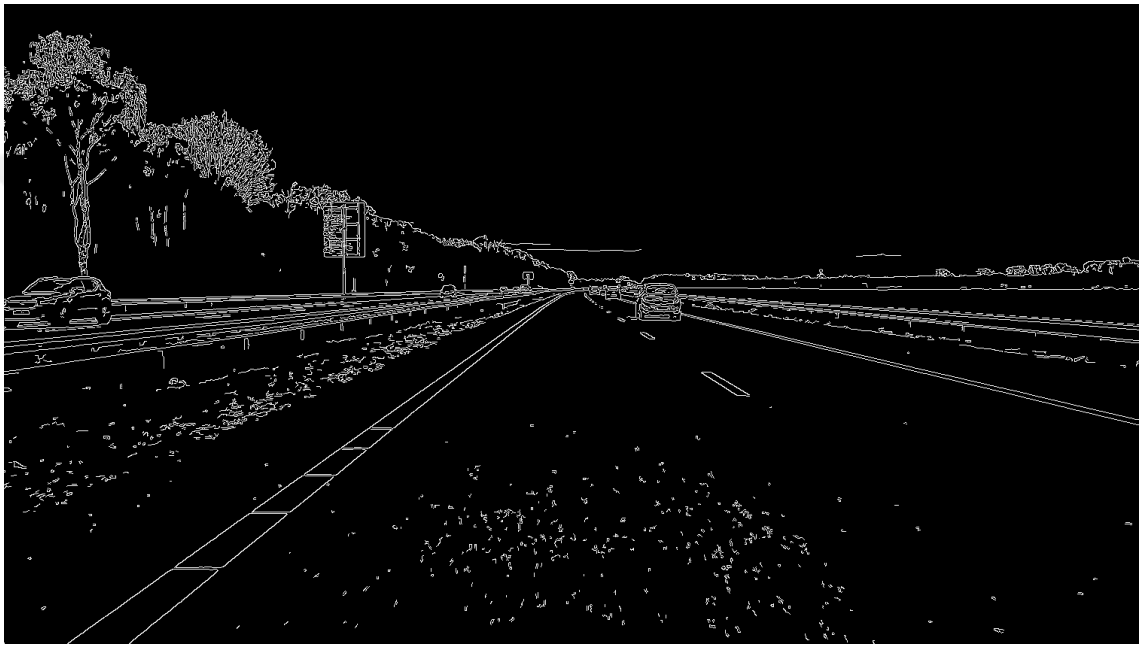
Şekil 2.4. Piksel sınır belirleme (Gurusamy, 2017)

Görselde görüldüğü üzere neredeyse tüm pikseller kuzeyi gösteren gradyan yönüne sahiptir. Bu nedenle kuzey ve güneyindeki pikseller ile karşılaştırma işlemi yapılmaktadır. Bu örnekte maksimum olarak tanımlanan pikseller beyaz kenarlık ile gösterilmiştir. Diğer tüm pikseller bastırılarak görselde kenarlar net olarak gösterilmiş olacaktır (Song et al., 2017).

İkili eşik değeri yöntemi ile kenarların birleştirilmesi işlemi;
Zayıf kenar noktalarını baskılama işlemi sonrasında kalan bazı kenar pikselleri de işaretlenmektedir. Bu kalan pikseller genellikle pürüzlü yüzeylerde ve gürültülü görüntülerde meydana gelmektedir. Bu sorunun giderilmesi için kenarlar daha güçlü şekilde renklendirilmelidir. Bunun için belirli bir eşik değeri kullanılması gerekmektedir. Canny Kenar Algılama algoritması burada çift eşikleme kullanmaktadır. Yüksek eşikten daha güçlü olan kenar pikselleri güçlü olarak işaretlenir. Düşük eşik değerinden daha zayıf olan kenar pikselleri ise bastırılır. İki eşik arasında kalan piksel değerleri ise zayıf olarak işaretlenir.

Histerezis ile kenar izleme;

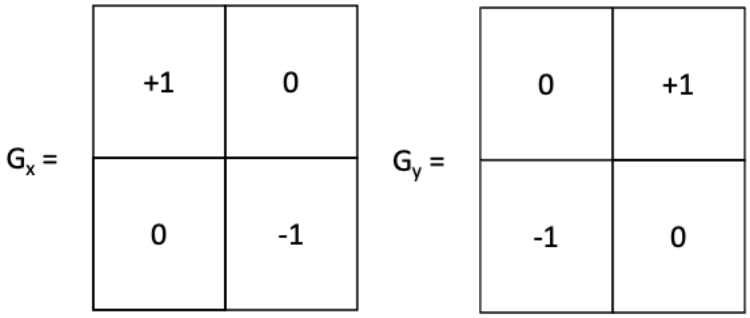
Yukarıda gerçekleştirilen işlemlerden sonra, güçlü kenarlar keskin kenarlar olarak adlandırılmıştır. Zayıf kenarlar görüntüye yalnızca güçlü kenarlar ile bağlantılı iseler ekleneceklerdir. Mantıken gürültü ve renk gibi nedenlerin güçlü kenar ile sonuçlanma ihtimali düşüktür. Bu nedenle güçlü kenarlar yalnızca orijinal görüntüdeki gerçek kenarlar sayesinde oluşacaktır. Zayıf kenarlar ise gerçek kenarlardan veya gürültü/renk varyasyonları neticesinde tanımlanabilir.



Şekil 2.5. Canny kenar algılama algoritması uygulaması

2.4.3 Roberts Kenar Algılama

Roberts kenar algılama metodu resim üzerindeki 2x2 boyutlu geçişleri ölçerek işlemi gerçekleştirmektedir. Şekil 2.6'da konvolüsyon matrisleri görülmektedir. Bu yöntem ile keskin kenarların ortaya çıkartılması amaçlanmaktadır. Daha iyi performans almak için sistem net görseller ile beslenmelidir. Zira 2x2'lik matrisler kullanarak çalıştığı için net olmayan(bulanık) resimlerde kenar bulma konusunda yüksek performans gösterememektedir (Shrivakshan et al., 2012).



Şekil 2.6. Robert operatörü tarafından kullanılan maske

Bu işlemleri gerçekleştirirken aşağıdaki formülleri kullanabiliriz.

$$|\mathrm{Gx}| = |\mathrm{P1} - \mathrm{P4}| \tag{5}$$

$$|\mathrm{Gy}| = |\mathrm{P2} - \mathrm{P3}| \tag{6}$$

Olacak şekilde,

$$|\mathrm{G}| = |\mathrm{Gx}| + |\mathrm{Gy}| \tag{7}$$

$$|\mathrm{G}| = \sqrt{(Gx^2 + Gy^2)} \tag{8}$$

Formülleri kullanılarak bulunabilir. Tespit edilen kenarın resim ile yapmış olduğu açı aşağıdaki formül kullanılarak bulunabilir. Şekil 2.7'de kullanılan giriş görseli ve Şekil 2.8'de uygulama sonrası ortaya çıkan kenarlar görülebilmektedir.

$$\theta = \arctan\left(\frac{Gx}{\mathrm{Gy}}\right) - \frac{3\pi}{4} \tag{9}$$



Şekil 2.7. Giriş görseli



Şekil 2.8. Roberts kenar algılama uygulaması

2.4.4. Prewitt Kenar Algılama

Prewitt Kenar Algılama, dijital görüntülerde kenarları algıla işlemi için yaygın olarak kullanılan metotlardan biridir. Bu metot, görüntü yoğunluğunun yatay ve dikey yönlerdeki değişim oranını temsil eden, görüntü yoğunluğu fonksiyonunun birinci dereceden gradyanın hesaplanması ilkesine dayanır. Prewitt operatörü gradyan değerlerini elde etmek için görüntüyle evrilen, biri yatay biri dikey iki yön için 3x3 matrislerden oluşur.

Yatay matrislerin sağ kısmında pozitif değeler, sol kısmında ise negatif değer yer alırken orta kısmında sıfırlar yer almaktadır. Bunun gibi, dikey matris alt satırda pozitif değerlere, üst satırda negatif değerlere ve orta sütunda ise sıfırlara sahiptir. Görüntünün bu matrislerle evrişimi, biri yatay yön ve diğeri dikey yön için olmak üzere iki gradyan görüntü oluşturur (Yang et al., 2014).

Kenar kuvveti daha sonra Pisagor teoremi kullanılarak hesaplanan gradyanın büyüklüğü kullanılarak iki gradyan görüntüsü birleştirilerek hesaplanır. Kenarın yönü, dikey ve yatay gradyan değerlerinin oranının arktanjant fonksiyonu kullanılarak hesaplanır.

Prewitt operatörü, bilgisayarlı görü ve görüntü işlemede yaygın olarak kullanılan basit ve hızlı bir kenar algılama yöntemidir. Ancak, gürültüye duyarlı olabilir ve yanlış kenarlar üretilebilir. Bu nedenle, kenar algılamanın doğruluğunu artırmak için genellikle diğer kenar algılama yöntemleriyle birlikte kullanılır. Şekil 2.9'da Sobel filtresinin kullanımına dair örnek görseller verilmiştir.


(A)

(B)

(C)

Şekil 2.9. Prewitt filtresi uygulama örnekleri. **A)**x-ekseninde uygulanmış filtre örneği **B)** y-ekseninde uygulanmış filtre örneği **C)** x ve y eksenlerinde uygulanmış filtre örneği

2.4.5. Sobel Kenar Algılama

Sobel kenar algılayıcısı, dijital görüntülerde kenarları tespit etmek için kullanılan bir başka tekniktir. Yatay ve dikey yönlerde birinci dereceden görüntü türevlerini hesaplamak için iki ayrı evrişim çekirdeği kullanan gradyan tabanlı bir metottur. Oluşan degrade görüntüler daha sonra orijinal görüntüdeki kenarları vurgulayan bir görüntü oluşturmak için birleştirilir (Gao et al., 2010).

Yatay ve dikey Sobel çekirdekleri, sırasıyla yatay ve dikey yönlerde görüntü türevlerini hesaplamak için giriş görüntüsüyle iç içe geçmiş 3x3 matrislerdir. Bu matrisler Şekil 2.10'da görülmektedir.

$G_x =$

-1	0	1
-2	0	2
-1	0	1

$G_y =$

-1	-2	-1
0	0	0
1	2	1

Şekil 2.10. Sobel filtresi

Evrişim işlemi, karşılık gelen çekirdek elemanlarını komşu piksel değerleriyle çarparak ve sonuçları toplayarak her pikseldeki türevi hesaplar. Ortaya çıkan yatay ve dikey gradyan görüntüleri daha sonra her pikseldeki genel gradyan büyüklüğünü hesaplamak için birleştirilir:

$$G = \sqrt{(Gx^2 + Gy^2)} \quad (10)$$

Denklem (10)'de G_x ve G_y sırasıyla yatay ve dikey gradyan görüntüleridir.

 **(A)**  **(B)**

 **(C)**

Şekil 2.11. Sobel filtresi uygulanmış kalibrasyon görselleri **A)** x-ekseninde Sobel filtresi uygulanmış görsel **(B)**y-ekseninde Sobel filtresi uygulanmış görsel **(C)**x ve y ekseninde Sobel filtresi uygulanmış görsel

Ortaya çıkan gradyan büyüklük görüntüsü daha sonra orijinal görüntüdeki kenarları tanımlamak için eşiklenir. Eşik değeri tipik olarak deneylere ve özel uygulamalara göre belirlenir.

Sobel kenar dedektörü, dijital görüntülerde kenarları tespit etmek için basit ve etkili bir yöntemdir. Nesne algılama, özellik çıkarma ve görüntü bölümleme gibi bilgisayarla görme uygulamalarında kullanılmaktadır. Şekil 2.11'de bu filtrenin uygulaması ve uygulama çıktıları görülmektedir.

2.4.6. Hough Kenar Dönüşümü

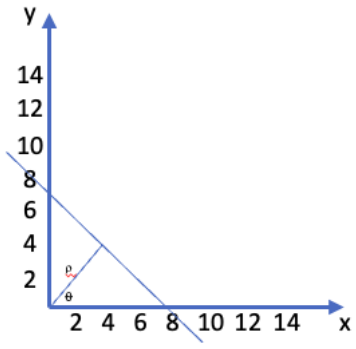
Hough kenar dönüşümü, görüntülerde düz çizgiler, çemberler ve elipsler gibi şekilleri tespit etmek için görüntü işlemede kullanılan bir özellik çıkarma tekniğidir. 1962 yılında Paul Hough tarafından bilgisayarlı analiz çalışmalarında kullanılmak üzere geliştirilmiştir (Hart, 2009).

Hough dönüşümü, bir görüntüdeki şekilleri bir parametre uzayında veya Hough uzayında tanımlanabilecek parametrik denklemler olarak temsil etme fikrine dayalı olarak çalışır. Hough uzayı, görüntüdeki her noktanın Hough uzayındaki bir eğriye veya bir dizi eğriye karşılık geldiği görüntü uzayının bir dönüşümüdür.

Hough dönüşümünü kullanarak çizgileri tespit etme durumunu ele alalım. Görüntü uzayında bir doğru, y = mx + c denklemiyle temsil edilebilir; burada m, doğrunun eğimidir ve c, y-kesme noktasıdır. Ancak Hough uzayında bu denklem bir doğru yerine bir nokta (m, c) olarak gösterilebilir.

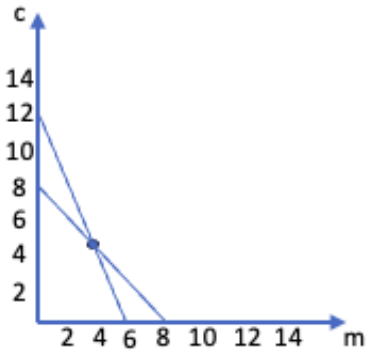
Hough dönüşümünü gerçekleştirmek için, algoritma görüntü uzayını tarar ve bulunan her kenar noktası (piksel) için, Hough uzayındaki o noktadan geçebilecek bir dizi olası çizgiyi hesaplar. Bu, olası her satır için Hough uzayındaki karşılık gelen değerleri artırarak yapılır. Sonuç, görüntüdeki en olası satırların parametrelerine (m, c) karşılık gelen en yüksek değerlerle Hough uzayında bir oy veya değer birikimidir. Kartezyen gösterim (m, c) yerine (ρ, θ) parametreleriyle kutup sistemine dönüştürülebilir. Dönüşüm sonrasında Denklem(11)'i elde edilir.

$$\rho = x\cos(\theta) + y\sin(\theta) \tag{11}$$



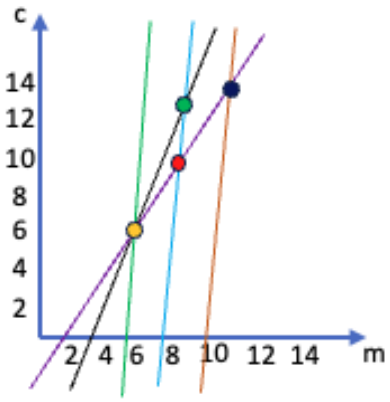
Şekil 2.12. Kartezyen koordinat sistemi gösterimi

Bu grafik ρ-θ uzayında çizilirse ve kısaca Hough uzayı olarak adlandırılsa, düz bir çizgi yerine bir nokta elde edilir. Bu gösterim Şekil 2.13'de gösterilmiştir (Hassanein et al., 2015).



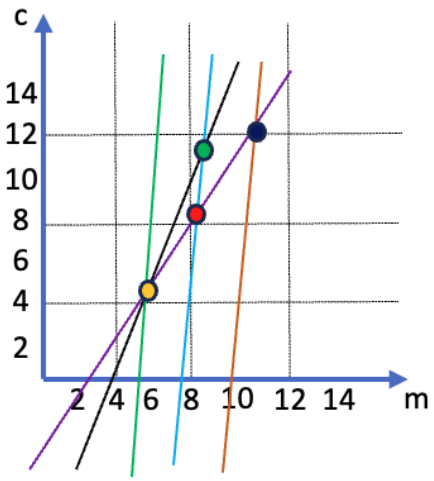
Şekil 2.13. Kartezyen koordinatta elde edilen nokta

Ve Kartezyen uzayda bir noktada kesişen birkaç doğru daha koyulursa Hough Şekil 2.14'te görülen grafik elde edilir:



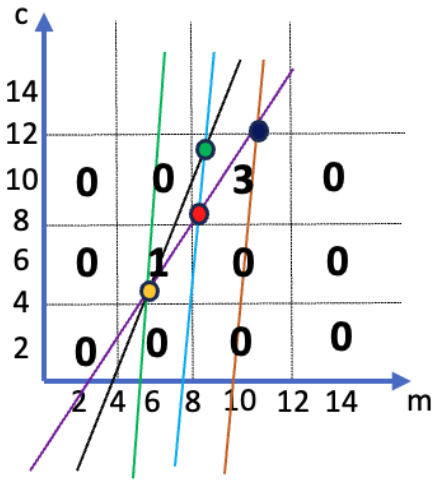
Şekil 2.14. Birden fazla doğrunun oluşturduğu noktalar kümesi

Şekil 2.14'te görülen grafiğin oylama işlemi için bölgelere ayrılması gerekmektedir. Oylama sonucunda piksellerin pozisyonları tespit edilecektir. Bölgelere ayrılmış grafik Şekil 2.15'te görülmektedir.



