

**ORTAM ETKİLEŞİMLİ GÜVENLİ SÜRÜŞ DESTEK
SİSTEMLERİNİN MODELLENMESİ**

Özgür KARADUMAN

**Doktora Tezi
Elektrik-Elektronik Anabilim Dalı
Danışman: Prof. Dr. Hasan KÜRÜM
Mart - 2015**

**T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**ORTAM ETKİLEŞİMLİ GÜVENLİ SÜRÜŞ DESTEK SİSTEMLERİNİN
MODELLENMESİ**

DOKTORA TEZİ

Özgür KARADUMAN

(04113201)

**Tezin Enstitüye Verildiği Tarih: 6 Şubat 2015
Tezin Savunulduğu Tarih: 6 Mart 2015**

**Tez Danışmanı : Prof. Dr. Hasan KÜRÜM (F.Ü.)
Diğer Jüri Üyeleri : Prof. Dr. Mustafa POYRAZ (F.Ü.)
Prof. Dr. Mehmet KAYA (F. Ü.)
Prof. Dr. Vasif Vagifoğlu NABİYEV (K.T.Ü.)
Yrd. Doç. Dr. Zeki OMAÇ (T.Ü.)**

MART - 2015

ÖNSÖZ

Fırat Üniversitesi ailesine katıldığım zamandan bu yana bana olan güvenini ve inancını her zaman hissettiren, doktora çalışmalarımın gerçekleşmesi için imkan sağlayan, çalışmalarım esnasında pozitif yaklaşımlarıyla moral veren, akademik görüşlerinden ve tecrübelerinden her zaman faydalandığım, desteğini sürekli arkamda hissettiğim ve hakkını ödeyemeyeceğim çok değerli büyüğüm, hocam ve danışmanım Prof. Dr. Hasan KÜRÜM' e minnettarlığımı bildirir, sonsuz teşekkür ederim.

Zaman ve mekan kavramı olmaksızın desteklerini esirgemeyen, bilimsel bir karakter kazanmamda başrol oynayan, üzerimdeki emeğini hiçbir zaman inkar edemeyeceğim çok değerli hocam Yrd. Doç. Dr. Haluk EREN' e çok çok teşekkür ederim.

Çalışmalarına çok uzaklardan destek veren ve uluslararası bilimsel tecrübelerinden faydalanmaktan ve kendisini tanımaktan onur duyduğum Ohio University' den saygıdeğer Prof. Mehmet ÇELENK hocama çok teşekkür ederim.

Doktora sürecinde huzurlu bir şekilde çalışmalarımı yürütmem için anlayışlarıyla ve yardımlarıyla destek olan başta Prof. Dr. Mustafa POYRAZ, Prof. Dr. Hasan Gül, Yrd. Doç. Dr. Koray PARLAK, Doç. Dr. Muhsin GENÇOĞLU, Prof. Dr. Mehmet KAYA, Yrd. Doç. Dr. Mustafa KAYA, Yrd. Doç. Dr. Zeki OMAÇ, Öğr. Gör. Ayhan ÇİFTÇİ olmak üzere tüm mesai arkadaşlarım ve amirlerime çok teşekkür ederim.

Bugünlere gelmemde emeği olan ve bana her zaman güven telkin eden aileme, varlıklarıyla bile moral olan ve zaman zaman da bana katlanmak zorunda kalan eşime ve çocuklarıma, maddi manevi destek olan yakınlarıma, iyi dileklerini dualarını esirgemeyen samimi dostlarıma ve burada isimlerini zikretmeyi unutmuş olabileceğim herkese çok çok teşekkür ederim.

İÇİNDEKİLER

Sayfa No

ÖNSÖZ.....	II
İÇİNDEKİLER.....	III
ÖZET.....	VII
SUMMARY.....	VIII
ŞEKİLLER LİSTESİ.....	IX
TABLolar LİSTESİ.....	XV
SEMBOLLER LİSTESİ.....	XVI
KISALTMALAR.....	XX
1. GİRİŞ	1
1.1. Problem Tanımı	4
1.2. İlgili Konularda Yer Alan Araştırmalar ve Çalışmanın Önemi	4
1.2.1. Düşük Seviye Sürücü Destek Sistemleri ile ilgili Çalışmalar	8
1.2.2. Yüksek Seviye Sürücü Destek Sistemleri ile ilgili Çalışmalar	10
1.3. Tez Çalışmasının Akışı	11
1.3.1. Destekleyici Çalışmalar ve Araştırmaya Katkıları	15
2. DİKEY-YATAY SATIR TARAMA VE OPTİK KENAR AKIŞ KÜMELEME YOLUYLA YAKLAŞAN ARABA TESPİTİ	19
2.1. Videodan Resim Çiftlerinin Çıkarılması	20
2.2. Resim Çiftlerinin Kenarlarının Çıkarılması.....	21
2.3. Kenarları Çıkarılmış Resim Çiftlerine Optik Akış Yönteminin Uygulanması	21
2.4. Hareket Vektörlerinin Sınıflandırılması	22
2.5. Kümeleme ve Nesnelerin Konumlarını Belirleme	23
2.6. Araç Tespit Etme	25
2.7. Deneysel Sonuçlar	26
2.7.1. Videodan Resim Çiftlerinin Çıkarılması	26
2.7.2. Kenar Algılama Yöntemi	26

2.7.3.	Optik Akış Vektörlerinin Çıkarılması	27
2.7.4.	Sınıflandırma	28
2.7.5.	Kümeleme ve Lokalizasyon	30
2.7.6.	Arkadan Gelen Aracın Algılanması	32
3.	ÜÇ-ARABA MODELLİ SOLLAMA SENARYOSU İÇİN BAYES AĞI KULLANARAK RİSK HESABI.....	36
3.1.	Sistemin Aşamaları	36
3.2.	Görüntü Çerçevelerine Kenar Algılama Metodunun Uygulanması ve Nesne Sınırlarının Oluşturulması	39
3.3.	Çerçeve Çiftlerinin Hareket Vektörü Haritalarının Çıkarılması	39
3.4.	Hareket Vektörlerinin Sınıflandırılması	40
3.5.	Lokalizasyon ve Kümeleme ile Ön ve Arkadaki Arabaların Pozisyonlarının Hesaplanması	41
3.5.1.	Kümeleme ve Lokalizasyon	41
3.5.2.	Durum Tanımlama	42
3.6.	Durum Ataması ve Risk Hesaplama	48
3.6.1.	Risk Durumları için Bayes Anlam Ağı Oluşturulması	48
3.6.2.	Bayes Ağı Yapılandırılması ve Risk Hesaplama	49
3.7.	DeneySEL Sonuçlar	51
4.	CAN-Bus VERİLERİ KULLANILARAK AGRESİF/SAKİN SÜRÜŞ TESPİTİ İÇİN ÖZNİTELİK SEÇİMİ ALGORİTMASI.....	57
4.1.	Sistemin Çalışması ve Aşamaları	58
4.2.	Veri Toplama ve Özniteliklerin Birbirleriyle İlişkilerinin Çıkarılması	59
4.3.	Korelasyon Tiplerinin Atanması	59
4.4.	Agresif ve Sakin Sürüşün Her İkisi için de Benzer İlişkiyi Gösteren Değişkenlerin Belirlenmesi	61
4.5.	Benzer İlişki Kümelerinin Çıkarılması	63
4.6.	Gereksiz Değişkenlerin Bulunması	64
4.7.	DeneySEL Sonuçlar	66
4.7.1.	Geliştirilen Yöntemin Uygulama Aşamaları	66
4.7.2.	Veri Toplama ve Özniteliklere Değişken Atama.....	66
4.7.3.	Değişkenlerin Birbirleriyle İlişkilerinin Hesaplanması	69

4.7.4.	İlişkilerin Korelasyon Tiplerinin Belirlenmesi	69
4.7.5.	Benzerlik Gösteren İlişki Davranışlarının Belirlenmesi	70
4.7.6.	Benzer İlişki Kümelerinin Çıkarılması	71
4.7.7.	Gereksiz ve İlgisiz Özniteliklerin Elenmesi	73
4.7.8.	Metodun Doğrulanması	73
4.8.	Öznitelik Seçim Algoritmasının Yol Profilini Algılama Problemine Uygulanması Sonuçları	76
4.8.1.	Yol Profili Algılama Problemi	76
4.8.2.	Yol Profili Tipinin Tanınmasında Kullanılan Metodun Adımları	76
4.8.3.	Metodun Doğrulanması	80
5.	ARKA VE ÖN KAMERA YOLUYLA ŞEHİRLERARASI YOLLARDAKİ VİRAJLARIN GEOMETRİK BİLEŞENLERİNİ KULLANARAK OLASILIKSAL RİSK HESABI.....	84
5.1.	Metodun Teorisi ve Aşamaları	85
5.2.	Viraj Yönünün Tespit Edilmesi	86
5.3.	Virajın Keskinliğinin Tespit Edilmesi	87
5.4.	Viraj Eğim Tipinin Tespit Edilmesi	89
5.5.	Güvenli Viraj Almak için Viraja Girmeden önce Kaza Riskinin Hesaplanması.....	91
5.6.	DeneySEL Sonuçlar	94
6.	TRAFİK SAHNE ANALİZİ İÇİN GRAF-KESME TABANLI BÖLGESEL RİSK HESAPLAMA	101
6.1.	Metodun Teorisi ve Aşamaları	102
6.2.	Trafik Sahnesi Tasarımı.....	104
6.2.1.	Trafik Sahnesinin Bölümlere Ayrılması.....	104
6.2.2.	Bölümlerdeki Oyuncu Kümelerinin Tanımlanması.....	105
6.3.	Graf Yapılandırma	107
6.3.1.	Sahne-Graf Dönüşümü	107
6.3.2.	Hücre Riskinin ve Transfer Risklerinin Hesaplanması	111
6.4.	Risk Hesaplama	114
6.4.1.	Graf-Kesme Teorisi ve Enerji Minimizasyonu	114
6.4.2.	Risk Enerji Minimizasyonu	116
6.5.	Bilgisayar Simülasyonları	119

7. SONUÇLAR, TARTIŞMALAR, ÖNERİLER VE GELECEKTEKİ ÇALIŞMALAR.....	125
7.1. Tezde Yapılan Çalışmalar ve Varılan Yargılar.....	126
7.1.1. Arkadan Takip Eden Araç Tespiti ve İzlenmesi	126
7.1.2. Sollama Esnasında Meydana Gelebilecek Kaza Risk Hesabı	128
7.1.3. Sürücünün Agresif veya Sakin Sürücü Olup Olmadığının Tespit Edilmesi.....	129
7.1.4. Yol Profilinin Tespit Edilmesi	130
7.1.5. Viraj Risk Durumunun Tespit Edilmesi.....	131
7.1.6. Bir Trafik Sahnesindeki Riskli Bölgelerin Analizi	132
7.2. Konu ile ilgili Gelecekteki Çalışmalar.....	134
KAYNAKLAR.....	137
ÖZGEÇMİŞ.....	158

ÖZET

Bu doktora çalışmasında, güvenli sürüş hedeflenerek İleri Sürücü Destek Sistemleri için yeni yaklaşımlar geliştirilmiştir. Otonom araçlar sürücüsüz hareket edebilen akıllı araçlardır. Dikkatsizlik, yorgunluk, uykusuzluk ve kurallara uymama gibi nedenler sürücülü araçlarla tam güvenli sürüşün gerçekleştirilmesi için önemli bir engeldir. Aksine, kontrolün sürücüde olmadığı otonom araçlarda ise sürücülerin neden olduğu sorunların ortadan kaldırılması hedeflenmiştir. Bu nedenle bu çalışmada, tam güvenli sürüşün gerçekleşmesi için ideal sürücü davranış modeli olarak otonom sürüş modeli kabul edilmiştir. Sürücü Destek Sistemleri adı verilen ve aktif güvenlik sağlayan akıllı sistemler, otonom sürüşün gerçekleşmesini sağlayan unsurlardır. Bu doktora çalışmasında, yeni Sürücü Destek Sistemleri yaklaşımları geliştirilerek otonom sürüş modeli hedefine katkıda bulunulması amaçlanmıştır. Çalışmada güvenli sürüş hedeflendiğinden dolayı, kaza risk hesabı yaparak tahminlerde bulunabilen, trafik sahnesi analizi yapabilen, sürücü ve yol profilleri çıkarabilen Yüksek Seviye Sürücü Destek Sistemleri yaklaşımları üzerinde daha çok durulmuştur. Bu bağlamda bu doktora çalışmasında; arkadan takip eden aracın tespiti ve izlenmesi, sollama esnasında meydana gelebilecek risk analizi; sürücünün agresif veya sakin sürücü olup olmadığının tespit edilmesi ve yolun eğim tipinin tespit edilmesi problemi için optimizasyon; virajı güvenli bir şekilde almak için risk durumunun tespit edilmesi; trafik sahnesindeki en riskli bölgelerin analizi çalışmaları yapılmıştır. Çalışmalarda geliştirilen yeni yaklaşımlarda, araçlarda standart hale gelmeye başlayan ön ve arka kamera, araçların dahili bilgilerini içeren CAN bus verileri gibi araçta zaten var olan bileşenler kullanılarak herhangi bir ek donanıma ihtiyaç duyulmadan problemlerin çözülmesi hedeflenmiştir. Bu tez çalışmasında; nesne hareket tespiti için optik-kenar akış tekniği ve yeni bir kümeleme algoritması; sollama esnasında sollanan araç üzerine kurulmuş bir risk ön kestirimi yaklaşımı; sürücünün ruh halini ve yol eğim tipini tespit etme problemleri için geliştirilen yeni bir özellik seçim algoritması; viraj dönmeden önce risk hesabı yapmak için virajın keskinliğini, viraj eğim tipini, yönünü tespit eden yeni geometrik yaklaşımlar; şehiriçi bir trafik sahnesindeki en riskli bölgeyi tespit etmek için sahnenin bir grafa dönüştürülüp iyi bilinen Graf-Kesme metodu kullanılarak risk analizi yapılan yaklaşımlar geliştirilmiştir. Bu tez çalışması 113M090 nolu TÜBİTAK projesi tarafından desteklenmiştir.

SUMMARY

MODELLING OF ENVIRONMENT-INTERACTIVE SAFE DRIVE ASSISTANT SYSTEMS

In this thesis, new approaches related to Advanced Driver Assistant Systems have been developed. Autonomous vehicles are intelligent-vehicles that can act driverless. The reasons such as violation of the traffic rules, inattention, fatigue, and insomnia are all significant obstructions to achieve full safety in cars with a driver. In contrast, thanks to the autonomous vehicles that are not in control of the driver are aimed to eliminate the problems caused by driver. Therefore, in this study as an ideal model of driver behavior, full safe driving has been adopted to fully autonomous driving model. Intelligent systems referring Driver Assistance Systems and active safety have been becoming as prominent terms for implementation of autonomous-driving. In this study, new approaches related to Driver Assistant Systems have been developed to contribute the concept of autonomous-driving. In this work, owing to the aim of safe driving, some approaches related to high level driver assistant systems have been focused, as exemplifying the risk estimate, driver and road profile detection, and accident prediction via risk estimation. In this sense, this thesis includes specified studies that are approaching vehicle detection and tracing, overtaking risk analysis, a feature selection method for both Aggressive/Calm driver detection problem and road slope type detection problem, risk estimation to get safe cornering, and traffic scene analysis for most risky region detection. Thanks to new approaches developed in the studies, we have aimed to tackle with the problem, without the need of the external hardware components already existing in a vehicle such as front and rear camera, gradually becoming standard in cars, or CAN-bus data involving internal informations belonging to the car. In this thesis; the approaches such as Optical-edge flow method for detection of object motion and a new clustering algorithm; overtaken car based upon an approach of risk estimation, a new feature selection for detection of driver mood and road slope type problems; geometric approaches such as road curvature, bend slope type, and bend direction estimate for get cornering; and risk analysis using Graph-Cut method for detection of most risky region in the urban traffic scene have been developed.

ŞEKİLLER LİSTESİ

Sayfa No:

Şekil 1.1.	(a) Pasif güvenlik: Hava yastığı, (b) Aktif güvenlik: Electronic Stability Control.....	1
Şekil 1.2.	Öndeki araçları algılayarak hız ve mesafe ayarı sağlayan bir SDS sistemi.....	2
Şekil 1.3.	İnsansız sürüş için üzerinde çalışılan araçlardan bazıları. (a) Carnegie Mellon Üniversitesinin Boss adını verdiği araç, (b) Stanford Üniversitesinin Junior adını verdiği araç, (c) Virginia Tech Üniversitesinin Odin adını verdiği araç, (d) MIT Üniversitesinin Talos adını verdiği araç, (e) Cornell Üniversitesinin Skynet adını verdiği araç	2
Şekil 1.4.	Toyota' nın kendi kendine park yapan ilk modeli Prius Hybrid	5
Şekil 1.5.	(a) Google' ın modifiye edilmiş Toyota Prius test aracı, (b) Google'ın Lexus RH450h model bir başka test aracı, (c) Otonom araçların kullanımına izin veren A.B.D. eyaletleri	6
Şekil 1.6.	Sürücü kontrollü araçlardan tam otonom araçlara doğru sürüş sistemlerinin gelişimi.....	7
Şekil 2.1.	Sistemin aşamaları	19
Şekil 2.2.	Bir hareket vektörünün büyüklüğünün hesaplanması.....	21
Şekil 2.3.	Çerçeveadaki x_1 , x_2 , y_1 , y_2 doğrularının kesişimleri ve kümenin sınırlarının belirlenmesi. K ile belirtilen bölge kümedir.....	25
Şekil 2.4.	(a) Videodan çıkarılan resimler, (b) Ham resim verilerinden çıkarılan kenar resimleri	26
Şekil 2.5.	Kenar algılama işleminden geçirilmemiş bir çerçeveadaki optik akış hareket vektörlerinin görüntüsü. Burada, görüntüdeki tüm nesneleri temsile eden optik akış vektörleri mevcuttur. Dolayısıyla, aranılan esas nesne olan aracın tespit edilmesi işlemi oldukça zorlaşmaktadır	27
Şekil 2.6.	Kenar algılayıcı uygulanmış hareket vektörlerinden oluşan çerçeve.....	28
Şekil 2.7.	Sınıflandırılmış hareket vektörleri. Sınıflandırma eşik kriteri olarak seçilen ortalama hareket vektöründen küçük olanlar kırmızı, büyük olanlar ise maviye boyanmıştır. Eşikten büyük olan maviler, araba olabilecek nesneleri göstermektedir.....	28

Şekil 2.8.	Resim çerçevesindeki hareket vektörlerinin büyüklük histogramı. Sınıflandırma, vektörlerin büyüklükleri baz alınarak, vektörlerin ortalama büyüklüklerinin değeri olan T eşğine göre yapılmıştır.....	29
Şekil 2.9.	T=4 alınarak yapılan sınıflandırma.....	30
Şekil 2.10.	Kümelerin sınırlarının DHCC ve DHCR histogramları ile belirlenmesi.....	31
Şekil 2.11.	(a) Aday kümeler (üstteki resim), (b) Tespit edilen araç (Altteki resim).....	33
Şekil 2.12.	(a) t anındaki aday kümeler, (b) t+1 anındaki aday kümeler, (c) t+2 anındaki aday kümeler, (d) t+3 anındaki aday kümeler.....	34
Şekil 2.13.	Arkadan yaklaşan araç tespiti, (a) arkadan çekilen görüntü çiftinin çıkarılmış kenarları, (b) Optik akış hareket vektörlerinin sınıflandırılması, kümeleneşi ve aday kümelerin tespit edilmesi, (c) Adaylar arasında aracın tespiti.....	35
Şekil 3.1.	Sistemin çalışma senaryosu.....	37
Şekil 3.2.	Ön ve arka kamera görüntülerini kullanan sistemin çalışma detayları.....	38
Şekil 3.3.	Hareket vektörlerinin olasılık yoğunluk fonksiyonu.....	41
Şekil 3.4.	Durum 2 etiketli 3-Araba modeli.....	45
Şekil 3.5.	Durum 5 etiketli 3-Araba modeli.....	46
Şekil 3.6.	Diğer durumlar. (a) Durum 1, (b) Durum 3, (c) Durum 4, (d) Durum 6.....	46
Şekil 3.7.	3-Araba soluma modeli için Bayes Anlam Ağının durum akış şeması.....	49
Şekil 3.8.	Yapılandırılmış Bayes Anlam Ağı.....	50
Şekil 3.9.	Video çerçeveleri ve kenar algılama. (a) Arka kamera görüntülerinden alınan resimler, (b) Ön kamera videolarından alınan yol görüntüleri, (c) Arka için kenar algılama ve nesne sınırlarının belirmesi, (d) Ön için kenar algılama ve nesne sınırlarının belirmesi.....	51
Şekil 3.10.	(a) Kenar algılayıcı uygulanmamış hareket vektörü haritası, (b) Kenar algılayıcı uygulandıktan sonra elde edilmiş hareket vektörü haritası (arka), (c) Kenar algılayıcı uygulandıktan sonra elde edilmiş hareket vektörü haritası (ön) (d) b' de elde edilen hareket vektörü kümesinin yakınlaştırılmış biçimi.....	52
Şekil 3.11.	(a) Arka kameradan, (b) Ön kameradan elde edilen aday kümelerin sınırları.....	53
Şekil 3.12.	(a) Eşikleme (T) ve DHCR-DHCC ile elde edilen kümeler, (b) K-Means ile elde edilen kümeler (ön kameradan alınan görüntüler için).....	53
Şekil 3.13.	K-Means algoritmasının adımları, (a) Kümelemenin başlangıç merkezi, (b) Başlangıç kümesinin merkezinin tekrar hesaplanarak sınırlarının	

güncellenmesi, (c) Yeni merkez ve sınırların güncellenmesi, (d) Merkezlerin değişmemesinden dolayı kümelerin son durumu.....	54
Şekil 3.14. Araba tespiti. (a) t anındaki aday kümeler (arka kamera), (b) t anındaki aday kümeler (ön kamera), (c) Araba tespiti (arkadaki araba), (d) Araba tespiti (öndeki araba).....	54
Şekil 3.15. Anlık pozisyon hesabı ve durum tespiti.....	55
Şekil 3.16. Uygulamanın aşamaları. (a) Arka ve ön kameradan alınan görüntü çiftleri, (b) Görüntü çiftlerine kenar algılayıcı uygulanması, (c) Görüntü çiftlerinin optik akış hareket vektörü haritalarının çıkarılması, (d) Sınıflandırma, kümeleme ve lokalizasyon, (e) Arkadaki ve öndeki arabaların tespiti, (f) Araba pozisyonlarının hesaplanması ve durum tipi tespiti	56
Şekil 4.1. Sistemin aşamaları.....	58
Şekil 4.2. Korele olan ve olmayan aralıklar.....	61
Şekil 4.3. Agresif ve Sakin sürüş için ($v_i v_j$) çiftlerinin korelasyon durumları. (a) Agresif sürüş için Direkt Korelasyon örneği, (b) Agresif sürüş için Ters Korelasyon örneği, (c) Agresif için Korele olmayan bir örnek, (d) Sakin sürüş için Direkt Korelasyon örneği, (e) Sakin sürüş için Ters Korelasyon örneği, (f) Sakin sürüş için korele olmama örneği.....	62
Şekil 4.4. SRC' deki çiftlerin ilişkilerini gösteren yönsüz graf	63
Şekil 4.5. Test sürüşü güzergahı. Kırmızı ile belirtilen kısım test yapılan güzergahı göstermektedir. Test, Elazığ şehrinde Abdullahpaşa ile Fırat Üniversitesi arasında trafiğin yoğun olduğu saatlerde yapılmıştır. Güzergahta hem hız yapılabilmeye müsait yollar hem de kavşak, trafik ışığı gibi yavaşlamayı, beklemeyi ve dikkati olmayı gerektirecek bölümler yer almaktadır.....	66
Şekil 4.6. SRC Kümeleri.....	72
Şekil 4.7. Agresif sürüş tespiti için test işlemi (9 v 15 değişken için).....	74
Şekil 4.8. Sakin sürüş tespiti için test işlemi (9 v 15 değişken için).....	74
Şekil 4.9. Agresif ve Sakin sürüşler için gereksiz değişkenler çıkarılmadan önce ve çıkarıldıktan sonra elde edilen performansların histogramı, (a) Sakin sürüş test sonuçları histogramı, (b) Agresif sürüş için test sonuçları histogramı.....	75
Şekil 4.10. Test sürüşü güzergahı.....	77

Şekil 4.11. 10 ve 15 değişken için Up yol profili algılama testi.....	81
Şekil 4.12. 10 ve 15 değişken için Down yol profili algılama testi.....	82
Şekil 4.13. Up ve Down durumları için gereksiz verilerin elenmesinden önce ve sonraki histogramlarla performans karşılaştırması. (a) Up durumu için 15 değişken ile elde edilen test histogramının sonuçları, (b) Down durumu için 15 değişken ile elde edilen test histogramının sonuçları, (c) Gereksiz 5 verinin elenmesinden sonra geriye kalan 10 veri ile Up durumu için histogram, (d) Gereksiz 5 verinin elenmesinden sonra geriye kalan 10 veri ile Down durumu için histogram.....	82
Şekil 5.1. Şehirlerarası bir viraj ve parametreleri	84
Şekil 5.2. Metodun Aşamaları.....	85
Şekil 5.3. Viraj yönü türleri, (a) sağ yönlü viraj, (b) düz yönlü, (c) sol yönlü viraj.....	86
Şekil 5.4. 3D' den 2D' ye dönüşüm.....	88
Şekil 5.5. Sadece ön kamera kullanıldığı durumda benzer geometrik özelliklere sahip iniş ve yokuşlu viraj örneği (a) Eğim tipi iniş (downhill) olan viraj (b) Eğim tipi yokuş (uphill) olan viraj.....	89
Şekil 5.6. Arka ve ön kameralardan alınan İniş/Çıkış özelliklerine sahip virajlar (a) İniş özelliğine sahip virajın ön kamera ile çekilmiş görüntüsü (b) Yokuş özelliğine sahip virajın ön kamera ile çekilmiş görüntüsü (c) İniş özelliğine sahip virajın arka kamera ile çekilmiş görüntüsü (d) Yokuş özelliğine sahip virajın arka kamera ile çekilmiş görüntüsü.....	90
Şekil 5.7. Bayes Bilgi Ağının Durum Akış Grafi.....	92
Şekil 5.8. Bayes Bilgi Ağının Yapılandırılması.....	93
Şekil 5.9. Elazığ-Harput yolunda sağa dönen bir viraj.....	95
Şekil 5.10. Viraj parametreleri.....	96
Şekil 5.11. Viraj görüntülerinden elde edilen keskinlik değerleri.....	96
Şekil 5.12. Arka ve ön kamera görüntüleri ile yolun eğim tipinin tespit edilmesi.....	97
Şekil 5.13. ROC eğrileri. Sadece ön kamera kullanıldığında ve her iki kamera birlikte kullanıldığında elde edilen eğim tipi tespiti doğruluk oranı.....	97
Şekil 5.14. Yol eğim tipinin tespit edilmesi ile ilgili ön ve arka kameradan alınan görüntülerden oluşan örnek bir veri seti	99
Şekil 5.15. Verisetlerinin her biri için risk hesabı sonuçları.....	100
Şekil 6.1. Metodun Aşamaları.....	103

Şekil 6.2.	Basit bir trafik sahnesi.....	104
Şekil 6.3.	Bölmelere ayrılmış bir trafik sahne taslağı.....	105
Şekil 6.4.	Bölmelerde hangi oyuncuların bulunabildiğini gösteren bölümlenmiş sahne taslağı. Burada komşular arasında risk transferi de söz konusudur.....	107
Şekil 6.5.	Trafik sahnesinden grafa dönüşüm. Her bir sahne bölümü grafin bir hücrecini, risk transferleri de grafin kenarlarına (edge) denk gelmektedir.....	108
Şekil 6.6.	Akıllı grafin akıllı hücre yapısı.....	109
Şekil 6.7.	Her bir hücrenin bir bölümü gösterdiği ve kenarlarının komşu bölümlerdeki risk transferlerini temsil ettiği akıllı graf.....	110
Şekil 6.8.	Hücrelerinin lokal riski ve hücrelerarası transfer edilen riski hesaplanmış olan graf.....	112
Şekil 6.9.	Bölmelere ayrılmış trafik sahnesindeki risk optimizasyonu için Graf-Kesme işlemi uygulanması. (a) Bölmelere ayrılmış sahne ve graf yapılandırmanın başlangıcı, (b) Bölümden hücreye dönüşüm vasıtasıyla sahnenin graf şeklinde gösterilmesi. Burada, n-link graf kenarıdır (edge), bölümler arası risk transferini temsil eder; t-link (s-v) ise kaynaktan hücelere etiketlemedir ve 1 etiketi verir, t-link (v-t) hücelerden hedefe olan etiketlemedir ve 0 etiketini verir, (c) Graph-Kesme işleminin uygulanması, (d) Graph-Kesme işlemi ile riskli bölge hesabı.....	115
Şekil 6.10.	Risk hesaplama için Graf-Kesme metodunun uygulanması.....	119
Şekil 6.11.	Örnek bir cadde taslağı.....	120
Şekil 6.12.	Bölmelere ayrılmış trafik sahnesi.....	120
Şekil 6.13.	Bölmelerdeki oyuncuların tanımlanması.....	121
Şekil 6.14.	Trafik sahnesinin grafa dönüştürülmesi.....	121
Şekil 6.15.	Hücelerdeki risklerin ve transfer risklerinin hesap edilmesi.....	122
Şekil 6.16.	Sahne-graf dönüşümünün sonucunda elde edilen graf.....	122
Şekil 6.17.	Graf-Kesme yoluyla risk enerji minimizasyonu.....	123
Şekil 6.18.	Trafik sahnesindeki en riskli bölgenin gösterimi.....	124
Şekil 7.1.	Yeni nesil otonom araçlarda Bağlı-Araçların (Connected Vehicle) sistem üzerindeki konumu. Bağlantılı-Araçlar aktif güvenlikte İSDS sistemlerini destekleyen ve araçların haberleşmesini sağlayarak tam güvenlik sağlayan topluluk zekasına sahip sistemlerdir.....	135

Şekil 7.2. Birbiri ile haberleşebilen araçlar ve yol altyapısı.....	136
---	-----

TABLÖLAR LİSTESİ

Sayfa No:

Tablo 1.1. Problem çözümünü kriter olarak alan çalışmaların sınıflandırılması.....	9
Tablo 1.2. Kriter olarak kullanılan sensörleri alan çalışmaların sınıflandırılması.....	10
Tablo 2.1. Nesnelerin çerçevedeki konumlarına göre araç olup olmadıklarını gösteren Look-up tablosu.....	31
Tablo 3.1. Durumların doğruluk tablosu.....	43
Tablo 3.2. 3-Araba sollama senaryosu durumları.....	44
Tablo 3.3. Takip mesafeleri için yakınlık dereceleri.....	47
Tablo 3.4. Takip mesafelerine göre tanımlanan risk durumları (Risk States-RS).....	48
Tablo 4.1. SRC kümelerine ait değişkenler.....	64
Tablo 4.2. Değişkenlerin ait oldukları SRC kümeleri.....	72
Tablo 4.3. Değişkenlerin ait oldukları SRC kümeleri.....	80
Tablo 5.1. Farklı veri setleri için viraj yönünün tespit edilmesi sonuçları.....	95
Tablo 5.2. Farklı veri setleri için eğim tiplerinin tespit edilmesi bilgileri.....	98
Tablo 6.1. Çalışmada tanımlanmış olan trafik sahnesi oyuncularını.....	106
Tablo 6.2. Oyuncuların atanmış ağırlıkları.....	111

SEMBOLLER LİSTESİ

Bölüm 2

F	: Resim çerçevesi (Frame)
M, N	: Resim çerçevesinin sırasıyla satır ve sütun sayısı
(I_i, I_j)	: Resim çerçeve çifti
$\vec{A}(x, y)$	: (x, y) konumundaki hareket vektörü
$ \vec{A}(x, y) $	: Hareket vektörünün büyüklüğü
T	: Eşik (Threshold)
c_{ij}	: Sınıflandırılmış hareket vektörlerinin yer aldığı resim çerçevesi elemanı
x_1, x_2, y_1, y_2	: Lokalizasyon algoritması tarafından hesaplanan sınırlar
S1	: y_1 ve y_2 yatay sınırları arasında kalan bölge
S2	: x_1 ve x_2 dikey sınırları arasında kalan bölge
K	: S1 ve S2 bölgelerinin kesişiminden elde edilen küme