Şekil 2.15. Birden fazla doğrunun oluşturduğu noktalar kümesinin bölgelere ayrılmış gösterimi

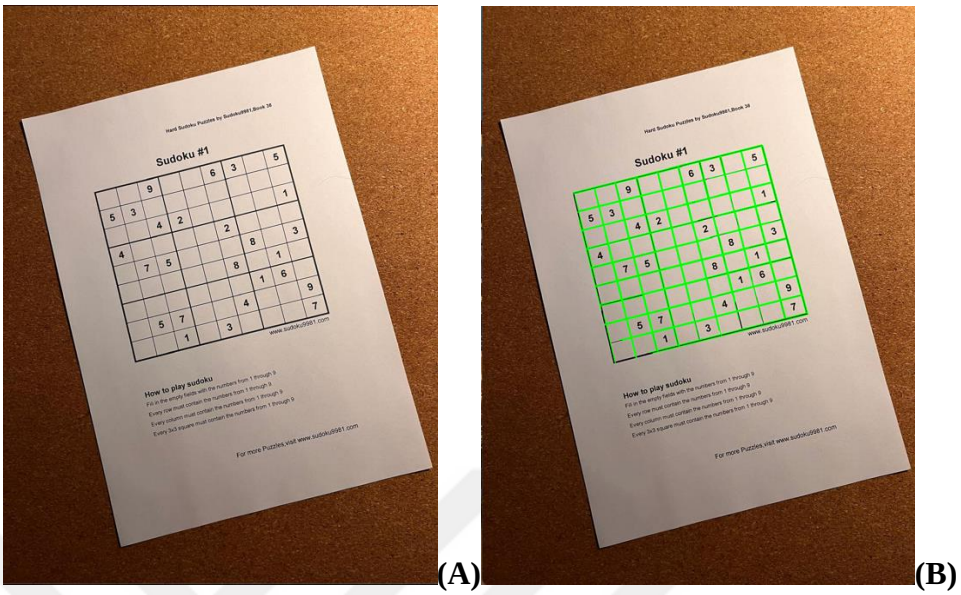
Bölgelere ayrılmış olan grafik içinde en çok noktayı barındıran bölge, görseldeki kenarı barınma ihtimali en yüksek olan bölgeyi temsil etmektedir. Şekil 2.16'te bu bölge 3 noktayı içeren bölgedir.



Şekil 2.16 Hough uzayında oylama işlemi sonrası oluşan grafik

Hough dönüşümü uygulandıktan sonra, Hough uzayındaki en belirgin çizgileri veya diğer şekilleri belirlemek için bir tepe bulma algoritması kullanılır. Bu tepe noktaları, orijinal görüntüde algılanan çizgileri veya diğer geometrik şekilleri temsil eder. Hough dönüşümünün uygulanmasından sonra görüntüdeki çizgiler net olarak tespit edilmiş olur

ve kullanıcı ara yüzü içeren sistemlerde bu bölgeler çizdirilerek sistemin doğruluğu hakkında geri bildirim verilir. Şekil 2.17'da örnek bir görsel eklenmiştir.



(A) **(B)**

Şekil 2.17. Sudoku üzerinde bir Hough dönüşümü denemesi **(A)** Sudoku görseli **(B)** Sudoku görseline Hough dönüşümü uygulaması

2.5. Kameranın Pozisyonlaması

Araçlardaki kameralar için ideal konum kullanım yapılacak uygulamaya göre değişiklik göstermektedir. Şerit takip uygulaması için araç üstüne yerleştirilen kameraların pozisyonu da sistem performansına etki etmektedir. Günümüzde farklı üreticilerin araç üstünde farklı konumlarda kameralar yerleştirdikleri görülmektedir.

Genel olarak, ön kamera aracın merkezine mümkün olduğunca yakın yerleştirilmeli ve öndeki yolu engelsiz bir şekilde görmelidir. Bu, kameranın şeritten ayrılma uyarısı, çarpışmadan kaçınma ve yaya algılama gibi uygulamalar için önemli olan geniş bir görüş alanı yakalamasına olanak tanır.

Ön kamera için ortak bir konum ön camda, dikiz aynasının arkasındadır. Bu konum, ilerideki yolun net bir görünümünü sağlar ve kurulum ve bakım için kolayca erişilebilir.

Ön kamera için bir diğer konum da aracın ızgarası veya tamponudur. Bu konum daha geniş bir görüş alanı sağlayabilir ve genellikle park yardımı ve düşük hızda manevra için kullanılır.

Araç ızgarasına konumlandırılan kameraların bir handikabı, yağmur, çamur, kar ve buz gibi çevresel etkilerden çabuk etkilenmesi ve temizlenmesi problemidir. Ön cama yerleştirilen kameranın yağmur, kar gibi etmenlerden etkilenmeden kullanılması için araç sileceklerinden faydalanılabilir (Weikl et al., 2022).

Ön kamera için en uygun konum aracın özel uygulamasına ve tasarımına bağlıdır. Otomotiv mühendisleri ve tasarımcıları, kamera yerleşimini belirlerken görünürlük, aerodinamik ve güvenlik gibi çeşitli faktörleri göz önünde bulundurur.

2.6. Kamera Verisi Toplanması

Bir şerit değiştirme uyarı sistemi için veri toplamak, yoldaki sürüş davranışı ve araç hareketleri hakkında ilgili bilgilerin toplanmasını içerir. Bu verileri toplamak için kameralar, sensörler ve GPS cihazları gibi çeşitli algılama teknolojileri kullanılarak araç konumu ve hızının doğru ve kesin ölçümleri elde edilebilir.



Şekil 2.18. Bu çalışmada kullanılan veri toplama ekipmanları

Veri toplamak için, test araçlarına sensörlerin ve kameraların yerleştirilmesini içeren bir veri toplama süreci tasarlamak ve kurmak gerekir. Bu sensörler ve kameralar, aracın hızı, konumu, hareket yönü gibi çeşitli parametreleri algılayıp takip edebiliyor. Bu bilgiler daha sonra aracın sürüş davranışındaki kalıpları belirlemek için saklanabilir ve analiz edilebilir (Baek et al., 2016).

Ek olarak, sistemin sağlam ve doğru olduğundan emin olmak için çok çeşitli yol koşullarında ve ortamlarında birden çok araçtan veri toplamak gerekir. Bu veriler, yol testi veya sürüş simülatörleri gibi çeşitli yöntemlerle toplanabilir. Analiz için daha kapsamlı bir veri seti sağlamak amacıyla otoyollar, şehir içi ve kırsal yollar gibi farklı yol türlerinden veri toplamak önemlidir.

Veriler toplandıktan sonra, herhangi bir hata veya tutarsızlığı gidermek için önceden işlenmesi ve temizlenmesi gerekir. Bu veriler daha sonra şeritten ayrılma uyarı sisteminin temelini oluşturan makine öğrenimi algoritmalarını eğitmek için kullanılabilir. Algoritmalar daha sonra doğruluklarını ve güvenilirliklerini artırmak için toplanan veriler kullanılarak ince ayar yapılabilir ve optimize edilebilir.

2.7. İlgi Bölgesi(Region of Interest – ROI)

Şerit algılama sistemleri, bir yoldaki şerit çizgilerini belirlemek ve bunlara göre aracın konumunu tahmin etmek için bilgisayarla görme tekniklerini kullanır. Şerit tespitindeki en önemli adımlardan biri, şerit çizgilerinin bulunması muhtemel ilgi bölgesini (ROI) bulmaktır (Chen et al., 2021).

İlgi alanı, şerit çizgilerinin bulunma olasılığının en yüksek olduğu görüntü alanıdır. Bu alan, şerit çizgilerinin aracın yakınında daha geniş ve araç uzaklaştıkça daha da dar görünmesi beklendiğinden, genellikle üstte alttan daha dar olan yamuk şeklinde bir bölge olarak tanımlanır. Yamuğun köşeleri, yamuğun sol üst, sağ üst, sol alt ve sağ alt köşelerini temsil eden dört nokta ile tanımlanır. Bu noktalar genellikle görüntünün sol üst köşesinin (0,0) olduğu ve x ekseninin sağı ve y ekseninin aşağıyı gösterdiği piksel koordinatlarında tanımlanır.

İlgi bölgesinin konumu ve boyutu, şerit algılama algoritmasına ve araçtaki kamera yerleşimine bağlı olarak değişebilir. Genel olarak, ilgi bölgesi, yolun şerit çizgilerinin bulunması muhtemel olduğu bölgesini kapsayacak şekilde seçilmelidir ve şerit algılama sürecine gürültü veya dikkat dağıtıcı unsurlar getirebilecek alakasız alanlardan kaçınmalıdır. Örneğin, gökyüzü, ağaçlar veya yoldaki diğer araçlar ilgi bölgesinden hariç tutulabilir.

İlgi bölgesi tanımlandıktan sonra şerit algılama algoritması, şerit çizgilerini algılamak ve izlemek için görüntünün bu alanına odaklanabilir. Algoritma, ilgi bölgesi içindeki şerit işaretlerini tanımlamak için kenar algılama, renk eşiği belirleme veya model tanıma gibi çeşitli teknikler kullanabilir. Aramayı ilgi bölgesi ile sınırlayarak, algoritma, gereken hesaplama miktarını azaltarak ve yanlış pozitifleri veya yanlış negatifleri en aza indirerek doğruluğunu ve verimliliğini artırabilir (Ding et al., 2013).

Özetle, ilgilenilen bölge, şerit algılama sistemlerinin, şerit çizgilerinin bulunma olasılığının yüksek olduğu görüntü alanını tanımlayan temel bir bileşenidir. ROI genellikle üstte alttan daha dar olan ve gürültü veya dikkat dağıtıcı unsurlara neden olabilecek yol dışında kalan alanları hariç tutmak için seçilen yamuk şeklinde bir bölge olarak tanımlanır. ROI'ye odaklanan şerit algılama algoritması, gereken hesaplama miktarını azaltarak ve yanlış pozitifleri veya yanlış negatifleri en aza indirerek doğruluğunu ve verimliliğini artırabilir.

3. MATERYAL VE YÖNTEM

3.1 Donanım ve Yazılımlar

Bu çalışmada farklı işletim sistemleri ve farklı donanımlar kullanılarak geliştirilen yazılımın ve yazılımı geliştirme sürecinde kullanılan algoritmaların performansları kıyaslanmıştır.

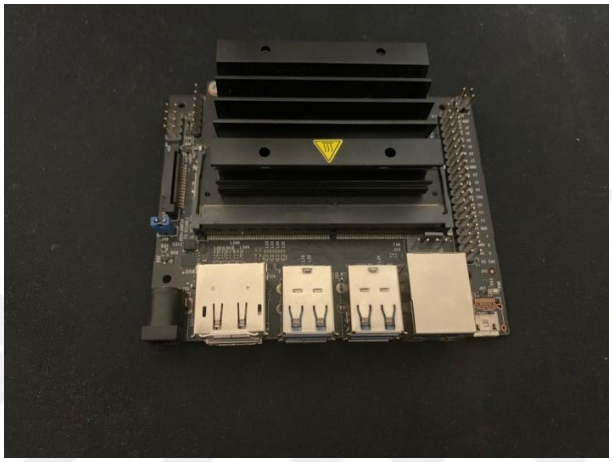
3.1.1 Donanım

Bilgisayar

Jetson Nano, NVIDIA tarafından tasarlanan, öncelikle gömülü sistemlerde ve yapay zekâ uygulamalarında kullanılmak üzere tasarlanmış tek kartlı bir bilgisayardır. Jetson Nano'nun teknik özellikleri aşağıdaki gibidir:

CPU: Jetson Nano, 1,43 GHz saat hızına sahip dört çekirdekli ARM Cortex-A57 CPU ile güçlendirilmiştir.
GPU: Jetson Nano, 1 teraflop performans sunabilen 128 çekirdekli Nvidia Maxwell GPU'ya sahiptir.
RAM: Jetson Nano, yüksek bant genişliği ve düşük güç tüketimi sağlayan 4 GB LPDDR4 RAM ile geliyor.
Depolama: Jetson Nano, depolama için bir microSD kart yuvası ve harici USB 3.0 sürücüleri için destek içerir.
Ağ oluşturma: Jetson Nano, Gigabit Ethernet'in yanı sıra Wi-Fi ve Bluetooth bağlantısını destekler.
GPIO: Jetson Nano, harici sensörlerin ve çevre birimlerinin bağlantısına izin veren 40 pinli GPIO başlığına sahiptir.
Ekran: Jetson Nano, 60Hz'de maksimum 4K çözünürlükle HDMI ve DisplayPort çıkışını destekler.
Güç: Jetson Nano, maksimum 10W güç tüketimi ile 5V DC girişi ile çalıştırılabilir.

Tüm bu teknik özellikleri ile Jetson Nano araç üstü bilgisayar olarak kullanılmak üzere en uygun adaylardan biri haline gelmektedir. Otonom araçlar, insansız hava araçları ve robotik sistemler için de kullanılan bu bilgisayar üzerinde barındırdığı GPIO portları sayesinde birden fazla sistemi kontrol etmek için uygun bir platformdur. Üzerinde işletim sistemi de barındırabilmesi sayesinde geniş bir yelpazede kullanım imkânı sunmaktadır. Şekil 3.1'de bu çalışmada kullanılan bilgisayar görülmektedir.



Şekil 3.1. Jetson Nano geliştirme kartı (Jetson Nano 2GB Geliştirici Kartı, 2024)

Çalışmalar esnasında donanım üzerinde performans kıyaslaması yapabilmek üzere ikinci ekipman olarak GPU barındıran bir kişisel bilgisayar kullanılmıştır.

Kişisel Bilgisayar; 8 adet performans çekirdeğine ve 2 adet verimlilik çekirdeğine sahip 10 çekirdekli CPU barındırmaktadır. Paralel işlem gücüne sahip 16 çekirdekli GPU ve yapay zekâ işlemleri için geliştirilmiş 16 çekirdekli yapa zekâ işlemcisine sahiptir. 200 GBps bellek bant genişliği ve 16 GB birleşik bellek barındırması ile 512 GB SSD içermektedir.

Kamera

Waveshare firmasından temin edilen RPi Camera (F) modeli, Jetson Nano ve Raspberry Pi gibi platformlarla sorunsuz entegrasyon için tasarlanmış gelişmiş bir optik sensördür. Görüntü işleme uygulamalarının ihtiyaçlarını karşılamak üzere özel olarak tasarlanan bu kamera modülü, 5 mega piksel çözünürlüğe sahiptir ve görüşün yüksek olmadığı çevre

koşullarında etkili performans için kızılötesi aydınlatma özelliklerine sahiptir. Şekil 3.2'de bu çalışmada kullanılan kamera görülmektedir.

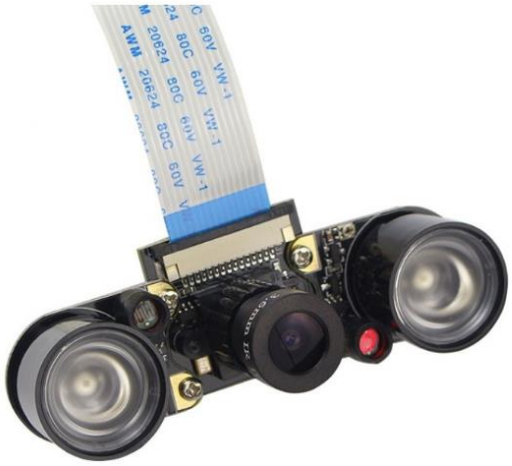
Görüntü Sensörü: Kamera modülü, 2592 x 1944 piksel çözünürlüğe sahip OmniVision OV5647 görüntü sensörü kullanılmaktadır. Bu 5 mega piksel sensör, ince ayrıntıları koruyarak ve doğru görüntü analizini kolaylaştırarak yüksek çözünürlüklü görüntü ve videoların yakalanmasını sağlar.

Kızılötesi Aydınlatma: Bu kameranın önemli bir yönü, entegre kızılötesi aydınlatma özelliğidir. Kamera merceğinin etrafındaki kızılötesi LED'lerle donatıldığından, insan gözüyle görülemeyen kızılötesi ışık yayar. Bu özellik, kameranın düşük ışık koşullarında veya tamamen karanlıkta resim çekmesini sağlar. Geleneksel görünür ışık kameralarının zorlandığı gece görüşü, nesne algılama, şerit algılama gibi uygulamalar için özellikle yararlıdır.

CSI Arayüzü: Kamera modülü, Kamera Seri Arayüzü (CSI) konnektörü aracılığıyla doğrudan Jetson Nano'ya bağlanır. Bu arabirim, kamera ile Jetson Nano arasında yüksek hızlı bir veri bağlantısı kurarak verimli veri aktarımı sağlar ve görüntü ve video çekimi sırasında gecikmeyi en aza indirir.

Odak Ayarı: Kamera, kullanıcıların belirli görüntüleme gereksinimlerine göre odağı manuel olarak ayarlamasına izin veren esnek bir odak halkasına sahiptir. Bu özellik, kameradan farklı mesafelerdeki nesnelerin keskin görüntülerini sağlayarak çeşitli uygulamalarda çok yönlülüğü artırır.

Yüksek çözünürlüklü video: Kamera, durağan görüntüler yakalamanın yanı sıra 1080p'ye kadar çözünürlükte ve saniyede 30 kare yüksek çözünürlüklü videolar kaydedebilir. Bu video kayıt yeteneği, Jetson Nano platformunda hareket analizi, video gözetimi ve video tabanlı araştırma içeren projeler için oldukça önemlidir. Otomotiv görüntü işleme uygulamalarında araçlar yüksek hızlarda kullanıldığı için bu özellik daha da önem kazanmaktadır. Bu hızlar üreticiden üreticiye değişkenlik göstermektedir.



Şekil 3.2. Waveshare RPi camera (F) modeli (TinyTronics, 2024)

3.1.2 Yazılım

Bu bölümde, bu çalışmada kullanılan yazılım dilleri hakkında detaylar belirtilmiştir.

Python

Python, görüntü işleme alanında giderek daha popüler hale gelen üst düzey bir programlama dilidir. Görüntü işleme için Python'un ana avantajlarından biri, kullanıma hazır kapsamlı kütüphaneleri ve araçlarıdır. Bu kütüphaneler, diğerlerinin yanı sıra görüntü işleme için çok çeşitli işlevler ve algoritmalar sağlayan NumPy, SciPy, OpenCV, Cushion ve scikit-image'ı içerir.

NumPy, Python'da sayısal hesaplama için hızlı ve verimli dizi işleme yetenekleri sağlayan güçlü bir kütüphanedir. NumPy dizileri, görüntüleri temsil etmek için kullanılabilir ve görüntü verilerinin hızlı ve verimli bir şekilde değiştirilmesine olanak tanır. SciPy kitaplığı, sinyal işleme, optimizasyon ve istatistiksel analiz işlevleri dahil olmak üzere bilimsel bilgi işlem için ek işlevler sağlar. NumPy ile SciPy, filtreleme, segmentasyon ve özellik çıkarma gibi gelişmiş görüntü işleme işlemlerini gerçekleştirmek için kullanılabilir.

OpenCV, nesne algılama, görüntü tanıma ve izleme dahil olmak üzere görüntü işleme için kapsamlı bir dizi algoritma ve araç sağlayan popüler bir açık kaynaklı bilgisayarlı görme kütüphanesidir. OpenCV, sürücüsüz arabalar ve robotik gibi gerçek zamanlı görüntü işleme uygulamaları için endüstride ve akademide yaygın olarak kullanılmaktadır.

Mevcut geniş kütüphane ve araç yelpazesine ek olarak, Python ayrıca son derece özelleştirilebilir ve genişletilebilir olup, araştırmacıların ve geliştiricilerin kendi özel görüntü işleme algoritmalarını ve araçlarını oluşturmalarına olanak tanır. Dil aynı zamanda platformlar arasıdır ve çeşitli işletim sistemlerinde görüntü işleme uygulamalarının geliştirilmesini ve çalıştırılmasını kolaylaştırır.

Genel olarak Python, görüntü işleme için güçlü ve esnek bir dildir ve gelişmiş görüntü işleme işlemleri için çok çeşitli kütüphaneler ve araçlar ile temel görüntü işleme görevleri için kullanımı kolay bir arabirim sunar.

3.2 Test Verisi

Uygulama geliştirme çalışmaları esnasında test için gerekli verilerin elde edilmesi gereklidir. Bu veriler toplanırken dikkat edilmesi gereken bazı adımlar vardır. İlk olarak kullanılacak verinin farklı sürüş senaryolarını içermesi gerekmektedir. Gerçek araçlar üzerinden alınmış verilerin, farklı yol şartları, şeritten ayrılma olayları, farklı şerit tarzları ve farklı hava koşullarını içeren veriler ile anlamlı bir test verisi elde edilmiş olur.

Bu verileri elde edebilmek için farklı kaynaklar bulunmaktadır. Bunlara örnek olarak KITTI(Karlsruhe Institute of Technologhy and Toyota Tehcnological Institute) ve ApolloScape veri setleri verilebilir. Bu kaynaklarda bilimsel araştırmalar için kullanıma uygun veriler bulunabilmektedir.

Bu çalışma için görüntüler yazar tarafından toplanarak işlenmiştir. Görüntüler çoğunlukla Hollanda ve Almanya otoyollarında ve sistemin şehir içi performansını görmek adına şehir içi ve tek şeritli yollarda günün farklı dilimlerinde ve farklı hava koşullarında toplanmıştır. Günün dilimleri gece ve gündüz olarak ayrılmıştır. Hava şartları ise yağışlı, yağışsız olarak ayrılmıştır. Toplamda dört farklı senaryoyu içermektedir. Veri setinin bu şekilde tercih edilmesindeki amaç günün farklı zaman dilimlerinde ve aydınlatma koşullarında sistem performansını, doğruluğunu ve güvenilebilirliğini ölçebilmektir. Aşağıda senaryolar açıklanmış ve performansa etki edebilecek değişkenler hakkında bilgi verilmiştir.

Gündüz Yağışsız: Gündüz, açık ve güneşli havalarda kaydedilen videolar.
Görüş: Yüksek.
Aydınlatma Koşulları: Doğal güneş ışığı, tutarlı ve parlak.
Potansiyel Zorluklar: Gölge oluşumu, yol yüzeyinden yansımalar ve yolda meydana gelen deformasyonlar.

Gündüz Yağışlı: Gündüz, yağışlı hava koşullarında kaydedilen videolar.
Görüş: Yağmur nedeniyle olası bulanıklık ile orta seviye.
Aydınlatma Koşulları: Gün ışığı ancak hava kapalı olduğu günlerde araç otomatik farları yolu aydınlatmaktadır.
Potansiyel Zorluklar: Kamera merceğinde su damlacıkları, ıslak yol yüzeyinden yansımalar.

Gece Yağışsız: Gece, yağışız koşullarda kaydedilen videolar.
Görüş: Sokak aydınlatması ve araç farlarına bağlı olarak orta düzeyde.
Aydınlatma Koşulları: Sokak lambaları ve araç farlarından gelen yapay ışık.
Potansiyel Zorluklar: Karşıdan gelen trafik ışıkları nedeniyle parlamalar, şerit işaretlerinin düşük kontrastı.

Gece Yağışlı: Gece, yağışlı hava koşullarında kaydedilen videolar.
Görüş: Yağmur ve karanlık nedeniyle düşük görüş mesafesi.
Aydınlatma Koşulları: Araç farları ile aydınlatma ve sokak lambaları.
Potansiyel Zorluklar: Yansımalar, parlamalar, su damlacıkları, araç silecek hareketleri ve düşük kontrast.

Veri seti her çevresel kategoriyle ilişkili video sekanslarını içermektedir ve bu sayede yol koşullarının farklı koşullar altında test edilmesi amaçlanmaktadır. Tüm kategorilerdeki toplam video uzunluğu 1 saat, 17 dakika, 8 saniyedir. Video verisi, şerit takip sistemlerinin test edilirken sistemin güçlü ve zayıf yönlerini anlamak için kritik öneme sahiptir. Geliştirilen şerit takip algoritmalarının zaman ve farklı çevresel koşullar altındaki tutarlılığını ve güvenilirliğini değerlendirmek için bir temel sağlar. Videoların kayıt altında olması ise algoritmanın tekrar tekrar test edilebilmesine olanak tanır.

Gündüz Yağışsız Videolar: Bu kategori için toplam süre 14 dakika, 13 saniyedir. Bu koşul altındaki her alt kategori, daha açık koşullar altında veri toplamanın daha basit doğasını yansıtan nispeten kısa video segmentlerine sahiptir.

Gündüz Yağışlı Videolar: Bu koşulda toplam süre 26 dakika, 7 saniyedir. Bu daha uzun süre, yağışlı koşulların getirdiği artan değişkenlik ve karmaşıklığı hesaba katmak için daha kapsamlı veri toplama ihtiyacını göstermektedir.

Gece Yağışsız Videolar: Toplam video süresi 24 dakika, 28 saniyedir. Özellikle bu kategorideki 'Geçişli' alt kategorisi (7:00), en uzun video segmentine sahip olup, bu geçiş bölgelerinin düşük ışık koşullarında nasıl etkilendiğini anlamaya yönelik bir odaklanmayı işaret etmektedir.

Gece Yağışlı Videolar: Kategoriler arasında en kısa toplam süre, 12 dakika, 20 saniyedir ve bu, bu zorlayıcı koşullar altında yüksek kaliteli veri toplamanın zorluklarını yansıtmaktadır. Daha kısa süreye rağmen, toplanan veriler, düşük ışık ve yağışın birleşik

zorlukları altında tespit sistemlerinin performansını değerlendirmek için kritik öneme sahiptir.

Video veri setinden programın çalıştırılması esnasında rastgele olarak ekran görüntülerinin alınması suretiyle sistemin ekran çıktıları kayıt altına alınmıştır. Her bir hava ve gün durumu için veri seti oluşturulmuştur. Şekil 3.3'te veri setinin ekran görüntüleri görülmektedir.



Şekil 3.3. Program çıktıları klasör görünümü

Şekil 3.4'te gece yağışlı hava şartında deformasyon içeren yolda alınan videolardan rastgele anlarda elde edilen program çıktıları görülmektedir. Tüm hava ve gün evresi şartları, her bir yol tipi için benzeri veriler elde edilmiştir. Elde edilen verilere ait sayısal değerler Çizelge 3.1, Çizelge 3.2, Çizelge 3.3 ve Çizelge 3.4'te görülebilmektedir.



Şekil 3.4. Gece yağışlı hava deforme yol ekran çıktıları

Veri seti, 2491 kare içermekte olup, farklı çevresel koşullar ve yol anomalilerine göre dikkatlice seçilip organize edilmiştir. Bu kategoriler, veri setinin çeşitliliğini ve gerçek dünya koşullarında yol durumlarının tespiti ve analizi zorluklarını anlamak için önemlidir.

Görsellerin dört çevresel koşula göre dağılımı incelenecek olursa,

Çizelge 3.1. Gündüz yağışsız veri seti kare sayıları

Yol Tipleri	Kare Sayısı
Deforme	96
Geçişli	29
Şerit Çizgili	204
Şerit Çizgisiz	81
Yol Çalışması	158

Bu kategori, açık görüş altında yol koşullarını yakalayan kareleri içerir ve daha zorlu koşullarla karşılaştırmalar için bir temel sağlar. Bu kategorideki kareler, yol izleme sistemlerinin optimal koşullarda tespit etmesi ve analiz etmesi gereken çeşitli yol özelliklerini vurgulamaktadır.

Çizelge 3.2. Gündüz yağışlı veri seti kare sayıları

Yol Tipleri	Kare Sayısı
Deforme	115
Geçişli	105
Şerit Çizgili	201
Şerit Çizgisiz	101
Yol Çalışması	206

Bu kategori, veri setindeki en geniş alt kümedir ve yağmurlu koşulların getirdiği karmaşıklığı yansıtır. Yağmur, yol görünürlüğünü ve yüzey koşullarını önemli ölçüde etkiler, bu da bu kategoriyi yol durumu algılama sistemlerinin dayanıklılığını değerlendirmek için kritik hale getirir. Bu kategorideki kare sayısının daha yüksek olması, yağmurun getirdiği değişkenliği yeterince yakalamak için daha fazla veri toplandığını göstermektedir.

Çizelge 3.3. Gece yağışsız veri seti kare sayıları

Yol Tipleri	Kare Sayısı
Deforme	132
Geçişli	169
Şerit Çizgili	190
Şerit Çizgisiz	78
Yol Çalışması	149

Gece yağışsız koşullarda yol koşullarını yakalamak, azalan görünürlüğün yol özelliklerinin tespitini nasıl etkilediğini anlamak için kritiktir. Bu kategori, doğal ışığın olmadığı yolun ve özellikle ilgi bölgesinin yapay ışık kaynakları ile aydınlatıldığı koşullarda şerit takip sistemlerinin performansını ölçmek için bir temel sağlar.

Çizelge 3.4. Gece yağışlı veri seti kare sayıları

Yol Tipleri	Kare Sayısı
Deforme	92
Geçişli	84
Şerit Çizgili	182
Şerit Çizgisiz	37
Yol Çalışması	82

Gece yağmurlu koşullar, veri setindeki en karmaşık koşulları temsil eder. Gün ışığının yokluğunda yapay ışıklandırmanın ve ıslak yol yüzeylerini bir araya getirir. Bu kategorideki veriler, yol durumu tespit sistemlerinin en zorlayıcı senaryosu olarak öngörülen koşullarda sistemin performansını test etmek için değerlidir.

Bu veri setinde yapılan sınıflandırma ve kapsamlı video verisi, geniş bir çevresel koşul yelpazesinde şerit takip sistemini test etmek ve doğrulamak için sağlam bir kaynak sağlar. Bu veri setinin yapısı, çeşitli çevresel faktörlerin yol özelliklerinin görünürlüğünü ve tespit edilebilirliğini nasıl etkilediğine dair kapsamlı bir analiz yapılmasına olanak tanır.

3.3 Performans Metrikleri ve Değerlendirme Kriterleri

Kullanılan veri setinin doğruluğu için kesin bir referans olmadığı için sonuçlar otomotiv sektörü profesyonelleri tarafından değerlendirilmiştir. Sonuçları değerlendirirken hata matrisi ve performans metriklerinden faydalanılmıştır.

Hata matrisi, doğru pozitif, doğru negatif, yanlış pozitif ve yanlış negatif tahminlerin sayılarını göstererek bir sınıflandırma modelinin performansını özetlemektedir. Hata matrisi modelin yapmış olduğu tahminleri detaylı inceleme fırsatı sunarken hataların nerede olduğunu ortaya koyar. Performans metriklerinin hesaplanmasında matristeki değerler temel oluşturur.

Çizelge 3.5. Hata matrisi

	Tahmin Edilen Pozitif	**Tahmin Edilen Negatif**
Gerçek Pozitif	TP	FN
Gerçek Negatif	FP	TN

Performans metrikleri Çizelge 3.5'te elde edilen veriler ışığında oluşturulabilmektedir. Bu çalışmada dikkate alınan performans metriklerinin listesi aşağıda görülebilmektedir.

Doğruluk: Doğru tahmin edilen verilerin toplam veriye bölünmesiyle elde edilir. Yüksek doğruluk modelin performansının yüksek olduğunu gösterir ancak veri setinin homojen dağılmadığı durumlarda yanıltıcı etkisi olabilir.

$$Doğruluk = \frac{DP + DN}{DP + DN + HP + HN} \tag{14}$$

Kesinlik: Kesinlik, Pozitif tahminlerin tüm pozitif tahminler içindeki oranıdır. Kesinlik bir modelin pozitif tahminlerinin kaç tanesinin doğru pozitif olduğunu ölçer.

$$Kesinlik = \frac{DP}{DP + HP} \tag{15}$$

Duyarlılık: Doğru pozitif örneklerin doğru ve hatalı pozitif örnekler içindeki oranı.

$$Duyarlılık = \frac{DP}{DP + HN} \tag{16}$$

Özgüllük: Doğru negatif verinin tüm gerçek negatif örnekler içindeki oranıdır. (Reway et al., 2018)

$$Özgüllük = \frac{DN}{DN + HP} \tag{17}$$

Yukarıda açıklaması yapılan metrikler ile uygulama sonrasında değerlendirmeler tamamlanmıştır.

Bu çalışmada kullanılan veri setinin güvenilirliğini ve pratik geçerliliğini sağlamak amacıyla, çeşitli yol koşulları ve çevresel senaryolardan seçilen bir alt küme görseller, 6 farklı sektör profesyoneli tarafından değerlendirilmiştir.

Uzman değerlendirmesi için temsili bir örnek oluşturmak amacıyla, her senaryodaki her alt kategoriden 10 rastgele görsel seçilmiştir. Bu metot, seçim yanlılığını önlemek ve her kategorinin çeşitliliğinin yeterince test ve tespit edilmesini sağlamak için seçilmiştir. Her bir sektör profesyoneline gönderilen senaryo ve alt kategoriler Çizelge 3.6'dakı gibidir.

Çizelge 3.6. Sektör profesyonellerine iletilen veri seti bilgisi

Senaryo	**Alt Kategoriler**	**Görsel Sayısı**
Gündüz Yağışsız	Deforme, Geçişli, Şerit Çizgili, Şerit Çizgisiz, Yol Çalışması	50
Gündüz Yağışlı	Deforme, Geçişli, Şerit Çizgili, Şerit Çizgisiz, Yol Çalışması	50
Gece Yağışsız	Deforme, Geçişli, Şerit Çizgili, Şerit Çizgisiz, Yol Çalışması	50
Gece Yağışlı	Deforme, Geçişli, Şerit Çizgili, Şerit Çizgisiz, Yol Çalışması	50
Genel Toplam		**200**

Rastgele seçilen görseller, otomotiv sektöründe aktif olarak çalışmakta olan iki kamera geliştirme uzmanı ve SGDS test alanlarında uzmanlaşmış dört sektör profesyoneline dağıtılmıştır. Bu profesyoneller, derin uzmanlıkları ve veri setinin gerçek dünya uygulamalarında karşılaşabileceği zorlukları eleştirel bir şekilde değerlendirebilmeleri nedeniyle seçilmiştir.