Bölüm 3

M, N	: Resim çerçevesinin sırasıyla satır ve sütun sayısı
$\vec{A}(x, y)$	: (x, y) konumundaki hareket vektörü
c_{ij}	: Sınıflandırılmış hareket vektörlerinin yer aldığı resim çerçevesi elemanı
x_1, x_2, y_1, y_2	: Lokalizasyon algoritması tarafından hesaplanan sınırlar
S1	: y_1 ve y_2 yatay sınırları arasında kalan bölge
S2	: x_1 ve x_2 dikey sınırları arasında kalan bölge
K	: S1 ve S2 bölgelerinin kesişiminden elde edilen küme
f	: Sollanan araç ile onun önündeki araç arasındaki mesafe
r	: Sollanan araç ile onun arkasındaki araç arasındaki mesafe
FD	: Takip mesafesi (Following Distance)
$\Delta(f+r)$	: t zaman içerisinde meydana gelen mesafe değişikliği
V1	: Sollanan aracın arkasındaki aracın hızı
V2	: Sollanan aracın önündeki aracın hızı
A	: Trafik yönü ile ilgili tanımlanan olay
$p(a_1)$	: A olayı ile ilgili araçların aynı yönde olma olasılığı
$p(a_2)$	: A olayı ile ilgili araçların karşı yönde olma olasılığı
B	: Öndeki araç şeridi ile ilgili tanımlı olay
$p(b_1)$	: B olayı ile ilgili, öndeki aracın Şerit1' de olma olasılığı
$p(b_2)$	: B olayı ile ilgili, öndeki aracın Şerit2' de olma olasılığı
C	: Arkadaki araç şeridi ile ilgili tanımlı olay
$p(c_1)$	: B olayı ile ilgili, öndeki aracın Şerit1' de olma olasılığı
$p(c_2)$	: B olayı ile ilgili, öndeki aracın Şerit2' de olma olasılığı
D	: Sollanan araç ile önündeki araç arasındaki f mesafesi ile ilgili tanımlanan olay
$p(d_1 a, b, c)$	: a, b, c olayları gerçekleştiği takdirde sollanan araç ile önündeki araç arası f mesafesinin yakın olma olasılığı
$p(d_2 a, b, c)$	: a, b, c olayları gerçekleştiği takdirde sollanan araç ile önündeki araç arası f mesafesinin uzak olma olasılığı

E	: Sollanan araç ile arkasındaki araç arasındaki r mesafesi ile ilgili tanımlanan olay
$p(e_1 a,b,c)$	: a,b,c olayları gerçekleştiği takdirde sollanan araç ile arkasındaki araç arası r mesafesinin yakın olma olasılığı
$p(e_2 a,b,c)$	: a,b,c olayları gerçekleştiği takdirde sollanan araç ile arkasındaki araç arası r mesafesinin uzak olma olasılığı
RS	: Risk durumu olayı (Risk State)
$p(RS d,e)$	: d ve e olayları gerçekleştiği takdirde RS olayının gerçekleşme olasılığı

Bölüm 4

v_i	: i . öznitelik
$\vec{V}$	: Öznitelikler vektörü
R^{ag}	: Agresif sürüş için çapraz korelasyon matrisi
R^{sa}	: Sakin sürüş için çapraz korelasyon matrisi
r_{ij}	: v_i ile v_j arasındaki korelasyon katsayısı
C_{ij}	: Korelasyon tipleri kümesi
C^{+1}	: Değişkenlerin doğrudan korele olması
C^{-1}	: Değişkenlerin ters korele olması
C^0	: Değişkenlerin korele olmaması
C^{ag}	: Agresif sürüş için korelasyon tipi matrisi
C^{sa}	: Sakin sürüş için korelasyon tipi matrisi
T	: Korelasyon tiplerini ayıran ve -1 +1 aralığında olan eşik değer
s_{ij}	: Benzerlik ilişkisi
S^{+1}	: Hem agresif hem de sakin sürüş korele tipinin C^{+1} olması
S^{-1}	: Hem agresif hem de sakin sürüş korele tipinin C^{-1} olması
S^0	: Hem agresif hem de sakin sürüş korele tipinin C^0 olması
NS	: Agresif ve sakin sürüş korelasyonlarının farklı tipte olması
$S^{Benzerlik}$	: Benzerlik İlişki Matrisi
SRC	: Benzerlik İlişki Kümeleri
SRC^{+1}	: Doğrudan korele çiftlerini barındıran küme
SRC^{-1}	: Ters korele çiftlerini barındıran küme
SRC^0	: Korele olmayan çiftleri barındıran küme
up	: Rampa yol
down	: İnişli yol

Bölüm 5

X	: Yatay eksen
O	: Sürücünün bakış noktası
Z	: Sürücünün X eksenine dik olan varsayım olarak bakış doğrultusu
α	: Viraj keskinlik açısı
r	: Aracın ön bakış noktasının viraj ufuk noktasına olan dik uzaklık mesafesi
h	: Başlangıç noktasından viraj ufuk noktası arasındaki mesafe

$\arccos(r/h)$	: α değerinin hesabı
β	: h ile X arasındaki açı
Z	: Temel eksen
f	: Odak mesafesi (focal length)
$g(u_g, v_g)$	: Resim düzleminde iki boyutlu g noktası
$d(u_d, v_d)$	: Resim düzleminde iki boyutlu d noktası
$G(x, y, z)$	: g noktasının üç boyutlu dünyadaki konumu
$D(x, y, z)$	: d noktasının üç boyutlu dünyadaki konumu
z_g	: G noktasının uzaklığının Z eksenî üzerindeki uzaklığı (h)
z_d	: D noktasının gerçek uzaklığının Z eksenî üzerindeki uzaklığı (r)
y_g	: G noktasının Y ekseninden Z eksenine dik uzaklığı
y_d	: D noktasının Y ekseninden Z eksenine dik uzaklığı
x_g	: G noktasının X ekseninden Z eksenine dik uzaklığı
x_d	: D noktasının X ekseninden Z eksenine dik uzaklığı
u_g	: g noktasının resim düzleminde x eksenine dik uzaklığı
u_d	: d noktasının resim düzleminde x eksenine dik uzaklığı
ϕ	: Viraj açısı: Ön kamera görüntüsünde yol iç kenarı ile dış kenarın teğeti arasında kalan açı
Ψ	: Yol ufuk açısı: Arka kamera görüntüsünde yol kenarı ile ufuk noktası teğeti arasındaki açı
G	: Arazi durumunu gösteren olay
$p(g1)$	: Arazinin düz olma olasılığı
$p(g2)$	: Arazinin dağlık olma olasılığı
V	: Aracın hızını gösteren olay
$p(v1 g)$	: G olayına bağlı olarak araç hızının düşük olma olasılığı
$p(v2 g)$	: G olayına bağlı olarak araç hızının yüksek olma olasılığı
S	: Yolun eğim tipi ile ilgili olay
$p(s1 g)$	: G olayına bağlı olarak yol eğim tipinin yukarı olma olasılığı
$p(s2 g)$	: G olayına bağlı olarak yol eğim tipinin aşağı olma olasılığı
N	: Viraj keskinliği için tanımlanmış olay
$p(n1 g)$	: G olayına bağlı olarak yol keskinliğinin düşük olma olasılığı
$p(n2 g)$	: G olayına bağlı olarak yol keskinliğinin yüksek olma olasılığı
D	: Viraj yönü için tanımlanmış olay
$p(d1)$	: Viraj yönünün sol olma olasılığı
$p(d2)$	: Viraj yönünün sağ olma olasılığı
A	: Viraj dönüş riski için tanımlanan olay
$p(a_1 d, v, s, n)$	: D , V , S ve N olaylarına bağlı olarak viraj riskinin düşük olma olasılığı
$p(a_2 d, v, s, n)$	: D , V , S ve N olaylarına bağlı olarak viraj riskinin yüksek olma olasılığı

Bölüm 6

A, B, C	: Trafik sahnesinin bölüm tipleri
$A1, A2, A3$	: Sırasıyla Seviye 1, Seviye 2 Seviye 3' deki A tipi bölümler
$B1, B2, B3$	: Sırasıyla Seviye 1, Seviye 2 Seviye 3' deki B tipi bölümler
$C1, C2, C3$	: Sırasıyla Seviye 1, Seviye 2 Seviye 3' deki C tipi bölümler
y_i	: Trafik sahnesi oyuncular

Y	: Trafik sahnesi oyuncu kümesi
P	: Yaya (Pedestrian)
H	: Araç (Vehicle)
S	: Trafik İşaretleri (Traffic Signs)
L	: Trafik Işıkları (Traffic Lights)
K	: Yaya Geçidi (Crosswalk)
$G(V,E)$	: Düğüm ve Kenarlardan oluşan graf
$w(y_i)$	: i . oyuncunun risk ağırlığı
Y^{x^j}	: $X \in \{A, B, C\}$ ve $j \in \{1,2,3\}$ olmak üzere X^j bölümüne (hücreesine) ait oyuncu listesi
ξ^{x^j}	: $X \in \{A, B, C\}$ ve $j \in \{1,2,3\}$ olmak üzere X^j bölümündeki (hücreesindeki) oyuncuların toplam ağırlığı, yani hücre lokal riski
$\sum_i w(y_i^{x^j})$	: ξ^{x^j} hesabı
ρ	: Potansiyel risk
τ	: Total risk ($\xi + \rho$)
$\sum_i^n \rho_i^{x^j}$	: n komşulu bir X^j hücreesine gelen toplam potansiyel risk
s	: Kaynak (source)
t	: Hedef (sink)
N	: Her biri $\{p, q\}$ ile ifade edilen tüm komşu hücre çiftleri kümesi
l_p	: p hücresinin değeri 1 ya da 0 olan etiketi
L	: Her biri 1 veya 0 olan ve l_p olarak temsil edilecek etiketler kümesi
$E(L)$	: Maliyet fonksiyonu
$\text{argmin}_L E(L)$	: Maliyet fonsiyonunun minimize edilmesi
$R(L)$	: Bölgesel terim
$B(L)$	: Sınır terimi
δ_{l_p}	: Etiket 1 olarak işaretlenmiş işlem yapılacak bölge işareti (1 ya da 0)
δ_{l_q}	: Etiket 0 olarak işaretlenmiş işlem yapılacak bölge işareti (1 ya da 0)
λ_R	: Bölgesel terim için kullanılan ağırlık katsayısı
λ_B	: Sınır terimi için kullanılan ağırlık katsayısı
$B_{p,q}$	: $e^{-\sum q_E^{\text{gönderici}}}$ olarak belirlenen sınır terimi
$\delta_{l_p \neq l_q}$	: İki bölgenin komşu hücrelerinin işleme alınmasını sağlayan etiket


KISALTMALAR

NHTSA	: The National Highway Traffic Safety Administration
ESC	: Electronic Stability Control
NHTSA	: The National Highway Traffic Safety Administration
SDS	: Sürücü Destek Sistemleri
DS-SDS	: Düşük-Seviye Sürücü Destek Sistemleri
YS-SDS	: Yüksek-Seviye Sürücü Destek Sistemleri
İSDS	: İleri Sürücü Destek Sistemleri
ADAS	: Advanced Driving Assistant Systems
ITS	: Intelligent Transportation Systems
ACC	: Adaptive Cruise Control
BBN	: Bayesian Belief Network
CAN	: Controller Area Network
ITSC	: Intelligent Transportation System Conference
IV	: Intelligent Vehicles
ICCVE	: International Conference on Connected Vehicle
ITS	: Intelligent Transportation Systems
fps	: Frame per Second
VHSL	: Vertical Horizontal Line Scanning
DHCC	: Density Histogram of Cluster Columns
DHCR	: Density Histogram of Cluster Rows
PDF	: Probability Density Function
FD	: Following Distance
RS	: Risk State
SRC	: Similar Relation Clusters
DSR	: The Algorithm Detection of Same Relations


1. GİRİŞ

Kara ulaşımı alanında iki önemli husus vardır: Konfor ve Güvenlik. Konfor hem sürücü hem de yolcu açısından rahat seyahat etme anlamında gelse de yakıt tüketimi, haberleşme, yol şartlarına uyum gibi unsurları da içeren, araç-çevre etkileşimine dayanan tüm durumları kapsamaktadır. Güvenlik ise ulaşım esnasında meydana gelebilecek can ve mal kayıplarının en aza indirilmeye çalışılmasıdır. Türk İstatistik Enstitüsü' nün 2012 yılı raporuna göre Türkiye' de yaklaşık 130 bin kaza meydana gelmiştir [1]. The National Highway Traffic Safety Administration (NHTSA) kuruluşunun raporlarına göre Amerika Birleşik Devletlerinde her yıl yaklaşık 6 milyon sekizyüz bin kaza meydana gelmektedir [2]. Ayrıca, Dünya Sağlık Örgütü' nün 2013 yılı raporlarına göre her yıl dünyada 1.24 milyon kişi trafik kazalarında yaşamını yitirmektedir [3]. Buradan hareketle ulaşımında öncelikli hedefin tam güvenlik olduğu gerçeği ortaya çıkmaktadır. Tam güvenlikten anlaşılması gereken, can kaybının ve maddi kayıpların sıfıra indirilmesidir. Örneğin Volvo firması 2020' ye kadar kaza yapmayan araba yapma iddiasında bulunmaktadır [4].

İki tür güvenlik vardır: Aktif güvenlik ve Pasif güvenlik. Pasif güvenlik can kaybını en aza indirmek amacıyla araca yerleştirilmiş hava yastığı, emniyet kemeri gibi kaza anında devreye giren ve akıllı olmayan güvenlik unsurlarıdır. Aktif güvenlik ise seyir esnasında sürücüye destek olan, ortamdaki farklı durumları analiz ederek ön kestirimler ve risk hesapları yapabilen, sonuç olarak olası bir kazayı engellemeyi hedefleyen akıllı sistemlerdir. Öte yandan tam güvenli bir sürüşün gerçekleşmesi, aktif güvenliğin başarılı olmasına bağlıdır. Önemli olan kazaların olmamasıdır. Kaza olduktan sonra can ve mal kaybının olmaması garantisi yoktur.



(a)



(b)

Şekil 1.1. (a) Pasif güvenlik örneği: Hava yastığı, (b) Aktif güvenlik örneği: Electronic Stability Control [5].

Güvenli sürüş için araç-sürücü-ortam üçlüsünün birbiriyle ilişkisi önemlidir. Sürücü ve araç dışındaki herşey ortam (çevre) olarak kabul edilmektedir. Sürücü davranışları, aracın donanım ve teknik özellikleri ile çevre şartlarına göre değişebilir. Bir başka ifadeyle aracın özelliklerine ve çevrenin durumuna göre sürücünün nasıl davranacağı, güvenli sürüş için hayati önem taşımaktadır. Bu sebeple sürücünün daha az hata yapmasını sağlamak amacıyla Sürücü Destek Sistemleri (SDS) geliştirilmiş ve bu konuda çok sayıda çalışma yapılmıştır [6-13].



Şekil 1.2. Öndeki araçları algılayarak hız ve mesafe ayarı yapan bir SDS sistemi [5].

SDS sistemleri genelde araca yerleştirilen donanım ve yazılımların oluşturduğu akıllı sistemlerdir. SDS' ler yol şartlarını ya da trafikteki farklı durumları algılayarak sürücünün karşılaşılabileceği zorlukları hesaplayıp uyarın, ya da bir noktadan başka bir noktaya güvenli bir ulaşımın gerçekleşebilmesi için sürücüye yardımcı olan sistemlerdir. Tam güvenlik için varılmak istene ideal hedef, giderek sürücünün kontrolünü ortadan kaldırmak ve tüm seyahati güvenli bir sürüşe dönüştüren akıllı otonom sürüş sağlamaktır [14]. Şekil 1.3' de bu alanda dünyanın ileri gelen üniversitelerinden bazılarının üzerinde çalıştığı insansız araçlar yer almaktadır.



Şekil 1.3. İnsansız sürüş için üzerinde çalışılan araçlardan bazıları. (a) Carnegie Mellon Üniversitesinin Boss adını verdiği araç, (b) Stanford Üniversitesinin Junior adını verdiği araç, (c) Virginia Tech Üniversitesinin Odin adını verdiği araç, (d) MIT Üniversitesinin Talos adını verdiği araç, (e) Cornell Üniversitesinin Skynet adını verdiği araç [5].

Otonom araçlar bir sürücü olmadan kendi kendine karar verebilen, bir noktadan diğer bir noktaya güvenli ve konforlu bir şekilde varılmasını sağlayan araçlardır. Burada bir sürücünün yerine, tüm işlemleri akıllı bir aracın kendi kendine çok daha güvenli bir şekilde gerçekleştirebileceği kabulü ile hareket edilmektedir. Zira sürücülerin dikkatsizlik, yorgunluk, negatif ruh hali, bilgisizlik, kurallara uymama, sorumsuzluk gibi hem psikolojik hem de sosyolojik anlamda beşeri zaafiyetleri bulunmaktadır. Oysa iyi kurgulanmış bir akıllı araç, sürücülerin tüm becerilerini gerçekleştirme yeteneğinin yanı sıra, onların tüm beşeri dezavantajlarının ortadan kaldırılmasını sağlayabilir. Bu anlamda ideal bir sürüş için örnek alınabilecek sürücü davranış modeli akıllı otonom sürüş modeli olabilir. Daha açık bir ifadeyle, ideal bir sürücü davranışı, tam güvenli sürüş sağlayabilecek SDS sistemleriyle donatılmış akıllı araçlarla gerçekleştirilen tam otonom sürüş modelidir. İdeal otonom araçlar sürücünün olmadığı, kendi kendine sürüş gerçekleştiren ve diğer araçlarla da haberleşebilen ve bu sayede tam güvenlik sağlayan akıllı araçlardır.

Bu çalışmada, ideal sürücü davranışlarına bir model olmasından dolayı tam otonom sürüş sistemleri örnek alınarak akıllı araç modelleri için yeni SDS yaklaşımları geliştirilmiştir.

SDS' ler otonom sürüşün sağlanabilmesi için gerekli olan akıllı sürüşü sağlamaktadır. Tez çalışmasında sürücü destek sistemleri Düşük-Seviye Sürücü Destek Sistemleri (DS-SDS) ve Yüksek-Seviye Sürücü Destek Sistemleri (YS-SDS) başlıkları altında ele alınmıştır. DS-SDS sistemler ile ilgili yapılmış oldukça fazla çalışma bulunmaktadır. Örneğin yolun, yol şeridinin ve sınırlarının tespit edilmesi, trafik ışıklarının ve işaretlerinin tespit edilmesi, nesne tespiti ve takibi, kör nokta tespiti gibi düşük düzey çalışmalar oldukça fazla yapılmıştır. Üstelik birçoğu OpenCV kütüphanesinde tek bir komut haline bile gelmişlerdir [15]. Bununla birlikte, otonom araçların gerçekleştirilmesi için gerekli olan unsurlar trafik sahnesi analizi, kaza risk hesapları, trafik yönetimi ve sürücü davranışları üzerine yapılan yoruma dayalı yaklaşımlar ve karar verebilen akıllı sistemelerdir. Bu nedenle bu tez çalışmasında, YS-SDS sistemleri üzerine daha fazla yoğunlaşmıştır.

1.1 Problem Tanımı

Ulaşım sistemleri; taşıma ekonomisi, lojistik, trafik yönetimi, sürücü davranışı, yol ve araç güvenliği, yolcu taşıma ve benzeri konularla beraber geniş bir alanı kapsamaktadır. Özellikle kara taşımacılığında çevre şartları, trafik karmaşıklığı ve araç dinamikleri nedeniyle güvenlik açısından risk oranı daha yüksektir. Bu nedenle sürücü performansı güvenli sürüş için hayati önem taşımaktadır. Bu özelliği ile on yıllardır sürücülere yardımcı olan akıllı araç sistemleri araştırmacıların ilgisini çekmiştir [16-25].

Bu tez çalışmasında, ideal sürüş için sıfır hata ve maksimum güvenlik hedeflenerek kendi kendine hareket edebilen ve tam güvenlik sağlayan otonom sürüş tekniği model olarak alınmıştır. Sürücülerin yorgunluk, uykusuzluk, dikkatsizlik gibi zaafiyetlerinden ortaya çıkan hataların önüne geçmek için sürücüye yardımcı olabileceği düşünülen sayısız çalışma yapılmış, onlarca yöntem geliştirilmiştir. Sürücünün işini kolaylaştıran veya yardımcı olan her mekanizma İleri Sürücü Destek Sistemleri (İSDS) (Advanced Driving Assistant Systems - ADAS) ismi ile literatürde yer almıştır. Bu sebeple İSDS desteği olan araçlar Akıllı Araçlar olarak adlandırılmaktadır. Buna bağlı olarak akıllı olan tüm araçlar Akıllı Ulaşım Sistemleri (ITS) alanı altında incelenmektedir. Otonom sürüşe geçme sürecinde en önemli rol İSDS' nindir. Çünkü sürücünün araç üzerindeki kontrolü İSDS aşamasından sonra sürücüsüz ve insansız araçlara geçmektedir. Bir başka ifadeyle tam otonom sürüşe geçiş, İSDS sistemlerinin başarısına bağlıdır.

SDS sistemlerindeki çeşitlilik ve araç üzerindeki kontrolü arttıkça sürücünün kontrolü azalmaktadır. Dolayısıyla giderek daha güvenli ve akıllı olan otonom sürüşe yaklaşılmaktadır. Otonom sürüşlerde kararları artık sürücü değil aracın kendisi verir. Bu nedenle analiz yapabilme ve karar verme yeteneğine sahip akıllı YS-SDS sistemlerin geliştirilmesi otonom sürüşe yapılacak katkı anlamına gelmektedir.

1.2. İlgili Konularda Yer Alan Araştırmalar ve Çalışmanın Önemi


Fransız araştırmacı Nicolas Joseph Cugnot tarafından 1769' da geliştirilen ve "Self-Propelled Mechanical Vehicle - Kendinden Tahrikli Mekanik Araç" adıyla dünyanın ilk otomobili olarak kabul edilen araçla [26] başlayan otomotiv serüveni günümüzde akıllı araçlar kavramı ile birlikte insansız araçlar üretme hedefiyle hızla geliştirilmeye devam

etmektedir. Üreticilerin asıl hedefi Tam Güvenli Sürüş (Fully Safe Driving)' tür. Ağırlıklı olarak yirminci yüzyılın ikinci yarısıyla birlikte geliştirilmeye başlanan, kazadan sonraki can ve mal kayıplarını azaltmayı hedefleyen pasif güvenlik sistemlerinden sonra 2000' li yıllara doğru kazanın olmamasını sağlamayı hedefleyen aktif güvenlik sistemleri ön plana çıkmıştır. 1951' de Mercedes-Benz firmasının burkulma-bölgesi kavramını ortaya çıkararak çarpışma testleri yapmaya başlaması [27] ve 1970' lerde Ford ve General Motor' un hava yastığı üretmesi [28], pasif güvenlik ile ilgili önemli kilometre taşlarıdır. 1978' de Mercedes S serisinde Bosch üretimi ABS sistemi kullanması [29], 1981' de Honda' nın navigasyon sistemi kullanması ve Mitsubishi firmasının Adaptive Cruise Control (ACC) sistemini geliştirmesi [5], 1995' de Bosch' un elektronik denge control sistemini geliştirmesi [30] ile sürücüler için pasif güvenlikle beraber aktif güvenlik kavramı da gelişmeye başlamıştır. 2001 yılında Nissan' ın şeritten ayrılma uyarı sistemi kullanmasıyla [31] artık aktif güvenlik sistemleri "Akıllı" olma özelliği kazanmış ve hem artan araç sayısı hem de trafik güvenliği problemleri nedeniyle sürücü destek sistemlerine daha çok ihtiyaç duyulmaya başlanmıştır. 2000' li yıllarla birlikte, otomotiv teknolojisinin gelişmesine paralel olarak bilgisayar teknolojisinin de gelişmesiyle, çiftli-kamera (stereo camera), RADAR, LIDAR, ultrasonik algılayıcılar, kızılötesi ışınlar, GPS, CAN bus, accelerometer, jiroskop ve benzeri algılayıcı tabanlı teknolojilerin kullanımının yaygınlaşmasıyla İSDS sistemleri geliştirilmiş ve hedefler sürücüsüz araçlara doğru yönelmiştir. Böylece kendi kendine sürüş (self-driving), insansız araç (unmanned vehicle), otonom sürüş (autonomous driving) gibi kavramlar ortaya çıkmıştır. 2002 yılında Toyota firması gece görüşlü araç geliştirmiş [5], 2003 yılında otomatik park etme sistemlerini geliştirmiştir [32].



Şekil 1.4. Toyota' nın kendi kendine park yapabilen ilk modeli Prius Hybrid [32].


2008’ de BMW trafik ışıklarını algılama [33], 2010 yılında ise Volvo ve Mercedes yaya algılama sistemlerini kullanmışlardır [34]. 2011 yılında Google ve Stanford Üniversitesi işbirliği ile insansız araç trafiğe çıkarılmış ve Aralık 2013’ de Amerika Birleşik Devletlerinin California, Nevada, Michigan ve Florida eyaletlerinde otonom arabaların kullanımlarına izin verilmiştir [35].



Şekil 1.5. (a) Google’ ın modifiye edilmiş Toyota Prius test aracı, (b) Google’ ın Lexus RH450h model bir başka test aracı, (c) Otonom araçların kullanımına izin veren A.B.D. eyaletleri [35].

Başlangıçta mucitlerin kişisel çalışmalarıyla geliştirilen araçlar, zamanla daha ileri seviyelere taşınmış ve günümüzde insanların hayatında ihtiyaç haline gelmiştir. Bunun sonucu olarak otomotiv sanyinde bir çoğu bütçeleri ile dünya devi haline gelen firmalar ortaya çıkmış ve ülkelerin ticari politikalarında önemli bir yer edinmiştir. Bununla beraber araç üreten firmaların ihtiyaç, talep ve tercihlerden doğan rekabet ortamında başarılı olmalarında, güçlü araştırma geliştirme birimlerine sahip olmaları ve bilim dünyası ile yaptıkları işbirliği önemli rol oynamıştır. Bunun yanısıra, araç sayısının artması ve özellikle gelişmekte olan ülkelerdeki trafik kazalarının artması otomotiv dünyasında güvenli sürüş kavramını ön plana çıkarmış ve hem maddi kaybı hem de can kaybını en asgari düzeye indirmek, dolayısıyla kazaların önüne geçebilmek için sürücü destek sistemleri alanında araştırmacıların yaptığı çalışmalar bu yönde artmıştır. Günümüzdeki çalışmaların hedefi, güvenlik için sürücünün araç üzerindeki kontrolünü mümkün olduğu kadar azaltabilmek, sonrasında sürücüsüz ve insansız araçlar geliştirmektir [36-39].

Şekil 1.6’ de sürüş ve güvenlik özelliklerine göre araç sistemlerinin sınıflandırılması, birbirleriyle ilişkileri ve özellikleri verilmiştir.



Şekil 1.6. Sürücü kontrollü araçlardan tam otonom araçlara doğru sürüş sistemlerinin aşamaları

Akıllı araçlar ile ilgili yapılan çalışmalar hangi araç ya da yöntem kullanılırsa kullanılsın sürüş özellikleri ve güvenlik kontrolü açısından Şekil 1.6' daki sınıflardan birinin altında incelenirler. Burada aşağıdan yukarı doğru ilerledikçe sürücünün kontrolünün giderek azaldığı görülmektedir. En alt seviyede kontrol tamamen sürücüye aittir ve araçta hiçbir aktif güvenlik unsuru yoktur. Bir başka ifadeyle kazayı önleyebilen veya sürücüye destek olabilen mekanizmalar bulunmamaktadır. Sonraki seviye SDS Sistemlerinin ortaya çıktığı ve kazayı engelleme yoluyla aktif güvenliğin sağlandığı İleri SDS, yani İSDS bölümüdür. İSDS' deki başarı ve sürücüye destek oranı ne kadar fazlaysa sürücüsüz ve insansız araçlara doğru o kadar yaklaşılmaktadır. En ideal seviye ise

güvenliğin tamamen sağlanmış olduğu ve birbirleriyle haberleşebilen akıllı araçların olduğu tam otonom araçlardır. Bu çalışmada ağırlıklı olarak İSDS sistemleri geliştirilerek, ideal sürüş olan tam otonom sürüşe doğru ilerlemeye katkıda bulunulması amaçlanmıştır.

İSDS' ler genel olarak iki başlık altında incelenmiştir: Yüksek Seviye SDS (YS-SDS) ve Düşük Seviye SDS (DS-SDS). DS-SDS daha çok ortamdaki nesnelerin tespitine, tanınmasına ve takibine dayanmaktadır. YS-SDS ise çevredeki olayların yorumlanmasına ve trafik sahnesinin analizine dayanan ve risk ön kestirimleri yapabilen sistemlerdir. Ayrıca, YS-SDS' lerin önemli bir uygulama alanı da sürücünün ruh halinin analizi ve sürücü davranışlarıdır.

1.2.1. Düşük Seviye Sürücü Destek Sistemleri ile ilgili Çalışmalar

Oldukça geniş bir kapsama alanına sahip olan DS-SDS' leri iki başlık altında incelemek faydalı olacaktır:

1. Problem çözümü yaklaşımı bakımından
2. Kullanılan sensör sistemleri bakımından

Problem çözümü yaklaşımı bakımından çalışmalar iki başlık altında incelenebilir: Geometrik-Tabanlı Yöntemler ve Özellik-Tabanlı Yöntemler.

Geometrik-Tabanlı yöntemler daha çok yol orta çizgilerini (mid line) [40], yol sınırlarını (road boundary) [41, 42], yol şeritlerini (lane) algılama ve takip etme (detection and tracking) [43-61]; araç tespit etme ve takip etme (vehicle detection and tracking) [62-82]; yol geometrisi kullanarak yol algılama ve takip etme (road detection), yolun düşey ve yatay eğim tiplerini tespit etme (slope type detection) [83, 109]; güvenli viraj alma yardımı (bend negotiation assistant) ve viraj hız ayarlama sistemleri [110-130]; trafik işaretlerini, trafik ışıklarını, yaya geçidini tespit etme (traffic sign, traffic lights and crosswalk detection) [131-135]; ufuk noktası tespit etme ve takip etme (vanishing point detection) [136, 137]; yayaları algılama ve takip etme (pedestrian detection and tracking) [138-146] gibi daha çok nesne tespiti ve takibi yapan sistemlerle ilgili çalışmalardır.

Özellik-Tabanlı yaklaşıma sahip olan sistemler ise bir görüntüdeki resim dokusunun özelliklerinin genellikle istatistiksel olarak analiz edildiği yöntemlere dayanan çalışmalardır [147-153].

Tablo 1.1’ de, problem çözümü yaklaşımı bakımından yapılan çalışmaların yaygın olanlarının listesi verilmiştir.

Tablo 1.1. Problem çözümünü kriter olarak alan çalışmaların sınıflandırılması

PROBLEM ÇÖZÜMÜ YAKLAŞIMI BAKIMINDAN ÇALIŞMALAR
<u><i>Geometrik-Tabanlı Yaklaşım Sahip Çalışmalar</i></u> Şerit/Yol Sınırları/Viraj/Yol Tespit ve Takibi Yol Geometrisi Kullanılarak Yatay Yol Eğimi Tespiti Viraj için Araç Hızı Hesaplama Yolun Eğim Tipinin Tespiti Trafik Işıklarını ve İşaretlerini Tespit Etme Yayaları Tespit Etme ve Takibi Ufuk Noktası Tespiti ve Takibi <u><i>Özellik-Tabanlı Yaklaşım Sahip Çalışmalar</i></u> İstatistiksel Metodlar

Sensör sistemleri bakımından çalışmalar Bilgisayarla Görme-Tabanlı Sistemler (Vision-Based) ve Görme-Tabanlı Olmayan (NonVision-Based) Sistemler şeklinde iki kısımda incelenebilir.

Bilgisayarla Görme-Tabanlı sistemleri kullanan çalışmalar; Çiftli Görme (Stereo Vision) [6, 42, 64, 88] ve Çoklu Bakış (Multi-view) özelliklerine sahip kameralarla yapılan çalışmalar [154]; tek kamera kullanan [7, 155]; araçların ön ve arkalarında bulunan kameralarla iki bakışlı (two-view) teknikler kullanan çalışmalardır [156].