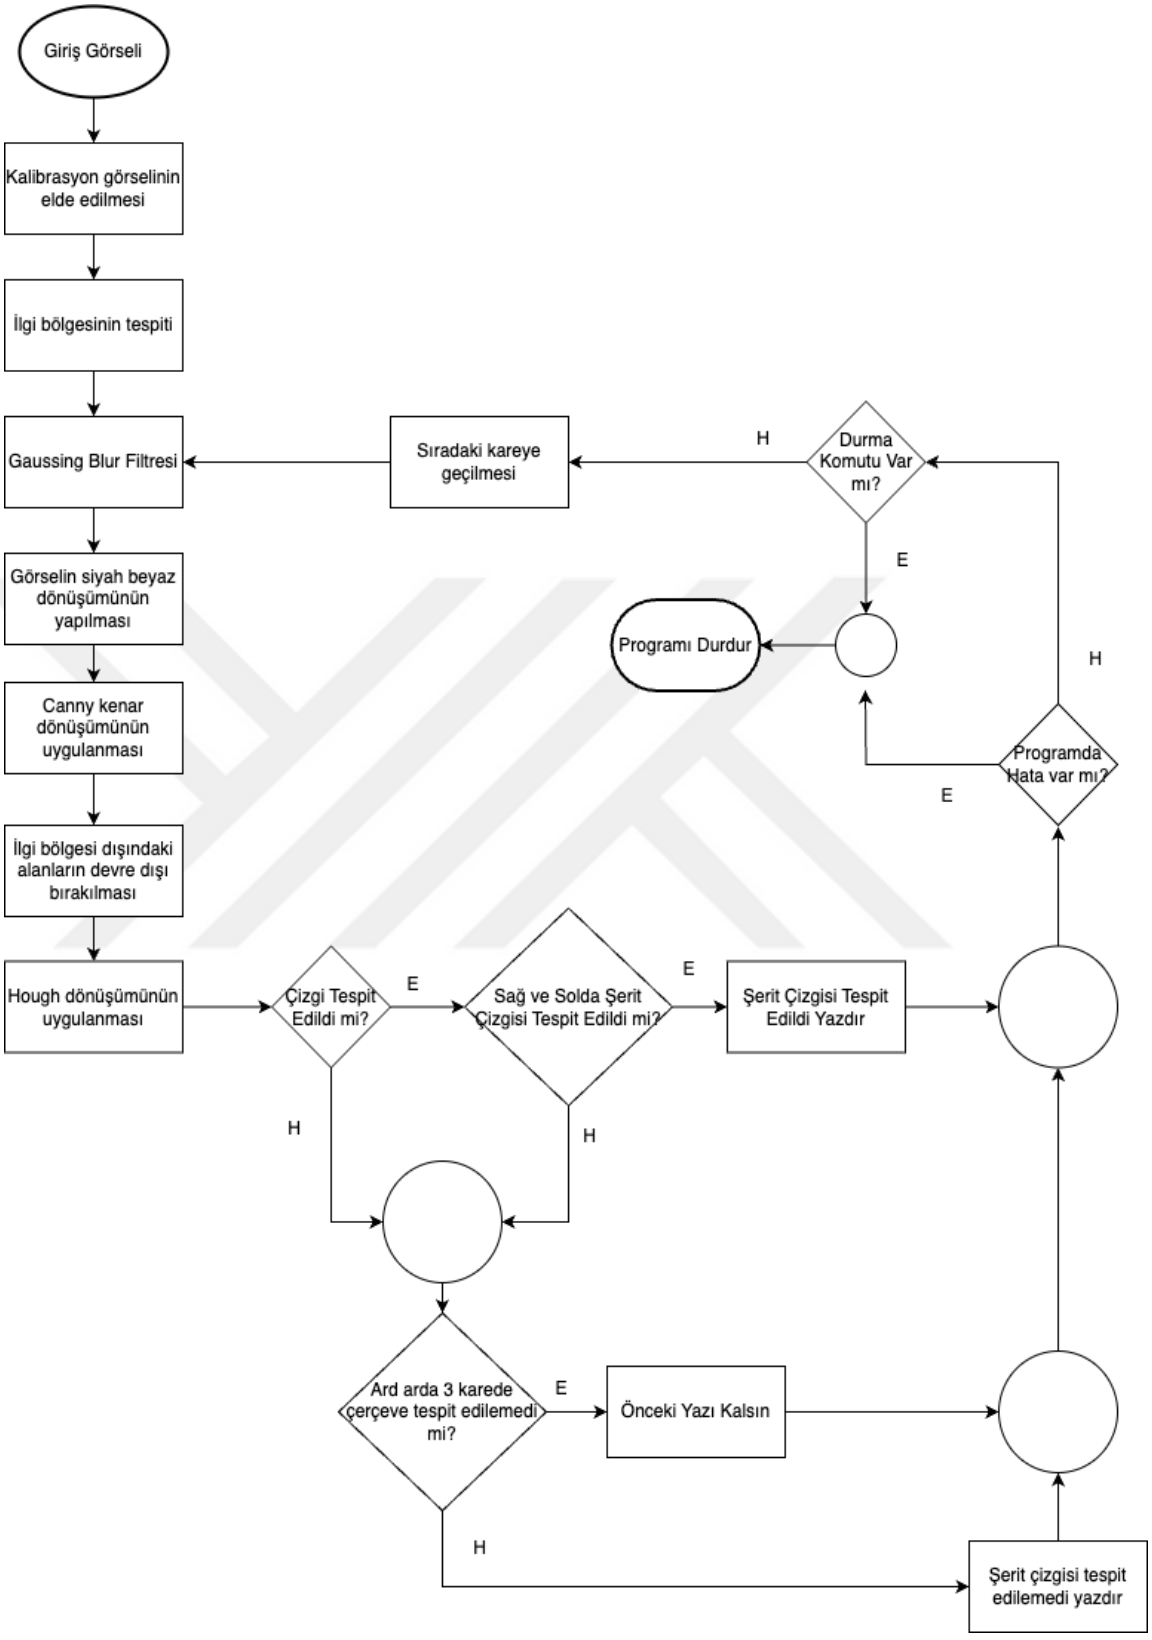
Her bir sektör profesyoneline gönderilecek olan toplamda 200 görsel rastgele seçilmiş olup, her bir sektör profesyoneline farklı görseller iletilmiştir. Değerlendirme süreçlerinde toplamda 1200 görselden faydalanılmıştır. Her uzmandan görselleri aşağıdaki kriterler doğrultusunda değerlendirmeleri istenmiştir:

Bu uzman doğrulama adımı, veri setinin yalnızca teorik senaryoları yansıtmakla kalmayıp, sektör profesyonelleri tarafından anlaşıldığı şekliyle gerçek dünya koşulları ile uyumlu olmasını sağlamada kritik rol oynamıştır. Bu süreçte elde edilen bulgular, araştırmanın genel güvenilirliğini ve uygulamaya yönelik etkisini artırmıştır.

3.4 Uygulama

Uygulama gerçeklenirken, Şekil 3.5'te gösterilen akış süreci takip edilmiştir. İlk etapta giriş görseli alınarak araç özelinde ilgi bölgesi tespiti yapılacaktır. Takip eden süreçte görselin siyah beyaz dönüşümü, gürültü giderilmesi işlemleri yapılacaktır. Canny kenar dönüşümü uygulaması ile görsel sadeleştirilecektir. Ardından bu alanda Hough dönüşümü uygulandıktan sonra eşik değeri tespiti yapılarak test videosu ile performans ölçümü yapılacaktır.

Performans testlerinden sonra uygulama farklı işlem gücüne sahip bilgisayarlarda video verileri ile test edilecektir. Çalışmanın sonunda ise gerçek zamanlı olarak kameradan gelen veri ile farklı işlem gücüne sahip bilgisayarlar kullanılarak testler gerçekleştirilerek sonuca ulaşılacaktır.



Şekil 3.5. Test videosu süreç akış şeması

3.3.1. Kamera Konumlandırılması

Bu tez çalışması için kullanılan görüntüler yazarın kendi imkanları ile toplanmıştır. Görüntülerin toplanması için FIAT 500 model araç kullanılmıştır. Endüstride ’de kullanıldığı üzere kamera pozisyonlaması için ön cam, dikiz aynası yanı bölgesi alınmıştır. Şekil 3.6’da araç görseline yer verilmiştir.



(A)



(B)



(C)

 **(D)**  **(E)**

Şekil 3.6. Tez çalışmasında kullanılan aracın önden görüntüsü **(A)** Araç içinde Jetson nano yerleşimi **(B)** Test aracı içindeki kamera konumu **(C)** Test Aracı kamera çıktısı **(D)** Araç içi test ortamı **(E)**

3.3.2. Uygulama Çıktıları

Sistemin ilk kalibrasyonunun yapılabilmesi için araç üstüne yerleştirilen kamera ile ilk otoyol görseli alınmıştır. Bu görsel Şekil 3.7'de görülebilmektedir. Araç üstünden alınan görseller ile ilgi alanının belirlenmesi işlemine geçilmiştir.



Şekil 3.7. Kalibrasyon görseli

Görsel programa tanıtılarak bilgisayar üzerinden doğrulaması yapılmıştır. Kenar tespiti görseldeki farklı renklerde meydana gelen keskin geçişlerden faydalanılarak yapılmaktadır. Görseli işlerken daha yüksek performans elde edebilmek için görsel RGB (Red Green Blue)'den siyah beyaza çevrilmektedir. Bu sayede görüntü işlemede hız artmaktadır. Siyah beyaz dönüşümü sonrasında eşik değerlerinde meydana gelecek farklar daha belirgin hale gelecektir. Görüntüde yer alan piksellerin arasındaki keskin geçişler görüntüdeki kenarları gösterecektir.

Siyah beyaz dönüşümü uygulandıktan sonra kalibrasyon görüntümüz Şekil 3.8'de görüldüğü hali almaktadır.



Şekil 3.8. Siyah beyaz dönüşümü uygulanmış kalibrasyon görseli

Gaussian filtresi uygulaması ile resimdeki gürültüden kurtulmak mümkün hale gelmektedir. Bunun yanı sıra Gaussian filtresi ile kenarların da keskinliğinden bir kayıp olmamaktadır. Bu sayede sistemi yanıltıcı unsurlardan kurtulmak için fayda sağlanmış olur. Şekil 3.9'da Gaussian filtresi uygulanmış kalibrasyon görseli görülmektedir.



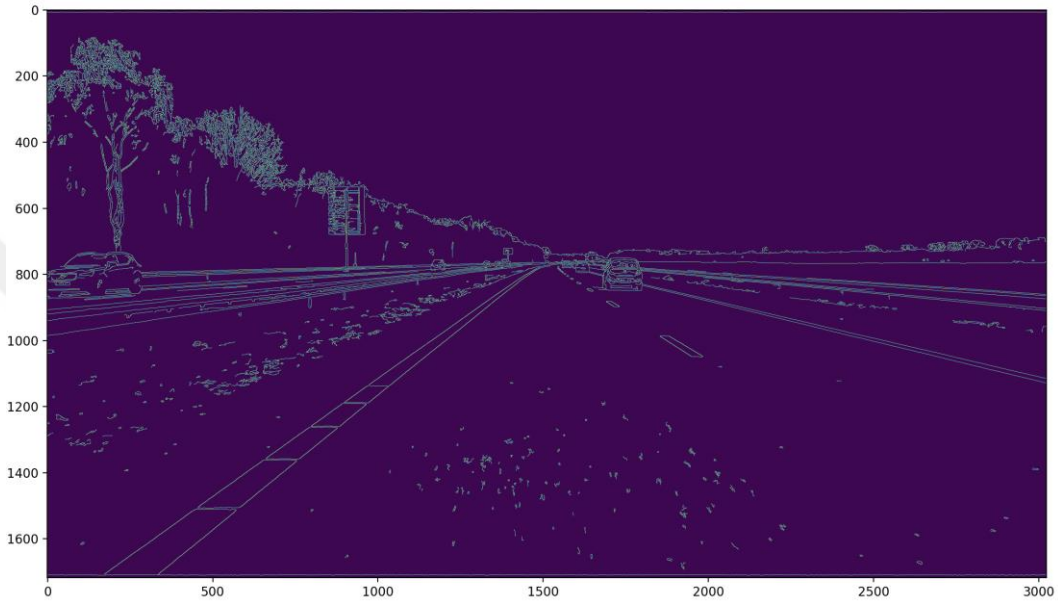
Şekil 3.9. Gaussian filtresi uygulanmış kalibrasyon görseli

Gaussian filtresi uygulanması işleminin ardından Canny kenar tespiti işlemi uygulanarak görseldeki tüm kenarlar tespit edilir. Şekil 3.10'da Canny kenar dönüşümü uygulanmış kalibrasyon görseli görülmektedir.



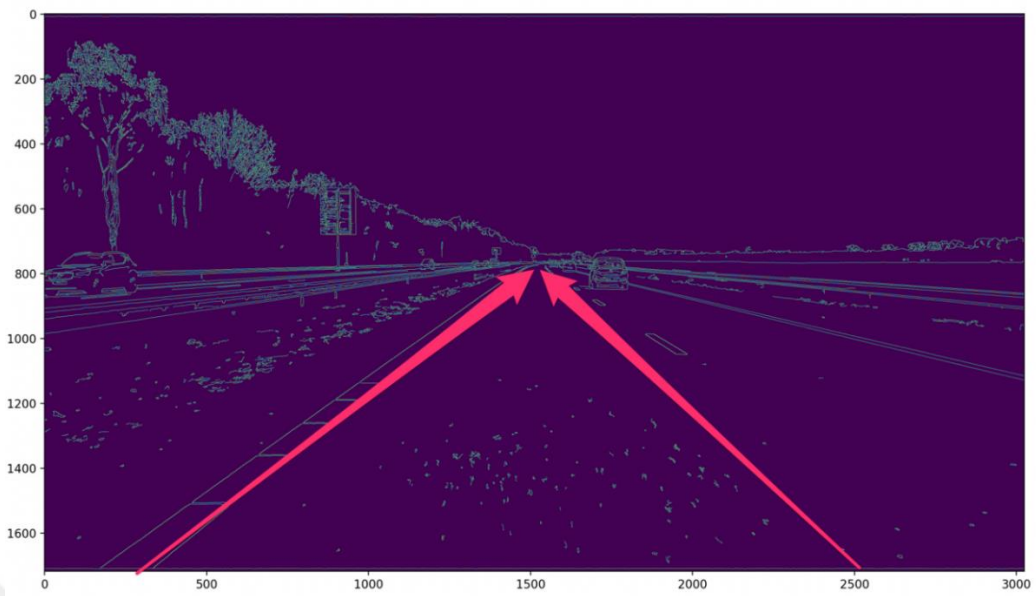
Şekil 3.10. Canny kenar dönüşümü uygulanmış kalibrasyon görseli

Canny Kenar Dönüşümü uygulaması ile yol şeritleri ile kameranın görüş alanı içindeki tüm kenarları tespit edilmektedir. Aynı zamanda tüm bu kenarların işlenmesi için hesaplamalar yapılmaktadır. Bu da çalışan işlemcinin işlem kapasitesinde gereksiz yer işgal etmektedir. Bunun önüne geçmek ve sadece ilgili alanları tespit etmek için "İlgi Alanı Belirleme" işlemi gerçekleştirilmektedir.

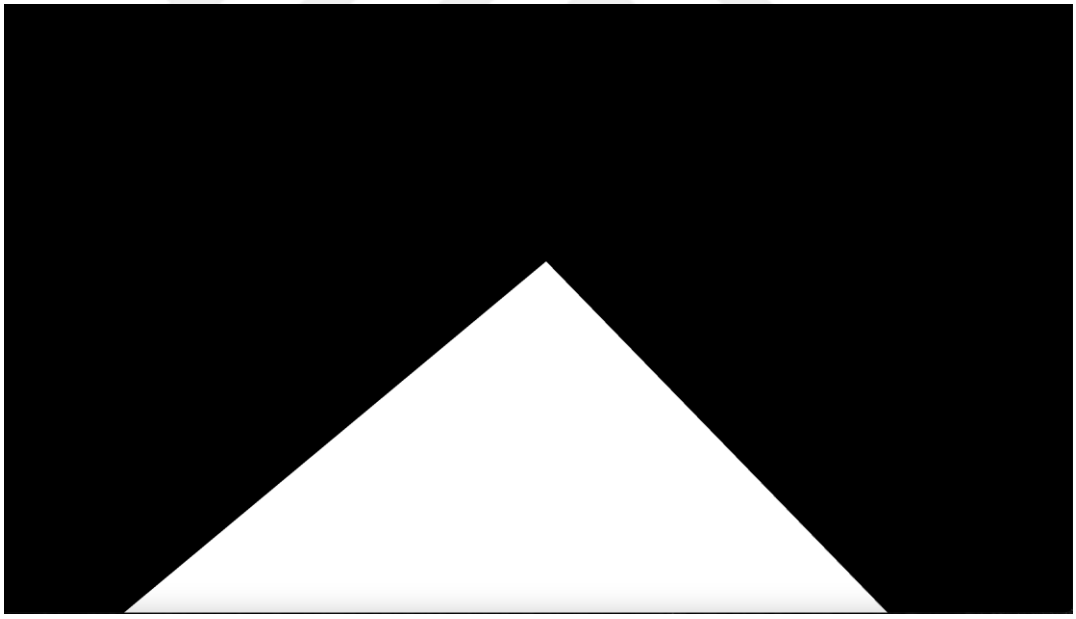


Şekil 3.11. Matplotlib kütüphanesi ile kalibrasyon görselinin koordinat tespiti

Şekil 3.11'de görüldüğü üzere kalibrasyon görselinin koordinat bilgileri Matplotlib kütüphanesi ile tespit edilmiştir. İlgi alanı bu görsel üzerinde **350 x 2500** pikselleri arasında olduğu görülmektedir. Ufuk çizgisine bakıldığı zaman ise **770** numaralı pikselin seçilmesi ile ilgi alanı üçgeni elde edilebilmektedir. Şekil 3.12'da ilgi bölgesi üçgeni görülmektedir.



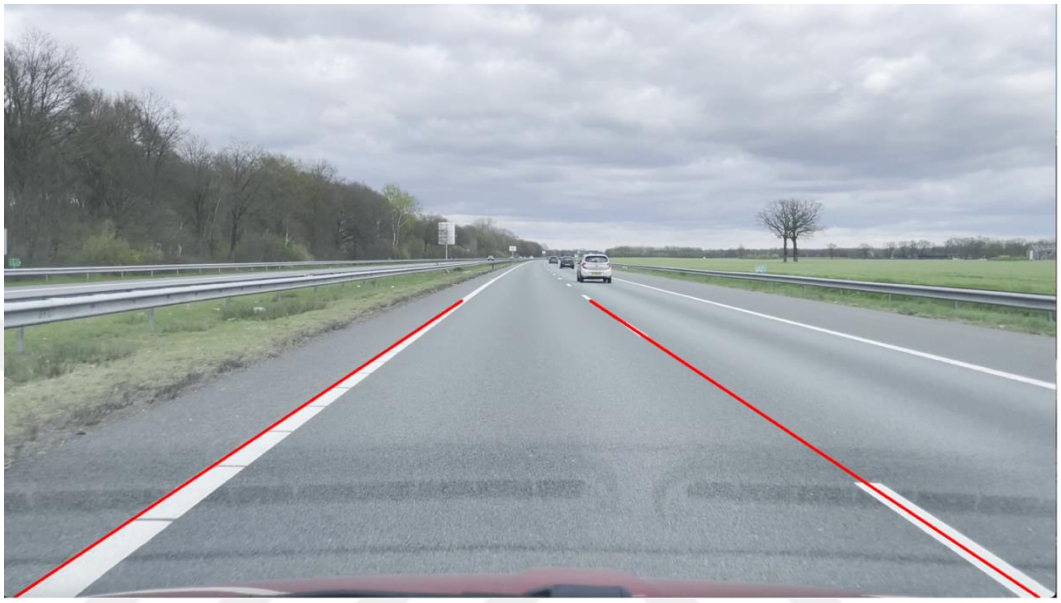
Şekil 3.12. İlgi bölgesi üçgeni



Şekil 3.13. İlgi bölgesinin dışında kalan alanın kalibrasyon bölgesinden çıkarma uygulaması

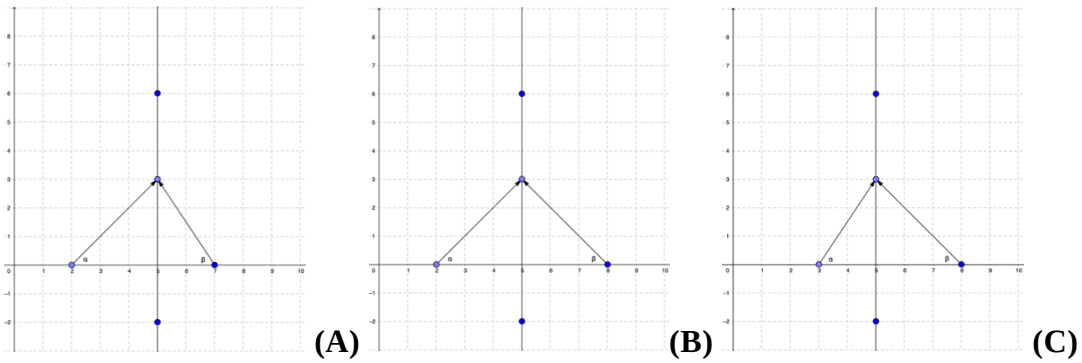
İlgi alanları görüntüye eklendikten sonra yol çizgileri tespiti adımına geçiş yapılır. Bu işlem için Hough dönüşüm algoritması uygulanılarak yolda bulunan çizgilerin görselde işaretlenmesi yerine getirilecektir. Hough dönüşümü ile karede bulunan dikey ve sinüzoidal çizgiler tespit edilebilecektir.

Hough dönüşümü uygulandıktan sonra sistem başarımını gözlemleyebilmek için siyah beyaz dönüşümü kaldırılarak tespit edilen çizgiler belirgin bir renkle çizilmektedir. Kalibrasyon görseli ile alınan ilk kare Şekil 3.14'de görülmektedir.



Şekil 3.14. Hough dönüşümü uygulanmış kalibrasyon görseli

Görselde aracın şeridin dışına çıkıp çıkmadığının tespitine sağ ve sol şerit için çizilen iki doğrunun yaptığı açıya bakarak karar verilebilir. Şerit çizgilerinden yataya göre daha büyük açı yapan şeritten bir ayrılma olduğu tespit edilir. Şekil 3.15'de görülen açıların eşitliği ideal durumu sembolize eder. ($\alpha = \beta$)



Şekil 3.15. Grafik üzerinde şeritten ayrılma tespiti **(A)** Sağ şeritten ayrılma **(B)** İdeal durum **(C)** Sol şeritten ayrılma (İleri, 2017)

4. BULGULAR VE TARTIŞMA

Çalışma kapsamında 2 farklı bilgisayar sisteminde, geliştirilen SGDS algoritmaları test edilmiştir. Jetson Nano ve kişisel bilgisayar ile geliştirilen sistem hem gerçek zamanlı hem de çevrimdışı şekilde test edilmiştir. Yapılan çalışmalar kapsamında geliştirilen bu sistemlerin performansına dair bulgular ve değerlendirmeleri aşağıda görülmektedir.

Günün farklı dilimlerinde ve farkı hava durumlarında yapılan testler esnasında alınan bazı örnek ekran görüntüleri Şekil 4.1 ve Şekil 4.2'de gösterilmiştir.



(A)

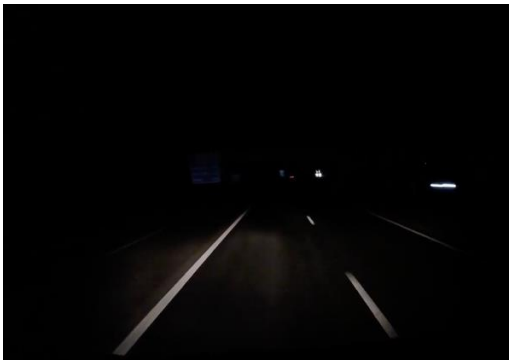


(B)

Şekil 4.1. Gündüz alınan ekran görüntüleri **(A)** Gündüz yağışlı hava **(B)** Gündüz yağışsız hava



(A)



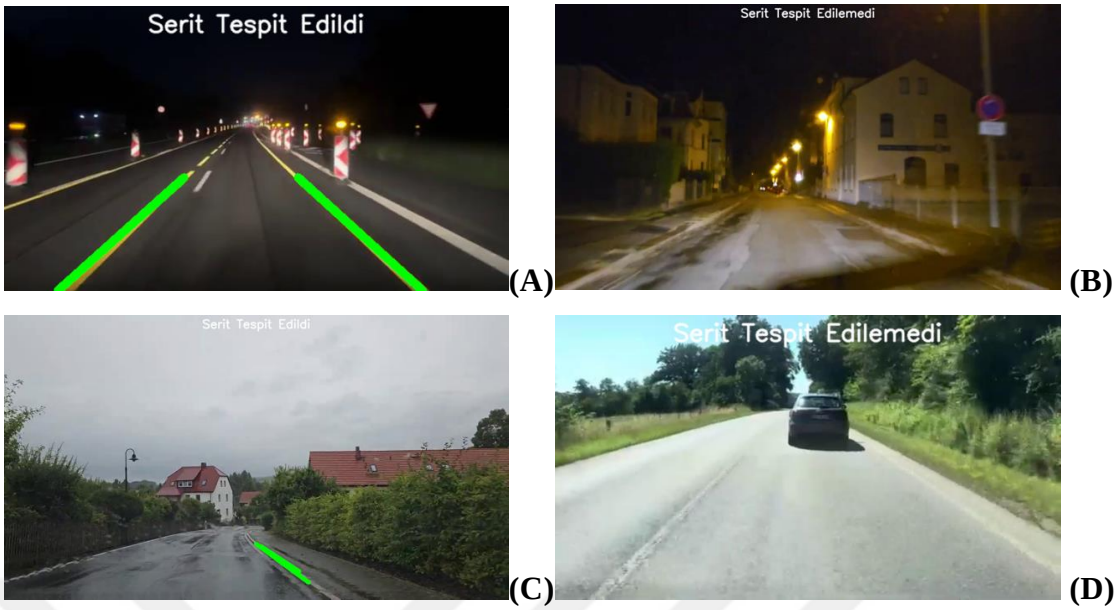
(B)

Şekil 4.2. Gece alınan ekran görüntüleri **(A)** Gece yağışsız hava **(B)** Gece yağışlı hava

Sistemin başarım ölçümü, otomotiv sektöründe araç ön kamera geliştirme uzmanları ve test mühendisleri ile yapılmıştır. Geliştirilen program çalışırken yol verileri içerisinde rastgele alınan anlık görüntüler ile sistemin başarımı ölçülmüştür. Günün değişik zaman dilimlerinde ve değişken hava koşullarında alınan görüntülerle test edilen sistemin davranışlarında farklılıklar olduğu gözlemlenmiştir.

Testler esnasında yapılan gözlemlerde, sistemin şerit çizgilerini tespit etmesi ve bunu belirtmesi 'doğru pozitif', yolda şerit çizgilerinin olmaması ve sistemin bunu 'Şerit tespit edilemedi' olarak belirtmesi 'doğru negatif', yolda şerit çizgisi olmamasına rağmen sistemin 'Şerit tespit edildi' şeklinde geri bildirim vermesi 'yanlış pozitif' ve sistemin yolda şerit çizgisi olmasına rağmen 'Şerit tespit edilemedi' şeklinde geri bildirim vermesi ise 'yanlış negatif' olarak adlandırılmaktadır.

Her bir uzmanın değerlendirmesi, doğru pozitif (TP), doğru negatif (TN), yanlış pozitif (FP) ve yanlış negatif (FN) sayıları üzerinden hesaplanarak genel performans metriklerine dönüştürülmüştür. Elde edilen genel sonuçlar, algoritmanın çeşitli yol koşullarında ve hava durumlarında performansını kapsamlı bir şekilde değerlendirmemize olanak sağlamıştır. Şekil 4.3'te her bir değerlendirme kriterine ait olan örnek görseller görülmektedir.



(A) **(B)** **(C)** **(D)**

Şekil 4.3. Şerit çizgisi tespit algoritması değerlendirilecek program çıktıları **(A)** Doğru pozitif **(B)** Doğru Negatif **(C)** Yanlış pozitif **(D)** Yanlış negatif

Çizelge 4.1. Algoritmanın genel performans ölçümleri

Değerlendirme sonuçları	Değerlendirilen kare sayısı
TP	889
TN	175
FP	108
FN	28

Çizelge 4.1'de görülen değerler ile hesaplanan toplam değerlendirme sonuçlarına göre, tüm değerlendirmecilere gönderilen 1200 görselden alınan sonuçlar, algoritmanın doğruluk oranı %88,67 olarak belirlenmiştir. Bu oran, modelin genel olarak doğru tahminlerde bulunduğunu göstermektedir. Tespit oranı %96,95 olarak hesaplanmış olup, algoritmanın yol koşullarını tespit etme konusundaki başarısını vurgulamaktadır. Bununla birlikte, yanlış pozitif oranı %38,16 olarak ölçülmüştür ve bu da modelin yanlış şerit çizgisi tespitlerini düşük seviyede tutmayı başardığını göstermektedir.

Duyarlılık, modelin gerçek pozitifleri doğru bir şekilde tespit etme yeteneğini ifade eder ve %96,95 olarak hesaplanmıştır. Kesinlik, modelin pozitif tahminlerinin doğruluğunu gösterir ve %89,17 olarak belirlenmiştir. Bu sonuç, modelin tespit ettiği pozitif durumların büyük çoğunluğunun doğru olduğunu göstermektedir. Ancak,

özgüllük %61,84 olarak hesaplanmıştır, bu da modelin doğru negatif örnekleri doğru bir şekilde ayırt etme kapasitesinin sınırlı olduğunu ortaya koymaktadır. Çizelge 4.2'de genel değerlendirmenin performans metrikleri görülmektedir.

Çizelge 4.2. Algoritmanın performans metrikleri

Algoritma Performans Metrikleri	**Değer(%)**
Doğruluk Oranı (Accuracy)	88,67%
Tespit Oranı (Detection Rate)	96,95%
Yanlış Pozitif Oranı (False Positive Rate)	38,16%
Duyarlılık (Sensitivity)	96,95%
Kesinlik (Precision)	89,17%
Özgüllük (Specificity)	61,84%

Elde edilen veriler ışığında hava durumu ve gün ışığı etkisi arasındaki farkı tespit etmek için ilk olarak tüm değerlendirmecilerin yağışlı ve yağışsız havadaki yaptığı incelemelerin sonuçları yukarıda belirtilen performans metrikleri ile incelenmiştir. Yağışlı havada alınan sonuçlar gündüz yağışlı ve gece yağışlı veri seti grubundan alınırken, yağışsız hava sonuçları da aynı şekilde gündüz ve gece yağışsız hava koşullarında alınan veriler ile sınıflandırılmıştır. Tüm değerlendirmecilere gönderilen verilerden yukarıda belirtilen gruplara giren 100 verinin sonuçları çıkartılmıştır. Performans metrikleri Çizelge 4.3 ve Çizelge 4.4'te görülmektedir.

Çizelge 4.3. Yağışlı havada ölçülen performans metrikleri

Yağışlı Hava Performans Metrikleri	
Doğruluk oranı	89,50%
Yanlış pozitif oranı	30,77%
Duyarlılık	96,62%
Kesinlik	89,94%
Özgüllük	69,23%

Çizelge 4.4. Yağışsız havada ölçülen performans metrikleri

Yağışsız Hava Performans Metrikleri	
Doğruluk oranı	87,83%
Yanlış pozitif oranı	47,24%
Duyarlılık	97,25%
Kesinlik	88,46%
Özgüllük	52,76%

Yağışlı koşullar altında algoritmanın doğruluk oranı %89,50 olarak hesaplanmışken, yağışsız koşullarda bu oran %87,83 olarak tespit edilmiştir. Bu fark, yağışlı koşullarda modelin daha yüksek bir doğruluk oranına sahip olduğunu göstermektedir. Bu durum, yağışlı koşullarda veri setinin model için daha belirgin özellikler sunduğunu ve modelin bu tür verilerde daha iyi performans gösterdiğini düşündürmektedir.

Yağışlı ve yağışsız koşullarda duyarlılık değerleri birbirine oldukça yakındır. Yağışlı koşullarda duyarlılık %96,62 olarak hesaplanmış, yağışsız koşullarda ise %97,25 olarak belirlenmiştir. Her iki koşulda da yüksek tespit oranları ve duyarlılık değerleri, modelin doğru pozitifleri tespit etme yeteneğinin güçlü olduğunu göstermektedir. Bununla birlikte, yağışsız koşullarda duyarlılığın bir miktar daha yüksek olması, bu koşullarda modelin doğru tespit yapma kapasitesinin biraz daha iyi olduğunu göstermektedir.

Yanlış pozitif oranı, yağışlı koşullarda %30,77, yağışsız koşullarda ise %47,24 olarak hesaplanmıştır. Bu sonuçlar, modelin yağışsız koşullarda daha fazla yanlış pozitif sonuç ürettiğini göstermektedir.

Kesinlik, yağışlı koşullarda %89,94, yağışsız koşullarda ise %88,46 olarak hesaplanmıştır. Yağışlı koşullarda biraz daha yüksek kesinlik oranı, modelin bu koşullarda yaptığı pozitif tahminlerin daha doğru olduğunu ve yanlış pozitif oranının görece düşük tutulabildiğini göstermektedir. Bu, yağışlı koşulların modelin pozitif sınıflandırmalarını daha güvenilir hale getirdiğini sergilemektedir.

Özgüllük, yağışlı koşullarda %69,23 iken, yağışsız koşullarda %52,76 olarak belirlenmiştir. Bu, yağışlı koşullarda modelin negatif örnekleri doğru bir şekilde ayırt etme kapasitesinin daha yüksek olduğunu göstermektedir. Yağışsız koşullarda ise özgüllüğün düşük olması, modelin bu koşullarda yanlış pozitif sonuçlar üretme eğiliminde olduğunu ve doğru negatif durumları ayırt etme konusunda zayıf kaldığını göstermektedir.

İkinci kıyaslama noktası ise gün ışığı ve yapay ışıklandırmanın sistem performansına etkisi olacaktır. Gündüz alınan sonuçlar gündüz yağışlı ve gündüz yağışsız veri seti grubundan alınırken, gece alınan sonuçlar da aynı şekilde gece yağışlı ve gece yağışsız hava koşullarında alınan veriler ile sınıflandırılmıştır. Tüm değerlendirmecilere gönderilen verilerden yukarıda belirtilen gruplara giren 100 verinin sonuçları çıkartılmıştır. Performans metrikleri Çizelge 4.5 ve Çizelge 4.6'te görülmektedir.

Çizelge 4.5. Gündüz ölçülen performans metrikleri

Gündüz Ölçülen Performans Metrikleri	
Doğruluk oranı	87,00%
Yanlış pozitif oranı	34,68%
Duyarlılık	95,78%
Kesinlik	87,21%
Özgüllük	65,32%

Çizelge 4.6. Gece ölçülen performans metrikleri

Gece Ölçülen Performans Metrikleri	
Doğruluk oranı	90,33%
Yanlış pozitif oranı	47,24%
Duyarlılık	97,96%
Kesinlik	90,91%
Özgüllük	56,36%

Gece koşullarında algoritmanın doğruluk oranı %90,33 olarak belirlenirken, gündüz koşullarında bu oran %87,00 olarak hesaplanmıştır. Bu fark, algoritmanın gece koşullarında daha yüksek bir doğruluk oranına sahip olduğunu göstermektedir. Bu

durum, gece koşullarında veri setinin sistem için daha belirgin özellikler sunduğunu ve sistemin bu tür verilerde daha iyi performans gösterdiğini göstermektedir. Özellikle, gece koşullarında elde edilen daha yüksek doğruluk, sistemin bu koşullarda daha az hatalı tespitte bulunduğunu göstermektedir.