Görme-Tabanlı olmayan çalışmalar ise Akıllı telefon ve Jiroskop (Gyroscope) [157], Accelerometer [8, 157] gibi sensörler kullanan çalışmalar, CAN bus gibi lokal araç verilerini kullanarak problem çözen çalışmalar [158, 159], Radar ve Lidar gibi algılayıcılar kullanan çalışmalar [10, 106, 117], Odometer [6] ve GPS [8] gibi hız ve konum tespit eden araçları kullanan çalışmalar şeklinde özetlenebilir.

Tablo 1.2’ de, kullanılan sensorler bakımından yapılan çalışmaların en yaygın olanları verilmiştir.

Tablo 1.2. Kullanılan sensörleri kriter olarak alan çalışmaların sınıflandırılması

KULLANILAN SENSÖR BAKIMINDAN ÇALIŞMALAR
<u><i>Bilgisayarla Görme-Tabanlı Çalışmalar</i></u> Çiftli Görme ve Çoklu-Bakış Ön ve Arka Kameraların Kullanıldığı İkili Bakış Sadece Ön Kameranın Kullanıldığı Çalışmalar <u><i>Görme-Tabanlı Olmayan Çalışmalar</i></u> Akıllı Telefonlar, Accelerometer ve Jiroskop CAN bus Verilerinin Kullanıldığı Çalışmalar Radar ve Lidar Kullanılan Çalışmalar Odometer ve GPS Kullanılan Çalışmalar

1.2.2. Yüksek Seviye Sürücü Destek Sistemleri ile ilgili Çalışmalar

Yüksek Seviye Sürücü Destek Sistemleri (High-Level Driver Assistant Systems) Olay Temelli (Event-Based) sistemlerdir. YS-SDS' ler olası kazaların önüne geçebilmek için, Sürücü-Araç-Çevre arasındaki olayları yorumlayarak analizler ve önkestimler yapan aktif güvenlik sağlayarak tam güvenli otonom sürüşe yardımcı olan destek sistemleridir.

YS-SDS uygulamalarının başlıcaları Trafik Sahne Analizi (Traffic Scene Analysis) ve Trafik Yönetimi (Traffic Management) [160-178], Viraj Alma Risk Analizi (Road Curve Negotiation Risk Analysis) [179], Sollama Risk Analizi (Overtaking Risk Analysis) [156], Yaya Koruma (Pedestrian Protection) [24, 142, 180], Trafik İhlali (Traffic Violation) [181], Çakışma Önleyici Sistemler (Collision Avoidance) [182, 183], Adaptif Seyir Kontrol (Adaptive Cruise Control) [184] şeklindedir. Ayrıca sürücüler üzerine yoğunlaşmış Sürücü Yorgunluk Algılama (Driver Fatigue Detection) [185], Sürücü Uyku Hali Algılama (Driver Drowsiness Detection) [186, 187], Agresif Sürüş Algılama (Aggressive Driving Detection) [159], Sürücü ruh halinin algılanması ve sürücü davranışı analizi (Driver Mood and Behavior Detection) [188-208] gibi uygulamalar sürücünün seyir esnasında hata yapmasını önleyen yardımcı sistemlerdir.

1.3. Tez Çalışmasının Akışı

Bu tez çalışmasında amaç, bir sürücünün tam güvenli bir şekilde araç kullanmasını sağlayan sistemlerin geliştirilmesine katkıda bulunan yeni İSDS yaklaşımları geliştirmektir. Bir sürücü için en ideal sürüş modeli tam otonom araçlar, yani tamamen İSDS sistemleri ile gerçekleştirilen sürücüsüz araç sistemleridir. Dolayısıyla İSDS sistemleri ne kadar ileri düzeyde olursa tam güvenliğin sağlanmasına ve güvenli sürüşe de o kadar yaklaşmış olacaktır. Bu nedenle bu tez çalışması sürecinde, yeni İSDS yaklaşımları geliştirilmiş ve bu çalışmalar uluslararası bilimsel toplantılarda da kabul görmüştür. İSDS' ler bu tez çalışmasında DS-SDS ve YS-SDS olmak üzere iki başlık altında ele alınmıştır.

Düşük düzey uygulamalar genelde bir nesnenin tespit edilmesi, tanınması ya da hareketli ise takip edilmesi şeklindedir. Örneğin arkadan takip eden bir aracın izlenmesi bunlardan biridir. Bu tür uygulamalara düşük-düzeyle denilmesinin sebebi bir analiz ya da yorumlama yapılmamasıdır.

Yüksek-düzeyle uygulamalar ise bir trafik sahnesinin, bir olayın analizi ya da yorumlanması veya sürücü davranışlarının analizi şeklinde olmaktadır. Yüksek-seviyeli uygulamalarda hareketli veya sabit birden fazla nesnenin birbiriyle ve test aracı ile ilişkileri yorumlanarak analiz edilir ve genelde bir ön kestirim (prediction) yapılır. Örneğin bir araç sollama olayı veya bir virajı güvenli bir şekilde almanın risk durumunun analiz edilmesi, bir trafik sahnesinde en riskli bölgelerin hesaplanması, sürücülerin davranışlarının tespit edilmesi birer yüksek seviye uygulamadır. Yüksek seviyeli uygulamalarda aracın yakıt türünden veya kullanılan sensörlerden bağımsız olarak çözümler üretilir. Bu tez çalışması döneminde aşağıdaki çalışmalar yapılmıştır:

- Arkadan takip eden aracın tespiti ve izlenmesi (DS-SDS)
- Sollama esnasında meydana gelebilecek risk analizi (YS-SDS)
- Sürücünün agresif veya sakin sürücü olup olmadığını tespit eden bir çalışma (YS-SDS)
- Yolun eğim tipini tespit eden bir çalışma (YS-SDS)
- Virajı güvenli bir şekilde almak için risk durumunu tespit eden bir çalışma (YS-SDS)
- Trafik sahnesindeki en riskli bölgeleri analiz eden bir çalışma (YS-SDS)

Tez çalışmasının ikinci bölümünde, “Arkadan takip eden araç tespiti ve izlenmesi” çalışması yer almaktadır. Bu çalışmada kameradan alınan görüntülerle bir yoldaki araç ya da araçların tespit edilmesi ve takip edilmesi amaçlanmıştır. İçinde bulunulan araçtan yoldaki diğer araçları tespit etmek ve takip etmek, Akıllı Araç Sistemleri geliştirmek için ve SDS’ ler için önemli bir düşük-düzey (low-level) aşamadır. Araç tespit ve takip işlemlerini gerçekleştirebilmek için aşağıdaki adımlar izlenmiştir:

Araç kamerasından elde edilen görüntüdeki resim kenarlarının çıkarılması: Bilinen kenar çıkarma maskeleri kullanılmıştır. Ağırlıklı bir şekilde Prewitt maskesi kullanılmıştır. Kenar algılama işleminin buradaki kullanım amacı, sonraki aşamada optik akış çıkarmadaki işlem maliyetini ve karmaşıklığını azaltmaktır.

Görüntüdeki optik akış hareket vektörlerinin (motion vector) çıkarılması: Optik akış, ardarda alınan görüntülerdeki hareket eden nesnelerin tespit edilmesi için kullanılan etkili bir yöntemdir. Ardışık iki görüntüdeki yer değiştiren piksellerin değişim miktarının bir vektör şeklinde temsiline dayanmaktadır. Dolayısıyla hareket eden bir aracın tespiti için de oldukça etkili bir şekilde kullanılabilir.

Hareket vektörlerinin kümelenmesi (Clustering): Optik akış hareket vektörleri, örneğin ortalama vektör büyüklüğü gibi bir eşikleme kriteri ile kümeler şekline getirilmektedir. Buradaki amaç, hareket etmeyen nesneleri eleyerek araç olma olasılığı olan hareketli nesneleri ortaya çıkarmaktır. Bu adımda K-means kümeleme algoritmasından faydalanılmıştır.

Kümelerin sınıflandırılması ve araç tespiti: Araç olabileceği düşünülen hareket vektörü kümelerinin görüntüde yer alan yol sahnesindeki konumuna ve büyüklüğüne göre sınıflandırılarak araba olup olmadığı tespit edilmektedir.

Tez çalışmasının üçüncü bölümünde, “Sollama esnasında meydana gelebilecek risk analizi” çalışması yer almaktadır. Bilindiği gibi hatalı sollamadan dolayı meydana gelen kazalar ölümcül kazalardır. Bu çalışmada bu kazaların önlenmesinde sollanan aracın kritik rol oynadığı fikrinden yola çıkılmıştır. Sollanan aracın arkasına ve önüne yerleştirilen kameralarla sollamadan önceki risk durumlarının tespit edilerek sollanan araç sürücüsüne önlem alması için bir sürücü destek sistemi geliştirildi. Sistemin aşamaları ve kullanılan yöntemler aşağıdaki gibidir:

Sollama durum tespiti (Case detection): Burada üç aşama vardır:

- Sollanan araçtaki ön ve arka kameralardan faydalanarak öndeki ve arkadaki araçların tespiti: Bu işlem için kenar çıkarma ve optik akış yöntemleri kullanılmıştır. Ayrıca K-means kümeleme algoritmasından faydalanılmıştır.
- Tespit edilen araçların hangi şeritlerde olduklarının tespiti
- Sollama anının tanımlanması: Daha önce tanımlanmış durumlardan hangisi olduğunun tespit edilmesi

Sollama anında tespit edilen durumun değerlendirilmesi: Risk tespiti için iyi bilinen bir olasılıksal yöntem olan Bayesian Belief Network (BBN) kullanılmıştır. Sollanan aracın önündeki ve arkasındaki araçların şerit konumu mesafeleri ve araçların yönlerinin BBN üzerinde tanımlanması ile risk hesabı yapılmıştır.

Tez çalışmasının dördüncü bölümünde, “Sürücünün agresif ya da sakin sürücü olup olmadığını tespit edilmesi” çalışması yer almaktadır. Bu çalışmada sürücülerin araç kullanma davranışlarını tespit etme uygulamaları yapıldı. Özellikle sürücülerin agresif veya sakin sürüşleri üzerine çalışma yapıldı. Bu çalışmada sürücülerin aracı sürüş karakterlerini belirlemek için aracın CAN-bus çıkışından alınan veriler kullanıldı. Yapılan test sürüşlerinde bilinçli bir şekilde agresif araç sürüşü ve sakin sürüş, bir başka ifadeyle olması gereken ideal sürüş gerçekleştirildi. Veriler korelasyon, regresyon ve özellik seçimi (feature selection) yöntemleri ile değerlendirilerek agresif ve sakin sürüş tanımları yapıldı. Bu tanım yapılırken, sürücünün gaz pedalını, freni, debriyajı kullanım biçimi ve sürüş esnasında *devir* (RPM), *yakıt oranı* (Fuel Rate), *yakıt tüketimi* (Fuel Cost), *tork* gibi CAN-bus verilerinden elde edilebilen değerlerin ağırlıklandırılması yapıldı. Test sürüşleri yapıldıktan sonra agresif sürüş ile sakin sürüş ikili olarak sınıflandırıldı ve regresyon denklemi ile ağırlıklandırıldı. Ardından herhangi bir sürücü aracı sürerken bu sınıfların hangisine ait olduğu tespit edildi. Ayrıca, bu tespit yapılırken CAN-bus verileri ikişer ikişer çapraz korelasyona (cross correlation) tabi tutuldu ve aralarındaki ilişkiler değerlendirilerek CAN-bus verilerinin hangilerinin etkisiz olduğu özellik seçimi (feature selection) ve değişken seçimi (variable selection) yöntemleriyle belirlenerek optimizasyon yapıldı.

Tez çalışmasının bu bölümünde geliştirilen metodla, “Düşey yol eğiminin tür tespiti” uygulaması da gerçekleştirilmiştir. Bu uygulamada da CAN Bus verileri kullanılmaktadır. Yol eğim tipinin (slope type) belirlenmesi, yani yolun rampa veya iniş olup olmadığına karar verilmesinde aracın devir, tork, hız, ivme, egzoz gaz çıkışı, yakıt tüketimi gibi verilerden hangilerinin gereksiz olduğu tespiti yapıldı. Bunun için yine regresyon, korelasyon yöntemleri ve öznitelik seçimi (attribute selection) algoritmalarından faydalanıldı.

Tez çalışmasının beşinci bölümünde, “Virajı güvenli bir şekilde almak için viraja girmeden önceki risk durumunu tespit edilmesi” çalışması yer almaktadır. Bu çalışmada Bilgisayarla Görme teknikleri kullanılarak sürücüye virajın riskli yol durumlarını tespit edecek bir sürücü destek sistemi hedeflendi. Özellikle de yatay virajlı yollar (horizontal curved road) üzerine çalışmalar yapıldı. Amaç, araç viraja girmeden önce virajın risk durumunu çıkararak sürücünün virajı güvenle alabilmesi için gerekli hazırlıkları yapması için uyarmaktır. Bu çalışma kapsamında bir araca yerleştirilmiş kamera ile yolun geometrik özelliklerini, yani yol kenarlarını, yolun ufuk noktasını (vanishing point) ve yol eğriliğini (road curvature) tespit etmek için kamera görüntülerinden faydalanıldı. Yolun eğim tipini tespit etmek için aynı zamanda araç arka kamerası da kullanıldı. Bu çalışmada yol geometrisinden ve Pinhole Kamera geometrisinden faydalanılarak yol görüntüsündeki cisimlerin uzaklıkları hesaplandı ve yol tespiti, şerit tespiti, yol kenarlarının tespiti yapıldı. Ayrıca, virajın eğriliği hesaplandı.

Tez çalışmasının altıncı bölümünde, “Trafik sahnesindeki en riskli bölgelerin tespit edilmesi” çalışması yer almaktadır. Bu çalışmada, şehir içindeki bir caddenin riskli bölgelerinin tespit edilerek caddedeki sürüşte dikkat edilmesi gereken riskli bölgeleri önceden sürücüye haber veren bir YS-SDS sistemi geliştirilmesi amaçlanmıştır. Bu çalışmada yol bir sahne; yoldaki araç, yay, ışık gibi trafik unsurları da sahnedeki oyuncular olarak düşünülmüştür. Çalışmada önerilen metoda göre yol sahnesi bölgelere ayrıldı ve her bir bölgedeki oyunculardan kaynaklanan riskler hesaplandı. Her bir bölge bir graf elemanı gibi düşünülerek iyi bilinen Graf-Kesme (Graph-Cut) yöntemi kullanılarak riskli bölgeler hesaplandı.

Son bölümde ise yapılan çalışmaların tartışması ve gelecekte yapılacak çalışmalar yer almaktadır.

1.3.1. Destekleyici Çalışmalar ve Araştırmaya Katkıları

Tez çalışması süresince geliştirilen yöntemler ve uygulamalar uluslararası konferans ve sempozyumlara sunulmuş, bunların sonucunda tez konusu alanında bizzat IEEE kuruluşu tarafından düzenlenen ve desteklenen en prestijli uluslararası sempozyumlarda tez çalışmasına ait yedi çalışma kabul görmüş, sunulmuş, yayınlanmış ve atıf almaya başlamıştır. Mevcut durumda hepsi IEEE veritabanında taranabilmektedir.

İlk çalışma 16-19 Eylül 2012 tarihlerinde Alaska, ABD’ de düzenlenen ve Akıllı Ulaşım Sistemleri alanında prestijli konferansların başında gelen IEEE ITSC (Intelligent Transportation Systems Conference) konferansında sunduğumuz "Approaching Car Detection via Clustering of Vertical Horizontal Line Scanning Optical Edge Flow" başlıklı çalışmadır. Bu çalışma bir DS-SDS sistemidir. Aracın arkasından yaklaşmakta olan ve sürücünün dikkatinden kaçabilecek araçların tespitini arka kamera görüntülerinden yapmayı amaçlayan bir çalışmadır. Bu çalışma, yoldaki bir nesnenin tespiti ve takibi uygulamalarına bir örnektir. Çalışmadaki nesne arkadan yaklaşan bir araçtır ve bu aracın takibinde optik akış hareket vektörleri kullanılmıştır. Çalışmada optik akış yönteminin karmaşıklığını ve işlem maliyetini azaltmak için arka kameradan alınan görüntünün önce kenar algılama işleminden geçirilmesi ve araç tespiti için yeni bir kümeleme yaklaşımı olan yatay ve dikey tarama histogramlarının geliştirilmesi çalışmanın yenilikleridir.

İkinci çalışma, Haziran 2013’ de Avustralya’ nın Gold Coast şehrinde düzenlenen ve yine bu alanda en prestijli konferanslardan biri olan IEEE IV (Intelligent Vehicle) konferansında sunduğumuz "Interactive risky behavior model for 3-car overtaking scenario using joint Bayesian Network" başlıklı çalışmadır. Bu çalışma bir YS-SDS sistemidir. Bu çalışma, sollama esnasında sollayan aracın hatasını telafi edebilmesi için sollanan araç üzerine kurulu bir uyarı sistemidir. Sollanan aracın arkasındaki ve önündeki kameralar ile sollama durumları algılanmakta ve kaza riski hesaplanmaktadır. Çalışmadaki yaklaşıma göre, eğer sollamadan hemen önce olası bir kaza riski görünüyorsa, daha doğru bir ifadeyle kaza riski yüksekse sollayan araç yeterli bir mesafe uyarı yaparak sollayan aracın kendi şeridine geçebilmesi için önlem alabilir. Bu çalışmada, önceki çalışmada geliştirilen yatay

düşey tarama yöntemi ve araçların farklı sollama durumlarını analiz ederek risk miktarını ortaya çıkaran Bayes Belief Network yönteminden faydalanılmıştır. Çalışma 3-Araba üzerinde geliştirilmiş ve çoklu araç çalışmaları için bir model olarak önerilmiştir.

Üçüncü çalışma, Aralık 2013' de düzenlenen Las Vegas, ABD' de düzenlenen ve IEEE' nin önem verdiği ve gelecek nesil araçların önemli bir çalışma alanı olan Connected Vehicle (IEEE International Conference on Connected Vehicle - ICCVE) konferansında sunulan "An effective variable selection algorithm for Aggressive/Calm Driving detection via CAN bus" başlıklı çalışmadır. Bu çalışmadaki amaç, sürücünün agresif mi yoksa normal bir sürüş mü gerçekleştirdiği tespiti için aracın CAN-bus çıkışından alınan verilerin değerlendirilerek gereksiz verilerin elenmesidir. Çalışmada CAN-bus veri çiftleri için hesaplanan korelasyon katsayıları kullanılarak yeni bir algoritma geliştirilmiş ve agresif sürüşü tespit eden verilerin seçimi ve dolayısıyla gereksiz olanların elenmesi işlemi gerçekleştirilmiş olmaktadır. Ayrıca, test işlemlerinde çoklu regresyon denkleminde faydalanılmıştır.

Dördüncü çalışma, Aralık 2013' de Hangzhou, Çin' de düzenlenen IEEE CISP (Conference on Image and Signal Processing) konferansında sunduğumuz "Similar Association Set Based Attribute Selection Algorithm for Road Profile Detection" başlıklı çalışmadır. Bu çalışmada, yolun rampa veya iniş olup olmadığını tespit etmek için kullanılan CAN bus verilerinin seçimi amaçlanmıştır. Yöntem olarak üçüncü çalışmada geliştirilen metod kullanılmıştır.

Beşinci çalışma, ilk çalışmada bahsi geçen IEEE ITSC konferansının Ekim 2014' de Qingdao, Çin' deki organizasyonunda (ITSC'14) sunduğumuz "Graph-Cut Based Regional Risk Estimation for Traffic Scene" başlıklı çalışmadır. Bu çalışma tipik bir YS-SDS sistemidir. Bu çalışmada kent içindeki bir caddenin sürücü için en riskli bölgesinin tespit edilmesi amaçlanmıştır. Çalışma bir trafik sahnesi analizi (traffic scene analysis) örneğidir. Caddedeki yol ve çevresindeki araç, yaya, trafik ışığı, trafik işareti, yaya geçidi gibi her trafik unsuru birer oyuncu olarak kabul edilmiştir. Bu çalışmada trafik sahnesi bölümlere ayrılmış ve her bir bölüm bir hücre olarak düşünülerek bir graf dönüşümü yapılmıştır. Her oyuncunun bulunduğu bölümdeki risk ağırlıkları kullanılarak iyi bilinen Graf-Kesme metodu ile sahnenin riskli bölgeleri tespit edilmiştir.

Altıncı çalışma, Kasım 2014' de Viyana, Avusturya' da düzenlenen IEEE ICCVE konferansında sunduğumuz "Regional Risk Estimation for Drivers Cutting Intelligent

Graph with Intra-Cells Enabling Risk Transfer for Street Players" başlıklı çalışmadır. Bu çalışma beşinci çalışmanın temelini oluşturmaktadır. İlgili konferansların düzenlenme tarihlerinden dolayı bu çalışma beşinci çalışmadan daha sonra sunulmuştur. Bu çalışmada trafik sahnesinin bir graf şeklinde düşünülerek cadde için analiz yapılması ve sürücüyü uyarması amaçlanmıştır. Graf-Kesme metodu bu çalışmadaki analizlerin ardından geliştirilerek beşinci çalışmada kullanılmıştır.

Yedinci çalışma, altıncı çalışma ile birlikte IEEE ICCVE'14 konferansında sunulan "Probabilistic Risk Assessment using Major Features of Rural Road Curves via Rear and Front Car Cameras" başlıklı çalışmadır. Bu çalışmada, viraja girmeden önce virajın ve aracın durumları Bayes Anlam Ağı ile değerlendirilerek risk hesabı yapılmıştır. Virajın mevcut şartlardaki kaza riskinin hesaplanabilmesi için aracın ön ve arka kamerasından alınan görüntülerden faydalanılarak virajın yönü, viraj açısı, yolun eğimi gibi özellikleri geliştirilen yeni yaklaşımlarla tespit edilerek aracın o viraja tespit edilen özellikleriyle ve mevcut hızıyla girdiği takdirde kaza olma riskinin ne kadar olacağı hesabı yapılmıştır.

Sekizinci çalışma yedinci çalışma üzerine kurulmuş ve ters bakış (Inverse View) yöntemi geliştirilerek ve Bayes Anlam Ağı yerine değerlendirme için yeni bir algoritma kullanılarak yenilenmiş ve daha da geliştirilmiş şekliyle SCI' de taranan IEEE Intelligent Transportation Systems (IEEE ITS) dergisine yollanmış ve değerlendirme aşamasına alınmıştır. Ayrıca, beşinci çalışmanın sahne bölmeleme algoritması ve oyuncuların dinamik ağırlıklandırılması ve en önemlisi bölünmüş yolların da ele alınarak her türlü yol sahnesine uyarlanabilir ölçekli bir hale getirilmesi işlemleri üzerinde çalışılmakta ve yine ITS dergisine yollanması planlanmaktadır. Bunlara ilave olarak yine aynı dergiye yollanmak üzere otonom ve bağlantılı araçlar (Autonomous and Connected Vehicles) konulu araştırma yayını üzerinde çalışılmaktadır. Bu çalışma aynı zamanda gelecekte yapılması planlanan çalışmalara bir altyapı oluşturacaktır. Connected Vehicles ile ilgili yaklaşımlar tezin son bölümünde tartışılmıştır.

Aşağıdaki listede bu tez çalışması kapsamında yapılmış, kabul edilmiş, sunulmuş ve IEEE veritabanında yayınlanan uluslararası çalışmalar verilmiştir:

1. Karaduman, O., Eren, H., Kurum, H., and Celenk, M., 2012. Approaching Car Detection via Clustering of Vertical Horizontal Line Scanning Optical Edge Flow, *15th*

International IEEE Conference on Intelligent Transportation Systems (ITSC'12), Anchorage, Alaska, USA, September 16-19, pp. 502-507.

2. Karaduman, O., Eren, H., Kurum, H., and Celenk, M., 2013. Interactive risky behavior model for 3-car overtaking scenario using joint Bayesian network, *IEEE Intelligent Vehicles Symposium (IV'13)*, Gold Coast, Australia, pp. 1279-1284.

3. Karaduman, O., Eren, H., Kurum, H., and Celenk, M., 2013. An effective variable selection algorithm for Aggressive/Calm Driving detection via CAN bus, *IEEE International Conference on Vehicles and Expo (ICCVE'13)*, Las Vegas, USA, pp. 586-591.

4. Karaduman, O., Eren, H., Kurum, H., and Celenk, M., 2013. Similar Association Set Based Attribute Selection Algorithm for Road Profile Detection, *IEEE In Image and Signal Processing (CISP'13)*, Hangzhou, China, Vol. 3, pp. 1376-1381.

5. Karaduman, O., Eren, H., Kurum, H., and Celenk, M., 2014. Graph-Cut Based Regional Risk Estimation for Traffic Scene, *IEEE Intelligent Transportation System Conference (ITSC'14)*, Qingdao, China, 8-11 October, pp. 968-973.

6. Karaduman, O., Eren, H., Kurum, H., and Celenk, M., 2014. Regional Risk Estimation for Drivers Cutting Intelligent Graph with Intra-Cells Enabling Risk Transfer for Street Players, *IEEE International Conference on Connected Vehicle & Expo (ICCVE'14)*, Vienna, Austria, 3-7 November.

7. Karaduman, O., Eren, H., Kurum, H., and Celenk, M., 2014. Probabilistic Risk Assessment using Major Features of Rural Road Curves via Rear and Front Car Cameras, *IEEE International Conference on Connected Vehicle & Expo (ICCVE'14)*, Vienna, Austria. 3-7 November.

2. DİKEY-YATAY SATIR TARAMA VE OPTİK KENAR AKIŞ KÜMELEME YOLUYLA YAKLAŞAN ARABA TESPİTİ

Bu çalışmanın amacı, trafikte arkadan yaklaşan bir araç için sürücüye uyarıda bulunan bir sürücü destek sistemi gerçekleştirmektir. Sürücülerin aracın arkasındaki trafik sahnesine olan hakimiyeti, aracın önündeki trafik sahnesine olan hakimiyetinden daha azdır. Özellikle yorgun, uykusuz veya dalgın ruh hallerine sahip sürücülerin arkadan gelen trafiğe karşı dikkatleri oldukça azalmaktadır. Dolayısıyla sürücü dikkatinin azalmasının kazaları arttırması kaçınılmazdır.

Çalışmanın temeli, aracın arkasına monte edilmiş bir kameradan alınan videodan çıkarılan resim çiftleri kullanılarak nesne hareket tespitine dayanmaktadır. Resim çiftleri kullanılarak iyi bilinen optik akış yöntemi ile resim çerçevesinde araç olabilecek hareketli nesne araştırılmaktadır. Optik akış yönteminin işlem maliyetini azaltmak amacıyla yol resim çerçevelerine kenar çıkarma uygulanmış ve optik akış kenarları çıkarılmış karelere uygulanmıştır. Ayrıca, optik akış hareket vektörlerinin kümelenip sınıflandırması için düşey ve yatay olarak hareket vektörü yoğunluk tespit yöntemi geliştirilmiştir. Sistemin aşamaları aşağıdaki gibi listelenmiş ve Şekil 2.1’ deki gibi gösterilmiştir.

- A. Videodan resim çiftlerinin çıkarılması
- B. Resim çiftleri kenarlarının çıkarılması
- C. Kenarları çıkarılmış resim çiftlerine optik akış uygulanması
- D. Hareket vektörlerinin sınıflandırılması
- E. Kümeleme ve nesnelerin yer tespiti
- F. Araç tespiti



Şekil 2.1. Sistemin aşamaları [155].

2.1. Videodan Resim Çiftlerinin Çıkarılması

Aracın arkasındaki kameradan çekilen video görüntüleri içerisinde bir araç tespiti yapılabilmesi için videodan resim çiftlerinin çıkarılması gerekmektedir. Çünkü hareketli nesnelerin tespit edilebilmesi için seçilen ve optik akış adı verilen yöntem, ardışık iki resim çerçevesi arasındaki hareket vektörlerinin çıkarılmasına dayanmaktadır. Çerçeve çiftleri N çerçeve içerisinde herhangi bir k örnekleme adımı ile seçilmektedir. Örneğin $k=4$ olarak seçildiğinde ham çerçeve dizisi içerisinde sırasıyla 1, 5, 9, 13, numaralı ve 4' er adımla ilerleyen çerçeveler seçilmiş olacaktır. Aşağıda, k örnekleme adımı ile ham veriler içerisinde seçilen çerçeve çiftleri için denklem yer almaktadır.

$$I_j = F_{k(i-1)+1} \quad i=1, 2, \dots, N \quad j=1, 2, \dots, M \quad (2.1)$$

Burada N çerçeve sayısı olmak üzere $F=\{F_1, F_2, F_3, \dots, F_N\}$ dizisi, videodan ham veri olarak alınan resim çerçevelerini göstermektedir. $I=\{I_1, I_2, I_3, \dots, I_M\}$ dizisi, k örnekleme adımlarıyla seçilen çerçevelerdir. M burada seçilen çerçeve sayısını göstermektedir. Seçilen I çerçeve dizisi içerisinde optik akış yönteminde kullanılacak ardışık çerçeve çiftleri $(I_1, I_2), (I_2, I_3), (I_3, I_4), \dots, (I_{(M-1)}, I_{(M)})$ çiftleridir.


Örnekleme adımı k ' nın seçilmesi hassasiyet açısından önemlidir. Optik akış yöntemi ardışık iki çerçeve arasındaki piksel değişimlerini inceler. Değişimin büyüklüğü yöntemin başarısını doğrudan etkilemektedir. Bir videodaki çerçeve çiftlerinin çok büyük örnekleme adımlarıyla alınması değişim hassasiyetini kaybedeceği için yöntemin başarısız olmasına sebep olabilir. Örnekleme adımının çok yakın alınması da işlem maliyetini oldukça arttırabilir. Özellikle saniye başına çerçeve sayısı (frame per second - fps) yüksek olan videolarda tüm çerçeveleri değerlendirmek işlem maliyetini oldukça arttırabilir. Aynı sonuç örneğin ikişer veya üçer adımlarla seçilen çerçeve adımlarıyla da elde edilebilir. Dolayısıyla k örnekleme adım sayısı videonun fps özelliği de düşünülerek en uygun seçilmelidir. Örneğin 15 fps olan bir videonun örnekleme adımı $k=3$ seçiliyorsa 30 fps' lik bir videodan örnekleme adımı $k=5$ veya 6 olarak seçilebilir. Buradan da anlaşılacağı üzere, optik akış vektörlerinin nesneleri doğru temsil edebilmeleri için resim çiftlerinin çerçeve aralığının en uygun seçilmesi gerekmektedir.

2.2. Resim Çiftleri Kenarlarının Çıkarılması

Kenar çıkarma, bir resmin yoğunluğunun değişim miktarı ile ilgili iyi bilinen bir yöntemdir [209]. Resim çiftlerine optik akış yöntemi uygulamadan önce resimlerin kenarlarının çıkarılması, gri-seviye bir resimden ikili resme dönüşüm gerçekleştiği için ve bu sayede çok daha az sayıda piksel ile çalışıldığı için optik akış metodunun işlem maliyetini de oldukça azaltacaktır. Ayrıca, resimlerde gürültüye yol açan nesne sayıları da azalacağı için nesne tespiti ve tanımı işlemleri de kolaylaşacaktır.

2.3. Kenarları Çıkarılmış Resim Çiftlerine Optik Akış Yönteminin Uygulanması

Bir video çerçevesindeki her piksel hareketinin o çerçevedeki hızının ve yönünün tanımlanması Optik Akış olarak adlandırılır. t anında (x,y) konumunda olan $p(x,y,t)$ pikseli, $t+1$ anında dx kadar x yönünde ve dy kadar y yönünde yer değiştirmiş olabilir ve bu durumda $p(x+dx, y+dy, t+1)$ şeklinde gösterilir. Eğer $dx=u$ ve $dy=v$ olarak atanırsa piksel hareketi, $\sqrt{u^2 + v^2}$ ile hesaplanan Öklit mesafesine ve $\tan^{-1}(\frac{v}{u})$ ile hesaplanan açıya sahip bir vektör olarak tanımlanabilir. Bu vektör Hareket Vektörü (Motion Vector) olarak adlandırılır. Şekil 2.2’ de bir hareket vektörü gösterilmiştir.



Şekil 2.2. Bir hareket vektörünün büyüklüğünün hesaplanması [155].