Gece koşullarında duyarlılık %97,96 olarak hesaplanmışken, gündüz koşullarında bu metrik %95,78 olarak belirlenmiştir. Her iki koşulda da yüksek tespit oranları ve duyarlılık değerleri, modelin doğru pozitifleri tespit etme yeteneğinin güçlü olduğunu göstermektedir. Bununla birlikte, gece koşullarında tespit oranı ve duyarlılığın biraz daha yüksek olması, bu koşullarda sistemin doğru tespit yapma kapasitesinin biraz daha iyi olduğunu göstermektedir. Bu sonuçlar, sistemin gece koşullarında daha etkin bir şekilde çalıştığını ve yolda meydana gelen bozucu etkilerden daha az etkilenirken doğruluğu daha yüksek sonuçlar verdiği görülmektedir.

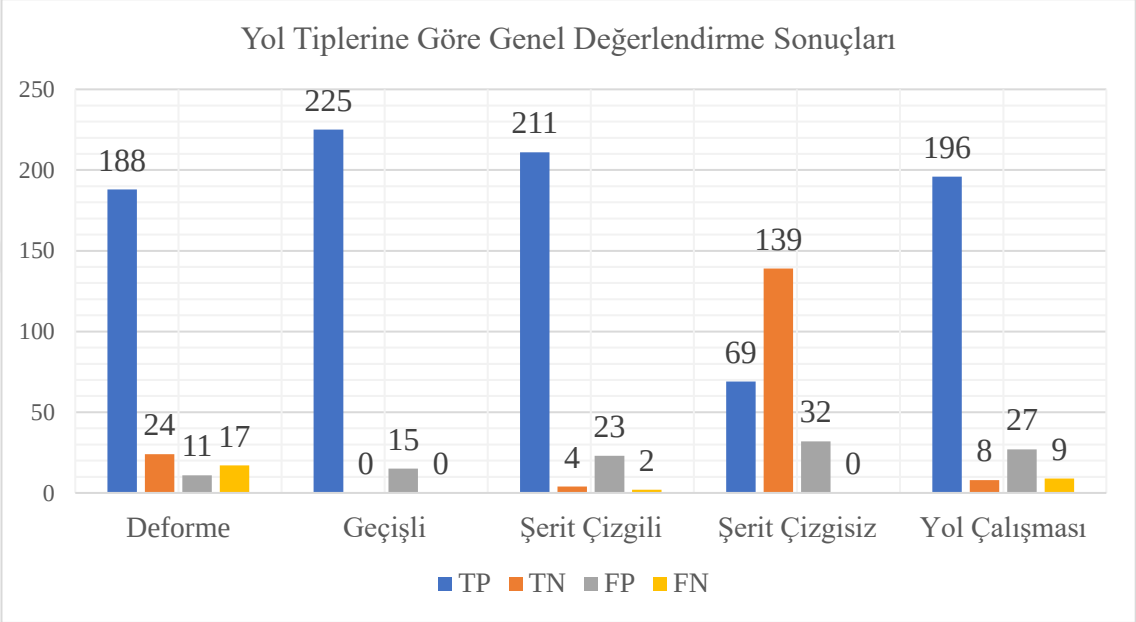
Yanlış pozitif oranı, gece koşullarında %47,24, gündüz koşullarında ise %34,68 olarak hesaplanmıştır. Bu sonuçlar, modelin gece koşullarında daha fazla yanlış pozitif sonuç ürettiğini göstermektedir. Bu durum, gece koşullarında aydınlatma koşullarının veya görsel karmaşıklığın sistemin yanlış pozitif tahmin yapma olasılığını artırdığını düşündürebilir. Özellikle, gece koşullarında araç ve çevre aydınlatmasının yol üzerinde kenar tespitine sebep olabilecek şekilleri daha belirgin hale getirmesi bu duruma sebep olmaktadır.

Kesinlik, gece koşullarında %90,91, gündüz koşullarında ise %87,21 olarak hesaplanmıştır. Gece koşullarında daha yüksek kesinlik oranı, sistemin bu koşullarda yaptığı pozitif tahminlerin daha doğru olduğunu ve yanlış pozitif oranının görece düşük tutulabildiğini göstermektedir. Bu, gece koşullarının sistemin pozitif sınıflandırmalarını daha güvenilir hale getirdiğini düşündürebilir.

Özgüllük, gece koşullarında %56,36, gündüz koşullarında ise %65,32 olarak belirlenmiştir. Gündüz koşullarında sistemin negatif örnekleri doğru bir şekilde ayırt etme kapasitesinin daha yüksek olduğu görülmektedir. Bu bulgu, gündüz

koşullarında negatif sınıflandırmaların daha doğru olduğunu göstermektedir. Ancak, özgüllük oranlarının her iki durumda da mükemmel olmaması, sistemin hem gece hem de gündüz koşullarında bazı negatif durumları yanlış pozitif olarak sınıflandırma eğiliminde olduğunu göstermektedir.

Çizelge 4.7. Yol koşullarının karmaşıklık matrisi elemanlarına dağılımı

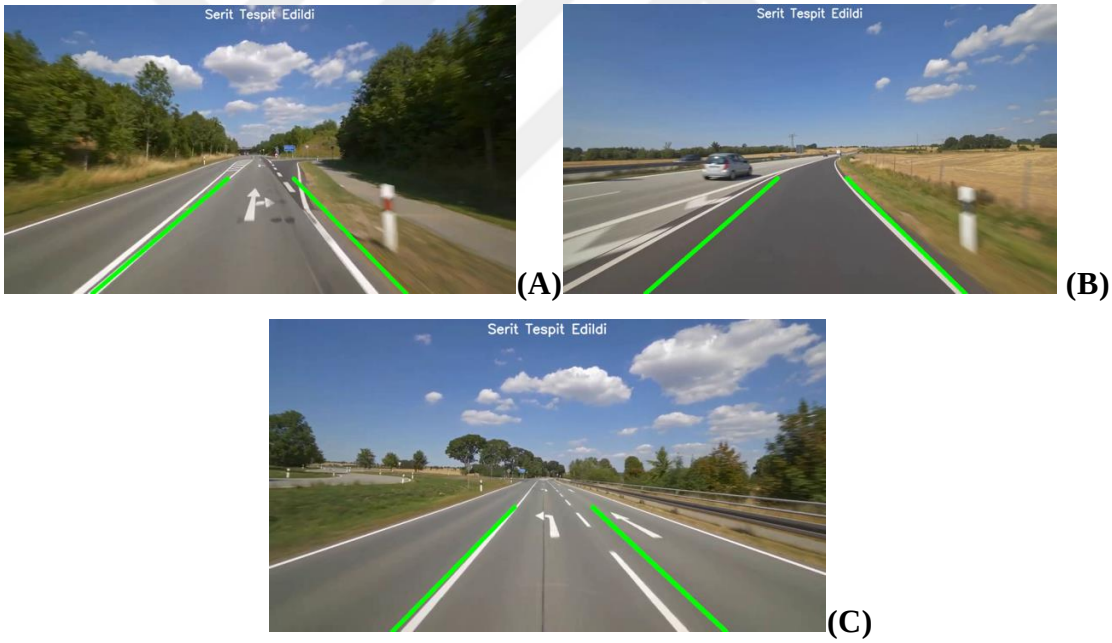


Tüm yol tipleri göz önünde bulundurularak yapılan değerlendirmelere göre, değerlendirmecilere yol tipi başına gönderilen 240 kare görselden alınan sonuçlar Çizelge 4.7'de görülmektedir. Bu çizelgeye göre, deforme yol tipinde, modelin toplamda 188 doğru pozitif ve 24 doğru negatif tahmin yaptığı görülmektedir. Yanlış pozitif sayısı 11 iken, yanlış negatif sayısı 17 olarak kaydedilmiştir. Bu sonuçlar, modelin deforme yol koşullarını tanımlamada genel olarak başarılı olduğunu göstermektedir. Ancak, 17 yanlış negatif, modelin bazı deforme yol durumlarını kaçırdığını, bu da daha fazla iyileştirme ve optimizasyon gerektirebileceğini göstermektedir.

Geçişli yollar kategorisinde, model 225 doğru pozitif tahmin yapmıştır. Yanlış pozitif sayısı 15, yanlış negatif ise 0 olarak belirlenmiştir. Bu, modelin geçişli yolları tespit etmede çok başarılı olduğunu, ancak diğer durumları doğru bir şekilde ayırt etmede zorluk yaşadığını göstermektedir. Bu kategorideki yanlış pozitiflerin sayısı, modelin

diğer yol koşulları ile geçişli yolları karıştırma eğiliminde olabileceğini göstermektedir.

Şerit çizgili yol kategorisinde, modelin 211 doğru pozitif ve 4 doğru negatif tahmin yaptığı görülmektedir. Ancak, modelin 23 yanlış pozitif ve 2 yanlış negatif tahmini bulunmaktadır. Bu, modelin şerit çizgili yolları tespit etmede yüksek bir başarı oranına sahip olduğunu, ancak yanlış pozitif oranının nispeten yüksek olması nedeniyle bazı durumlarda şerit çizgili yolları yanlış bir şekilde tanımlama eğiliminde olabileceğini göstermektedir. Bu durumlara örnek görseller Şekil 4.4'te görülmektedir. Şekil 4.4 (A)'da yolun dar olması sebebiyle yol dışında kalan bölgenin sisteme yaptığı bozucu etki, Şekil 4.4 (B)'de yolun ilgi bölgesinin dışına çıkacak şekilde genişlemesi ve Şekil 4.4 (C)'de yola çizilen şerit çizgisi dışı çizgilerin etkisi görülmektedir.



(A) **(B)** **(C)**

Şekil 4.4. Şerit çizgili yol hatalı tespit örnekleri **(A)** Şerit dışındaki bozucu etkiler **(B)** Şeritte meydana gelen genişlemeler **(C)** Yol kaplamasına çizilen şerit çizgisi dışı işaretler

Şeritsiz yollar kategorisinde, modelin performansının sayısal değerleri diğer kategorilere göre farklılık göstermektedir. Toplamda 69 doğru pozitif ve 139 doğru negatif tahmin yapılırken, 32 yanlış pozitif ve 0 yanlış negatif tahmin yapılmıştır. 69 doğru pozitif sayısı mevcut veri setinde, gündüz yağışsız hava durumunda şeritsiz

yol tipinde yolda sağ şerit çizgisinin mevcut olması ve sol şerit çizgisinin bulunmamasıdır. Şekil 4.5 (A)'da buna örnek bir görsel bulunabilir. Program bu sağ şerit çizgilerini yüksek doğrulukla tespit edebilmiştir. Bu durum, modelin şeritsiz yolları tanımlamada dikkatli olduğunu ve pozitif tahminlerde genellikle doğru sonuçlar elde ettiğini göstermektedir. Ancak, 32 yanlış pozitif, modelin bazı durumlarda şerit çizgili yolları şeritsiz olarak tanımlama eğiliminde olduğunu göstermektedir. Şekil 4.5 (B)'de buna örnek bir görsel yerleştirilmiştir. Bu görselde yol kaplamasında herhangi bir şerit çizgisi olmamasına rağmen yolda meydana gelen renk farkının oluşturduğu yanıltıcı etki görülmektedir.



(A)



(B)

Şekil 4.5. Şerit çizgisiz yol tespit örnekleri **(A)** Tek şerit çizgili yol örneği **(B)** Şerit çizgisiz yolda yapılan hatalı tespit

Yol çalışması kategorisinde, model 196 doğru pozitif ve 8 doğru negatif tahmin yapmıştır. Yanlış pozitif sayısı 27 ve yanlış negatif sayısı 9'dur. Bu sonuçlar, modelin yol çalışması koşullarını tanımada genellikle başarılı olduğunu, ancak yanlış pozitiflerin sayısının yüksek olmasının, modelin yol çalışması olan bölgelerde şeritlerin farklı renkler ve değişik yol şerit çizimlerindeki farklılıklar doğru tespit etme konusunda performansı düşürdüğü görülmüştür.

Sistemin yapmış olduğu tespitlerin hava durumu ve gün evresi ile değerlendirmesi Çizelge 4.8'den faydalanılarak yapılmıştır.

Çizelge 4.8. Gündüz yağışsız hava tüm değerlendirmecilerin değerlendirme sonuçları

Gündüz Yağışsız Tüm Performans Değerlendirmeleri	Adet
TP	198
TN	56
FP	34
FN	12

Çizelge 4.9. Gündüz yağışsız hava tüm değerlendirmecilerin performans metrikleri sonuçları

Gündüz Yağışsız Performans Metrikleri Değerleri	
Doğruluk oranı	84,67%
Yanlış pozitif oranı	37,78%
Duyarlılık	94,29%
Kesinlik	85,34%
Özgüllük	62,22%

Gündüz yağışsız koşullarında, sistem 198 doğru pozitif ve 56 doğru negatif tahmin yapmıştır. Bununla birlikte, sistem 34 yanlış pozitif ve 12 yanlış negatif tahmini yapmıştır. Sistemin doğruluk oranı %84,67 olarak hesaplanmıştır. Yanlış pozitif oranı %37,78 ve duyarlılık %94,29 olarak belirlenmiştir. Kesinlik %85,34 iken, özgüllük %62,22 olarak hesaplanmıştır. Bu veriler, sistemin gündüz yağışsız koşullarında genel olarak yüksek bir tespit oranına sahip olduğunu, ancak yanlış pozitif oranının görece yüksek olması nedeniyle bazı yanlış tespitlerde bulunabildiğini göstermektedir. Ayrıca, özgüllüğün %62,22 olması, sistemin doğru negatif örnekleri tanımlamada sınırlı bir yeteneğe sahip olduğunu göstermektedir.

Çizelge 4.10. Gündüz yağışlı hava tüm değerlendirmecilerin değerlendirme sonuçları

Gündüz Yağışlı Tüm Performans Değerlendirmeleri	Adet
TP	211
TN	57
FP	26
FN	6

Çizelge 4.11. Gündüz yağışlı hava tüm değerlendirmecilerin performans metrikleri sonuçları

Gündüz Yağışlı Performans Metrikleri Değerleri	
Doğruluk oranı	89,33%
Yanlış pozitif oranı	31,33%
Duyarlılık	97,24%
Kesinlik	89,03%
Özgüllük	68,67%

Gündüz yağışlı koşullarında sistemin performansı, 211 doğru pozitif ve 57 doğru negatif tahmin ile oldukça yüksek olarak belirlenmiştir. Yanlış pozitif sayısı 26 ve yanlış negatif sayısı 6 olarak tespit edilmiştir. Bu sonuçlar, sistemin doğruluk oranını bu koşulda %89,33'e yükselmiştir. Yanlış pozitif oranı %31,33'e düşmüştür. Duyarlılık %97,24 ve kesinlik %89,03 olarak hesaplanmıştır. Özgüllük ise %68,67 olarak belirlenmiştir. Bu sonuçlar, sistemin yağışlı gündüz koşullarında daha yüksek bir doğruluğa ve tespit oranına sahip olduğunu, yanlış pozitif oranının düşüklüğü sayesinde daha az hatalı tespit yaptığını göstermektedir. Bu durum, sistemin yağışlı koşullarda daha güvenilir performans sergilediğini ve pozitif sınıflandırmalarda daha başarılı olduğunu ortaya koymaktadır.

Çizelge 4.12. Gece yağışsız hava tüm değerlendirmecilerin değerlendirme sonuçları

Gece Yağışsız Tüm Performans Değerlendirmeleri	Adet
TP	262
TN	11
FP	26
FN	1

Çizelge 4.13. Gece yağışsız hava tüm değerlendirmecilerin performans metrikleri sonuçları

Gece Yağışsız Performans Metrikleri Değerleri	
Doğruluk oranı	91,00%
Yanlış pozitif oranı	70,27%
Duyarlılık	99,62%
Kesinlik	90,97%
Özgüllük	29,73%

Gece yağışsız koşullarında, sistemin performansı en yüksek doğruluk oranına sahip olduğu senaryo olarak öne çıkmaktadır. Toplamda 262 doğru pozitif tahmin yapılırken, sadece 11 doğru negatif tahmin yapılmıştır. Yanlış pozitif ve yanlış negatif sayıları ise sırasıyla 26 ve 1'dir. Bu sonuçlara göre, gece yağışsız modelin doğruluk oranı en yüksek seviyede olduğu koşul olan %91,00 olarak belirlenmiştir. Duyarlılık değeri %99,62 ile oldukça yüksektir, bu da modelin neredeyse tüm pozitif durumları doğru tespit ettiğini göstermektedir. Yanlış pozitif oranı %70,27 olup, özgüllük %29,73 olarak kaydedilmiştir. Bu veriler, modelin gece yağışsız koşullarda negatif durumları tanımlamada çok başarılı olduğunu ancak pozitif örnekleri ayırt etmede ciddi zorluklar yaşadığını göstermektedir.