Eğer t anında (x,y) çerçeve konumunda olan bir piksel $E(x,y,t)$ ise, x ve y için sırasıyla u ve v hızlarına sahip olan hareket vektörü $A = (u(x,y), v(x,y)) \equiv (u,v)$ olarak tanımlanır. Optik akış metodu bir diferansiyeldir. Denklem 2.2’ de gösterilen ve resim parlaklığının zaman içerisinde sabit olduğu varsayımına dayanmaktadır.

$$dE/dt = 0 \quad (2.2)$$

Yukarıdaki türev için zincir kuralı uygulandığında aşağıdaki denklem elde edilir.

$$\frac{dE}{dx} \frac{dx}{dt} + \frac{dE}{dy} \frac{dy}{dt} + \frac{dE}{dt} = 0 \quad (2.3)$$

Eğer $u=dx/dt$ ve $v=dy/dt$ alınırsa iki bilinmeyenli tek bir lineer denklem elde edilir.

$$E_x u + E_y v + E_t = 0 \quad (2.4)$$

Burada E_x , E_y ve E_t sırasıyla x , y ve t 'ye göre resim parlaklığının kısmi türevleridir. Denklem 2.4, v 'nin bileşenleri üzerine tek bir kısıtlama olduğunu gösterir ve parlaklık gradyanına doğru açıda parlaklık eğrilerinin yönlerine uymaz. Bu nedenle akış hızı (u,v) ek kısıtlamayı vermeksizin elde edilemez. Bu problemin üstesinden gelinebilmesi için iyi bilinen Horn-Schunck algoritması kullanılır [210]. Bu algoritma bir dizi resim çerçevesinden 2-Boyutlu bir hız hesaplamak için geliştirilmiş bir diferansiyel denklemdir. Parlaklık kısıtlaması her çerçeve dizisinde bulunan bir pikselin bir çerçeveden sonrakine gri seviyesinin değişmediği varsayımına dayanmaktadır. Diğer taraftan, parlaklık kısıtlaması tek bir hız alanı ortaya çıkarmaz. Bir düzenleme veya düzleştirme eklenerek düzleştirilmiş terimin ağırlıklı toplamı ve parlaklık kısıtlaması hatası minimize edilerek hesaplanabilir [211].

2.4. Hareket Vektörlerinin Sınıflandırılması

Hareket vektörlerinin büyüklüğü pikselin hız bilgilerini içerir ve bu büyüklük aynı zamanda nesne hızı ile orantılıdır. Böylece, bu gerçek göz önüne alındığında, hareket vektörü büyüklüklerinin ortalaması farklı hızlardaki hareketli nesnelerin sınıflandırılması için eşik (Threshold-T) olarak kullanılabilir. Bir resim çerçevesinin (x,y) konumundaki bir hareket vektörünün Öklit mesafesi aşağıdaki gibi yazılabilir:

$$|\vec{A}(x,y)| = \sqrt{u^2 + v^2} \quad (2.5)$$

Çerçeveadaki tüm hareket vektörlerinin büyüklük ortalaması Denklem 2.6 ve 2.7' deki gibi hesaplanabilir.

$$\begin{aligned}
\text{toplama}(A) &= \sum_{i=1}^M \sum_{j=1}^N |\vec{A}(x_i, y_j)| \\
&= |\vec{A}(x_1, y_1)| + |\vec{A}(x_1, y_2)| + \dots + |\vec{A}(x_1, y_N)| + |\vec{A}(x_2, y_1)| + |\vec{A}(x_2, y_2)| + \\
&\quad |\vec{A}(x_2, y_N)| + \dots + |\vec{A}(x_M, y_1)| + |\vec{A}(x_M, y_2)| + \dots + |\vec{A}(x_M, y_N)|
\end{aligned} \tag{2.6}$$

Burada toplama(A) hareket vektörlerinin büyüklükleri toplamı, M ve N çerçevenin sırasıyla satır ve sütun sayılarıdır. Hareket vektörlerinin büyüklüklerinin ortalamaları aşağıdaki şekilde hesaplanabilir.

$$\text{ortalama}(A) = \frac{\text{toplama}(A)}{M \times N} = \frac{1}{M \times N} \sum_{i=1}^M \sum_{j=1}^N |\vec{A}(x_i, y_j)| \tag{2.7}$$

Hareket vektörlerinin ortalama değeri eşik (T) olarak kullanılabilir. Sonuç olarak bu sınıflandırmada eşik $T = \text{ortalama}(A)$ alınarak aşağıdaki gibi tasarlanabilir:

$$c_{ij} = \begin{cases} 0 & |\vec{A}(x_i, y_j)| \leq T \\ 1 & |\vec{A}(x_i, y_j)| > T \end{cases} \tag{2.8}$$

Burada c_{ij} , sınıflandırılmış vektörler içeren çerçeve elemanıdır. Hareket vektörlerinin boyutlarına göre T eşik değerinden küçük veya eşit olanlar bir sınıf, boyutları T eşik değerinden büyük olanlar ise diğer sınıftır. Buradaki mantık, ortalama vektör hızından düşük olan hareket vektörlerinin, yaklaşmakta olan bir aracı temsil edemeyeceğidir.

2.5. Kümeleme ve Nesnelerin Konumlarını Belirleme

Nesnelerin pikselleri birbirine komşudurlar ve kütle halinde birlikte hareket edildiğinden dolayı aynı zamanda hızları da birbirine çok yakındır. Dolayısıyla benzer büyüklüğe ve hıza sahip hareket vektörlerinin aynı grupta olduğu varsayılabilir ve bunun sonucu olarak aynı kümede (Cluster) yer alabilirler. Dolayısıyla bu kümelerin her biri birer araç olmaya aday nesneleri temsil etmektedir.

Küme olarak düşünülen hareket vektör gruplarının sınırlarını belirleme işlemi ise sınırlama veya yerini belirleme (lokalizasyon) olarak adlandırılır. Sınıflandırılmış ve

kümelenmiş hareket vektörlerinden oluşan bir çerçevede kümelerin lokalizasyonu aşağıdaki algoritma yardımıyla gerçekleştirilebilir.

Algoritma: Yatay Düşey Tarama Algoritması

```

Loop Düşey_Tara do
  if ( $|\overrightarrow{MV}| \geq \text{Threshold}$ ) then
    - Kümelerin başlangıç değeri olarak işaretlen ve enini hesapla.
    - Look-up tablosuna göre genişliğin aralığını eşleştir.
      if Look-up tablosunda eşleşebiliyorsa then
        Bu genişliği kaydet
      endif
    else
      Sonraki hareket vektörüne geç
    endif
  endLoop
repeat Yatay_Tara

```

Ayrıca, belirtilen Look-up tablosu kullanılarak, çerçeve içindeki konumda araç boyutlarına uymayan kümelerin elenebilmesi mümkündür. Lokalizasyon algoritması ile yapılan işaretleme sonrasında aday kümeler aşağıdaki gibi belirlenebilir:


$$S1 = \{\forall c_{ij} < y_1 \cap \forall c_{ij} > y_2 \mid c_{ij} \in \{C\}\}$$

$$S2 = \{\forall c_{ij} > x_1 \cap \forall c_{ij} < x_2 \mid c_{ij} \in \{C\}\}$$

$$K_n = \{S1 \cap S2\} \quad n=1,2,3,\dots$$

(2.9)

Burada x_1, x_2, y_1, y_2 lokalizasyon algoritması tarafından hesaplanan sınırlardır. C , sınıflandırılmış hareket vektörleri c_{ij} ' lerden oluşan bir çerçevedir. $S1, y_1$ ve y_2 arasında, $S2$ ise x_1 ve x_2 arasında kalan alandır. K_n ile belirtilen alan $S1$ ve $S2$ arasında kesişen alandır. Şekil 2.3' de bu yaklaşım gösterilmiştir. Hem yatay hem de düşey kesişimler alınarak aday kümelerin belirlenmesi sağlanabilir.



Şekil 2.3. Çerçeve içindeki x_1 , x_2 , y_1 , y_2 doğrularının kesişimleri ve kümenin sınırlarının belirlenmesi. K ile belirtilen bölge bir kümedir [155].

2.6. Araç Tespit Etme

Araç tespit etme probleminde iki önemli yaklaşım bulunmaktadır. İlki bir çerçevenin altındaki nesnelerin üsttekilere göre daha büyük gözükmeleridir. Bir başka ifadeyle, resmin en üst kısmında bulunan bir araba en alttaki arabadan daha büyük olamaz. Lokalizasyon algoritmasında adı geçen Look-up tablosu, bu varsayımdan yola çıkılarak hazırlanmıştır. Geliştirilen Look-up tablosu özellikle bir resimdeki arabanın konum ve boyutunun kestirimi ile ilgili hareket vektör kümelerinin aday nesnelerle karşılaştırılması işlemi için anlamlı bilgiler içermektedir. İyi bilinir ki, bir arabanın resmin en üst kısmında olma olasılığı oldukça zayıftır. Çünkü bir araba gökyüzünde olamaz.


İkinci önemli yaklaşım ise araba olmaya aday hareket vektörü kümelerinin sonraki çerçevelerde de gözükp gözükmeyişidir. Bir başka ifadeyle, eğer t anında var olan bir küme, ardından gelen $t+1$ veya $t+2$ gibi yakın zaman dilimlerinde kayboluyorsa, bu nesne arkadan yaklaşan bir araba olarak düşünülemez. Araba olduğu düşünülse bile yaklaşan değil, geride kalarak gözden kaybolan bir araç olarak düşünülebilir.

Bu iki basit yaklaşım yardımı ile arkadan yaklaşan bir aracın tespiti yapılabilmektedir. Burada hatırlanması gereken nokta, bu aşamaya gelinceye kadar önceki aşamalarda gürültülerin azaltılması ve bu sayede kolay işlem yapılmasını sağlayabilecek verilerin elde edilmiş olmasıdır.

2.7. Deneyisel Sonuçlar

2.7.1. Videodan Resim Çiftlerinin Çıkarılması

Araç resim verisi aracın arkasına monte edilmiş kameradan alınan video klip görüntüleridir. Şekil 2.4’ de, ardarda gelen resim çerçevelerinde test aracıyla aynı yönde olan ve gitgide yaklaşan bir aracın görüntüleri yer almaktadır.



Şekil 2.4. (a) Videodan çıkarılan resimler (Üstteki çerçeveler), (b) Ham resim çerçevelerine kenar algılama uygulanan çerçeveler (Alttaki çerçeveler) [155].


2.7.2. Kenar Algılama Yöntemi

Seyahat halindeyken yol düz olmamasına rağmen, yol çevresindeki nesneler sürekli değişmektedir. Çünkü video kamera sabit değildir ve bağlı olduğu araçla birlikte hareket etmektedir. Bu durumda resim çerçevelerinde, çevredeki her hareket eden nesneyi gösteren hareket vektörü kümeleri bulunmaktadır. Bu durum, bir aracın arkasından gelen başka bir aracın tespit edilmesini, başka bir ifadeyle algılanmasını zorlaştırmaktadır. Bu problemin üstesinde gelebilmek için resim çerçeve çiftlerine optik akış metodundan önce kenar algılama metodu uygulanmıştır.

Kenar uygularken iyi bilinen Prewitt maskesi uygulanmıştır. Prewitt maskesi, bir arabada doğal olarak çok bulunan yatay ve düşey kenarları iyi algılayabilen bir maskedir [209]. Şekil 2.4’ de videodan alınan çerçevelerin optik akış işleminden önce kenar algılayıcıdan geçirilmiş hali gösterilmiştir. Şekil 2.5’ de ise kenar algılama işleminden geçirilmemiş bir çerçevenin optik akış hareket vektörlerinin yer aldığı ve oldukça karmaşık gözüken bir resim çerçevesi verilmiştir.

2.7.3. Optik Akış Vektörlerinin Çıkarılması


Hareketli nesneleri temsil etmesi için kullanılan bir yöntem olan optik akış burada, arka kameradan çekilen görüntüdeki yaklaşan araçları tespit etmek amacıyla kullanılmıştır. Önceki kısımda da belirtildiği gibi herhangi bir filtreden geçmemiş hareket vektör grupları, gürültülerle birlikte ham veri olarak çok anlamlı olmayabilir. Gürültüleri azaltan ve daha az veri üzerinde işlem yapılmasını sağlayan kenar algılama yöntemi aynı zamanda işlem maliyetini de azaltmaktadır.



Şekil 2.5. Kenar algılama işleminden geçirilmemiş bir çerçevedeki optik akış hareket vektörlerinin görüntüsü. Burada, görüntüdeki tüm nesneleri temsil eden optik akış vektörleri mevcuttur. Dolayısıyla, aranılan esas nesne olan aracın tespit edilmesi işlemi oldukça zorlaşmaktadır [155].

Şekil 2.5’ de kenar uygulanmamış optik akış ham verisine sahip bir resim çerçevesi bulunmaktadır. Şekil 2.6 ‘da ise kenar algılayıcı filtresinden geçirilmiş bir çerçevenin optik akış hareket vektörleri gözükmemektedir.


Şekil 2.5 ve Şekil 2.6, sırasıyla ham veri ile filtreden geçirilmiş verilerin farkını ortaya koymaktadır. Kenar algılama filtresinden geçirilmiş çerçevedeki verilerin gürültülerden arınmış ve daha açık veriler olduğu belirgin bir şekilde gözükmemektedir. Şekil 2.6’ daki veriler sınıflandırma ve kümeleme işlemlerinin yapılabilmesi için çok daha uygundur. Çünkü burada yol ve araç dışında gürültü olarak düşünülebilecek diğer nesneler kenar algılama yönteminden sonra elenmiştir. Ayrıca, gürültülerden dolayı oluşan işlem yükü de azaltılmış olmaktadır.



Şekil 2.6. Kenar algılayıcı uygulanmış hareket vektörlerinden oluşan çerçeve [155].


2.7.4. Sınıflandırma

Ortalama büyüklükten daha büyük hızlara sahip olan ve ortalamadan daha küçük olan diğer hareket vektörler şeklinde bir sınıflandırma yapmak, yaklaşan bir aracın hızı ile çevrede bulunan ve hareket etmeyen diğer nesneler arasında bir sınıflandırma yapmak anlamına gelmektedir. Çünkü vektör büyüklüğü, nesnelerin hızıyla doğrudan ilişkilidir. Burada ortalama vektör büyüklüğü ile bir eşikleme yöntemi kullanılmıştır. Şekil 2.7 ‘de ortalama hareket vektörü değerinden büyük olan hareket vektörleri mavi ile, diğerleri de kırmızı ile gösterilmiştir. Burada mavi ile gösterilenler, çerçevedeki nesnelerdir. Arkadan gelen araba, bu nesnelerin içerisinde seçilecektir.




Şekil 2.7. Sınıflandırılmış hareket vektörleri. Sınıflandırma eşik kriteri olarak seçilen ortalama hareket vektöründen küçük olanlar kırmızı, büyük olanlar ise maviye boyanmıştır. Eşikten büyük olan maviler, araba olmaya aday nesneleri göstermektedir [155].

Burada hareket vektörlerinin ortalama değeri yaklaşık 5.9' dur. Dolayısıyla bu ortalama, eşik değeri olarak seçilmiştir ($T=5.9$). Şekil 2.8' de, Şekil 2.7' de verilen çerçevedeki hareket vektörlerinin büyüklük, bir başka deyişle hız (velocity) histogramı verilmiştir. Bu histogramda yatay sütunda hareket vektörlerinin büyüklük değerleri ve dikey sütunda ise hareket vektörlerinin hangi büyüklükte kaç adet olduğu bilgisi verilmiştir. T değerinden küçük olan hareket vektörleri Sınıf 1 olarak belirtilmiş ve Şekil 2.7' de yer alan çerçevedeki kırmızı bölgeye denk düşmektedir. T eşliğinden büyük olanlar ise Sınıf 2 olarak adlandırılmıştır ve Şekil 2.7' deki mavi bölgeleri temsil etmektedir. Bu sayede görüntü, gürültülerden ve gereksiz işlem yükü getirebilecek verilerden arındırılmış olmaktadır.



Şekil 2.8. Resim çerçevesindeki hareket vektörlerinin büyüklük histogramı. Sınıflandırma, vektörlerin ortalama büyüklüklerinin değeri olan T eşliğine göre yapılmıştır [155].

Bunlara ilave olarak, farklı eşik değerleri de test edilmiştir. Ortalama vektör büyüklüğünden daha büyük olan ve daha küçük olan eşik değerleri kullanılarak, seçilen ortalama değerinin doğruluğu test edilmiştir. Örneğin ortalama vektör büyüklüğü 5.9' dan daha büyük bir değer olarak $T=8$ değeri, ortalama değer 5.9' dan daha küçük bir değer olarak da $T=4$ değeri sınıflandırma eşik değeri olarak test edilmiştir. Şekil 2.9' da, $T=4$ alınarak yapılan hareket vektörü sınıflandırılması görülmektedir.




Şekil 2.9. $T=4$ alınarak yapılan sınıflandırma [155].

Burada yine kırmızılar T değerinden düşük vektörleri, maviler ise T değerinden yüksek vektörleri temsil etmektedir. Görüldüğü üzere bu sınıflandırmada boyutları çok küçük olan vektörler de mavi sınıfına dahil olmuşlardır ve aranılan araç olma için düşünülebilecek nesneler sınıfına girmişlerdir. Ancak bunlar birer gürültüden ibarettir. Dolayısıyla kümeleme, nesne algılama işlemlerinin karmaşıklığına yol açtığı gibi, işlem maliyetinin de artmasına sebep olmaktadır.

2.7.5. Kümeleme ve Lokalizasyon

Sınıflandırılmış hareket vektörlerinden oluşan çerçevede bulunan vektörlerden birbirleriyle yakın ve aynı yönde olanlar bir küme olarak tanımlanabilir ve hareketli bir nesneyi temsil etme potansiyeline sahiptirler. Hareket vektörlerinin kümelenmesi ve kümenin çerçevedeki konumunun tespit edilmesi, çerçevede bir araç olup olmadığını algılama için önemli bir adımdır. Çünkü kümelerin boyutları ve konumları, içinde bir yol olan çerçevede nesnelerin ne olup olamayacağı konusunda önemli ipuçları vermektedir. Şekil 2.10' da kümeleme işlemi yapılmış çerçeve görülmektedir.



Şekil 2.10. Kümelerin sınırlarının DHCC ve DHCR histogramları ile belirlenmesi [155].

Şekil 2.10’ daki çerçevelenmiş küme görüntüleri, nesneleri temsil eden hareket vektörlerinin birer küme oluşturması amacıyla yatay ve düşey satır tarama (Vertical Horizontal Line Scanning - VHSL) yöntemiyle sınırların belirlenmesi işlemini gören lokasyon belirleme algoritması kullanılarak elde edilmiştir. Şekil 2.10’ da açıkça görülmektedir ki geliştirilen Küme Sütunlarının Yoğunluk Histogramı (Density Histogram of Cluster Columns - DHCC) ve Küme Satırlarının Yoğunluk Histogramı (Density Histogram of Cluster Rows - DHCR) yandan ve alttan hizalandığında çerçevedeki kümelere denk gelmektedir. Bir başka deyimle, histogramlardaki yoğunlaşmalar yani tepe noktalarının olduğu bölgeler, kümelerin olduğu bölgelerdir. Bu özellik, kümelerin sınırlarının belirlenmesinde kullanılmaktadır. Aynı zamanda lokasyon da belirlenmiş olur. Kümeleri elde etmek için tarama algoritması çalıştırılırken Tablo 2.1’ de görülen Look-up tablosundan faydalanılmıştır.

Tablo 2.1. Nesnelerin çerçevedeki konumlarına göre araç olup olmadıklarını gösteren Look-up tablosu


MESAFE ARALIĞI	GENİŞLİK	YÜKSEKLİK
$0 < i \leq (M/5)$	Araç yok	
$(M/5) < i \leq (2M/5)$	$N/20 - N/16$	$M/24 - M/16$
$(2M/5) < i \leq (3M/5)$	$N/18 - N/14$	$M/18 - M/12$
$(3M/5) < i \leq (4M/5)$	$N/12 - N/8$	$M/14 - M/8$
$(4M/5) < i \leq M$	$N/6 - N$	$M/10 - M$
M: Satır sayısı N: Sütun sayısı		

Tablo 2.1’deki deęerler tecrube ile oluřturulmuřtur. Ana fikir iyi bilinen bir varsayım olan, resimde bir nesnenin resmin ařaęısına doęru daha bryrk olacaęıdır. rneęin bir aracın resmin orta kısmındaki bryrklyęr ile resmin altına doęru bryrklyęr aynı deęildir. rnkrr resmin alt kısmı, nesnenin daha yakın olduęu kısımdır. Bunun yanısıra, iinde bir yol olan resimde yolun ufukta biten kısmı ufuk noktası (vanishing point) olarak bilinmektedir ve genelde resmin orta kısmına yakın bir noktadır. Arka kameranın monte edildięi nokta ise en yakın noktadır ve resmin en altındadır. Bu durumda resmin en rst kısmı arazi rykselteleri, aęaęlar ve gkyryzry gibi nesnelerdir. Dolayısıyla tablonun oluřturulmasında, bir arabanın gkyryzrynde olamayacaęı gibi geręeklerden yola rıkılarak resmin belli brylrmlerinde hangi trr nesnelerin olabileceęi veya olamayacaęı tanımları yapılarak basit bir yaklařım kullanılmıřtır. Tablodaki deęer aralıklarında kullanılan mantık, bir arabanın M satır ve N srytunlu bir resim reręevesinin i. satırında genislik ve rykseklięinin M ve N cinsinden ne olabileceęi ryzerine kurulmuřtur. rneęin resim enine 5 brylgeye ayrılmıř ve 0-M/5 brylgesi yolun bitiřinin, yani ufuk noktasının daha rsty olacaęı iin (arazi řekilleri, gkyryzry vs) tabloya grrr bu brylgedeki bir kymenin bir arabayı temsil edemeyeceęi varsayılmaktadır. Resmin alt kısımlarına ilerledikrre aracın boyutlarının bryrydryęr grrrylmektedir.

2.7.6. Arkadan Gelen Aracın Algılanması


Look-up tablosu kullanılarak kymeleme ve lokalizasyon iřlemleri ile grrryrtrylerin temizlenmesinin ardından aday kymeler (candidate clusters) ortaya rıkmıřtır. Artık bu kymelerin hangilerinin araę olup olamayacaęına karar verilip aracın resimde tespit edilmesi iřlemine geęilmiřtir. Bu iřlemde kymelerin resimdeki konumları ve bryryklryklerinin deęerlendirilmesinin yanında, aracın arkasından rkekilen bu hareketli grrryntrynry devamı esnasında kymelerin yerlerini koruyup korumadıkları da rnemli bir ipucudur. Arkadan yaklařan araę reręeve de sryrekli olacaktır, ancak yol rervresinde hareketsiz bir nesne bir sryre sonra reręeve de bulunmayacaktır. Bir bařka ifadeyle, ilerleyen reręevelerde gzyden kaybolan nesneler ya araba deęildir ya da araba olup da yaklařmayan veya kendisinden uzaklařılan bir arabadır. Dolayısıyla Yanlıř-Pozitifler, yani olumlu gibi gzyryken ama aslında aranmayan yanlıř nesneleri temsil eden aday kymelerin bryryrk bir kısmı bu yaklařımla elenebilmektedir. Geręek aranan ise Geręek-Pozitif

nesnelerdir. Eğer elenmeyen aday kümelerin boyutları Look-up tablosuna da uyuyorsa Gerçek-pozitif olarak kabul edilip arkadan yaklaşan araba olarak tespit edilmesi işlemi tamamlanmış olur. Önceki adımda belirlenen aday kümeler ve aralarından arabanın tespit edilmesi işlemi Şekil 2.11’ de verilmiştir.



Şekil 2.11. (a) Aday kümeler (üstteki resim), (b) Tespit edilen araç (Alttaki resim) [155].


Üstteki şekilde aday olan iki küme görülmektedir. Bu kümelerden sağ üstte kırmızı ile gösterilen küme elenmiştir. Elenmesinin ilk sebebi, Look-up tablosuna göre o konumda bir arabanın olamayacağıdır. İkinci sebebi ise kümenin genişliği 95 piksel olarak hesaplanmıştır. Bu çerçeve boyutlarında bu boyutta ve o konumda bir arabanın olması mümkün değildir. Bu kümenin elenme adımları Şekil 2.12’ de gösterilmiştir.




Şekil 2.12. (a) t anındaki aday kümeler, (b) $t+1$ anındaki aday kümeler, (c) $t+2$ anındaki aday kümeler, (d) $t+3$ anındaki aday kümeler [155].

Şekil 2.12 (a)' da sınırları belirlenmiş kümeler (kırmızı ve yeşil aralıkların kesişimleri) t anında mevcut olan aday kümelerdir. Daha önce belirtilen Look-up tablosuna göre konuma göre büyüklük eliminasyonunun yanında bu problem için en önemli ipucu arkadan gelen aracın takip halindeyken resim çerçevesinde her t anında bulunması gerektiğidir. Şekil 2.12 (a)' da var olan aday kümelerden sağ üst köşede olan küme, $t+2$ anında zayıflamış ve Şekil 2.12 (d)' de tamamen kaybolmuştur. Dolayısıyla bu küme takip eden ve yaklaşan hareketli bir araba olamaz. Bununla birlikte Şekil 2.12 (a)' daki merkeze yakın küme, tüm çerçevelerde tüm zaman dilimlerinde mevcuttur. Bulunduğu konum ve boyutları da tablo değerleri ile doğrulandığı için bu kümenin arkadan yaklaşan bir arabayı temsil eden bir hareket vektörü kümesi olduğu tespit edilmiştir. Resim çerçevesine bakıldığında elenen aday kümenin sık bir ağaç topluluğu olduğu görülmektedir.


Bir başka görüntü ve araç tespiti Şekil 2.13' de gösterilmiştir.



(a)



(b)



(c)

Şekil 2.13. Arkadan yaklaşan araç tespiti. (a) Arkadan çekilen görüntü çiftinin çıkarılmış kenarları, (b) Optik akış hareket vektörlerinin sınıflandırılması, kümelenmesi ve aday kümelerin tespit edilmesi, (c) Adaylar arasında aracın tespiti [155].

3. ÜÇ-ARABA MODELLİ SOLLAMA SENARYOSU İÇİN BAYES AĞI KULLANARAK RİSK HESABI

Bu çalışmada, seyahat halindeyken ön ve arkasında araç bulunan bir aracın sollanması halinde meydana gelebilecek kaza riskinin hesaplanması amaçlanmıştır. Sollama senaryosu 3-Araba modeli için ele alınmıştır. Modele göre sollama senaryosunda başrolde olan araç ortadaki, yani sollanan araçtır. Çoğu zaman sollayan aracın aldığı riski sollanan araç telafi etmektedir. Eğer sollama esnasında sollayan aracın karşısına bir araç çıkarsa çarpışmayı önlemek için sollanan araç hızını azaltarak sollayan aracın kendi şeridine geçebilmesini sağlayabilmektedir. Böyle bir durumda kritik görev sollanan araca aittir. Dolayısıyla çalışmada senaryo sollanan araca göre kurulmuştur. Sollanan aracın ön ve arkasına yerleştirilmiş kameralarla seyir halindeyken sollamanın kaza riski hesaplanmaktadır. Sollanan aracın arka ve ön kısmındaki araçların mesafeleri ve hangi şeritlerde bulundukları, risk hesabı için ele alınan risk durumlarının tanımında önemli rol oynamaktadır. Örneğin, sağdan ilerleyen bir trafik için (bundan sonraki her örnek sağdan ilerleyen trafik için verilecektir) arkadaki araç sol şeride geçmişse ve mesafesi kısa ise sollama olayı başlamış demektir ve o sırada karşı yönden gelen bir araç mevcutsa çarpışma riski için hesaplanacak olasılık çok yüksek olacaktır.

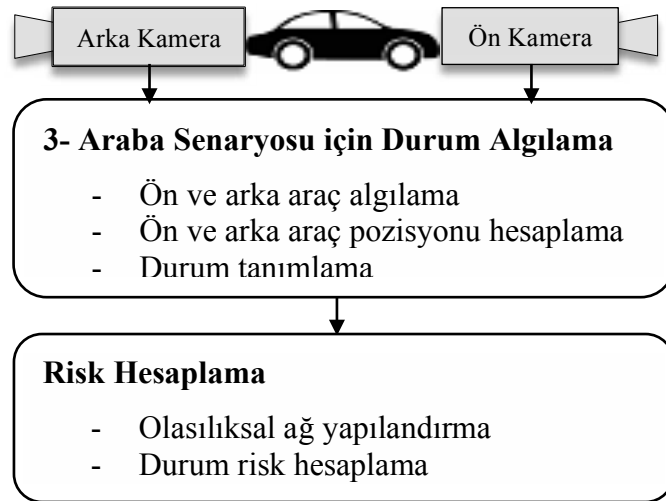
Çalışmada ön ve arkadaki araçların tespitleri için optik akış metodu kullanılmıştır. 3-Araba modeli için düşünülen sollama senaryolarındaki kaza risk hesapları ise Bayes Ağ Modeli kullanılarak yapılmıştır.

3.1. Sistemin Aşamaları

Bu çalışmada sollama için mantıklı durumların algılanması gerekmektedir. Bir aracın bir başka aracı güvenli bir şekilde sollaması için sollamanın ardından kendi şeridine geçmesi gerekmektedir. Aynı zamanda, sollanan araç ile onun önündeki araç arasında sollayan aracın kendi şeridine geçeceği kadar yeterli bir mesafe de olmalıdır. Yeterli mesafeyi tanımlamak için önemli bir parametre, sollayan araçla sollanan aracın önündeki aracın aynı yönde mi olduğu yoksa karşı yönden mi geldiğidir. Bir başka ifadeyle trafiğin tek yönlü mü yoksa iki yönlü mü olup olmadığı, sollayan aracın sollama sonrası kendi şeridine güvenli bir şekilde geçmesi için oldukça önemlidir. Eğer 3-Araba sollama senaryosunda sollanan aracın arkasındaki ve önündeki araçlar aynı yönlü ise sollanan araç


önündeki araçla yeterli bir mesafe bırakmalıdır. Bu mesafenin yeterli olmaması durumunda sollayan araç sollamanın ardından kendi şeridine tekrar geçemeyebilir, ya da kendi şeridine zamanından önce geçmek isteyerek sollanan aracın önüne kırarak muhtemel bir kazaya sebebiyet verebilir. Eğer trafik akışı iki yönlüyse sollayan aracın karşısına karşı yönden bir araba çıkabilir demektir. Bu durumda sollanan aracın önündekiyle bırakacağı mesafe, aynı yönlü trafiktekinden daha fazla olmalıdır. Çünkü sollayan araçla karşıdan gelen araç birbirlerinin toplam hızı kadar bir hızla birbirlerine yaklaşırlar. Bunun sonucunda sollayan aracın karşıdan gelen araç ile çarpışmaması için sollayan aracın kendi şeridine geçebilmesi için çok daha az bir süre vardır. Yani sollanan araç ile karşıdan gelen araç arasındaki mesafe, sollayan aracın sollama sonrası kendi şeridine geçebilecek kadar süre fırsatını verebilecek yeterlilikte olmalıdır.

Sollama işleminde asıl aksiyon sollayan ile karşıdan gelen araç arasındaki olmasına rağmen sollamada en kritik rolü, sollama anındaki kaza riskini önceden kestirebilen ve olası bir kazayı önlemek için aradaki mesafeyi hızını azaltarak açabilme şansına sahip olan sollanan araç oynamaktadır. Sollama öncesi risk hesaplandığında eğer tehlike varsa sollanan aracın sürücüsü aracını yavaşlatarak sollayan aracın kendi şeridine geçmesi için güvenli bir alan bırakır. Sonuç olarak, sollanan aracın sürücüsü sürekli sollanan aracın davranışını kontrol ederek olası bir kazayı önleyebilir.



Şekil 3.1. Sistemin çalışma senaryosu [156].

Şekil 3.1’ de çalışmanın bileşenleri genel hatlarıyla özetlenmiştir. Şekil 3.2’ de ise sistemin ayrıntılı aşamaları verilmiştir.



Şekil 3.2. Ön ve arka kameradan alınan görüntüleri kullanan sistemin aşamaları [156].

3-Araba senaryosunda sollama olayı üç araba ile modellenmiştir: Ortada olan sollanan araba, arkada olan sollayan araba ve öndeki araba. Sistem sollanan araba üzerine kurulmuştur. Sollanan arabanın ön ve arkasına monte edilmiş kameralarla yoldaki araba

pozisyonlarının durumları değerlendirilerek risk durumuna göre kazayı önleyebilecek önlem alabilmesi üzerine kurulmuştur. Sistemin iki ana bölümü vardır: Birincisi, 3-Araba Senaryosu için Durum Algılama, ikincisi de Risk Hesaplama. Birinci bölümdeki aşamalarda hem ön hem de arka kameradan alınan görüntülerin ayrı ayrı değerlendirilerek ön ve arkadaki araçların durumlarının tanımlanması işlemi gerçekleştirilmektedir. İkinci bölümde ise sollanan aracın arkasındaki ve önündeki durumlar değerlendirilerek risk hesabı yapılması işlemi gerçekleştirilmektedir.

3.2. Görüntü Çerçevelerine Kenar Algılama Metodunun Uygulanması ve Nesne Sınırlarının Oluşturulması

Sollanan aracın ön ve arka kamerasındaki video kliplerden alınan resimler, seyir halinde iken öndeki ve arkadaki araçların pozisyonlarının, yani bulundukları yol şeridi ve mesafelerinin görüntülerini, kısacası sollama durum tanımının yapılabilmesi için gerekli yol görüntülerini içermektedir. Bu görüntülerden arabaların tespit edilip pozisyonlarının algılanabilmesi için işlem yükünün hafifletilebilmesi ve gürültünün azaltılması gerekmektedir. Bu sebeple, görüntülerin optik akış hareket vektörlerinin çıkarılmadan önce kenar algılayıcı ile sadece gerekli olan nesnelerin elde edilmesi ve gürültülerin azaltılması işlem maliyetini de azaltacaktır.

3.3. Çerçeve Çiftlerinin Hareket Vektörü Haritalarının Çıkarılması

Bir video çerçevesindeki her piksel hareketinin o çerçevedeki hızının ve yönünün tanımlanması “Optik Akış” olarak adlandırılır. t anında (x,y) konumunda olan $p(x,y,t)$ pikseli, $t+1$ anında dx kadar x yönünde ve dy kadar y yönünde yer değiştirebilir ve $p(x+dx, y+dy, t+1)$ şeklinde gösterilir. Eğer $dx=u$ ve $dy=v$ olarak atanırsa piksel hareketi, $\sqrt{u^2 + v^2}$ ile hesaplanan Öklit mesafesine ve $\tan^{-1}(\frac{v}{u})$ ile hesaplanan açıya sahip bir vektör olarak tanımlanabilir.

Bölüm 2’ de (x,y) noktasından $(x+u, y+v)$ noktasına harekete eden bir pikseli temsil eden bir hareket vektörü Şekil 2.2’ de daha önce gösterilmiştir.

3.4. Hareket Vektörlerinin Sınıflandırılması

Hareket vektörlerinin büyüklüğü piksel hızındaki bilgileri içerir ve bu büyüklük aynı zamanda nesne hızı ile orantılıdır. Böylece, bu gerçek göz önüne alındığında, hareket vektörü büyüklüklerinin ortalaması farklı hızlardaki hareketli nesnelerin sınıflandırılması için eşik olarak kullanılabilir. Bir resim çerçevesinin (x,y) konumundaki bir hareket vektörünün öklit mesafesi $|\vec{A}(x,y)| = \sqrt{u^2 + v^2}$ şeklinde gösterilebilir.

Çerçevedeki tüm hareket vektörlerinin büyüklük ortalaması Denklem 3.1' deki gibi hesaplanabilir. Hareket vektörlerinin büyüklükleri toplamı, M ve N çerçevenin sırasıyla satır ve sütun sayılarıdır. Hareket vektörlerinin büyüklüklerinin ortalamaları aşağıdaki şekilde hesaplanabilir.


$$\text{ortalama}(A) = \frac{\text{toplama}(A)}{M \times N} = \frac{1}{M \times N} \sum_{i=1}^M \sum_{j=1}^N |\vec{A}(x_i, y_j)| \quad (3.1)$$

Hareket vektörlerinin ortalama değeri eşik (T) olarak kullanılabilir. Sonuç olarak bu sınıflandırma $T = \text{ortalama}(A)$ olarak Denklem 3.2' deki gibi tasarlanabilir.

$$c_{ij} = \begin{cases} 0 & |\vec{A}(x_i, y_j)| \leq T \\ 1 & |\vec{A}(x_i, y_j)| > T \end{cases} \quad (3.2)$$

Burada c_{ij} , sınıflandırılmış hareket vektörlerini içeren çerçeve elemanıdır. Hareket vektörlerinin boyutlarına göre T eşik değerinden küçük veya eşit olanlar bir sınıf, boyutları T eşik değerinden büyük olanlar ise diğer bir sınıftır. Burada, ortalama vektör hızından düşük olan hareket vektörlerinin, hareket eden bir arabayı temsil edemeyeceği gerçeği ile hareket edilmiştir. Eğer hareket vektör büyüklüğü ortalama vektör büyüklüğünden küçükse bu hareket vektörleri araba gibi hızlı hareket eden bir nesneye ait olamayacağı varsayımı ile elenmektedir.

Şekil 3.3' de hareket vektörlerinin Olasılık Yoğunluk Fonksiyonlarının (Probability Density Function – PDF) Gaussian eğrisine yakın olduğu gösterilmiştir. Burada araca ait vektörlerin birim çemberdeki sıfır noktasına yakın vektörler olduğu söylenebilir. Bu sayede aday kümeler için doğrulama işlemi gerçekleştirilebilir.



Şekil 3.3. Hareket vektörlerinin olasılık yoğunluk fonksiyonu [156].

3.5. Lokalizasyon ve Kümeleme ile Ön ve Arkadaki Arabaların Pozisyonlarının Hesaplanması

3.5.1. Kümeleme ve Lokalizasyon

Bir nesneyi oluşturan pikseller birbirine komşulardır. Aynı zamanda beraber hareket ettikleri için hızları da birbirine yakındır. Dolayısıyla benzer büyüklük ve hızlara sahip olan hareket vektörleri aynı sınıfta kabul edilmelerine ek olarak aynı kümede oldukları da kabul edilebilir. Tanımlanan kümelerin sınırları ve boyutları, onların resim üzerindeki lokalizasyonu göstermektedir. Küme lokalizasyon algoritması daha önce Bölüm 2’ de verilmiştir. Buna ilave olarak bir Look-up tablosu kullanılarak aracın boyutları ve bulunduğu konum bilgilerinden dolayı kümelerin elenmesi işlemi gerçekleştirilebilir. Bölüm 2’ de Tablo 2.1’ de böyle bir tablo örneği verilmiştir. Lokalizasyon algoritması ile küme işaretleme işleminin ardından aday kümeler aşağıdaki denklemler yardımıyla elenebilir:

$$S1=\{\forall c_{ij}<y_1 \cap \forall c_{ij}>y_2 \mid c_{ij} \in \{C\}\}$$

$$S2=\{\forall c_{ij}>x_1 \cap \forall c_{ij}<x_2 \mid c_{ij} \in \{C\}\}$$

$$K_n=\{S1 \cap S2\} \quad n=1,2,3\dots \quad (3.3)$$

Burada x_1 , x_2 , y_1 ve y_2 lokalizasyon algoritması tarafından hesaplanan sınırlardır. C sınıflandırılmış hareket vektörlerinden oluşan tüm resmi temsil etmektedir. $S1$, y_1 ve y_2 çizgileri arasında kalan kesişim bölgesini; $S2$, x_1 ve x_2 sınırları arasında kalan kesişim bölgesini temsil etmektedir. K_n ise $S1$ ile $S2$ ’ nin kesişimi olan bir kümeyi temsil etmektedir. Kümeler kesinleştirilirken hem düşey hem de dikey bölümlerin kesişimleri alınarak aday kümeler etiketlenmektedir. Ardından, lokasyon belirleme algoritması

kümelerin düşey ve yatay sınırlarını belirlemek veya etiketlenmiş kümelerin yerlerini bulmak için çalıştırılmaktadır [156].

3.5.2. Durum Tanımlama

3-Araba sollama senaryosunda arabaların durumlarının tanımlanması (case identification), yani arabaların birbirlerine olan mesafeleri ve hangi arabanın hangi şeritte olduğu gibi bilgilerin algılanması gerekmektedir. Çünkü sollama esnasındaki kaza riskinin büyüklüğü, sollamada rol alan arabaların durumlarına bağlıdır. Sollama esnasında kaza riskini belirlemede rol oynayan araç durumlarını oluşturan iki ana parametre vardır. Birincisi araçların yönü, ikincisi ise araçların bulunduğu şerit.

Trafiğin yönü tek yönlü ve çift yönlü olmak üzere iki türdür. Tek yönlü trafikte sollama esnasında sollayan aracın karşısına karşı yönden gelen bir araç çıkmaz. Sollayan aracın burada dikkat edeceği hususlar, virajlı yol, hava şartları, kendi şeridine güvenli geçiş, hız gibi kontrolün tamamen kendisinde olduğu unsurlardır. Oysa çift yönlü trafikte sollayan araç her an karşı yönden gelen bir araçla karşılaşma tehlikesi içerisinde. Dolayısıyla sollama esnasında ilk ve en çok dikkat edilecek husus karşı yönden bir aracın gelip gelmediğidir. Sollamalarda meydana gelen kazaların büyük bir bölümü çift yönlü yollardaki karşı yönden gelen başka bir araçla çarpışmalardan oluşmaktadır. Dolayısıyla araçların yönü, dolayısıyla karşıdan araç gelip gelmediği sollamalardaki riski önemli ölçüde etkilemektedir.

Araçların durumunu belirleyen ikinci önemli husus ise bulundukları şerittir. Eğer 3-Araba modelindeki arabalardan arkada olan, yani sollayacak araba eğer kendi şeridinde ise, yani sağ şeritte ise henüz sollama fiili gerçekleşmeye başlamamış demektir. Arkadaki aracın bulunduğu şerit sollamanın başlayıp başlamadığını gösteren önemli bir parametredir. Sağ şeritten sol şeride geçen arkadaki araç sollamanın ilk adımını gerçekleştirmiş demektir. Dolayısıyla arkadaki arabanın sol şeritte olduğu her durum riskin artmaya başladığını göstermektedir. Öte yandan, sollama senaryosunun kendi üzerinde kurulduğu sollanan arabanın her zaman kendi şeridinde olduğu varsayılmaktadır. Öndeki araçların şeritleri ise yine araçların yönüne bağlı olarak farklı riskler taşımaktadır. Örneğin araçlar aynı yönlüyken, sollanan aracın önündeki araç sol şeritteyse arkadan gelip sollama yapan aracın sollama sonrası kendi şeridine geçebilmesi için bir engel oluşturmaktadır.

Eğer karşı yönden ve sol şeritten bir araç geliyorsa bu durum, karşıdan gelen araçla sollayan aracın bir çarpışma yaşayabileceği anlamındadır. Tüm durumlar içerisinde en riskli durum bu durumdur.

Sollama işleminde hem araçların yönü hem de arabaların bulundukları şeridin parametre olarak bir durum değişkeni şeklinde kullanılması ile mevcut tüm durumlar tanımlanabilir. 3-Araba senaryosunda ARAÇLARIN YÖNÜ, ARKADAKİ ARAÇ ŞERİDİ ve ÖNDEKİ ARAÇ ŞERİDİ parametreleri kullanılarak elde edilen tüm senaryolarla ilgili doğruluk tablosu Tablo 3.1’ de verilmiştir.

Tablo 3.1. Durumların doğruluk tablosu [156].

ARAÇLARIN YÖNÜ	ARKA ARAÇ ŞERİDİ	ÖN ARAÇ ŞERİDİ	DURUM
0	0	0	Durum 1
0	0	1	Durum 2
0	1	0	Durum 3
0	1	1	Durum 4
1	0	0	Durum 5
1	0	1	Önemsiz
1	1	0	Durum 6
1	1	1	Önemsiz

Burada 3 değişkenli bir doğruluk tablosu olduğundan dolayı tüm durumlar $2^3=8$ tanedir. Bu tablodaki ikilik sistem mantığı ile belirtilen “mantıksal-0” ve “mantıksal-1” değerlerinin anlamları her değişken için farklıdır. ARAÇLARIN YÖNÜ değişkeni mantıksal değeri; eğer tüm araçlar aynı yönlü ise 0, karşı yönden araç geliyorsa 1’ dir. ARKA ARAÇ ŞERİDİ değişkeni mantıksal değeri; eğer arkadaki araç sol şeritteyse 0, sağ şeritteyse 1’ dir. Benzer şekilde ÖNDEKİ ARAÇ ŞERİDİ değişkeni mantıksal değeri; eğer öndeki araç sol şeritteyse 0, sağ şeritteyse 1’ dir. Örneğin, 0 0 1 durumunda araçların aynı yönlü (0), arkadaki aracın sol şeritte (0) ve öndeki aracın da sağ şeritte olduğu (1) anlaşılmaktadır. Bu durum, Durum 2 satırıdır. Benzer şekilde 1 1 0 durumu sözkonusu ise sırasıyla, karşıdan arabanın geldiği, arkadan gelen aracın sağ şeritte olduğu ve karşıdan gelen aracın (öndeki araç) sol şeritte olduğu anlaşılmalıdır. Bu durum, Durum 6 satırıdır. Burada dikkat edilecek bir başka husus bazı 1 0 1 ve 1 1 1 durumlarının “önemsiz” olarak etiketlenmiş olmasıdır. Bu etiketin anlamı, böyle bir durumun dikkate alınmayacağıdır. Bu iki durumun özelliği, karşıdan gelen aracın sağ şeritte yani sollanan araçla aynı şeritte

olmasıdır. Tablo 3.1’ deki varsayıma göre 3-Araba senaryosunda ortada olan yani sollanan araç ile karşı yönden gelen araç aynı şeritte olmamalıdır. Çünkü bu durum zaten karşı yönden gelen aracın yanlış şeritte olduğunu göstermektedir. Eğer aynı şeritte olacaklarsa aynı yönde olmalıdırlar. Dikkat edilirse “önemsiz” olan satırlar karşıdan gelen araç durumlarıdır. Buna ilave olarak bu çalışmadaki kabullerde, sollanan aracın sürekli sağ şeritte olacağı durumu sözkonusudur. Dolayısıyla karşıdan gelen araç sollanan araçla aynı şeritte çarpışacak şekilde gelmesi zaten sollama olayı olmadan başka bir durumdan dolayı çarpışmanın olmasına sebebiyet vermektedir. Bu yüzden bu durum “önemsiz” olarak dikkate alınmayacak bir durum olarak etiketlenmiştir. Tablo 3.1’ deki doğruluk tablosunun bir başka şekilde gösterilişi Tablo 3.2’ deki gibidir.


Tablo 3.2. Üç-Araba sollama senaryosu durumları [156].

Araçlar Aynı Yönlü			Araçlar Karşı Yönlü		
Ön Arka	şerit 1 (sol)	şerit 2 (sağ)	Ön Arka	şerit 1 (sol)	şerit 2 (sağ)
şerit 1 (sol)	Durum 1	Durum 2	şerit 1 (sol)	Durum 5	X
şerit 2 (sağ)	Durum 3	Durum 4	şerit 2 (sağ)	Durum 6	X

Tablo 3.2’ den de görüleceği üzere çalışmada, aynı yönlü trafikte dört ve çift yönlü trafikte iki olmak üzere 3-Araba senaryosunda risk durumları hesaplanacak altı farklı sollama senaryosu söz konusudur. Burada, Ön ve Arka’ dan kasıt sırasıyla 3-Araba modelinde sollanan aracın arkasındaki ve önündeki arabalardır. Daha önce de belirtildiği üzere bu çalışmadaki her işlem sağdan akan trafiğin kabulü üzerinedir. Dolayısıyla buradaki şerit 1 ve şerit 2, sırasıyla sol ve sağ şeritleri temsil etmektedir. Örneğin Durum 2 tanımından anlaşılanlar; aynı yönlü trafikte, yani tüm araçlar aynı yönde ilerlerken sollanan aracın arkasındaki arabanın sol şeritte ve öndeki aracın sağ şeritte olduğudur. Benzer şekilde Durum 5, sollanan aracın arkasındaki arabanın sol şeritte ve karşı yönden gelen öndeki aracın da sol şeritte olduğudur. Bu durum eğer mesafeler de kısaysa en riskli durum olarak göze çarpmaktadır.


X ile belirtilen durumlar ise daha önce de belirtildiği gibi karşıdan gelen aracın sollanan araçla aynı şeritte olduğu ve zaten bu şekilde olursa bir çarpışmanın kaçınılmaz olduğu

durumlardır. Bu yüzden X durumları sollama senaryosunun kurgulanmasına imkan vermediği için dikkate alınmayacak ve “önemsiz durum” (don’t care) olarak düşünülecektir. Şekil 3.4’ de araçların aynı yönde olduğu bir duruma örnek olarak Durum 2 verilmiştir.




Şekil 3.4. Durum 2 etiketli 3-Araba modeli [156].

Burada görüldüğü üzere tüm araçlar aynı yönde hareket etmektedir. Arkadaki araç sollama yapmak üzere sol şeride (şerit 1) geçmiş durumda ve sollanan araçla arasında r kadar mesafe bulunmaktadır. Şekil 3.4’ de f ile belirtilen mesafe ise sollanan araç ile önündeki araç arasındaki mesafedir. Öndeki araç da aynı yönde seyir halindedir. Dolayısıyla Şekil 3.4’ de gösterilen durum, tüm araçların aynı yönde hareket ettiği, arkadaki aracın sol, öndeki aracın sağ şeritte olduğu Durum 2 olarak etiketlenen durumdur. Bu şekilde bir etiket verilerek her mümkün olan durum için bir tanımlama yapılmıştır. Örneğin Şekil 3.5’ de öndeki aracın ve arkadaki aracın şerit 1’ de (sol şerit) olduğu, öndeki aracın karşıdan geldiği Durum 5 etiketli durum gösterilmiştir.



Şekil 3.5. Durum 5 etiketli 3-Araba modeli [156].



Şekil 3.6. Diğer durumlar. (a) Durum 1, (b) Durum 3, (c) Durum 4, (d) Durum 6 [156].

Şekil 3.6’ da ise tanımlanan diğer durumlar verilmiştir. Buradaki şekillerde öndeki arabanın yönüne ve bulundukları şeritlere dikkat edilmelidir. Örneğin Şekil 3.6 (d)’ de öndeki araba karşı yönden ve Şerit 1’ den gelmektedir. Sonuç olarak her bir durum birbirinden farklıdır ve dolayısıyla her bir tanımlanan durum birbirinden farklı sollama risklerine sahiptir. Sollama pozisyonundaki olası kaza riskini etkileyen bir başka faktör sollanan araba ile sollayan arasındaki mesafe (r) ve sollanan araç ile öndeki araç arasındaki mesafe (f)’ dir. Bu mesafelere takip mesafesi (Following Distance - FD) adı verilmektedir. Tablo 3.3’ de ön ve arkadaki arabaların takip mesafesinin hıza (V) göre hesaplanarak yakın ya da uzak şeklinde derecelendirilmesi verilmiştir. Takip eden aracın hızının yarısı, kriter olarak kullanılmıştır.

Tablo 3.3. Takip mesafeleri için yakınlık dereceleri [156].

Takip Mesafesi (FD)	Mesafe Derecesi
$FD < (V/2) \text{ m}$	Yakın
$(V/2) \leq FD$	Uzak

Takip mesafesi trafikte, öndeki aracın fren ve benzeri yolla aniden yavaşlaması veya durması durumunda arkadaki aracın çarpılmaması için gerekli olan durma mesafesi olarak bilinir. Buradaki problemde sollama için sollamadan sonra kendi şeridine geçebilmesi için sollayan aracın ihtiyaç duyduğu yeterli sollama mesafesidir (Overtaking Range). Sollama mesafesi araçların aynı yönde olup olmadığına, karşı yönden araç gelip gelmediğine bağlı olarak farklılık gösterir. Tüm araçların aynı yönde ilerlediği bir durumda t zaman içerisinde yapılan mesafe değişikliği ($\Delta(f+r)$) sollama mesafesi için yeterli olabilirken, karşı yönden gelen araç varken yapılan bir sollamada araçlar birbirine toplam hızları kadar yaklaştıkları için $\Delta(f+r)$ değişikliği t zamanından çok daha kısa bir süre içerisinde gerçekleşir. V1 arkadaki ve V2 öndeki araç olmak üzere aynı yönde ilerleyen iki arabanın hızları olsun ve $V1 > V2$ olsun. Bu durumda arkadaki araç diğerine $(V1-V2)$ hızıyla yaklaşmış olur. Ancak V1 ve V2 hızlarına sahip ve birbirlerine doğru hareket eden arabalar birbirlerine $(V1+V2)$ hızıyla yaklaşırlar. Açık bir şekilde görülmektedir ki birbirlerine doğru hareket eden araçların yaklaşma hızları oldukça fazladır ve her geçen t süresinde risk oranı artmaktadır. Dolayısıyla karşıdan bir aracın geldiği durumda kaza riskinin minimum olabilmesi için aynı yönlü trafiğe göre çok daha büyük bir mesafe olmalıdır. Özellikle f mesafesi ne kadar büyük olursa, sollayan araç sollamadan sonra kendi şeridine geçmek için

o kadar fazla zamana sahip olmuş olur. İdeal sollama mesafeleri için r mesafesinin en çabuk ve güvenli geçilecek kadar kısa olmasına, f mesafesinin ise sollamadan sonra güvenli şeride, yani sağ şeride geçmeye yetebilecek kadar fazla olmasına ihtiyaç bulunmaktadır. Bu mantık ile düşünülecek olunursa, f ve r mesafelerine bağlı olarak sollama mesafelerinin risk durumları tanımlanabilir. Tablo 3.4’ de tanımlanan risk durumları bu mantık ile oluşturulmuştur. Tablo, iki yakınlık derecesi (yakın ve uzak) üzerinden hareket edilerek $2^2=4$ durum için oluşturulmuş ve işlem maliyetini yükseltmemesi açısından ara değerler kullanılmamıştır.

Tablo 3.4. Takip mesafelerine göre tanımlanan risk durumları (Risk States-RS) [156].

Arkadaki araç mesafesi (r)	Öndeki araç mesafesi (f)	Risk Durumu
Yakın	Yakın	YÜKSEK
Yakın	Uzak	DÜŞÜK
Uzak	Yakın	ÇOK YÜKSEK
Uzak	Uzak	ORTA


Burada, f mesafesi yani sollandıktan sonra sağ şeride geçmek için mevcut mesafe az olursa riskin her zaman yüksek olacağı mantığı söz konusudur. En ideal durum r mesafesinin kısa, f mesafesinin uzun olduğu durumdur. En riskli durum ise sollanacak araçla mesafenin (r) uzun, sollandıktan sonraki mesafenin (f) kısa olduğu durumdur.

3.6. Durum Ataması ve Risk Hesaplama

3.6.1. Risk Durumları için Bayes Anlam Ağı Oluşturulması

Trafik akarken araçların takip mesafesi de şeritleri de değişir. Akışın her anında farklı durumlar gözlemlenebilir. Böylece, sollama için her bir durumun çarpışma riski takip mesafeleri de dikkate alınarak modellenenebilir. Buna ilave olarak, hesaplama işleminde her bir durum için arabaların konumlarının da düşünülmesi gerekmektedir. 3-Araba modelinde kaza riski Durumlar ve Takip Mesafeleri olmak üzere iki ana faktörden oluşur. Dolayısıyla kaza risk durumu $RS\{durum(AraçYönleri, ÖndekininŞeridi, ArkadakininŞeridi), f, r\}$ şeklinde tanımlanabilir. Burada RS risk durumunu (Risk State) göstermektedir. $durum(AraçYönleri, ÖndekininŞeridi, ArkadakininŞeridi)$ ise alt işlemidir. Örneğin $durum(AynıYön, Şerit 1, Şerit 2)$ ile Durum 2 durumu gösterilirken $durum(KarşıYön, Şerit 1, Şerit 1)$ ile Durum 5 durumu gösterilmektedir. Burada f, sollanan araç ile onun önündeki

aracın arasındaki mesafe, r ise sollayan araç ile sollanacak araç arasındaki mesafedir. Bunlardan yola çıkılarak $p(RS)$ ile gösterilen risk durum olasılığı, olasılık ilişkilerinden oluşan ve iyi bilinen Bayes Anlam Ağı (Bayesian Belief Network-BBN) ile gösterilebilir [212]. Şekil 3.7’ de sollama için düşünülen Bayes Anlam Ağının durum akışı, durumları gösteren düğüm noktaları verilmiştir.




Şekil 3.7. 3-Araba sollama modeli için Bayes Anlam Ağının durum akış şeması [156].

Burada sırasıyla $p(a)$, $p(b)$ ve $p(c)$ olasılıklarına sahip A, B ve C düğümleri, ilgili durumların tanımlandığı bağımsız olaylardır. A olayı trafik yönü ile ilgilidir. B olayı öndeki arabanın şeridi ile ilgili tanımdır. C olayı ise arkadaki aracın bulunduğu şeridi belirtmektedir. $p(a)$, $p(b)$ ve $p(c)$ olasılıklarına sahip olaylara bağlı olan D ve E düğümleri f ve r takip mesafelerini göstermektedir. RS düğümü ise $p(d|a,b,c)$ ve $p(e|a,b,c)$ olaylarına bağlı olan ve aynı zamanda önerilen Bayes Anlam Ağının sonuç aşaması olan Risk Hesabını veren $p(RS|d,e)$ ’ yi gösterir.

3.6.2. Bayes Ağı Yapılandırılması ve Risk Hesaplama

Bayes Anlam Ağının düğümlerinin belirlenmesinden sonra düğümlerdeki ve o düğümlerin bağımlı olduğu diğer olaylara bağlı olarak olasılık oranları belirlenerek Ağı yapılandırılması gerçekleştirilmesi gerekmektedir. Şekil 3.8’ de ana ve alt düğümlere olasılık oranı değerleri atanmış Bayes Anlam Ağı verilmiştir. Burada durum ve olayların olasılıkları çarpışma risk durumu düşünülerek geliştirilmiştir.



Şekil 3.8. Yapılandırılmış Bayes Anlam Ağı [156].

A olayı trafiğin yönü ile ilgilidir. A olayı a_1 =aynı ve a_2 =karşılıklı şeklinde iki duruma sahiptir. Bu durumlar daha önce de belirtildiği gibi sırasıyla, araçların tümünün aynı yönde seyrettiği trafik durumu (a_1) ile karşı yönden araçların gelebildiği ve trafiğin karşılıklı gidip gelebildiği durumlardır (a_2). Ayrıca, a_1 ve a_2 durumlarının olasılıkları sırasıyla $p(a_1)$ ve $p(a_2)$ olarak gösterilmiştir. $p(a_1)=0.3$ ve $p(a_2)=0.7$ olarak atanmıştır. Çünkü sollamada karşıdan araba gelirken kaza riski çok daha fazladır. B olayı sollanan aracın önündeki aracın şerididir. Ve yolun iki şeritli olduğu varsayımı ile iki şerit durumu söz konusudur, b_1 =Şerit 1 ve b_2 =Şerit 2. Bu durumların (b_1 ve b_2) olma olasılığı ve değerleri sırasıyla $p(b_1)=0.6$ ve $p(b_2)=0.4$ ’ dür. C olayı sollayan aracın şerididir. Ve yolun iki şeritli olduğu varsayımı ile iki şerit durumu söz konusudur, c_1 =Şerit 1 ve c_2 =Şerit 2. Bu durumların (b_1 ve

b_2) olma olasılığı ve değerleri sırasıyla $p(c_1)=0.6$ ve $p(c_2)=0.4$ ' dür. D olayı takip edilen öndeki aracı göstermektedir. D olayının olasılıkları, d_1 =yakın ve d_2 =uzak için A, B ve C olaylarına bağlı olarak $p(d_1|a,b,c)$ ve $p(d_2|a,b,c)$ ' dir. E olayı sollanan araç ile sollayan araç arasındaki mesafeyi göstermektedir. RS olayı ise D ve E olaylarına bağlı olan risk olayıdır.

3.7. DeneySEL Sonuçlar

Bu çalışmada sollanan aracın arka ve önünde bulunan kameraların her birinden alınmış yol görüntüleri kullanılmıştır. İşlemlerin aşamaları aşağıdaki gibidir:

Adım 1: Ön ve arka kameralar aracılığıyla alınan videolar kullanılarak resim çiftlerinin elde edilmesi ve onların kenarlarının çıkarılması

Adım 2: Kenar algılama ardından resim çiftlerinin optik akış haritalarının çıkarılması


Adım 3: Hareket vektörlerinin sınıflandırılması

Adım 4: Kümeleme ve araba tespiti

Adım 5: Durum algılama

Adım 6: Sollamanın kaza riskini hesaplama


Adım 1: Her iki kamera tarafından alınan görüntüler eşzamanlı olarak işlenmiş ve durum algılama için birleştirilmiştir. Ardından, arabaların pozisyonları hesaplanmıştır. Şekil 3.9 (a) ve (b)' de sırasıyla arka ve ön kameradan alınan videoalardan elde edilen çerçeve çiftleri gösterilmiştir.



Şekil 3.9. Video çerçeveleri ve kenar algılama. (a) Arka kamera görüntülerinden alınan resimler, (b) Ön kamera videolarından alınan yol görüntüleri, (c) Arkadaki görüntüler için kenar algılama ve nesne sınırlarının ortaya çıkması, (d) Ön için kenar algılama ve nesne sınırlarının ortaya çıkması [156].

Şekil 3.9 (c) ve (d)' de ön ve arka kameralardan alınan çerçeve çiftlerine kenar algılayıcı uygulanmış halini gösterilmektedir. Sonraki adımlarda videolardaki arabaların algılanması için hareket vektörü haritası çıkarılması gerekmektedir. Ancak gürültüler ve diğer nesnelerden kaynaklanabilecek Pozitif Yanlış sonuçlardan kaçınmak ve işlem yükünü hafifletmek amacıyla ön ve arka kameralardan elde edilen resim çiftlerine kenar algılayıcı uygulanmıştır.

Adım 2: Şekil 3.10 (a)' da kenar algılayıcıdan geçmemiş ham verinin hareket vektörü haritası gözükmemektedir. Şekil 3.10 (b) ve (c)' de ise kenar algılayıcıdan geçmiş arka ve ön kamera görüntü çiftlerinden elde edilmiş optik akış hareket vektör haritaları görülmektedir.




Şekil 3.10. (a) Kenar algılayıcı uygulanmamış hareket vektörü haritası, (b) Kenar algılayıcı uygulandıktan sonra elde edilmiş hareket vektörü haritası (arka), (c) Kenar algılayıcı uygulandıktan sonra elde edilmiş hareket vektörü haritası (ön) (d) b' de elde edilen hareket vektörü kümesinin yakınlaştırılmış biçimi [156].

Adım 3: Araba algılama için çıkarılan hareket vektörü haritası içerisinde gürültülerden kurtulmak ve araba olabilecek nesnelerin tespiti için bir eşik kullanılarak vektörlerin


sınıflandırma işlemi gerçekleştirilmiştir. Çerçeveedeki vektörlerin büyüklük ortalaması T eşiği için bir kriter olarak kullanılmıştır [155]. Bu ortalamanın altındakiler bir sınıf, üstündekiler diğer bir sınıftır. T eşiğinden büyük sınıflar araba olabilecek hareket büyüklüğüne sahiptir kabulü ile T' den düşük hareket vektörü sınıfı elenmiştir.

Adım 4: DHCR ve DHCC histogramları kullanılarak Küme Belirleme Algoritması [156] ile elde edilen sınırları belirlenmiş aday kümeler Şekil 3.11' de verilmiştir.




Şekil 3.11. (a) Arka kameradan, (b) Ön kameradan elde edilen aday kümelerin sınırları [156].

Şekil 3.12' de kullanılan kümeleme algoritmasını doğrulamak için K-Means kümeleme algoritması ile elde edilen kümeler gösterilmiştir.




Şekil 3.12. (a) Eşikleme (T) ve DHCR-DHCC ile elde edilen kümeler (ön kamera görüntüleri için), (b) K-Means ile elde edilen kümeler (ön kameradan alınan görüntüler için) [156].




Şekil 3.13. K-Means algoritmasının adımları. (a) Kümelemenin başlangıç merkezi, (b) Başlangıç kümesinin merkezinin tekrar hesaplanarak sınırlarının güncellenmesi, (c) Yeni merkez ve sınırların güncellenmesi, (d) Merkezlerin değişmemesinden dolayı kümelerin son durumu [156].

Şekil 3.14’ de doğrulanmış kümeler ve arabaların tespit edilmesi gösterilmiştir.



Şekil 3.14. Araba tespiti. (a) t anındaki aday kümeler (arka kamera), (b) t anındaki aday kümeler (ön kamera), (c) Araba tespiti (arkadaki araba), (d) Araba tespiti (öndeki araba) [156].