Çizelge 4.14. Gece yağışlı hava tüm değerlendirmecilerin değerlendirme sonuçları

Gece Yağışlı Tüm Performans Değerlendirmeleri	Adet
TP	218
TN	51
FP	22
FN	9

Çizelge 4.15. Gece yağışlı hava tüm değerlendirmecilerin performans metrikleri sonuçları

Gece Yağışlı Performans Metrikleri Değerleri	
Doğruluk oranı	89,67%
Yanlış pozitif oranı	30,14%
Duyarlılık	96,04%
Kesinlik	90,83%
Özgüllük	69,86%

Gece yağışlı koşullarında model, 218 doğru pozitif ve 51 doğru negatif tahmin yapmıştır. Yanlış pozitif ve yanlış negatif sayıları ise sırasıyla 22 ve 9 olarak belirlenmiştir. Bu sonuçlar ile birlikte, modelin doğruluk oranı %89,67 olarak belirlenmiştir. Duyarlılık %96,04 olarak hesaplanmıştır. Yanlış pozitif oranı %30,14 olup, kesinlik %90,83 ve özgüllük %69,86 olarak kaydedilmiştir. Bu sonuçlar, modelin gece yağışlı koşullarda dengeli bir performans sergilediğini, yanlış pozitif oranının düşük olduğunu ve pozitif sınıflandırmalarda oldukça başarılı olduğunu göstermektedir. Ayrıca, özgüllük oranının %69,86 olması, modelin negatif örnekleri tanımlama kapasitesinin yağışsız gece koşullarına göre daha iyi olduğunu göstermektedir.

Tüm hava koşulları göz önüne alınırsa, genel olarak, "Gece Yağışsız" koşullarda model en yüksek doğruluk ve tespit oranına ulaşmış olup, bu durum modelin pozitif sınıflandırma kapasitesinin çok güçlü olduğunu göstermektedir. Bununla birlikte, bu koşulda özgüllüğün düşük olması, negatif sınıflandırma kapasitesinin artırılması gerektiğini göstermektedir. “Gece Yağışlı” koşullarda model, pozitif ve negatif örnekleri dengeleyerek tutarlı bir performans sergilemektedir. Diğer koşullarla

karşılaştırıldığında, gece yağışlı koşulların özgüllük ve yanlış pozitif oranı açısından daha iyi bir denge sağladığı, ancak tespit oranı ve duyarlılık açısından en iyi performansın gece yağışsız koşullarda elde edildiği söylenebilir. Bu bulgular, modelin gece koşullarında daha iyi çalıştığını, ancak yağışlı ve yağışsız durumlar arasında belirli performans farklarının olduğunu göstermektedir.

"Gündüz Yağışsız" ve "Gündüz Yağışlı" koşullarda modelin performansı karşılaştırıldığında, yağışlı koşullarda doğruluk oranının ve diğer metriklerin daha yüksek olduğu gözlemlenmiştir. Gündüz yağışlı koşullar altında modelin genel performansı, daha yüksek doğruluk, tespit oranı, duyarlılık ve kesinlik değerleriyle Gündüz yağışsız koşullara göre daha iyidir. Yağışlı koşullarda model, yanlış pozitif oranını ve yanlış tespitleri azaltmada daha başarılı olup, negatif örnekleri ayırt etmede daha yüksek bir kapasite sergilemektedir. Bu bulgular, modelin yağışlı koşullarda daha güvenilir bir performans sergilediğini ve genel doğruluğun bu koşullarda daha yüksek olduğunu göstermektedir.

Gündüz yağışsız havada yapılan test sürüşlerinde şeritlerin doğru olarak tespiti %84,67 olarak ölçülmüştür. Şerit tespitinde yapılan hataların sebeplerinin başında yolda meydana gelen deformasyonların olduğu görülmüştür. Şekil 4.6 (A)'da bu duruma örnek bir görsel görülebilir. Sol şerit çizgisinin tespit edilebilmesine rağmen yolda meydana gelen deformasyon ile diğer şeritte meydana gelen doğrusal çizginin sistem tarafından tespit edilmesi sistemi hataya sevk etmiştir. Bununla beraber günün dilimine bağlı olarak yolda oluşan bariyer, ağaç, trafik işaret ve işaretçilerinin oluşturduğu gölgelerin sebep olduğu görülmüştür. Aynı zamanda geçiş yapılan altgeçitlerin de gölgeli olması sebebiyle kameranın odaklanma sırasında yaşadığı zaman kaybı esnasında şeritlerin tespitinde yanıldığı gözlenmiştir. Şekil 4.6 (B)'de buna örnek bir görsel görülmektedir.



(A)


(B)

Şekil 4.6. Gündüz yağışsız deforme yol örneği **(A)** Yolda meydana gelen yanıltıcı çizgi **(B)** Yolda zamanla meydana gelen deformasyon

Gündüz yağışlı havada başarım oranını %89,33 olarak hesaplanmıştır. Başarı oranını gündüz yağışsız hava durumuna göre artıran en önemli etkenlerden birisi, yağmur sebebiyle ıslanan yolda şerit çizgilerinin güneşli güne göre daha belirgin hale gelmesi olduğu ve yolda meydana gelen deformasyonların daha az belirgin hale gelmesi olduğu görülmüştür. Şekil 4.7 (A)'da bir adet deforme yol örneği görülmektedir. Yolda şerit çizgisi olmayan siyah bir çizgi, yağmurun da etkisi ile daha koyu bir hâl almış ve beyaz şerit çizgisinin tespitine olanak sağlamıştır. Bu hava tipinde sistemi hataya sevk eden durumlardan biri yolda şerit çizgisi olmamasına rağmen sol şeritten ilerlerken bariyer ve yol sınırlarının şerit olarak algılanmasıdır. Şekil 4.7 (B)'de bu duruma örnek bir görsel görülmektedir. Sistemi hataya götüren bir başka durum yolda meydana gelen çalışmalardan dolayı araçların karşı şeride geçişinin sağlanması için yapılan çalışmalardır. Şekil 4.7 (C)'de buna örnek bir görsel görülmektedir. Şeritlerin olmadığı yollarda ise kaldırım kenarları sistemi yanıltıcı etki göstermektedir. Buna örnek bir görsel Şekil 4.7 (D)'de görülmektedir. Şeritsiz yollarda sistemin hangi tip çizgileri tespit ettiğini daha net anlamak için Hough dönüşümü metodu ile çizdirilen çizgilerin ortalaması alma işlemi yerine doğrudan tespit edilen tüm çizgilerin görsel üzerine çizdirilmesi gerçekleştirilmiş ve birden fazla çizgi çizdirilmesi durumunda "Şerit Tespit Edildi" ibaresinin yerleştirilme işlemi gerçekleştirilmiştir. Bundan dolayı görselde sağ ve sol şerit bölgelerinde birden fazla çizgi görülmektedir. Bu şekilde görülen görsel bir yanlış pozitif olarak değerlendirilmiştir.



Şekil 4.7. Gündüz yağışlı hava örnekleri **(A)** Yolda meydana gelen deformasyondan kaynaklanan hatalı tespit **(B)** Yol bariyerinin şerit olarak tespit edildiği bir örnek **(C)** Yol çalışması bölgesinde sonradan çizilen şerit çizgileri **(D)** Şerit çizgisiz bölgede hatalı bir şekilde tespit edilen kaldırım

Gece yapılan testler sistemin tespit başarısının gündüze oranla daha yüksek olduğu deneyler olarak görülmüştür. Şekil 4.8 ve Şekil 4.9'da sırasıyla gece yağışlı ve gece yağışsız yapılan test sürüşlerinden örnek görselleri içermektedir.

Gece yağışlı havada yapılan testlerde sistemin başarım oranı %89,67 olarak hesaplanmıştır. Burada en önemli etken yolda meydana gelen en önemli etkenin araç farları ve şehir aydınlatmalarının araç ilgi bölgesini aydınlatması olmuştur. Aydınlatma sayesinde yolda meydana gelen deformasyonların daha az belirgin olması sistemin şeritleri tespit ederken gündüze oranla daha başarılı sonuçlar vermesine olanak sağlamıştır. Sistemi hataya sevk eden senaryolar incelendiğinde Şekil 4.8'de görülen senaryolar gözlemlenmiştir. Şekil 4.8 (A)'da sistemin kaldırımı şerit çizgisi olarak algıladığı bir örnek görülmektedir. Ancak sileceğin çalışması esnasında herhangi yanıltıcı bir etkisinin olmaması sistemin güçlü yanlarından biridir. Şekil 4.8 (B)'de yolda yapılan yol kaplaması yenileme çalışması sonrası görülen renk değişimi sistemi hataya sevk etmiştir. Şekil 4.8 (C)'de yol çalışması

sonrası genişleyen yolda sistemin ilgi bölgesi için yapılan kalibrasyonun gerekliliklerinin karşılanmaması nedeniyle sağ şerit çizgisinde tespit yapılamamıştır.



(A)



(B)



(C)

Şekil 4.8. Gece yağışlı hava örnekleri **(A)** Şerit çizgisiz yolda yapılan yanlış pozitif örneği **(B)** Deforme olmuş olda yapılan yanlış pozitif örneği **(C)** Yol çalışması olan yolda tespit edilemeyen sağ şerit çizgisi

Gece yağışsız havada yapılan testlerde sistemin başarımı %91 ile sistemin en yüksek doğruluk oranı ile çalıştığı zaman dilimi ve hava durumu olarak tespit edilmiştir. Gece şartlarında başarımın yüksek olması yağışlı hava şartlarında da belirtildiği üzere yolun araç farkları ya da sokak lambaları tarafından aydınlatılması ile şeritlerin belirgin hale gelmesidir Sistemin hatalı pozitif ya da hatalı negatif olarak yaptığı tespitlerin sebepleri Şekil 4.9'da görülmektedir. Şekil 4.9 (A)'da yol çalışması olan bir bölgede yol çalışması esnasında sürücülerin takip etmesi gereken sarı çizgiler ile beyaz çizgilerin oluşturduğu farklı şeritlerden kaynaklanan hatalı bir tespit görülmektedir. Şeritler tespit edilebilmiş ancak tespit edilen tüm şeritlerin ortalamasının alınması nedeniyle sarı çizginin üstüne çizdirme işlemi yapılamamıştır. Şekil 4.9 (B)'de sağ ve sol şeritlerin tespitinde herhangi bir sorun ile karşılaşılmazken bir saniye önceki karede otobüs şeridinde bulunan düz çizgiler sistemi şerit çizgisi dışında başka bir şerit çizmeye sevk etmiştir. Şekil 4.9 (C)'de otoyol dışına çıkışta meydana gelen şerit genişlemesi neticesinde sistem yol dışında kalan renk geçişlerini şerit olarak algılamış ve hatalı bir çizim gerçekleştirmiştir.



(A)


(B)


(C)

Şekil 4.9. Gece yağışsız hava örnekleri **(A)** Yol çalışmasında çizilen sarı çizgilerin etkisi **(B)** Şehir içinde yola yazılan ve çizilen şekilleri etkisi **(C)** İlgi bölgesi değişimlerinin etkisi

Çizelge 4.16. Hata analizi

Deforme yol	30
Yol çalışması	22
Geçişli yol renkleri	17
Yol genişliği farkı	35
Şerit çizgisiz bölgede hatalı tespit	27
Yoldaki işaret ve yazılar	3
Yağış nedeniyle görüş yetersizliği	2

Bu hata analizi, geliştirilen SGDS algoritmasının farklı yol ve çevre koşulları altında karşılaştığı hataları detaylandırmaktadır. Analiz, çeşitli yol tipleri ve hava koşulları altında yapılan testlerden elde edilen hataları sınıflandırarak, algoritmanın performansını etkileyen ana faktörleri belirlemeyi hedeflemiştir.

Deforme yollar, sistemin performansını olumsuz etkileyen en önemli faktörlerden biridir. Yol yüzeyinde meydana gelen çatlaklar, tümsekler ve çukurlar gibi deformasyonlar, algoritmanın şerit çizgilerini yanlış algılamasına ve hatalı pozitif

sonuçlara yol açmasına neden olmuştur. Bu tür hatalar, sistemin deformasyonları şerit olarak tanımlama eğiliminde olduğunu göstermektedir.

Yol çalışması bölgelerinde yapılan testler, algoritmanın şerit tespiti yaparken hatalı sonuçlar üretmesine neden olmuştur. Geçici şerit çizgileri, farklı renklerdeki işaretler ve yönlendirme çizgileri, sistemin bu tür alanları yanlış pozitif veya yanlış negatif olarak sınıflandırmasına sebep olmuştur.

Geçişli alanlar yol kaplamasında meydana gelen renk geçişlerini ifade eder, yani yol kaplamasın türünün değişmesi ya da yolda yapılan çalışma sonrası yapılan yol kaplamasının yaptığı renk farkı, algoritmanın şerit tespiti yaparken zorlandığı başka bir faktördür. Bu tür bölgelerde, sistemin farklı yol renklerini şerit olarak algılayarak hatalı pozitif sonuçlar ürettiği gözlemlenmiştir.

Yol genişliğindeki değişiklikler, sistemin hatalı tespitlerde bulunmasına neden olan en yaygın hata kaynağı olmuştur. Yol genişliğinin değiştiği yerlerde, sistemin şerit çizgilerini yanlış bir şekilde algıladığı veya yeni şeritlerin ortaya çıkmasını kaçırdığı gözlemlenmiştir.

Şeritsiz yollarda yapılan testlerde, sistemin mevcut olmayan şeritleri algılayarak yanlış pozitif sonuçlar ürettiği görülmüştür. Özellikle kaldırım kenarları veya yol kenarındaki diğer yapılar, sistem tarafından şerit olarak algılanmış ve hatalı sonuçlara yol açmıştır. Yol yüzeyinde bulunan işaretler ve yazılar, sistemin şerit tespitini zorlaştıran bir diğer faktördür. Bu tür işaretler, algoritmanın yanlış pozitif sonuçlar üretmesine neden olmuş, bu da yol işaretlerinin şerit olarak algılanmasına yol açmıştır. Yağış koşulları, sistemin performansını etkileyen diğer bir faktördür. Yoğun yağış sırasında görüş mesafesinin azalması, algoritmanın şerit çizgilerini doğru bir şekilde algılamasını zorlaştırmış ve bazı yanlış negatif sonuçlara yol açmıştır.

Bu hata analizi, geliştirilen SGDS algoritmasının çeşitli çevresel ve yol koşulları altında karşılaştığı zorlukları ve bu zorlukların sistem performansını nasıl etkilediğini ortaya koymaktadır. Sistemin, özellikle deforme yol yüzeyleri, yol çalışmaları ve şeritsiz bölgeler gibi karmaşık koşullarda daha hassas ve doğru tespitler yapabilmesi için ek eğitime ve optimizasyona ihtiyacı olduğu belirlenmiştir. Gelecekteki çalışmalar, bu tür zorlukların üstesinden gelmek ve sistemin genel performansını artırmak için gerekli iyileştirmelere odaklanmalıdır.

Sistemin performansını etkileyen çeşitli hata kaynakları, farklı hava ve ışık koşullarında yapılan testlerle ortaya konmuştur. Gündüz yağışsız koşullarda sistemin yanlış tespitlerinin başlıca sebepleri arasında yoldaki deformasyonlar ve güneş ışığına bağlı olarak oluşan gölgeler bulunmaktadır. Özellikle yolda meydana gelen çatlak veya deformasyonlar, sistem tarafından yanlış bir şekilde şerit çizgisi olarak algılanmakta ve bu da yanlış pozitif sonuçlara yol açmaktadır. Ayrıca, yol kenarındaki bariyerler, trafik işaretleri ve ağaç gölgeleri gibi faktörler de sistemin hata yapmasına neden olabilmektedir.

Gündüz yağışlı koşullarda ise sistemin performansı genel olarak iyileşmiş olsa da, yanlış pozitif hatalar halen mevcuttur. Yağmurun etkisiyle yolda belirginleşen çizgiler, şerit çizgisi olmayan alanların şerit olarak algılanmasına neden olabilmektedir. Örneğin, yolda şerit olmamasına rağmen bariyerlerin veya yol kenarında bulunan kaldırımları şerit olarak algılanması, sistemin yanlış pozitif tahminler yapmasına yol açmıştır. Ayrıca, yol çalışmaları sırasında geçici olarak konulan veya değiştirilmiş şeritler, sistemin şerit tespitinde yanılmasına neden olabilmektedir.

Gece yağışlı koşullarda, aydınlatmanın etkisiyle yoldaki deformasyonların daha az belirgin olması, sistemin performansını iyileştirmiştir. Ancak, yine de bazı yanlış pozitif hatalar gözlenmiştir. Bu hataların başlıca sebebi, özellikle yetersiz ışıklandırma koşullarında kaldırım kenarlarının veya yol kenarındaki diğer yapıların şerit çizgisi olarak algılanmasıdır. Ayrıca, yol yenileme çalışmaları sonrası oluşan renk değişimleri de sistemin yanlış tespit yapmasına neden olmuştur.

Gece yağışsız koşullarda ise sistemin en yüksek performansı gösterdiği gözlenmiştir. Ancak, bu koşullarda da bazı hata kaynakları mevcuttur. Örneğin, yol çalışması olan bölgelerde geçici sarı çizgilerin veya yol kenarındaki beyaz çizgilerin yanlış yorumlanması, yanlış pozitif sonuçlara yol açmıştır. Ayrıca, otoyol çıkışlarında genişleyen şeritler, sistemin şerit dışındaki renk geçişlerini yanlış bir şekilde şerit olarak algılamasına neden olmuştur.

5. SONUÇLAR

Bu çalışmada 2 farklı işletim sistemi üzerinde, geliştirilmiş olan "şerit takibi yapan bir SGDS" gerçekleştirilmiştir ve sistemin kullanımı için optimum sistem önerilmiştir. Geliştirilmiş SGDS algoritmasının performansı, farklı hava ve ışık koşulları altında detaylı bir şekilde incelenmiştir. Algoritma, gündüz ve gece farklı hava koşullarında teste tabi tutulmuş ve her bir koşulda modelin doğruluk, tespit oranı, yanlış pozitif oranı, duyarlılık, kesinlik ve özgüllük gibi performans metrikleri değerlendirilmiştir.