Adım 5: Şekil 3.15’ de görülen şemada, sollanan aracın önündeki ve arkasındaki arabaların yönleri ve bulundukları şerit gözönüne alınarak hangi tip durumda olduğuna karar verilmektedir. a1-b1-c2 durumu Şekil 3.8’ de Durum 3’ e denk gelmektedir. Çünkü sollanan arabanın önündeki araba Şerit 1’ de (b1), arkasındaki araç Şerit 2’ de (c2) ve araçlar aynı yöndedir (a1).




Şekil 3.15. Anlık pozisyon hesabı ve durum tespiti [156].

Adım 6: Durum tipinin tespitinin ardından, bu durumun ne kadar risk taşıdığı Bayes Ağı kullanılarak hesaplanmıştır. Aynı yöndeki trafik akışında eğer öndeki araç Şerit 1’ de ve sollanan araca yakın iken arkadaki araç Şerit 2’ de ve sollanan araca uzaksa Risk Durumunun çok yüksek olma olasılığı şu şekilde hesaplanabilir:

$$\begin{aligned}
 & p(a_1, b_1, c_2, d_1, e_2 | rs_1) \\
 &= p(a_1)p(b_1)p(c_2)p(d_1|a_1, b_1, c_2)p(e_2|a_1, b_1, c_2)p(rs|d_1, e_2) \\
 &= (0.3)(0.6)(0.4)(0.7)(0.4)(0.9) \\
 &= 0.018
 \end{aligned}$$

Burada a_1 aynı yönlü araba, b_1 öndeki arabanın Şerit 1’ de olması, c_2 arkadaki arabanın Şerit 2’ de olması, d_1 öndeki aracın ortadaki araca yakın olması, e_2 arkadaki aracın ortadaki araca uzak olması, rs_1 riskin yüksek olma olasılığıdır. $p(d_1|a_1, b_1, c_2)$ a_1 - b_1 - c_2 durumlarında d_1 olma olasılığı; $p(e_2|a_1, b_1, c_2)$ a_1 - b_1 - c_2 durumlarında e_2 olma olasılığıdır. $p(rs_1|d_1, e_2)$ ise d_1 ve e_2 olması durumunda rs ’nin çok yüksek olma olasılığıdır.

Bu hesap için izlenen adımların özeti tek bir şekilde aşağıdaki gibi verilebilir. Aracın hem ön hem de arka kamerasından alınan görüntülerin eş zamanlı olarak işlenerek en son adımda hesap yapılması Şekil 3.16’ da gösterilmiştir.



Şekil 3.16. Uygulamanın aşamaları. (a) Arka ve ön kameradan alınan görüntü çiftleri, (b) Görüntü çiftlerine kenar algılayıcı uygulanması, (c) Görüntü çiftlerinin optik akış hareket vektörü haritalarının çıkarılması, (d) Sınıflandırma, kümeleme ve lokalizasyon, (e) Arkadaki ve öndeki arabaların tespiti, (f) Araba pozisyonlarının hesaplanması, durum tipi tespiti ve risk hesaplama [156].

Burada Şekil 3.16 (f) işleminden sonra, yani araçların durumlarının tespitinin ardından Bayes Anlam Ağı ile risk hesabı yapılmaktadır.


4. CAN-Bus VERİLERİ KULLANILARAK AGRESİF/SAKİN SÜRÜŞ TESPİTİ İÇİN ÖZNİTELİK SEÇİMİ ALGORİTMASI

Bu çalışmada Agresif/Sakin Sürüş Tespiti problem için CAN-Bus (Control Area Network) verilerinin en uygun özniteliklerini (attribute) belirleme algoritması geliştirilmiştir. Bu çalışma ile, sürücülerin seyahat halindeyken aracı agresif ya da sakin sürüş alışkanlığına dikkat çekerek sürücüye destek sağlamaya katkıda bulunulmuştur. Problemdeki tüm özniteliklerin işleme koyulması sistemin karmaşıklığını arttırmaktadır. Bu nedenle, özniteliklerde eleme yapılarak bu karmaşıklık ve dolayısıyla işlem maliyeti azaltılabilir. Bu amaçla çalışmada önerilen algoritma, sürücünün ruh halini belirlemeden önce gereksiz öznitelikleri eleyerek en uygun öznitelikleri seçmektedir. Çalışmada öncelikle farklı sürücülere bilinçli olarak agresif ve sakin davranacakları şekilde sürüş testi yaptırılarak veri toplanmıştır. Ardından, önemsiz verileri eleyebilmek için yeni bir algoritma geliştirilmiştir. Önerilen yöntem, hem agresif hem de sakin sürüşte görülen ve birbiriyle ilişkili özniteliklerin benzer korelasyon karakteri gösterenleri yok etmeye dayanmaktadır.

Araba sürülürken bazen gaz pedalı itilir veya serbest bırakılır. Aynı zamanda seyahat halindeyken bazen vites çok hızlı değiştirilebilir. Eğer vites uygun olmayan biçimde değiştirilirse veya gaz pedalına basılırsa bu sürüş şekli agresif sürüş olarak düşünülebilir. Agresif sürüş, aynı zamanda yakıt tüketimini arttırabilir, motor ömrünü azaltabilir. Buna ilave olarak agresif sürüş yapan sürücü tecrübeli bir sürücü olsa bile seyahat halindeyken her zaman bir riske sahip demektir. Çoğu araştırmalarda sürüş profilini bulmak için jiroskop, radar, lidar, kamera gibi ek sensörler kullanılmıştır [213-215]. Bununla birlikte, bu çalışmada sistemin olabildiğince basit olmasına çalışılmıştır. Zaten bu çalışmada asıl çözülecek problem arabanın maliyetini ya da karmaşıklığını arttıran fazladan sensörler olmaksızın sürücünün profilini çıkarmaktır. Bu nedenle, çalışmayı en az veri ile çok basit bir yoldan yapmak gerekmektedir. Bu çalışmada sadece sürücünün agresif/sakin ruh halini gösteren CAN-bus verileri kullanılmıştır. Bu noktada ihtiyaç duyulan yöntem bir optimizasyon yapılarak tüm verileri kullanmak yerine, etkisi olmayan gereksiz öznitelikleri elemektir. Bu amaçla çalışmada gereksiz özniteliklerin elimine edilmesine dayanan bir tür özellik seçim algoritması (Feature Selection Algorithm) geliştirilmiştir. Algoritma, öznitelik çiftlerinin benzerlik ilişkilerinden yola çıkılarak benzer göstergelere sahip özniteliklerin birinin elenmesi veya seçilmesi esasına dayanmaktadır.

4.1. Sistemin Çalışması ve Aşamaları

Sistemin amacı arabanın CAN-bus çıkışı ile elde edilen eğitim verilerinin optimize edilerek Agresif/Sakin sürüş profilinin tespit edilmesidir. *Absolute throttle position*, *Calculated Load*, *Intake air rate*, *Speed*, *O2 sensor*, *Fuel rate*, *Boost pressure*, *RPM* gibi CAN-bus verileri öznitelik olarak düşünülebilir ve bunlardan agresif/sakin sürüşte aynı etkiyi gösterenler belirlenebilir. Başka bir öznitelikle aynı etkiyi gösterenler, gereksiz öznitelik (redundant attribute) olarak adlandırılır. Öte yandan sisteme hiçbir etkisi olmayanlar ise ilgisiz öznitelik (irrelevant attribute) olarak adlandırılır. Özniteliklerin bazılarının sisteme aynı etkiyi veriyor olabilmesinin en büyük sebebi arabadaki mekanik bileşenlerin birbirlerine bağlı olarak çalışmasıdır. Örneğin tork değeri, gaza basma ile artmaktadır. Dolayısıyla gaz pedalı pozisyonu ile tork özniteliklerinin bir sistemin çalışmasına olan etkileri benzer olabilir. Bu nedenle bunlardan birisi elenmek için aday olarak düşünülebilir. Sonuç olarak geliştirilen algoritma, gereksiz ve ilgisiz özniteliklerin elenmesini sağlamaktadır. Anafikir, hem agresif hem de sakin sürüşte aynı etkileri gösteren veya hiçbir etki göstermeyen özniteliklerin elenmesidir. Şekil 4.1’ de, geliştirilen algoritmanın adımları yer almaktadır.



Şekil 4.1. Sistemin aşamaları [159].

4.2. Veri Toplama ve Özniteliklerin Birbirleriyle İlişkilerinin Çıkarılması

İlk başta, arabanın CAN-bus çıkışı ile elde edilen eğitim verilerinden özniteliklerin birbirleriyle ilişkili (correlated) olup olmadığı control edilmelidir. İlişki işlemi tüm özniteliklerin birbiriyle çapraz korelasyon katsayılarının (Cross correlation coefficients) Agresif ve Sakin sürüş durumları için ayrı ayrı bulunmasıdır. Öznitelikler birer değişken olarak temsil edilerek, tüm özniteliklerin aşağıdaki gibi bir vektör ile temsil edilmesi mümkündür:

$$\vec{V} = [v_1 \ v_2 \ \dots \ v_n] \quad (4.1)$$

Burada n değişken sayısını, $v_1 \dots v_n$ ise öznitelikleri temsil eden değişkenleri göstermektedir. Değişkenlere çapraz korelasyon uygulandığında Agresif ve Sakin sürüşler için ayrı ayrı korelasyon katsayı matrisleri oluşmaktadır. Aşağıda bu matrisler verilmiştir:

$$R^{ag} = \begin{matrix} & \begin{matrix} (v_1) & (v_2) & \dots & (v_n) \end{matrix} \\ \begin{matrix} (v_1) \\ (v_m) \end{matrix} & \begin{bmatrix} r_{11} & r_{12} & \dots & r_{1n} \\ \vdots & \ddots & \ddots & \vdots \\ r_{m1} & r_{m2} & \dots & r_{mn} \end{bmatrix} \end{matrix}_{m \times n} \quad (4.2)$$

$$R^{sa} = \begin{matrix} & \begin{matrix} (v_1) & (v_2) & \dots & (v_n) \end{matrix} \\ \begin{matrix} (v_1) \\ (v_m) \end{matrix} & \begin{bmatrix} r_{11} & r_{12} & \dots & r_{1n} \\ \vdots & \ddots & \ddots & \vdots \\ r_{m1} & r_{m2} & \dots & r_{mn} \end{bmatrix} \end{matrix}_{m \times n} \quad (4.3)$$

Burada r_{mn} değişkenlerin korelasyon katsayılarıdır. Örneğin r_{12} değeri v_1 ile v_2 değişkenlerinin arasındaki korelasyon katsayısını göstermektedir. Agresif ve Sakin sürüş verileri farklı veriler olduğu için her ikisi için de sırasıyla ayrı ayrı R^{ag} ve R^{sa} matrisleri oluşturulmuştur.

4.3. Korelasyon Tiplerinin Atanması

Denklem 4.4 ve 4.5 deki matrisler $c_{ij} = \{C^{+1}, C^{-1}, C^0 \mid \forall c \in C^{ag} \vee C^{sa}\}$ olmak üzere Agresif/Sakin sürüş için korelasyon durumlarını ve tiplerini gösterir:


$$C^{ag} = \begin{bmatrix} c_{11} & c_{12} & \cdots & c_{1n} \\ \vdots & \vdots & \ddots & \vdots \\ c_{m1} & c_{m2} & \cdots & c_{mn} \end{bmatrix}_{m \times n} \quad (4.4)$$

$$C^{sa} = \begin{bmatrix} c_{11} & c_{12} & \cdots & c_{1n} \\ \vdots & \vdots & \ddots & \vdots \\ c_{m1} & c_{m2} & \cdots & c_{mn} \end{bmatrix}_{m \times n} \quad (4.5)$$

Korelasyon iki değişken arasında birbirlerine olan bağımlılığı gösterir. Bu bağımlılık -1 ile +1 arasında değer alan korelasyon katsayısına (r_{mn}) bakılarak tespit edilir. Eğer bu değer sıfıra yakınsa iki değişken birbirine bağlı değildir. -1' e veya +1' e ne kadar yakınsa bağımlılığı o kadar güçlüdür. Korelasyon üç türdür: *Doğrudan Korele (Directly Correlated)*, *Ters Korele (Inversely Correlated)* ve *Korele olmayan (Uncorrelated)*. Eğer iki değişken arasındaki korelasyon katsayısı +1 değerine yakınsa ve biri artarken diğeri de artıyorsa veya biri azalırken diğeri de azalıyorsa *Doğrudan Koreledir*. Eğer korelasyon katsayısı -1 ise ve biri artıyorken öteki azalma şeklinde ise *Ters Koreledir*. Eğer korelasyon katsayısı 0 ise o değişkenler birbirine korele değildirler. Buradaki korelasyon katsayıları bir eşik (T) değeri ile sınıflandırılabilir. Örneğin +0.5 değerinden büyük olan korelasyon katsayı değeri Doğrudan Korele sayılabilir. Aynı şekilde -0.5 değerinden daha küçükler de Ters Korele sayılabilir. -0.5 ile +0.5 aralığındakilerin de Korele Olmayan sınıfına dahil edilmesi mümkündür. Buradaki T değerinin seçilmesinin herhangi bir metodu olmamakla birlikte korelasyon için oluşturulan serpilme diyagramına bakılarak probleme göre karar verilebilir. Bu çalışmadaki çapraz korelasyon matrisindeki korelasyon katsayıları bir T eşik değeri seçilerek bu üç korelasyon sınıftan birine dahil edilerek sınıflandırılmışlardır. Denklem 4.6' da korelasyon katsayılarının sınıflandırılması verilmiştir. Bu durumda her katsayıya üç sınıftan birisi atanacaktır. Örneğin r_{23} katsayısının değeri denklemdaki aralıklardan hangisine uyuyorsa o değeri alacaktır. Ya C^{+1} , ya C^0 ya da C^{-1} değerine sahip olacaktır.

$$c_{ij} = \begin{cases} C^{+1} , & +T \leq r_{ij} \leq +1 \\ C^0 , & -T < r_{ij} < +T \\ C^{-1} , & -1 \leq r_{ij} \leq -T \end{cases} \quad (4.6)$$

Burada $i=1..m$ ve $j=1..n$ olmak üzere $C^{+1}=Doğrudan\ Korele$, $C^{-1}=Ters\ Korele$, $C^0=Korele\ Olmayan$ şeklindedir. Şekil 4.2’ de Denklem 4.6’ da belirtilen korelasyon değer aralıkları gösterilmiştir.



Şekil 4.2. Korele olan ve olmayan aralıklar [159].

4.4. Agresif ve Sakin Sürüşün Her İkisi için de Benzer İlişkiyi Gösteren Değişkenlerin Belirlenmesi


Korelasyon katsayıları gözden geçirilirken hem Agresif hem de Sakin sürüşte benzer ilişki gösteren çiftler seçim işleminde eleme için adaydırlar ve çifti oluşturan değişkenlerden biri elenebilir. Örneğin, eğer (v_i, v_j) değişken çifti, aynı benzerlik oranına sahipse v_i ve v_j benzer demektir ve her ikisi de elenme için adaydır. Buna ilave olarak değişken çiftleri Agresif için farklı karakteristiğe, Sakin için farklı karakteristiğe sahipse benzer olmayan (non-similar) adı verilir. Dolayısıyla $s_{ij} = \{S^{+1}, S^{-1}, S^0, NS \mid \forall s \in S^{Benzerilişki}\}$ olmak üzere hem Agresif hem de Sakin sürüş durumlarında benzer ilişkiler içeren *Benzerlik İlişki Matrisi* (Similar Relation Matrix) elde edilir. Denklem 4.7’ de benzer ilişkileri gösteren Benzerlik İlişki Matrisi verilmiştir.

$$S^{Benzerilişki} = \begin{bmatrix} s_{11} & s_{12} & \cdots & s_{1n} \\ \vdots & \vdots & \ddots & \vdots \\ s_{n1} & s_{n2} & \cdots & s_{nn} \end{bmatrix}_{n \times n} \quad (4.7)$$

Denklem 4.8’ de benzerlik ilişkisinin çıkarılışı verilmiştir.

$$s_{ij} = \begin{cases} S^{+1}, & c_{ij}^{ag} = c_{ij}^{sa} = C^{+1} \\ S^{-1}, & c_{ij}^{ag} = c_{ij}^{sa} = C^{-1} \\ S^0, & c_{ij}^{ag} = c_{ij}^{sa} = C^0 \\ NS, & c_{ij}^{ag} \neq c_{ij}^{sa} \end{cases} \quad (4.8)$$

Eğer $c_{ij}^{ag} = C^{+1}$ ve $c_{ij}^{sa} = C^{+1}$ ise hem Agresif hem de Sakin sürüş, Doğrudan Korele biçimde benzerliğe sahiptir. Bu durumda Agresif ve Sakin sürüş için değişken çiftinin benzer ilişkileri $s_{ij} = S^{+1}$ olarak atanır. Benzer şekilde, eğer $c_{ij}^{ag} = C^{-1}$ ve $c_{ij}^{sa} = C^{-1}$ ise değişken çiftlerindeki benzerlik Ters Korelasyon şeklindedir. Bu durumda Agresif ve Sakin sürüş için $(v_i v_j)$ değişken çiftinin benzerlik ilişkisi $s_{ij} = S^{-1}$ olarak atanır. Eğer $c_{ij}^{ag} \neq c_{ij}^{sa}$ ise örneğin, $c_{ij}^{ag} = C^{-1}$ ve $c_{ij}^{sa} = C^{+1}$ ise Agresif ve Sakin sürüş için benzer ilişki davranışı görülmemektedir. Bu durumda Agresif ve Sakin sürüş için $(v_i v_j)$ çiftinin ilişki benzerliği $s_{ij} = NS$ olarak atanacaktır.



Şekil 4.3. Agresif ve Sakin sürüş için $(v_i v_j)$ çiftlerinin korelasyon durumları. (a) Agresif sürüş için Doğrudan Korelasyon örneği, (b) Agresif sürüş için Ters Korelasyon örneği, (c) Agresif için Korele olmayan bir örnek, (d) Sakin sürüş için Doğrudan Korelasyon örneği, (e) Sakin sürüş için Ters Korelasyon örneği, (f) Sakin sürüş için Korele olmama örneği [159].

Agresif ve Sakin sürüş için $(v_i v_j)$ çiftlerinin korelasyon durumları Şekil 4.3' de verilmiştir. Örneğin, eğer $(v_i v_j)$ çifti Agresif ve Sakin sürüş durumları için Şekil 4.3 (a) ve (b)' deki gibi tam benzer şekilde korele ise Benzerlik İlişkisi bu çift için Doğrudan Korele (C^{+1}) olarak belirlenmiş olur.

Gereksiz deęişken elemedeki aranan özellik, bir deęişkenin tüm SRC kümelerinde veya hiç birinde olup olmadığıdır. Bir başka ifadeyle, eęer v_i deęişkeni tüm SRC' lerde mevcutsa veya hiçbirinde yoksa, bu deęişken Agresif/Sakin sürüş için herhangi bir ayırtedici etkiye sahip olmayacağı için elenebilir.

Tablo 4.1. SRC kümelerine ait deęişkenler [159].

	SRC^{-1}	SRC^0	SRC^{+1}
v_1	1	1	1
v_2	1	0	1
v_3	0	1	0
$\vdots$	$\vdots$	$\vdots$	$\vdots$
v_{n-2}	0	1	0
v_{n-1}	0	0	0
v_n	1	1	1

Deęişkenlerin yer aldığı kümeler deęişkenlerin ait olduęu SRC' lerin belirtildięi Tablo 4.1 sayesinde kolayca görülebilir. Tablo 4.1' deki her bir satır, hangi deęişkenin hangi SRC' lerde yer aldığını gösterir. Eęer bir SRC' de v_i mevcutsa o SRC' nin olduęu yer 1 ile mevcut deęilse 0 ile gösterilmiştir. Örneğin tablodaki v_2 deęişkeninin SRC^{-1} ve SRC^{+1} kümelerinde mevcut, SRC^0 kümesinde mevcut olmadığı anlaşılmaktadır.

4.6. Gereksiz Deęişkenlerin Bulunması

Aşağıda verilen Aynı İlişkilerin Bulunması Algoritması (The Algorithm Detection of Same Relations - DSR), tüm SRC' lerde bulunması veya hiçbirinde bulunmayan deęişkenlerin tespit edilmesi işlemini gerçekleştirir.

Her bir satırdaki ($NumOfSRC$) SRC üyelięi Tablo 4.1' deki her deęişken, yani tüm n satır gözden geçirilerek tanımlanmıştır. Eęer deęişken tüm SRC kümelerinin üyesi ise (yani $NumOfSRC = m$ ise) veya herhangi bir SRC kümesinin üyesi deęilse (yani $NumOfSRC = 0$ ise), o deęişken elenebilecek gereksiz deęişkenlerin listesine (*RedundantVarList*) eklenebilir.

Algoritmanın tüm adımları çalıştırılarak, başka bir ifadeyle tüm deęişkenlerin kontrol edilmesi tamamlandıktan sonra *RedundantVarList* listesinde yer alan deęişkenler

elenebilecek potansiyel değişkenlerdir ve geri kalan değişkenler ise *SelectedVarList* listesinde yer alan seçilmiş değişkenler olacaktır [159].

Algorithm: Detection of Same Relations (DSR)

```
i ← 1, RedundantVarList ← { }, SelectedVarList ← { }
For i ≤ SRCTableRowNum
  Num_1s ← 0, j ← 0
  While j ≤ SRCTableColNum
    Num_1s ← Num_1s + 1
    j ← j + 1
  endWhile
  if Num_1s = SRCTableColNum or Num_1s = 0 then
    RedundantVarList ← RedundantVarList + {Vi}
  else
    SelectedVarList ← SelectedVarList + {Vi}
  endif
  i ← i + 1
endFor
Return SelectedVarList, RedundantVarList
```

4.7. Deneyisel Sonuçlar

4.7.1. Geliştirilen Yöntemin Uygulama Aşamaları

Yöntemde kullanılan işlemler sırasıyla aşağıdaki adımları içermektedir:

Adım 1. Veri toplama ve özniteliklere değişken atama

Adım 2. Değişken çiftlerinin birbirleriyle ilişkilerinin hesaplanması

Adım 3. İlişkilerin korelasyon tiplerinin belirlenmesi

Adım 4. Benzer ilişki davranışlarının belirlenmesi

Adım 5. Benzerlik ilişkisi kümelerinin çıkarılması

Adım 6. Gereksiz ve ilgisiz özniteliklerin elenmesi

4.7.2. Veri Toplama ve Özniteliklere Değişken Atama

Veri toplamak için test sürüşü denemeleri, yoğun bir trafiğe sahip yaklaşık 5 km' lik bir yolda yapılmıştır. Test güzergahı Şekil 4.5' de verilmiştir.



Şekil 4.5. Test sürüşü güzergahı. Kırmızı ile belirtilen kısım test yapılan güzergahı göstermektedir. Test, Elazığ şehrinde Abdullahpaşa mahallesi ile Fırat Üniversitesi arasında trafiğin yoğun olduğu saatlerde yapılmıştır. Güzergahta hem hız yapılabilmeye müsait yollar hem de kavşak, trafik ışığı gibi yavaşlamayı, beklemeyi ve dikkatli olmayı gerektirecek bölümler yer almaktadır [159].

Yoğun trafiğin seçilmesinin sebebi stresli ve riski fazla olan bir trafik ortamını oluşturmaktır. Deneme sürüşlerinin her biri belirtilen güzergahta test aracı ile beşer tur şeklinde yapılmıştır. Test sürüşlerinde farklı sürücüler kullanılmıştır. Farklı sürücülerin kullanılması ile aynı güzergah üzerindeki farklı sürücü davranışlarının eğitim verisi olarak kullanılması amaçlanmıştır. Test sürüşlerinde tüm veriler DynoScan yazılım aracı [216] ile aracın CAN-bus çıkışından alınarak kaydedilmiştir.

Deneyde kullanılan arabalar LPG yakıtı ile çalışan 2005 model Ford Focus, dizel motora sahip 2011 model Opel Astra ve yine dizel motora sahip Tata Vista araçlarıdır. Farklı marka ve modellere sahip arabaların kullanılması ile CAN bus çıkışlarındaki farklı verilerin elde edilmesi amaçlanmıştır. Ayrıca bu araçların motor hacimlerinin birbirine yakın ve ürettikleri tork değerlerinin birbirlerine yakın olmasına dikkat edilmiştir. Örneğin Opel Astra ve Tata Vista araçlarının ikisi de 1.3 motor hacmine ve sırasıyla 200 ile 190 torka sahiptirler. Performansları birbirine yakın olan araçların seçilmesi ile, sürücü davranışlarının ön plana çıkarılması amaçlanmıştır.

Araçların bir ortak özelliği de otomatik vites olmaması, düz vitesli olmalarıdır. Düz vites sürücü tarafından değiştirildiği için stresli yoğun bir trafikte kontrolün tamamen sürücüde olabilmesini sağlamaktır. Örneğin sürücü agresif bir kalkış ve hızlanmayı düz vitesli bir araçta daha belirgin yapabilmektedir. Erken vites değişikliği, devirsiz kullanma gibi davranışlar ancak düz viteste olabilmektedir. Otomatik viteste ise devir belirli bir değere gelmedikçe şanzıman vitesi değiştirmemektedir. Dolayısıyla test verileri değerlendirilirken veriler daha hassas ve agresiflik belirtileri düz viteste daha net olabilecektir. Zira, test sürüşü yapan sürücülerden her sürüş turunda kasıtlı olarak Agresif veya Sakin sürüş yapmaları istenmiştir. Sürücünün bilinçli olarak yaptığı gereksiz vites değiştirme ve ani hızlanma, ani vites değişiklikleri, tipik Agresif sürüş davranışlarıdır. Dolayısıyla test sürüşlerinin daha sağlıklı olmasına bu problemde düz viteslerin katkısı daha belirgin olmuştur. Test sürüşlerinde araçlardan alınan CAN bus verilerinden en yaygın olan 15 tanesi kullanılmıştır. Bu veriler özniteliklerdir ve algoritma çalıştırılırken değişken şeklinde işleme alınacaklardır. Söz konusu olan 15 CAN bus verisi orjinal isimleriyle ve anlamlarıyla aşağıdaki gibidir:

RPM: Devir

Speed: Hız

Absolute Throttle Position: Gaz pedalı pozisyonu

Calculated Load: Tork

Fuel Rate 2: Yakıt Oranı

Boost Pressure: Basınç

In Manifold Pressure: Giren hava basıncı

Instant Economy 2: Anlık yakıt ekonomisi

O2 Sensor BIS2: Oksijen sensörü

O2 Sensor BIS1: Oksijen sensörü

Short Fuel Trim BIS2: Yakıt döngü algoritması tarafından yapılan düzeltmeyi gösterir.

Ignition Timing Advance: Ateşleme zamanı

Air Flow Rate for MAP: Hava kütlesi miktarı

Short Fuel Trim B: Yakıt döngü algoritması tarafından yapılan düzeltmeyi gösterir.

Fuel Cost 2: Yakıt tüketimi.

Problem, bu verilerin hangilerinin agresif ve sakin sürüşleri tespit etmede gereksiz veya etkisiz olduğunu bulmaktır. Çalışmada geliştirilen yöntem, test verilerinden yola çıkarak değişkenlerin birbirine olan bağımlılıklarını değerlendirerek gereksiz ve ilgisiz öznitelikleri elemektedir.

CAN-bus çıkışı ile elde edilen veriler, problemdeki özniteliklerdir. Yöntem uygulanırken her birine birer değişken atamak bu özniteliklerle ilgili kolay işlem yapılabilmesini sağlamaktadır. Dolayısıyla özniteliklerin herbiri bir değişken ve bir vektörün elemanları olarak aşağıdaki gibi atanabilir :

$\vec{V} = [RPM, Speed, Absolute Throttle Position, Calculated Load, Fuel Rate2, Boost Pressure, Instant Economy2, O2 Sensor BIS2, O2 Sensor BIS1, Short Fuel Trim BIS2, Ignition Timing Advance, Air Flow Rate for MAP, Short Term Fuel Trim B1, Fuel Cost2]$

Yukarıdaki şekilde bir yapıda her bir öznitelik $\vec{V} = [v_1, v_2, \dots, v_{15}]$ vektöründeki sırasıyla $v_1 \dots v_{15}$ değişkenleri ile temsil edileceklerdir. Örneğin artık v_1 değişkeni *RPM* yani motor devrini, v_2 değişkeni *Speed* yani araç hızını, benzer şekilde v_{15} değişkeni *Fule Cost 2* yani yakıt tüketimi özniteliğini temsil etmektedir.

4.7.3. Değişkenlerin Birbirleriyle İlişkilerinin Hesaplanması

Agresif ve Sakin sürüş için değişkenler arasındaki ilişkiler Denklem 4.12 ve 4.13’ de verilmiştir. Denklem 4.12 ve 4.13’ deki matrisler ($v_i v_j$) Agresif ve Sakin sürüş için değişken çiftleri arasındaki korelasyon katsayılarını göstermektedir.

$$R^{ag} = \begin{matrix} & \begin{matrix} v_1 & v_2 & v_3 & \dots & v_{13} & v_{14} & v_{15} \end{matrix} \\ \begin{matrix} v_1 \\ \vdots \\ v_{15} \end{matrix} & \begin{bmatrix} X & 0.70 & 0.54 & \dots & 0.68 & -0.19 & -0.40 \\ & \vdots & & \ddots & & \vdots & \\ -0.40 & -0.19 & 0.68 & \dots & 0.29 & -0.48 & X \end{bmatrix}_{15 \times 15} \end{matrix} \quad (4.12)$$

$$R^{sa} = \begin{matrix} & \begin{matrix} v_1 & v_2 & v_3 & \dots & v_{13} & v_{14} & v_{15} \end{matrix} \\ \begin{matrix} v_1 \\ \vdots \\ v_{15} \end{matrix} & \begin{bmatrix} X & 0.93 & -0.002 & \dots & 0.76 & -0.15 & 0.60 \\ & \vdots & & \ddots & & \vdots & \\ 0.60 & -0.15 & 0.76 & \dots & 0.19 & 0.43 & X \end{bmatrix}_{15 \times 15} \end{matrix} \quad (4.13)$$

Bu şekilde tüm değişkenlerin birbiriyle olan ilişkilerinin bulunmasına çapraz korelasyon denilmektedir. R^{ag} matrisindeki birinci satır ikinci sütun değeri 0.70 olarak hesaplanmıştır. Bu değer Agresif sürüş durumunda RPM (v_1) ve Speed (v_2) öznelilik çifti arasındaki birbirine bağımlılık ilişkisinin yani aralarındaki korelasyonun hesaplanması ile elde edilen korelasyon katsayısıdır. Benzer şekilde R^{sa} matrisinde birinci satır ikinci sütun değeri 0.93’ dür. Bu değer de Sakin sürüş için elde edilmiş test verilerindeki RPM ve Speed ikilisinin arasında birbiri ile ilişkili olma hesaplanması ile elde edilen korelasyon katsayısıdır.