İncelenen videoların neticesinde, geliştirilen sistemin tüm hava ve gün evresinde yapılan testleri göz önünde bulundurulduğunda %88,67'lik bir başarım oranı ile çalıştığı görülmüştür.

Sistemin performansını etkileyen en önemli iki faktörün yol şartları ve yolun aydınlatılması olduğu görülmüştür. Yollarda kullanılan farklı şerit tipleri, yol adaları, yolda yapılan çalışmalar sonrası çizilen şeritlerin tamamlayıcı olmaması ya da şerit çizilmemesi gibi etkenler sistem üzerinde bozucu etki yaratmaktadır. Bunun yanı sıra yolda meydana gelen fren izleri, çatlaklar, bariyerler, ağaç, trafik lambası ve aydınlatma lambaları gibi çevresel yol ekipmanlarının gölgeleri de sistemi yanıltıcı unsurlar olarak görülmektedir.

Sistemin başarımı hem şehir içinde hem de otoyollarda ölçülmüştür. Sistemin şeritleri tespit etmekte zorlandığı alanlar genellikle şehir içleri olmuştur. Şehir içinde şeritlerin değişken genişliğe sahip olması, şehirlerdeki altyapı çalışmaları sonrası yolda sonradan yapılan asfalt çalışması sonrası renk farkı meydana gelmesi, bazı bölgelerde şerit olmaması gibi etkenler sistemin performansını olumsuz olarak etkilemektedir.

Sonuçlar, algoritmanın yağışlı ve yağışsız hava koşullarında nasıl performans gösterdiğine dair incelemeleri ortaya koymaktadır. Yağışlı koşullarda, sistemin genel doğruluğunun, kesinliğinin ve özgüllüğünün daha yüksek olduğu görülmüştür. Yanlış pozitif oranının daha düşük olduğu gözlemlenmiştir. Yağışsız koşullarda ise, sistemin duyarlılığının yüksek olmasına rağmen, özgüllüğün daha düşük olması dikkat çekicidir. Bu bulgular, sistemin yağışlı koşullarda daha güvenilir ve tutarlı

sonuçlar verdiğini, ancak yağışsız koşullarda negatif sınıflandırmalar yaparken hata yapmaya eğilim gösterdiği görülmektedir.

Sonuçlar, algoritmanın gece ve gündüz koşullarında nasıl performans gösterdiğine dair önemli bilgiler sunmaktadır. Gece koşullarında sistemin genel doğruluğu, kesinliği ve yanlış pozitif oranı daha yüksektir. Bu, modelin gece koşullarında daha tutarlı ve güvenilir sonuçlar verdiğini göstermektedir. Gündüz koşullarında ise sistemin doğruluğu ve kesinliği biraz daha düşmekte, ancak özgüllük oranı nispeten daha yüksektir. Bu, sistemin gündüz koşullarında pozitif sınıflandırmalar yaparken hataya daha meyilli olduğunu ancak negatif koşullar konusunda daha başarılı olduğunu göstermektedir.

Testi yapılan 2 farklı sistemin sonuçlara ulaşma konusunda bir farkı olmadığı her iki sistem de de geliştirilen kodun kullanıcı için aynı çıktıları verdiği görülmüştür. Sistemlerin maliyet ve uygulanabilirlik açısından incelenmesi yapıldığında NVIDIA Jetson Nano'nun boyut olarak daha küçük olması ve daha düşük maliyetli olması ön kamera uygulamasında işlem bilgisayarı olarak kullanılması için daha iyi bir aday haline getirmektedir.

Bu çalışmada, sistemin farklı yol tiplerinde gösterdiği performansıda ayrıca değerlendirmeye tabi tutulmuştur. Genel olarak, sistemin çeşitli yol tiplerini tanımlamada iyi bir performans sergilediği, ancak özellikle yanlış pozitif ve yanlış negatif tahminler konusunda bazı hatalı tespitler yaptığı görülmektedir. Bu sonuçlar, sistemin belirli yol koşulları altında daha fazla eğitime ve iyileştirmeye ihtiyaç duyabileceğini göstermektedir. Özellikle, sistemin şeritsiz ve geçişli yollar gibi daha karmaşık koşulları tanımlarken daha dikkatli olması ve yanlış pozitif oranlarını düşürmek için ek optimizasyonlar yapılması gerektiği açıktır. Gelecekteki çalışmalar, bu zayıf yönleri ele alarak sistemin genel doğruluğunu ve güvenilirliğini artırmaya odaklanmalıdır.

Sonuç olarak, geliştirilen sistemin şeritleri tespit etmedeki başarısı ve önerilen yöntemin farklı araç yükseklik ve genişlik koşullarına kolay uyarlanabilir olması nedeniyle başarılı olarak değerlendirilmekle birlikte, özgüllük oranının nispeten düşük olması, sistemin bazı koşullarda yanlış pozitif sonuçlar üretme eğiliminde olduğunu göstermektedir. Bu durum, sistemin yol durumu ve trafik koşulları algılama performansını artırmak için daha fazla optimizasyon ve eğitime ihtiyaç duyabileceğini düşündürmektedir. Çalışmanın bulguları, yol durumu izleme sistemlerinin geliştirilmesi ve optimize edilmesi için önemli bilgiler sunmakta ve gelecekteki araştırmalar için bir temel oluşturmaktadır. Gelecekte yol genişliğine uyum sağlayabilen, yoldaki deformasyon ve bozucu etkilerden daha az etkilenen bir sistem üzerinde çalışmalara devam edilecek olup bu sistemin farklı alanlara uyarlanması için çalışmalar sürdürülecektir.

KAYNAKLAR

Ansari, M., Kurchaniya, D. & Dixit, M. (2017). A Comprehensive Analysis of Image Edge Detection Techniques. *International Journal of Multimedia and Ubiquitous Engineering*. 12(11). 1-12. Doi: 10.14257/ijmue.2017.12.11.01.

Baek, S., Kim, H. & Chang, H. 2016. A Feasibility Test on Adopting Electric Vehicles to Serve as Taxis in Daejeon Metropolitan City of South Korea. *Sustainability*. 8. 964. Doi: 10.3390/su8090964.

Bannon, P., Venkataramanan, G., Sarma, D., Talpes, E. & McGee, B. . Compute and redundancy solution for the Full Self-Driving Computer 2019.

Broux, R., Lisova, E. & Mubeen, S. 2022. Communication Patterns in Automotive Systems.

Chen, Y., Wong, P.K. & Yang, Z.X. 2021. A NEW ADAPTIVE REGION OF INTEREST EXTRACTION METHOD FOR TWO-LANE DETECTION. *International Journal of Automotive Technology*. 22(6). 1631-1649. Doi: 10.1007/s12239–021–0141–0

Cheng, H.D., Jiang, X.H., Sun, Y. & Wang J., 2001. Color image segmentation: advances and prospects. *Pattern Recognition.* 34(12). 2259-2281. https://doi.org/10.1016/S0031-3203(00)00149-7.

Chitradevi, B. & Srimathi, P. 2014. An Overview on Image Processing Techniques. *International Journal of Innovative Research in Computer and Communication Engineering*. 2(11). 6466-6472.

Cicchino, J. B. Effects of Lane Departure Warning on Police-Reported Crash Rates. Journal of Safety Research, Vol. 66, 2018, pp. 61–70. https://doi.org/10.1016/j.jsr.2018.05.006

Çapraz, M.D., & Yılmaz, E. 2024. Şerit Tespiti Yapan Bir Sürücü Güvenlik Destek Sisteminin Çevresel Koşullar Altında Performans İncelemesi. 13. *ICAR Uluslararası Akademik Araştırmalar Kongresi.* sf. 246.

Dabral, S., Kamath, S., Appia, V., Mody, M., Zhang, B. and Batur U. 2014. Trends in camera based Automotive Driver Assistance Systems (ADAS). *2014 IEEE 57th International Midwest Symposium on Circuits and Systems (MWSCAS)*. pp. 1110-1115, doi: 10.1109/MWSCAS.2014.6908613.

Davies E.R. (2012). Computer and Machine Vision: *Theory, Algorithms, Practicalities Fourth Edition*. Academic Press.

Ding, D. Lee, C. & Lee, K. Y. 2013. An adaptive road ROI determination algorithm for lane detection. *IEEE International Conference of IEEE Region 10 (TENCON 2013)*. 1-4, doi: 10.1109/TENCON.2013.6718807

Emniyet Genel Müdürlüğü, Trafik Başkanlığı. Ülke Geneli Trafik İstatistik Bülteni. Eylül 2022.

Flusser, J., Farokhi, S., Höschl, C., Suk, T., Zitova, B. & Pedone, M. 2016. Recognition of Images Degraded by Gaussian Blur. *IEEE TRANSACTIONS ON IMAGE PROCESSING*. 25(2). 790-806. doi: 10.1109/TIP.2015.2512108.

Gao, W., Zhang, X., Yang, L. and Liu H. 2010. An improved Sobel edge detection. *3rd International Conference on Computer Science and Information Technology.* pp. 67-71, doi: 10.1109/ICCSIT.2010.5563693.

Gurusamy, V. 2017. Digital Clock Recognition using SVM Based Template Matching. International Journals of Advanced Research in Computer Science and Software Engineering. 7(6):337-345. DOI: 10.23956/ijarcsse/V7I6/0130

Hart, P. E. 2009. How the Hough transform was invented [DSP History]. *IEEE Signal Processing Magazine*. 26(6). 18-22. doi: 10.1109/MSP.2009.934181

Hassaballah, M. & Hosny, K. 2019. Recent Advances in Computer Vision: Theories and Applications. *Studies in Computational Intelligence.* doi: 10.1007/978-3-030-03000-1

Hassanein, A.S., Mohammad, S., Sameer, M. & Regap, M.E. 2015. A Survey on Hough Transform, Theory, Techniques and Applications. *IJCSI International Journal of Computer Science Issues.* 12(1). 139-156.

İleri, K. 2017. Sürücü Güvenliği İçin Gerçek Zamanlı Şeritten Ayrılma ve YSA Tabanlı Önden Çarpma Uyarı Sistemi. [Yüksek Lisans Tezi]. Karabük Üniversitesi

Jetson Nano 2GB Developer Kit - Get Started. (n.d.). NVIDIA Developer. https://developer.nvidia.com/embedded/learn/get-started-jetson-nano-2gb-devkit

Karayolları Genel Müdürlüğü. 2020. Trafik Güvenliği Dairesi Başkanlığı Trafik Güvenliği İşaretleme Şubesi Müdürlüğü. *Karayolu Trafik İşaretleme Standartları 1.*

Kim, J. & Shin, H. 2014. *Algorithm & SoC Design for Automotive Vision Systems. For Smart Safe Driving System. https://doi.org/10.1007/978-94-017-9075-8*

Kim, J., Han, D. & Senouci, B. 2018. Radar and Vision Sensor Fusion for Object Detection in Autonomous Vehicle Surroundings. *Tenth International Conference on Ubiquitous and Future Networks (ICUFN).* pp. 76-78, doi: 10.1109/ICUFN.2018.8436959.

Kocić, J., Jovičić, N. and Drndarević, V. 2018. Sensors and Sensor Fusion in Autonomous Vehicles. *26th Telecommunications Forum (TELFOR).* pp. 420-425, doi: 10.1109/TELFOR.2018.8612054

Kukkala, K., Tunnell, J., Pasricha, S. & Bradley, T. 2018. Advanced Driver-Assistance Systems. A path toward autonomous systems. *IEEE Consumer Electronics. Magazine*, https://doi.org/10.1109/MCE.2018.2828440

Kumar, G. & Bhatia, K.P., 2014. A Detailed Review of Feature Extraction in Image Processing Systems. *2014 Fourth International Conference on Advanced Computing & Communication Technologies.* Pg. 5-12. doi: 10.1109/ACCT.2014.74.

Luo, Y. & Duraiswami, R., 2008. Canny edge detection on NVIDIA CUDA. *2008 IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops*, Anchorage, AK, USA, 2008, pp. 1-8, Doi: 10.1109/CVPRW.2008.4563088

Madhok, A., Wang, B. & Piparsania, V. 2019. Storage Capacity Requirement for Autonomous Vehicles to Balloon Over 2TB in the Next Decade. Counterpoint Technology Market Research.

Meyer, M. & Kuschk, G. 2019. Deep Learning Based 3D Object Detection for Automotive Radar and Camera. *Proceedings of the 16th European Radar Conference. pp.* 133-136.

Mitshubishi Motors, Mitsubishi Motors Develops "New Driver Support System". https://www.mitsubishi-motors.com/en/corporate/pressrelease/corporate/detail429.html (1995, December 18)

Mohammad, W., Elomri, A. & Kerbache, L. 2022. The Global Semiconductor Chip Shortage: Causes, Implications, and Potential Remedies. *IFAC-PapersOnLine*. 55(10). 476-483. https://doi.org/10.1016/j.ifacol.2022.09.439.

NMICPS TiHAN Foundation. (November, 2022). Autonomous Driving and Connected Vehicles – TiHAN Testbed Usecase Manual. *Tihan IIT Hyderabad.*

Pai, N., Chen, P., Chen, S. & Chen, S. 2019. Realization of Internet of vehicles technology integrated into an augmented reality system. *Journal of Low Frequency Noise, Vibration and Active Control.* 0(0). pp. 1–16. DOI: 10.1177/1461348419835054

Reway, F. Huber, W., Riberio, E. P. 2018. Test Methodology for Vision-Based ADAS Algorithms with an Automotive Camera-in-the-Loop. *2018 IEEE International Conference on Vehicular Electronics and Safety (ICVES)* Doi: 10.1109/ICVES.2018.8519598

OpenCV. (2024, 10 August). Hough Line Transform. https://docs.opencv.org/3.4/d9/db0/tutorial_hough_lines.html

Qian, G., Fu, T. & Sun, L. 2021. Research on the fuel consumption conservation potential of ADAS on passenger cars. *E3S Web of Conferences.* Volume 268. https://doi.org/10.1051/e3sconf/202126801035.

SAE. Taxonomy and Definitions for Terms Related to Driving Automation Systems for On-Road Motor Vehicles. On-Road Automated Driving (ORAD) Committee. https://doi.org/10.4271/J3016_202104

Senapati, M., Anand, B., Thakur, A., Verma, H. & Rajalakshmi, P. 2021. Object Detection and Segmentation using LiDAR-Camera Fusion for Autonomous Vehicle. *2021 Fifth IEEE International Conference on Robotic Computing (IRC).* pp. 123-124, doi: 10.1109/IRC52146.2021.00029.

Sharifi, M., Fathy, M. & Mahmoudi, M. 2002. A Classified and Comparative Study of Edge Detection Algorithms. *Proceedings of the International Conference on Information Technology: Coding and Computing (ITCC'02).* pp. 117-120, doi: 10.1109/ITCC.2002.1000371.

Shrivakshan, G.T. & Chandrasekar, C. 2012. A Comparison of various Edge Detection Techniques used in Image Processing. *IJCSI International Journal of Computer Science Issues.* 9(5). 269-276.

Song, R., Zhang, Z. & Liu, H. 2017. Edge Connection based Canny Edge Detection Algorithm. *Journal of Information Hiding and Multimedia Signal Processing.* 8(6). 1228-1236. https://doi.org/10.1134/S1054661817040162

Sternlund, S., Strandroth, J., Rizzi, M., Lie, A. & Tingvall, C. (2017). The effectiveness of lane departure warning systems—A reduction in real-world passenger car injury crashes. Traffic Injury Prevention, 18:2, 225-229, DOI: 10.1080/15389588.2016.1230672.

TinyTronics. (2024, 10 August). Raspberry Pi Compatible Camera 5MP met IR Verlichting.https://www.tinytronics.nl/nl/sensoren/optisch/camera's-en-scanners/raspberry-pi-compatible-camera-5mp-met-ir-verlichting

Toyota. (October, 2023). RAV4 Owners Manual. https://toyotamanuals.com.au/docs/rav4-hybrid-owners-manual-oct-22-current/

Voulodimos, A., Doulamis, N., Doulamis, A. & Protopapadakis, E. 2018. Deep Learning for Computer Vision: A Brief Review. Computational Intelligence and Neuroscience Volume 2018, Article ID 7068349, 13 pages https://doi.org/10.1155/2018/7068349

Wang, Y. Chan, P.H. & Donzella, V. 2023. Semantic-Aware Video Compression for Automotive Cameras. *IEEE TRANSACTIONS ON INTELLIGENT VEHICLES.* 8(6). 3712-3722. Doi: 10.1109/TIV.2023.3267443

Weikl, K., Frisvad, J.R., Schroeder, D. & Stechele, W. 2022. Imaging through curved glass: windshield optical impact on automotive cameras. *Proceedings of SPIE Article 122310A SPIE - International Society for Optical Engineering.* https://doi.org/10.1117/12.2634714

Yang, L., Zhao, D., Wu, X., Li, H. & Zhai, J. 2014. An Improved Prewitt Algorithm for Edge Detection Based on Noised Image. *2011 4th International Congress on Image and Signal Processing.* Pp. 1197-1200. doi: 10.1109/CISP.2011.6100495.

Yurtsever, E., Lambert, J., Carballo, A., Takeda, K. 2020. A Survey of Autonomous Driving: Common Practices and Emerging Technologies. *IEEE Access.* PP(99):1-1. Doi: 10.1109/ACCESS.2020.2983149

Zam, M. ve Yılmaz, E. (2019). Trafik işaretlerini tanıyan bir sürücü güvenlik destek sistemi. [Yüksek lisans tezi, Bursa Uludağ Üniversitesi]