4.7.4. İlişkilerin Korelasyon Tiplerinin Belirlenmesi

Önceki adımda hesaplanan korelasyon katsayılarının, anlamlı ve kolay bir işleme sokulabilmesi için korelasyon katsayılarının bir eşik (T) ile sınıflandırılması gerekmektedir. Aksi halde işlem karmaşıklığı meydana gelecek ve çok sayıdaki veriler yöntemin uygulanmasını imkansızlaştıracaktır. Örneğin +0.8 olarak hesaplanmış bir korelasyon katsayısı ile +0.65 aslında aynı anlamdadır, ikisi de Doğrudan Koreledir. Aynı şekilde -0.05 ile +0.06 de sifıra yakın olmaları sebebiyle aynı sınıftadırlar ve ikisini ayrı

ayrı değerlendirmeye almak yerine tek bir sınıf numarası vererek aynı değer olarak düşünmek metodun uygulanabilirliği ve kolaylık açısından gereklidir. Burada eşik değeri $T=0.35$ olarak seçilmiştir. Bu eşik değeri kullanılarak tüm korelasyon katsayıları bir sınıf numarası ile etiketlenmiştir ve aşağıdaki matrisler elde edilmiştir.

$$C^{ag} = \begin{bmatrix} X & C^{+1} & C^{+1} & \dots & C^{+1} & C^0 & C^{-1} \\ & \vdots & & \ddots & & \vdots & \\ C^{-1} & C^0 & C^{+1} & \dots & C^0 & C^{-1} & X \end{bmatrix}_{15 \times 15} \quad (4.14)$$

$$C^{sa} = \begin{bmatrix} X & C^{+1} & C^0 & \dots & C^{+1} & C^0 & C^{+1} \\ & \vdots & & \ddots & & \vdots & \\ C^{+1} & C^0 & C^{+1} & \dots & C^0 & C^{+1} & X \end{bmatrix}_{15 \times 15} \quad (4.15)$$

Denklem 4.14 ve 4.15 sırasıyla Agresif ve Sakin sürüş durumları için korelasyon katsayılarının durumlarını, yani Doğrudan, Ters veya Korele Olmayan sınıflarından hangisi oldukları bilgilerini içermektedir. Örneğin C^{ag} matrisindeki ilk satır ikinci sütundaki C^{+1} matris elemanı R^{ag} matrisindeki aynı satır ve sütundaki korelasyon katsayısı olan 0.7 değerinin durumudur. Daha önce Denklem 4.6’ da belirtildiği üzere korelasyon katsayısı eğer T değerinden büyükse Direkt Korele sınıfındadır. Eğer korelasyon katsayısı $-T$ ile $+T$ arasındaysa Korele Olmayan sınıfındadır. Eğer $-T$ eşliğinden küçükse Ters Korele sınıfındadır. Uygulamada $T=0.35$ olduğu için 0.70 değeri C^{+1} olarak alınmıştır. Benzer şekilde R^{sa} matrisindeki birinci satır ikinci sütun değeri 0.93 katsayı değeri, eşik değeri $T=35$ olduğu için Doğrudan Koreledir ve C^{+1} durumu ile etiketlenmiştir. Aynı şekilde 0.19 değeri de -0.35 ile +0.35 eşik aralığında olduğu için korelasyon katsayısı sıfır olan sınıf ile yani C^0 ile etiketlenmiştir.

4.7.5. Benzerlik Gösteren İlişki Davranışlarının Belirlenmesi

Bu adımda, hem Agresif ve Sakin sürüş ilişkileri için benzerlik ilişkileri değerlendirilmiştir. Denklem 4.16’ da C^{ag} ve C^{sa} matrisleri eşleştirilerek elde edilmiş olan Benzerlik İlişki Matrisini ($S^{Benzerliklişkisi}$) gösterilmektedir. Bu benzerlikler $(v_i v_j)$ çiftlerinin aralarındaki korelasyonların benzerliğini göstermektedir.

$$S^{\text{Benzerliklişkisi}} = \begin{bmatrix} X & S^{+1} & NS & \dots & S^{+1} & S^0 & NS \\ & \vdots & & \ddots & & \vdots & \\ NS & S^0 & S^{+1} & \dots & S^0 & NS & X \end{bmatrix}_{15 \times 15} \quad (4.16)$$

Örneğin, Denklem 16' ya göre C^{ag} ve C^{sa} matrislerinin her ikisinin de ilk satır ikinci sütunlarındaki elemanların benzerlikleri Benzer İlişki Matrisinde S^{+1} olarak aynı satır ve sütun konumuna yazılmıştır. Benzer şekilde $c_{13}^{ag} = C^{+1}$ ve $c_{13}^{calm} = C^0$ olduğundan dolayı $s_{13}=NS$ değerini almıştır. Aynı şekilde $c_{1(14)}^{ag} = C^0$ ve $c_{1(14)}^{calm} = C^0$ olduğu için $s_{14}=S^0$ olarak belirlenmiştir.

4.7.6. Benzer İlişki Kümelerinin Çıkarılması (SRC Kümeleri)

$S^{\text{SimilarRelation}}$ matrisi vasıtasıyla, Doğrudan Korele Benzer İlişki Kümesi (*Directly Correlated Similar Relation Cluster* - SRC^{+1}), Ters Korele Benzer İlişki Kümesi (*Inversely Correlated Similar Relation Cluster* - SRC^{-1}) ve Korele Olmayan İlişki Benzerlik Kümesi (*Uncorrelated Similar Relation Cluster* - SRC^0) elde edilmiştir. Denklem 4.16, 4.17 ve 4.18 'de elde edilen SRC kümeleri verilmiştir. Bu kümelerdeki çiftler, aynı benzerlik davranışını gösteren öz nitelik çiftleridir. Örneğin SRC^{+1} kümesindeki (v_1v_2) çifti ile (v_6v_7) çifti aynı benzerlik ilişkine sahiptir. Aynı şekilde SRC^0 kümesindeki (v_2v_8) çifti ile $(v_{11}v_{13})$ değişken çifti aynı ilişki davranışına sahiptir.

$$SRC^{+1} = \{(v_1v_2), (v_1v_5), (v_1v_{13}), (v_2v_5), (v_2v_{13}), (v_3v_4), (v_3v_6), (v_3v_7), (v_3v_{13}), (v_4v_5), (v_4v_6), (v_4v_7), (v_4v_{13}), (v_5v_{13}), (v_6v_7), (v_{11}v_{14})\} \quad (4.16)$$

$$SRC^{-1} = \{(v_3v_8), (v_4v_8), (v_5v_8), (v_8v_{13}), (v_9v_{11}), (v_9v_{14})\} \quad (4.17)$$

$$SRC^0 = \{(v_1v_8), (v_1v_{11}), (v_1v_{12}), (v_1v_{14}), (v_2v_8), (v_2v_{11}), (v_2v_{12}), (v_2v_{14}), (v_3v_9), (v_3v_{10}), (v_3v_{11}), (v_3v_{14}), (v_4v_9), (v_4v_{10}), (v_4v_{11}), (v_4v_{14}), (v_5v_{11}), (v_5v_{14}), (v_6v_9), (v_6v_{10}), (v_6v_{11}), (v_6v_{14}), (v_7v_9), (v_7v_{10}), (v_7v_{11}), (v_7v_{14}), (v_8v_{10}), (v_8v_{12}), (v_{10}v_{11}), (v_{10}v_{12}), (v_{10}v_{14}), (v_{11}v_{13}), (v_{11}v_{15}), (v_{12}v_{15}), (v_{13}v_{14}), (v_{14}v_{15})\} \quad (4.18)$$


Tablo 4.2' de SRC kümelerinin hangi değişkenleri içerdiği bilgisi yer almaktadır. Bir değişkenin bir SRC kümesine ait olması 1, ait olmaması 0 olarak belirtilmiştir. Örneğin v_3 değişkeni her üç kümede de mevcuttur. v_{15} değişkeni ise sadece SRC^0 kümesinde

mevcuttur. Benzer şekilde v_6 ve v_7 değişkenleri SRC^{-1} ve SRC^0 kümelerinde bulunmaktadır, SRC^{+1} kümesinde bulunmamaktadır. Değişkenlerin bu şekilde aitlik listesinin yazılması, hangi değişkenin problemin çözümüne ne kadar katkıda bulunduğunun tespit edilmesinde, dolayısıyla gereksiz değişkenlerin elenmesinde kullanılacaktır.

Tablo 4.2. Değişkenlerin ait oldukları SRC kümeleri [159].

	SRC^{-1}	SRC^0	SRC^{+1}	
v_1	0	1	1	
v_2	0	1	1	
v_3	1	1	1	*
v_4	1	1	1	*
v_5	1	1	1	*
v_6	0	1	1	
v_7	0	1	1	
v_8	1	1	0	
v_9	1	1	0	
v_{10}	0	1	0	
v_{11}	1	1	1	*
v_{12}	0	1	0	
v_{13}	1	1	1	*
v_{14}	1	1	1	*
v_{15}	0	1	0	

Tablo 4.2’deki değişkenlerin hangi kümeye ait oldukları bir Venn şeması yardımıyla gösterildiğinde, hangi değişkenlerin hangi kümelerde ortak hangilerinde mevcut olduğu daha açık bir biçimde görülmektedir. Bu da değişken seçimi ve değişken eleme işlemlerinde kolaylık sağlamaktadır. Şekil 4.6’da değişkenlerin hangi benzerlik kümelerinde yer aldığını gösteren şema verilmiştir.



Şekil 4.6. SRC Kümeleri [159].


4.7.7. Gereksiz ve İlgisiz Özniteliklerin Elenmesi

Algoritma uygulandığında gereksiz değişkenler listesi $RedundantVarList = \{V_3, V_4, V_5, V_{11}, V_{13}, V_{14}\}$ ve seçilmiş değişkenler listesi $SelectedVarList = \{V_1, V_2, V_6, V_7, V_8, V_9, V_{10}, V_{12}, V_{15}\}$ şeklinde olmuştur. *SelectedVarList* listesinin değişkenleri Agresif/Sakin sürüş algılama problemini çözmek için yeterlidir. Bir başka deyişle *RedundantVarList* listesindeki değişkenler olmasa bile sadece *SelectedVarList* listesindeki değişkenlerin işaret ettiği özniteliklerle sürücünün Agresif mi yoksa Sakin mi sürüş yaptığı tespit edilebilir.


RedundantVarList listesindeki değişkenler CAN bus ile eldilen *Absolute Throttle Position, In Manifold Pressure, O2 Sensor B1S1, Short Fuel Trim B1S2, Short Term Fuel Trim B1, Fuel Cost 2* öznitelikleridir. Burada elenenlerin arasında dikkat çekici olan öznitelik *Absolute Throttle Position* (Gaz Pedalı Pozisyonu)' dur. Gaz pedalı sürücülerin en sık kullandığı ve en çok alışık olduğu unsurlardan birisidir. Bu özneliğinin elenmesi etkisiz olduğundan değil, aynı etkiyi veren başka özniteliklerin bu özneliği kapsamassındandır, dolayısıyla elenenler listesinde yer almıştır.

4.7.8. Metodun Doğrulanması

Metodun doğrulanması, gereksiz ve ilgisiz değişkenler çıkarıldıktan sonra geriye kalan seçilmiş değişkenler kullanılarak gerçekleştirilen Agresif/Sakin sürüş durumu algılama performansı ile tüm 15 değişkenle yapılan Agresif/Sakin sürüş durumu algılama performansının karşılaştırılması işlemidir. Test işlemi çoklu lineer regresyon analizi kullanılarak gerçekleştirilmiştir. Problemin değişkenleri regresyon denkleminin değişkenleridir. Test işleminde 1 sayısal değeri Agresif sürüş durumunu ve 0 değeri de Sakin sürüş durumunu göstermektedir. Eğer test sonucu 1 veya 1' e çok yakın ise Agresif sürüş durumu; eğer 0 veya sıfıra çok yakınsa Sakin sürüş durumu sözkonusudur. Şekil 4.7 tüm özniteliklerin (15 tane) kullanılması ile elenen 6 öznitelik çıkarıldıktan sonra kalan seçilmiş öznitelikler (9 tane) kullanılarak ayrı ayrı Agresif sürüş durumu algılama performanlarını göstermektedir.




Şekil 4.7. Agresif sürüş tespiti için test işlemi (9 ve 15 değişken için) [159].



Şekil 4.8. Sakin sürüş tespiti için test işlemi (9 v 15 değişken için) [159].

Şekil 4.7’ de, düz çizgi SelectedVarList listesindeki, yani elenenler çıkarıldıktan sonraki (9 öznitelik) Agresif sürüş durumu algılama performansını göstermektedir. Kesikli çizgi ise tüm özniteliklerin kullanılması ile gerçekleşen Agresif sürüş durumu algılama performansını göstermektedir. Şekil 4.8’ de Sakin sürüş için hem tüm verilerin hem de elenen öznitelikler çıktıktan sonra kalanlarla, yani seçilmiş özniteliklerle olan performans

gösterilmektedir. Şekil 4.8’ de düz çizgi *SelectedVarList* listesindeki, yani elenenler çıkarıldıktan sonraki (9 öznitelik) Sakin sürüş durumu algılama performansını göstermektedir. Kesikli çizgi ise tüm özniteliklerin kullanılması ile gerçekleşen Sakin sürüş durumu algılama performansını göstermektedir. Şekil 4.9 (a) ve (b)’ deki histogramlarda Agresif ve Sakin sürüş durum algılama için test sonuçları gösterilmiştir.



Şekil 4.9. Agresif ve Sakin sürüşler için gereksiz değişkenler çıkarılmadan önce ve çıkarıldıktan sonra elde edilen performansların histogramı. (a) Sakin sürüş test sonuçları histogramı, (b) Agresif sürüş için test sonuçları histogramı [159].

Mavi çubuklar tüm değişkenlerle elde edilen sonuçları gösterirken, kırmızı çubuklar değişkenler elendikten sonra yapılan test sonuçlarını göstermektedir. Açıkça görülmektedir ki elenen değişkenler çıkarıldıktan sonra sadece seçilmiş değişkenlerle yapılan test sonuçları ile tüm değişkenlerle yapılan test sonuçlarındaki bant genişlikleri birbirine

benzerdir. Örneğin Şekil 4.9 (a) ve (b)' de hem tüm değişkenlerle yapılan test sonuçları hem de elenenler çıkarıldıktan sonra yapılan test sonuçları $[-0.4 +0.4]$ aralığındadır. Buna ilave olarak test sonuçlarının birbirine çok yakın sayılarda olduğu da görülmektedir. Örneğin Şekil 4.9 (b)' de 0.8 olan sonuçtaki her iki çubuk da $[30-40]$ aralığında miktarlara sahiptir. Buradan da anlaşılmaktadır ki elenen öznitelikler olamadan da elde edilen sonuçlar aynıdır. Bu yöntem ile 15 özniteliğin 6 tanesi, yani %40 gibi bir eleme miktarı elde edilmiştir. Sonuç olarak, bu problemde 15 özniteliğin çözdüğü problemi 9 tanesinin de çözebildiği ortaya çıkmıştır.

4.8. Öznitelik Seçim Algoritmasının Yol Profilini Algılama Problemine Uygulanması

4.8.1. Yol Profili Algılama Problemi

Yol profilini anlama problemi, seyir halinde iken aracın CAN-bus çıkışından alınan verilerle yolun düşey eğim tipini (Vertical Slope Type) bulma problemidir. Problemdeki hedef yolun yokuş mu yoksa iniş mi olduğunu algılamaktır. Bu problem, Agresif/Sakin sürüş durumunu algılamada geliştirilen öznitelik eleme yöntemi aynı şekilde uygulanabilir. Çünkü problem çözme yöntemi benzerdir. Yol profili algılama probleminde de CAN-bus verileri kullanılmaktadır ve birbiriyle aynı işi yapan gereksiz öznitelikler bu problemde de bulunabilir. Dolayısıyla, aslında bir tür özellik seçme olan bu yöntem özniteliklerden (attribute) veya özelliklerden (feature) faydalanılarak çözülen her problem için uygulanabilir.

4.8.2. Yol Profili Bulmada Kullanılan Metodun Adımları

Yöntemde kullanılan işlemler sırasıyla aşağıdaki adımları içermektedir:

Adım 1. Veri toplama ve özniteliklere değişken atama

Adım 2. Değişken çiftlerinin birbirleriyle ilişkilerinin hesaplanması

Adım 3. İlişkilerin korelasyon tiplerinin belirlenmesi

Adım 4. Benzer ilişki davranışlarının belirlenmesi

Adım 5. Benzerlik ilişkisi kümelerinin çıkarılması

Adım 6. Gereksiz ve ilgisiz özniteliklerin elenmesi

Adım 1. Veri Toplama ve Özniteliklere Değişken Atama: Veri toplamak için yaklaşık 6 km mesafelik ve eğimi yaklaşık 5-30 derece arası bir yolda test sürüşleri yapıldı. Güzergah, problem gereği iniş ve yokuşu olan bir yoldur. Bu yolda her test, farklı araç ve sürücülerle dörder tur atılarak yapılmıştır. Farklı araba ve sürücülerle çalışılmasının sebebi, verilerin sadece o araca veya sadece o sürücüye ait özelliklerle sonucu yanlış yönlendirmeye yol açmaması içindir. Test sürüşleri esnasında CAN bus çıkışları DynoScan Software kullanılarak hem yokuş hem de iniş için ayrı ayrı kaydedilerek test verileri elde edilmiştir.



Şekil 4.10. Test sürüşü güzergahı [158].

Şekil 4.10’ da bu problemde kullanılan güzergah verilmiştir. Tüm OBD II verileri toplandıktan sonra iyi bilinen 15 aday öznitelik seçilmiştir. Bu 15 öznitelik şunlardır:

RPM, Speed, Absolute Throttle Position, Calculated Load, Fuel Rate 2, Boost Pressure, In Manifold Pressure, Instant Economy 2, O2 Sensor BIS2, O2 Sensor BIS1, Short Fuel Trim BIS2, Ignition Timing Advance, Air Flow Rate for MAP, Short Term Fuel Trim B, and Fuel Cost 2.

Geliştirilen algoritma, bu özniteliklere uygulanarak varsa içlerinden gereksiz olanları eleyecektir. CAN-bus ile alınan özniteliklerin işleme sokulabilmesi için bir vektörün değişkenleri olarak atanması işlemi aşağıdaki gibi yapılmıştır:

$\vec{V} = [RPM, Speed, Absolute Throttle Position, Calculated Load, Fuel Rate 2, Boost Pressure, In Manifold Pressure, Instant Economy 2, O2 Sensor BIS2, O2 Sensor BIS1, Short Fuel Trim BIS2, Ignition Timing Advance, Air Flow Rate for MAP, Short Term Fuel Trim B1, Fuel Cost 2]$.

Sırasıyla her bir öznitelik $\vec{V} = [v_1, v_2, \dots, v_{15}]$ vektöründeki değişkenlere atanır.

Adım 2. Değişken Çiftlerinin Birbirleriyle İlişkilerinin Hesaplanması: Problemden matematiksel notasyonun kolaylığı açısından yukarı için *up*, aşağı için *down* değişkenleri kullanılacaktır. Artık *up*=rampa, *down*=inişli yol olarak düşünülecektir. Denklem 4.19 ve 4.20 sırasıyla *up* ve *down* için değişkenler arasındaki ilişkilerin hesaplandığı ve korelasyon katsayılarının yer aldığı matrislerdir.

$$R^{up} = \begin{matrix} & \begin{matrix} v_1 & v_2 & v_3 & \dots & v_{13} & v_{14} & v_{15} \end{matrix} \\ \begin{matrix} v_1 \\ v_{14} \end{matrix} & \begin{bmatrix} X & 0.70 & 0.54 & \dots & 0.68 & -0.19 & -0.40 \\ & \vdots & & \ddots & & \vdots & \\ -0.40 & -0.19 & 0.68 & \dots & 0.29 & -0.48 & -0.09 \end{bmatrix} \end{matrix}_{14 \times 15} \quad (4.19)$$

$$R^{down} = \begin{matrix} & \begin{matrix} v_1 & v_2 & v_3 & \dots & v_{13} & v_{14} & v_{15} \end{matrix} \\ \begin{matrix} v_1 \\ v_{14} \end{matrix} & \begin{bmatrix} X & 0.93 & -0.002 & \dots & 0.76 & -0.15 & 0.60 \\ & \vdots & & \ddots & & \vdots & \\ 0.60 & -0.15 & 0.76 & \dots & 0.19 & 0.43 & 0.28 \end{bmatrix} \end{matrix}_{14 \times 15} \quad (4.20)$$

Denklem 4.19 ve 4.20' deki matrisler $(v_i v_j)$ *up* ve *down* eğim için değişken çiftleri arasındaki korelasyon katsayılarını göstermektedir.

Adım 3. İlişkilerin Korelasyon Tiplerinin Belirlenmesi: Bu adımda korelasyon sınıflandırma için eşik değeri $T=0.35$ olarak seçilerek önceki adımda bulunan her korelasyon katsayısı değerinin Doğrudan Korele, Ters Korele, Korele Olmayan sınıflarından birinin etiketinin verilmesi işlemi yapılmıştır.

$$C^{up} = \begin{bmatrix} X & C^{+1} & C^{+1} & \dots & C^{+1} & C^0 & C^{-1} \\ C^{-1} & C^0 & C^{+1} & \dots & C^0 & C^{-1} & C^0 \end{bmatrix}_{14 \times 15} \quad (4.21)$$

$$C^{down} = \begin{bmatrix} X & C^{+1} & C^0 & \dots & C^{+1} & C^0 & C^{+1} \\ C^{+1} & C^0 & C^{+1} & \dots & C^0 & C^{+1} & C^0 \end{bmatrix}_{14 \times 15} \quad (4.22)$$

Denklem 4.21 ve 4.22 sırasıyla *Up* ve *Down* durumları için korelasyon katsayılarının ait oldukları korelasyon türü etiketleri verilmiştir.

Adım 4. Benzer İlişki Davranışlarının Belirlenmesi: Bu adımda *up* ve *down* durumları için ilişkilerin benzerlikleri değerlendirmeye alınarak benzerlik sınıflandırması yapılmıştır. Denklem 4.23’ de C^{up} ve C^{down} matrisleri eşleştirilerek oluşturulan Benzerlik İlişki Matrisi ($S^{Benzerlikilişkisi}$) yer almaktadır. Bu matris, $(v_i v_j)$ değişken çiftlerinin benzer ilişki davranışlarını içermektedir.

$$S^{Benzerlikilişkisi} = \begin{bmatrix} X & S^{+1} & NS & \dots & S^{+1} & S^0 & NS \\ & \vdots & & \ddots & & \vdots & \\ NS & S^0 & S^{+1} & \dots & S^0 & NS & S^0 \end{bmatrix}_{14 \times 15} \quad (4.23)$$

Adım 5. Benzerlik İlişkisi Kümelerinin Çıkarılması: $S^{Benzerlikilişkisi}$ matrisi vasıtasıyla, Doğrudan Korele Benzer İlişki Kümesi (*Directly Correlated Similar Relation Cluster - SRC⁺¹*), Ters Korele Benzer İlişki Kümesi (*Inversely Correlated Similar Relation Cluster - SRC⁻¹*) ve Korele olmayan İlişki Benzerlik Kümesi (*Uncorrelated Similar Relation Cluster - SRC⁰*) elde edilmiştir. Denklem 4.24, 4.25 ve 4.26 ‘da elde edilen SRC kümeleri verilmiştir. Bu kümelerdeki çiftler, aynı benzerlik davranışını gösteren öznelilik çiftleridir. Örneğin SRC⁺¹ kümesindeki $(v_1 v_5)$ çifti ile $(v_{11} v_{14})$ çifti aynı benzerlik ilişkine sahiptir. Aynı şekilde SRC⁰ kümesindeki $(v_4 v_8)$ çifti ile $(v_9 v_{11})$ değişken çifti aynı ilişki davranışına sahiptir.

$$SRC^{+1} = \{(v_1 v_2), (v_1 v_5), (v_1 v_{13}), (v_2 v_5), (v_2 v_{13}), (v_3 v_4), (v_3 v_6), (v_3 v_7), (v_3 v_{13}), (v_4 v_5), (v_4 v_6), (v_4 v_7), (v_4 v_{13}), (v_5 v_{13}), (v_6 v_7), (v_{11} v_{14})\} \quad (4.24)$$

$$SRC^{-1} = \{(v_3 v_8), (v_4 v_8), (v_5 v_8), (v_8 v_{13}), (v_9 v_{11}), (v_9 v_{14})\} \quad (4.25)$$

$$SRC^0 = \{(v_1v_8), (v_1v_{11}), (v_1v_{12}), (v_1v_{14}), (v_2v_8), (v_2v_{11}), (v_2v_{12}), (v_2v_{14}), (v_3v_9), (v_3v_{10}), (v_3v_{11}), (v_3v_{14})\} \quad (4.26)$$

Tablo 4.3. Değişkenlerin ait oldukları SRC kümeleri [158].

	SRC^{-1}	SRC^0	SRC^{+1}
v_1	1	0	1
v_2	1	0	1
v_3	1	1	1
v_4	1	1	0
v_5	1	1	0
v_6	1	0	0
v_7	1	0	0
v_8	0	1	1
v_9	0	1	1
v_{10}	0	0	0
v_{11}	1	1	1
v_{12}	0	0	1
v_{13}	1	1	0
v_{14}	1	1	1
v_{15}	0	0	0


Table 4.3’ de değişkenlerin ait oldukları SRC kümeleri gösterilmiştir. Eğer bir değişken o kümede mevcutsa 1, değilse 0 olarak geçmiştir.

Adım 6. Gereksiz ve ilgisiz özniteliklerin elenmesi: Algoritma uygulandığında gereksiz değişkenler listesi $RedundantVarList = \{v_3, v_{10}, v_{11}, v_{14}, v_{15}\}$ ve seçilmiş değişkenler listesi $SelectedVarList = \{v_1, v_2, v_4, v_5, v_6, v_7, v_8, v_9, v_{12}, v_{13}\}$ şeklinde bulunmuştur. *SelectedVarList* listesinin değişkenleri *up/down* sürüş algılama problemini çözmek için yeterlidir. Bir başka deyişle *RedundantVarList* listesindeki değişkenler olmasa bile sadece *SelectedVarList* listesindeki değişkenlerin işaret ettiği özniteliklerle yolun rampa mı iniş mi olduğu tespit edilebilir.

4.8.3. Metodun Doğrulanması


Metodun doğrulanması, gereksiz ve ilgisiz değişkenler çıkarıldıktan sonra geriye kalan seçilmiş değişkenler kullanılarak gerçekleştirilen *up/down* yol profilini algılama

performansı ile tüm 15 değişkenle yapılan *up/down* yol profilini algılama performansının karşılaştırılması işlemidir. Test işlemi çoklu lineer regresyon analizi kullanılarak gerçekleştirilmiştir. Problemin değişkenleri regresyon denkleminin değişkenleridir. Test işleminde sayısal değer 1 *up* yol profilini ve 0 değeri de *down* yol profilini göstermektedir. Eğer test sonucu 1 veya 1' e çok yakın ise *up* yol profili; eğer 0 veya sıfıra çok yakınsa *down* yol profili sözkonusudur. Şekil 4.11 tüm özniteliklerin (15 tane) kullanılması ile elenen 5 öznitelik çıkarıldıktan sonra kalan seçilmiş öznitelikler (10 tane) kullanılarak ayrı ayrı *up* yol durumu algılama performanlarını göstermektedir.




Şekil 4.11. 10 ve 15 değişken için *up* yol profili algılama testi [158].

Şekil 4.11' de, düz çizgi *SelectedVarList* listesindeki, yani elenenler çıkarıldıktan sonraki (10 öznitelik) *up* yol durumu algılama performansını göstermektedir. Kesikli çizgi ise tüm özniteliklerin kullanılması ile gerçekleşen *up* yol durumu algılama performansını göstermektedir. Şekil 4.12 *Down* yol için hem tüm verilerin hem de elenen öznitelikler çıktıktan sonra kalanlarla, yani seçilmiş özniteliklerle olan performansı göstermektedir. Şekil 4.12' de düz çizgi *SelectedVarList* listesindeki, yani elenenler çıkarıldıktan sonraki (10 öznitelik) *down* yol durumu algılama performansını göstermektedir. Kesikli çizgi ise tüm özniteliklerin kullanılması ile gerçekleşen *down* yol durumu algılama performansını göstermektedir.



Şekil 4.12. 10 ve 15 değişken için *down* yol profili algılama testi [158].

Şekil 4.13 (a) ve (b)' de yolun *up* olmasını algılama işleminde 5 gereksiz özneteliğin elenmesinden sonra kalan 10 özneteliğin performansı histogramlarla gösterilmiştir.




Şekil 4.13. *up* ve *down* durumları için gereksiz verilerin elenmesinden önce ve sonraki histogramlarla performans karşılaştırması. (a) *up* durumu için 15 değişken ile elde edilen test histogramının sonuçları, (b) *down* durumu için 15 değişken ile elde edilen test histogramının sonuçları, (c) Gereksiz 5 verinin elenmesinden sonra geriye kalan 10 veri ile *up* durumu için histogram, (d) Gereksiz 5 verinin elenmesinden sonra geriye kalan 10 veri ile *down* durumu için histogram [158].

Up durumunun tespit edilmesi 1 ile gösterilmektedir. 1' e yakın olan [0.6-1.4] aralığı *up* durumunun tespit edildiğini göstermektedir. Şekil 4.12 (a) ve (c)' de kesikli çizgilerle belirtilen bant genişliğinin aynı aralıklarda kalması, hem 15 hem de 10 değişkenli testlerde aynı sonuçların alındığını göstermektedir. Bir başka ifadeyle *up* durumu tespitinde, elenen 5 değişken olmasa da problem geri kalan 10 değişkenle de çözülebilmektedir. Buradan çıkarılacak sonuç, elenen 5 değişkenin doğru olduğudur. Problem çözümünün bu 5 değişkenden herhangi birine bağımlı olması durumunda bant genişliklerinin birbirine göre çok farklı aralıklarda olması beklenir. Benzer şekilde *down* için de aynı durum geçerlidir. *Down* durumu için 0 tanımı yapılmıştır. Şekil 4.12 (b) ve (d)' de 0' a yakın olanlar *down* durumunu göstermektedir ve bant genişliklerinin aynı aralıkta kaldığı görülmektedir.

5. ARKA VE ÖN KAMERA YOLUYLA ŞEHİRLERARASI YOL VİRAJLARININ GEOMETRİK BİLEŞENLERİNİ KULLANARAK OLASILIKSAL RİSK HESABI

Bu çalışmanın amacı yolun düşey eğim tipi, yönü ve keskinliği (bend curvature) gibi virajın ana bileşenlerini kullanarak uzun yol virajları ile ilgili dönüş riskinin tahminini yapmaktır. Ön ve arka kameralarla elde edilen resimler bahsi geçen viraj özelliklerini algılayabilmek için kullanılmaktadır. Yolun eğim tipini tespit etmek için hem ön hem de arkadan alınan görüntü gerekirken, yönü ve keskinliğini tespit edebilmek için sadece ön kamera yeterli olmaktadır. Problem çözümündeki yaklaşım; ufuk noktası, yol sınırları ve yol şeritleri gibi görsel ipuçları kullanan geometrik metotlara dayanmaktadır. Çalışmadaki son aşamada, virajın temel geometrik özelliklerinin algılanması sonucunda elde edilen bilgiler ile olasılıksal bir yöntem olan Bayes Bilgi Ağı kullanılarak risk hesabı yapılmaktadır. Bu çalışma özellikle uzun yolda yorgunluk, uykusuzluk veya tecrübesizlik gibi nedenlerle virajlara giriş hızlarını ayarlayamayan sürücüler için yapılmıştır ve otonom sürüş hedefinin önemli bir bölümü olan İSDS modelidir.

Şekil 5.1’ de şehirlerarası bir yoldaki viraj görüntüsü ve virajın temel geometrik özellikleri temsili olarak verilmiştir.




Şekil 5.1. Şehirlerarası bir viraj örneği ve parametreleri [179].

5.1. Metodun Teorisi ve Aşamaları

Güvenli sürüşü etkileyen ana faktörlerin bileşenleri bir yolun geometrik özellikleridir. Özellikle zorlu hava şartları altındaki yol şartları risklere sahiptir ve yolun geometrik yapısına bağlı olarak bu riskler daha da artabilir. Örneğin kaygan yolda yokuş aşağı sürüş yokuş yukarıya göre daha zordur ve risklidir. Üstelik yokuş aşağı yol virajlı olduğunda bu risk çok daha fazladır. Bu gerçek, yolun ana geometrik özellikleri üzerinde yoğunlaşılması gerektiğini ortaya koymaktadır. Dahası, bu özelliklerin biraraya gelerek oluşturdukları kombinasyonların oluşturdukları riskin olasılıksal hesabını da yapmak gerekmektedir.

Ön ve arka kameraların birbirinden bağımsız olarak aldığı görüntüler, yol özelliklerini bulmak için birlikte değerlendirilebilirler. Çoğu deneysel sistemler araç üzerinde haricen eklenmiş çoklu-bakış temelli olan pahalı donanım araçlarını içerir. Bu çalışmadaki yöntem ise yakın gelecekte araçlarda standart hale gelecek olan ön ve arka kameralarla elde edilen görüntüleri kullanmaya dayanmaktadır. Bu yaklaşım sistemin maliyeti üzerine olumsuz bir etkide bulunmayacağı gibi, aynı zamanda kullanıcı dostu da olacaktır. Geliştirilen yöntemin aşamaları Şekil 5.2’ de gösterilmiştir.




Şekil 5.2. Yöntemin Aşamaları [179].

Özellikle uzun yol sürücülerini için virajları alırken bir destek sistemi olması amaçlanan bu yöntemde viraj keskinliği, viraj yönü ve yol eğim tipi gibi temel geometrik ipuçları kullanılarak güvenli dönüşebilmesi için viraja girmeden önce bir risk hesabı yapılarak sürücünün uyarılması hedeflenmiştir. Aracın önündeki kameradan alınan görüntülerle sol veya sağ olacak olan virajın yönü ve virajın keskinliği tespit edilebilmektedir. Ancak,

yolun düşey eğim tipinin tespit edilebilmesi için öndeki kamera tek başına yetersiz kalmaktadır. Bu sebeple yol eğim tipinin tespit edilmesi için arkadaki kameradan alınan görüntülerin de ön kameradakilere beraber değerlendirilmeye alınması gerekmektedir. Çalışmada, viraja girmeden önce tespit edilen bu üç temel yol bileşeni kullanılarak virajın nasıl bir dönüş riskine sahip olduğunun hesabı Bayes Bilgi Ağı ile gerçekleştirilmiştir. Bayes Bilgi Ağı, parametre olarak aldığı bu yol bileşenlerini olasılıksal olarak değerlendirerek girilmek üzere olan virajın o andaki kaza riskini hesaplamaktadır.

5.2. Viraj Yönünün Tespit Edilmesi

Virajlar biçim olarak sola dönen, sağa dönen ve düz yol olarak sınıflandırılmaktadır. Viraj yönü güvenli dönüşte önemli rol oynamaktadır. Trafiğin sağdan ilerlediği ülkelerde sola dönen virajları almak sağa dönen virajları almaktan daha zordur. Çünkü virajın içten alınması daha güvenlidir. Virajın dönüş yönü, yol üzerindeki ufuk noktasının konumu tespit edildikten sonra basit bir şekilde elde edilebilir. Örneğin viraj ufuk noktası yol sahnesinin sağında ise viraj yönü sağa doğru, eğer sahnenin solundaysa viraj yönü sola doğrudur. X eksenini ile viraj ufuk noktası eksenini arasında kalan açı olan β açısı viraj yönünü tespit etmek için kullanılmaktadır. Şekil 5.3’ de sırasıyla sağ, düz ve sol yönlü viraj örnekleri ve β açısı gösterilmiştir.



Şekil 5.3. Viraj yönü türleri. (a) Sağ yönlü viraj, (b) Düz yol, (c) Sol yönlü viraj [179].

Şekil 5.3’ de görülen β açısı yönü belirleyicidir. Eğer β açısı dar açıysa, yani doksan dereceden küçükse viraj sağ yönlüdür. Eğer β açısı geniş açı ise yani $\beta > 90^0$ ise viraj sol yönlüdür. Eğer β açısı yaklaşık 90 derece ise yani $\beta \approx 90^0$ ise yol düzdür. Dolayısıyla bir viraj değildir. β açısından yola çıkılarak viraj yönünün tespit edilmesini sağlayan bu basit yaklaşım Denklem 5.1’ de verilmiştir.

$$\text{Viraj Yönü} = \begin{cases} \text{Sağ} & \beta < 90 \\ \text{Düz} & \beta \cong 90 \\ \text{Sol} & \beta > 90 \end{cases} \quad (5.1)$$

5.3. Virajın Keskinliğinin Tespit Edilmesi

Virajın keskinliği için iki parametre söz konusudur. Bu parametreler, başlangıç noktası olarak kabul edilen aracın ön bakış açısı noktasının viraj ufuk noktasına olan dik uzaklık mesafesi (r) ve başlangıç noktasından viraj ufuk noktası arasındaki mesafedir (h). Şekil 5.3’ de de gösterilen bu parametrelerin önemi aslında viraj keskinlik açısı olan α açısının cosinus bileşenleri olmasından kaynaklanmaktadır.

Şekil 5.3’ de O noktası kameranın görüş açısı (point of view) başlangıç noktasıdır. [OZ] doğrusu sürücünün bakış yönünü ve dolayısıyla aracın viraja girmeden önceki yönünü göstermektedir. $|Og|=h$ ve $|Od|=r$ olmak üzere $(gOd)=\alpha$ açısı viraj keskinlik açısıdır. Ayrıca, g noktası v_1 ve v_2 noktalarının ortasıdır. Eğer α açısı yaklaşık sıfır ise yol viraj değildir.


r ve h değerleri virajın keskinliği ile doğrudan ilişkilidir. Dolayısıyla Denklem 5.2’ de hesaplanması verilen α açısı virajın keskinliğini vermektedir.

$$\cos(\alpha) = \frac{r}{h} \Rightarrow \alpha = \arccos\left(\frac{r}{h}\right) \quad (5.2)$$

r mesafesinin h mesafesine oranı, α açısının cosinüsüdür. Dolayısıyla α açısı, r/h oranının arccos değeri alınarak bulunmaktadır. Bu bağıntıdan da anlaşılacağı üzere viraj geometrisinde birer parametre olan r ve h değerleri değiştikçe virajın keskinliği de değişecektir. Örneğin viraj ufuk noktasına olan dik uzaklık (r) ne kadar kısa olursa viraj

keskinliđi o kadar fazla, ne kadar uzunsa o kadar az olur. Aynı şekilde h mesafesinin de kısa olması virajı keskinleřtirmektedir.

řekil 5.4' de r ve h parametrelerinin hesaplanması için resim düzlemindeki görüntüleri verilmiřtir.



řekil 5.4. 3D' den 2D' ye dönüşüm [179].

$G(x,y,z)$ ve $D(x,y,z)$ noktaları resim düzlemi üzerinde sırasıyla $g(u_g, v_g)$ ve $d(u_d, v_d)$ noktalarına denk düşmektedir. O noktası optik merkezi ve f odak noktası mesafesidir (focal length). Denklem 5.3 ve 5.4' de Pinhole Kamera Modeline göre üçgen benzerliđi kullanılarak çıkarılmıř denklemler yer almaktadır.

$$\frac{f}{z_d} = \frac{u_d}{x_d} \Rightarrow z_d = \frac{fx_d}{u_d} \quad (5.3)$$

$$\frac{f}{z_g} = \frac{u_g}{x_g} \Rightarrow z_g = \frac{fx_g}{u_g} \quad (5.4)$$

5.4. Viraj Eğim Tipinin Tespit Edilmesi

Problem, yolun düşey eğim tipinin yokuş mu yoksa iniş mi olduğunun tespit edilmesidir. Virajın şerit ve kenarlarının geometrik davranışları, tek kamera kullanılması ile elde edilen görüntülerde hem yokuş için hem de iniş için aynı olabilmektedir. Dolayısıyla sadece ön kameranın kullanımı viraj eğim tipinin tespiti için yeterli bilgi vermemektedir. Bununla birlikte, eğim tipi tespitinin performansı ön ve arka kameranın birlikte kullanılması ile artabilmektedir. Şekil 5.5’ de iki viraj örneği gösterilmiştir. İki viraj da benzer geometrik özellikler göstermektedir. Ancak, bu iki virajın eğim tipleri birbirine zıttır. Dolayısıyla sadece ön kameradan alınan görüntüler yanıltıcı olabilmektedir.



Şekil 5.5. Sadece ön kamera kullanıldığı durumda benzer geometrik özelliklere sahip iniş ve yokuş eğim tipine sahip viraj örneği. (a) Eğim tipi iniş (downhill) olan viraj (b) Eğim tipi yokuş (uphill) olan viraj [179].

Şekil 5.5 (a) ve (b) sırasıyla iniş ve yokuşu vermektedir. İlk bakışta bu virajların tipleri, yani iniş mi yokuş mu oldukları algılanamayabilir. Hatta yokuş olan iniş, iniş olan da yokuş şeklinde ters algılanabilir. Görsel algı ilk bakışta Şekil 5.5 (a)’daki virajın yukarı doğru olduğu yönündedir. Ancak gerçekte Şekil 5.5 (a)’daki viraj iniş tipindedir. Dolayısıyla buradan, eğim tipi tespit edilirken sadece ön kameradan alınan bilgilerin Yanlış Pozitifleri arttırdığı anlaşılmaktadır.

Yanlış Pozitifleri azaltmak için arka kameranın da işleme katılarak iki kameranın bilgilerinin birlikte değerlendirilmeye alınması önemli ölçüde katkı sağlamaktadır. Şekil 5.6’da ön ve arka kamera ile alınan resim görüntüleri verilmiştir.



Şekil 5.6. Arka ve ön kameralardan alınan iniş/çıkış özelliklerine sahip virajlar. (a) İniş özelliğine sahip virajın ön kamera ile çekilmiş görüntüsü, (b) Yokuş özelliğine sahip virajın ön kamera ile çekilmiş görüntüsü, (c) İniş özelliğine sahip virajın arka kamera ile çekilmiş görüntüsü, (d) Yokuş özelliğine sahip virajın arka kamera ile çekilmiş görüntüsü [179].

Şekil 5.6 (a)' da görülen resim virajın ön kamera ile alınan görüntüsü ve Şekil 5.6 (c)' de görülen resim aynı virajın aynı noktadan arka kamera ile alınan görüntüsüdür. Benzer şekilde Şekil 5.6 (b)' de görülen resim bir başka virajın ön kamera ile alınan görüntüsü ve Şekil 5.6 (d)' de görülen resim bu virajın aynı noktadan arka kamera ile alınan görüntüsüdür. Şekil (a) ve (b)' deki düz çizgiler virajın ufuk noktası yani bitiş noktası ile yol kenarına teğet çizgidir. Kesikli çizgiler ise virajın iç kenarına teğet olan çizgidir. Aynı şekilde Şekil (a) ve (b)' deki düz çizgiler virajın ufuk noktası yani bitiş noktası ile yol kenarına teğet çizgidir. Kesikli çizgiler ise virajın iç kenarına teğet olan çizgilerdir. Düz ve kesikli çizgilerin oluşturdukları açı virajın olduğu ön kamera görüntüsünde (Şekil 5.6 (a) ve (b)) Viraj Açısı olarak adlandırılmıştır ve ϕ ile gösterilmiştir. Düz ve kesikli çizgilerin oluşturdukları açı, arka kamera görüntülerinde (Şekil 5.6 (c) ve (d)) Yol Ufuk Açısını

oluşturmaktadır ve Ψ ile gösterilmektedir. ϕ ve Ψ açıları, virajın aşağı yönde eğime mi yoksa yukarı yönde bir eğime mi sahip olduğu bilgisini basit bir yaklaşımla verebilmektedir. Eğer ϕ açısı Ψ açısından büyükse, bir başka deyişle ön kameradan alınan Viraj Açısı arka kameradan alınan Yol Ufuk Açısından büyükse bu viraj yukarı yönde eğimi olan bir virajdır. Eğer Viraj Açısı (ϕ), Yol Ufuk Açısı (Ψ)’ndan küçükse o zaman bu viraj aşağı yönde eğimli olan bir virajdır. Eğer ϕ ile Ψ açısı eşitse bu viraj düz bir yoldaki virajdır, yani ne iniştir ne yokuştur. ϕ ile Ψ açıları arasındaki bu ilişki Denklem 5.5’de verilmiştir:


$$\text{Viraj Eğim Tipi} = \begin{cases} \text{Yukarı} & \phi > \psi \\ \text{Aşağı} & \phi < \psi \\ \text{Düz} & \phi = \psi \end{cases} \quad (5.5)$$

Denklem 5.5’ e göre Şekil 5.6 (a) ve (c)’deki viraj yukarı yönde eğimi olan bir virajdır. Çünkü ön kameradan çekilen Viraj Açısı (ϕ) ‘nın arka kameradan çekilen Yol Ufuk Açısından (Ψ) büyük olduğu görülmektedir. Şekil 5.6 (b) ve (d)’de sırasıyla ön ve arka kameralardan alınan görüntülerde ise Viraj Açısı (ϕ) < Yol Ufuk Açısı (Ψ) olduğundan dolayı bu virajın aşağı inişli bir viraj olduğu anlaşılmaktadır. Bu çalışmada geliştirilen bu basit yaklaşım sayesinde zaten araçta var olan, ek bir maliyet gerektirmeyen ve yakın gelecekte tüm araçlarda zorunlu hale gelecek olan ön ve arka kamera görüntülerindeki bilgiler birleştirilerek aracın yokuş mu çıktığı yoksa inişte mi olduğu tespit edilebilmektedir. Bu sayede Yanlış Pozitifler azalmakta ve Doğru Pozitifler artarak viraj alma risk hesabında önemli bir parametre olan yol eğim tipi daha doğru oranda tespit edilmiş olmaktadır. Dolayısıyla aşağı inen bir virajın kaza riskinin yokuş yukarı olan viraja göre daha fazla olduğu çok açık olmasından dolayı eğim tipinin doğru tespiti, viraj alma risk hesabında hayati önem taşımaktadır.

5.5. Güvenli Viraj Almak için Viraja Girmeden önce Kaza Riskinin Hesaplanması


Özellikle uzun yol virajlarında ortaya çıkan kaza riski Viraj Yönü, Araç hızı, Viraj Keskinliği ve Viraj Eğim Tipi gibi parametrelere bağlıdır. Bu parametreler kullanılarak viraj alma esansındaki kaza riski Bayes Bilgi Ağı yoluyla viraja girmeden önce

hesaplanabilir. Bayes Bilgi Ağı her biri bir parametre olan olayların (Event) olasılıklarının birbiriyle ilişkilerinin kombinasyonlarının yarattığı olasılıkları hesaplar. Bir başka ifadeyle Bayes Bilgi Ağı mantığında, olayların tek başlarına bir çıkarımda bulunmak için yeterli olmadığı ve olayların biraraya geldiğinde daha anlamlı olduğu ve adeta yeni bir olay gibi yeni bir olasılık oluşturduğu düşünülmektedir. Çünkü gerçek dünyada olaylar birbirini sürekli etkiler. Bu çalışmadaki problemde viraj riskini etkileyen bir kaç parametre vardır ve hepsi de birbiriyle ilişkilidir. Örneğin, virajın keskinliği kaza riskini etkileyen bir faktördür, ama yokuş aşağı inen bir virajda bu risk çok çok daha fazladır. Üstelik aracın hızı da buna eklendiğinde risk katlanarak artmaktadır. Bayes Bilgi Ağı bu şekilde birden fazla olayı birlikte değerlendirmektedir. Şekil 5.7’ de bahsi geçen viraj risk parametrelerinin rol aldığı Bayes Bilgi Ağı taslağını oluşturan bir olasılık ilişki grafi verilmiştir.



Şekil 5.7. Bayes Bilgi Ağının Durum Akış Grafi [179].

G ve D düğümleri sırasıyla olasılıkları $p(g)$ ve $p(d)$ olan olaylardır. G olayı arazi durumunu gösterirken D olayı virajın yönünü gösterir. V, S ve N düğümleri olasılıkları sırasıyla $p(v|g)$, $p(s|g)$ ve $p(n|g)$ olan olayları gösterir. V, S ve N olaylarının olasılıkları G olayına bağlıdır. A olayı viraj alma riskini gösterir ve olasılığı V, S, N ve D olaylarına bağlıdır. Viraj yönü, viraj keskinliği ve eğim tipi gibi tüm parametrelerle birlikte araç hızının önemli rol oynaması sebebiyle hız parametresi de Bayes Ağ yapısına eklenmiştir. Böylece Bayes Anlam Ağı ile özellikle uzun yol sürücüleri için farklı viraj şartları için bir risk modeli oluşturulmuştur. Şekil 5.8’ de bu model görülmektedir.



Şekil 5.8. Bayes Bilgi Ağının yapılandırılması [179].

G ve D ana (parent) düğümlerdir. V, S, N ve A düğümleri alt (child) düğümlerdir. G olayı için g_1 =düz ve g_2 =dağlık durumlarının olasılıkları sırasıyla $p(g_1)$ ve $p(g_2)$ ile ifade edilmektedir. Arazinin Türkiye şartlarında dağlık olma olasılığı daha fazla olduğu kabulünden dolayı $p(g_2)=0.6$ ve düz olma olasılığı da $p(g_1)=0.4$ olarak belirlenmiştir. Bayes Ağında G ana düğümüne ait üç alt düğüm mevcuttur. Bu düğümler arazi şartlarına bağlı olarak olasılıkları değişebilen araç hızı, viraj eğim tipi ve viraj keskinliğidir. Bu ana ve alt düğümlerdeki olayların olasılığı hesaplanırken, örneğin dağlık bir arazide aracın hızının yüksek veya düşük olma olasılığı, dağlık arazide eğimin yukarı veya aşağı olma olasılığı ve dağlık arazide viraj keskinliğinin düşük mü yüksek mi olduğu şeklinde

değerlendirme yapılır. Dolayısıyla v_2 =yüksek durumunun olma olasılığı $p(v_2|g)$ şeklinde ifade edilmektedir. $p(v_2|g)$ ' nin anlamı g durumunun gerçekleşmesi halinde v_2 durumunun olma olasılığıdır. Örneğin, g_2 =dağlık durumunun olması halinde aracın hızının düşük (v_1 =düşük) olma olasılığı $p(v_1|g_2)=0.7$ ' dir. Benzer şekilde g_2 olması durumunda hızın v_2 =yüksek olması olasılığı $p(v_2|g_2)=0.4$ ' dür. G ana düğümü ile S ve N düğümleri V ile olduğu gibi benzer şekilde hesaplanmaktadır. Bunlara bağlı olarak A düğümü V , S N ve D düğümlerinin alt düğümüdür. Bunun anlamı, A düğümündeki olayın olma olasılığı V , S N ve D düğümlerindeki olayların olma olasılıklarına bağlıdır. Örneğin dağlık bir arazide (g_2 =dağlık), bir aracın yüksek hızda gitmesi (v_2 =yüksek), virajın yukarı eğimli olması (s_1 =yukarı), virajın keskinliğinin fazla olması (n_2 =yüksek) durumlarında ve virajın sol yönlü olması (d_1 =sol) durumunda viraj alma riskinin yüksek olma olasılığı (a_2 =yüksek-risk) nedir sorusu $p(a_2|d_1, v_2, s_1, n_2)=?$ şeklinde ifade edilir. Bu örnek risk hesabı, aşağıdaki gibi yapılmaktadır:

$$\begin{aligned}\text{Virajın kaza riskinin yüksek olma olasılığı} &= p(d_1)p(v_2|g_2)p(s_1|g_2)p(n_2|g_2)p(a_2|d_1, v_2, s_1, n_2) \\ &= (0.5) \cdot (0.4) \cdot (0.5) \cdot (0.7) \cdot (0.5) \\ &= 0.035\end{aligned}$$

5.6. Deneysel Sonuçlar

Virajın kaza riskini hesaplama metodunun aşamaları aşağıda adım adım verilmiştir. Burada Adım 1, Adım 2 ve Adım 3' deki sonuçlar Adım 4' deki Bayes Bilgi Ağı yoluyla risk hesabı yapmakta kullanılmaktadır.

Adım 1: Viraj Yönünü Tespit Etmek


Adım 2: Viraj Keskinliğinin Hesabı

Adım 3: Viraj Eğim Tipinin Tespit Edilmesi

Adım 4: Virajın Kaza Riskinin Hesaplanması

Adım 1. Viraj Yönünün Tespit Edilmesi: Deneyler her biri 24 veri içeren dört set üzerinde yapılmıştır. Örnek viraj görüntüleri Elazığ-Harput mevkiinden alınmıştır. Harput beldesine çıkış ve iniş yolundaki virajlar hem iniş/çıkış, hem az-keskin/çok-keskin özelliklere sahip olan test verileri için uygun virajlar içermektedir.

Şekil 5.9’ da viraj görüntülerinden birisi verilmiştir. Metodun çalışmasında viraj ufuk noktası, virajın gidiş yönü için referans noktası olarak kabul edilmiştir. Şekil 5.9’ da ön kameradan elde edilen ve viraj yönü parametrelerini içeren resim verilmiştir. Burada G noktası virajın resimde gözden kaybolduğu viraj ufuk noktasıdır.



Şekil 5.9. Elazığ-Harput yolunda sağa dönen bir viraj [179].


Şekil 5.9’ da görüldüğü gibi viraj yönü, [OG] doğrusu ile yatay eksen arasındaki açı doksan dereceden küçük ($\beta < 90$) olduğu için sağ yöndedir. β açısı birim çemberin bir açısı olarak düşünülebilir.

Tablo 5.1. Farklı veri setleri için viraj yönünün tespit edilmesi sonuçları

VeriSeti 1	VeriSeti 2	VeriSeti 3	VeriSeti 4
240	240	240	240
0.000 (%)	0.000 (%)	0.000 (%)	0.000 (%)
Tüm Veri Setleri için Yanlış Sonuç Ortalaması Oranı: % 0.000			


Her bir set 24’ er örnek veri içermektedir. Bu adımda virajın yönünü tespit etmede ortalama başarı oranı %100 ve dolayısıyla yanlış çıkan sonuç oranı %0 şeklindedir.

Adım 2. Viraj Keskinliğinin Hesabı: Burada virajdaki r ve h parametreleri virajın keskinliğini bulmak için kullanılmıştır. Şekil 5.10’ da sağ yönlü viraj için yol parametreleri α , r , h , ve m olarak verilmiştir.



Şekil 5.10. Viraj parametreleri [179].

Şekil 5.10’ da verilen parametrelerin dünya koordinat sistemindeki karşı düşen değerler, daha önce Şekil 5.4’ de verilen kamera parametreleri ve dönüşümler kullanılarak hesaplanmıştır. Şekil 5.11’ de viraj görüntülerinden hesaplanmış r ve h değerleri ve bu değerler için hesaplanmış keskinlik açı değerleri verilmiştir. Bu değerler 24 örnekli bir veri seti için verilmiştir.




Şekil 5.11. Viraj görüntülerinden elde edilen keskinlik değerleri [179].

Burada α açısı, r ve h parametreleri sırasıyla kameranın merkezi (O) ile viraj ufuk noktasına (G) olan dik uzaklığın merkezden direk ufuk noktasına olan mesafesine oranının


ters kosinüsü ile hesaplanmıştır. α açısı ne kadar büyükse keskinlik değeri de o kadar büyük demektir. Şekil 5.11’ deki grafikten de görüldüğü üzere r değeri küçük h değeri yüksek ise keskinlik (α) artmaktadır. Her iki değer de yüksek olduğu yerde keskinlik azalmaktadır. Her iki değer de küçük olduğu yerde ise keskinlik artmaktadır.

Adım 3. Viraj Eğim Tipinin Tespit Edilmesi: Virajın eğim tipini tespit etmede ilk olarak ufuk noktası viraj açısı ve yol sınırlarının tespit edilmesi çok önemlidir. Çünkü virajın aşağı mı yoksa yukarı doğru mu olduğu bu parametrelerden anlaşılmaktadır. Şekil 5.12’ de arka ve ön kameralardan elde edilen görüntüler yer almaktadır. Buradaki kural hatırlanacağı üzere, eğer viraj açısı yol ufuk açısından daha büyükse viraj yokuş çıkan bir virajdır, yol ufuk açısı daha büyükse inişte olan bir virajdır.



Şekil 5.12. Arka ve ön kamera görüntüleri ile yolun eğim tipinin tespiti [179].

Şekil 5.13’ de ise sadece ön kameranın kullanıldığı durumlarda yapılan eğim tipi tespiti ile hem ön hem arka kameranın kullanıldığı zaman elde edilen eğim tipi tespiti sonuçları, ROC eğrileri ile verilmiştir.



Şekil 5.13. ROC eğrileri. Sadece ön kamera kullanıldığında ve her iki kamera birlikte kullanıldığında elde edilen eğim tipi tespiti doğruluk oranı [179].

Kırmızı eğri sadece ön kamera kullanıldığında elde edilen doğruluk oranını temsil etmektedir. Yeşil eğri ise yolun eğim tipinin tespitinde hem ön hem arka kamera ile birlikte kullanıldığında elde edilen doğruluk oranını göstermektedir. Açık bir biçimde görülmektedir ki her iki kamera kullanıldığında elde edilen doğruluk oranı tek kamera kullanıldığı duruma göre çok daha fazla başarılıdır. Çünkü iki kamera ile Doğru Pozitiflerin sayısı diğerine göre daha fazladır. Ayrıca eğrinin (0,1) noktasına yaklaşması da doğruluk oranının arttığını göstermektedir.

Tablo. 5.2. Farklı veri setleri için eğim tiplerinin tespit edilmesi sonuçları [179].


Veri Seti 1 Veri Seti 2 Veri Seti 3 Veri Seti 4	Yukarı Sol Viraj		Yukarı Sağ Viraj		Aşağı Sol Viraj		Aşağı Sağ Viraj	
	True	False	True	False	True	False	True	False
	6	0	5	1	5	1	5	1
	VeriSeti 1' in ortalama başarı oranı (%): 87.50							
	5	1	6	0	5	1	5	1
	VeriSeti 2' nin ortalama başarı oranı (%): 87.50							
	6	0	6	0	6	0	5	1
	VeriSeti 3' ün ortalama başarı oranı (%): 95.83							
	6	0	6	0	5	1	5	1
	VeriSeti 4' ün ortalama başarı oranı (%): 91.67							
	Tüm veri setlerinin başarı ortalaması (%): 90.62							

Tablo 5.2' de, farklı veri setlere ait viraj eğim tiplerini tespit etme testi sonuçları verilmiştir. Veri setlerinin her biri 24 örnekten oluşmaktadır. Test yapılırken her bir veri seti yukarı sol viraj, yukarı sağ viraj, aşağı sol viraj ve aşağı sağ viraj olmak üzere dört farklı gruba ayrılmıştır.

Veri Seti 3 ve Veri Seti 4, Veri Seti 1 ve Veri Seti 2' ye göre daha dağlık bir bölgeden alınmış örneklerdir. Yapılan testlerde, önerilen yöntemin dağlık bölgede daha başarılı olduğu görülmektedir.

Dağlık arazilerde eğim daha yüksek olduğundan, yöntemin temelini oluşturan ön ve arka kameralarda yakalanan açı farkları düz arazilerdekine göre daha yüksektir. Bu da


algılama işlemindeki başarıyı arttırmaktadır. Eğitim arttıkça eğitim tipini tespit etme başarısı da artmaktadır. Şekil 5.14’ de bir Veri Setine ait resimler verilmiştir.



Şekil 5.14. Yol eğim tipinin tespit edilmesi ile ilgili ön ve arka kameradan alınan görüntülerden oluşan örnek bir veri seti [179].

Burada, *rear* ile belirtilenler arka, *front* ile belirtilenler ön kameradan çekilen görüntülerdir. Örneğin ilk satırdaki ilk iki resim, yukarı çıkan bir virajın sırasıyla arka ve ön kameradan alınan görüntüleridir. Bu şekilde arka-ön kamera görüntüsü çiftlerinin oluşturduğu 24 çift resim bir veri setini oluşturmaktadır.

Step 4. Virajın Kaza Riskinin Hesaplanması: Şekil 5.15’ de Adım 1, 2 ve 3’ de tespit edilen veya hesaplanan parametreler kullanılarak ve daha önce belirtilen Bayes Bilgi Ağı şeklinde oluşturulmuş yapı kullanılarak gerçekleştirilmiş risk hesabının grafik şeklinde gösterimi yer almaktadır.



Şekil 5.15. Verisetlerinin her biri için risk hesabı test sonuçları [179].

Burada her biri 24 resim çiftinden oluşan dört veri seti mevcuttur. Sonuçlardaki kaza risk oranı % cinsinden ölçeklenerek verilmiştir. Sonuçlara bakıldığında, Veri Seti 3’ deki virajların en riskli viraj grubu olarak göze çarptığı görülmektedir. Bununla birlikte sonuçlara göre, Veri Seti 1’ deki viraj seti en az kaza riski olan virajlardan oluşmaktadır.

6. TRAFİK SAHNE ANALİZİ İÇİN GRAF-KESME TABANLI BÖLGESEL RİSK HESAPLAMA

Otonom araç uygulamalarının çoğu, yüksek risk taşıyan nesnelerin olduğu şehiriçi caddeler yerine şehirlerarası otoyollar üzerinde gerçekleştirilmiştir. Son on yılda insansız araçlara yönelik çalışmalar oldukça dikkat çekicidir. Araştırmacılar sadece trafik üzerindeki hareketsiz nesneleri değil, aynı zamanda sürücünün görüş alanındaki dinamik unsurları da düşünmektedirler. Çalışmaların çoğunda otomotiv teknolojisinin mevcut durumda büyük bir başarıyla gerçekleştirebildiği yaya, araçlar, trafik ışıkları veya trafik işaretleri gibi trafikteki unsurların tespit edilmesi, algılanması gibi işlemleri içermektedir [217, 218]. Dolayısıyla bu işlemler çoğunlukla düşük-seviye bilgisayarlı görme uygulamalarından, yani trafik sahnesindeki olayları anlama kavramını düşünmeden sadece resim, görüntü veya video verilerindeki işaret işlemeye dayanan tanıma işlemlerinden ibarettir. Teknolojinin hızla gelişmesiyle yüksek-seviye içerikli bilginin çıkarılması ve sürüşün gerçekleştiği yol ve çevresindeki stratejilerin değerlendirilip yorumlanması bir ihtiyaç olmuştur. Yakın gelecekte, birbiriyle haberleşen akıllı araçların yaygınlaşacağı ortamlarda araçların bilgi paylaşımı yapabilmesi için trafik unsurlarının yorumlanıp diğer araçların bilgilendirmesi büyük önem kazanacaktır. Bu durumda graf-tabanlı metodlar özellikle dinamik trafik unsurlarının yer aldığı yollardaki durumun tanımlanıp yorumlanması işleminde yararlı olacaktır. Bu düşünce, gelişen sosyal olaylarla ilgili sosyal hesap yapmanın bir türüdür. Dolayısıyla trafikte bulunan her potansiyel unsur bir futbol oyunundaki oyuncu gibi düşünülebilir ve trafikteki rolüne göre değerlendirilmeye alınabilir. Çalışmada kullanılan graf metodu, trafik sahnesini ve dolayısıyla oyuncuları bölümlere ayırarak oyuncuların hareketlerini daha da iyi tanımlayıp onların yarattığı potansiyel risklerin konumunun daha iyi belirlenmesini sağlamaktadır.

Bu çalışmada sürücülere yardımcı olması için yaya, araçlar, trafik ışıkları, trafik işaretleri ve yaya geçidi gibi farklı trafik unsurlarını içeren trafik sahnesine sahip bir caddenin bölgesel risk hesabı yapılmıştır. Trafik sahnesi üzerine odaklanmış birçok çalışmada genelde sadece hareketsiz unsurların tespiti ve algılanması düşünülürken, bu çalışmada trafik sahnesindeki oyuncuların dinamik hareketleri ve etkileri de hesaba katılmıştır. Geliştirilen yöntemde farklı potansiyel riskleri taşıyan trafik sahnesi unsurlarının bölüm bölüm ele alınmasını sağlayan bir satranç tahtası biçiminde bölmeleme tasarlanmıştır. Bu tasarımdaki her kare bir ya da birden fazla oyuncu içerebilir. Bununla

birlikte, her bir bölüm farklı risklere sahip olabilir. Önerilen model, bölmelenmiş trafik sahnesinin enerji minimizasyonunu iyi bilinen Graf-Kesme (Graph-Cut) algoritması [219] ile gerçekleştirerek her bir bölüm (partition) ve bölümlerin biraraya gelmesi ile oluşan bölgelerin (region) risk hesaplarını yapmaktadır. Bu yöntemde trafik sahnesi bir graf olarak temsil edilecek ve her bir bölüm grafın bir düğümü olarak düşünülecektir. Her biri birer graf düğümü olan bölümlerdeki hareket edebilen oyunculardan kaynaklanan risk transferleri de hesap edilebilecektir. Burada düğümler birer bellek hücresi gibi davranış gösterecek şekilde tasarlanmıştır. Bu bellek hücreleri düğümler arasındaki, yani bölümler arasındaki risk geçişleri bilgilerini içermektedir. Her trafik sahnesi bölümünün bir komşu bölüme yapabileceği risk transferinin önceden bilinmesi, potansiyel risk kavramını ortaya çıkarmaktadır. Örneğin bir bölümdeki yaya yer değiştirebilen bir oyuncudur ve komşu bölümlere geçiş yapabilir. Dolayısıyla bu yaya, komşu bölümler için bir potansiyel risk taşıyan unsurdur. Bu özellik, metodun risk tahmini yapabilmesini ve o sahneden geçen sürücü için daha güvenli bir uyarı sistemi geliştirilmesini sağlar. Yöntemde hem lokal riskler hem de komşu bölümlerden gelebilecek muhtemel potansiyel riskler hesaba katılarak bölümler ve bölümlerden oluşan bölgelerden hangisinin ya da hangilerinin yüksek riskte olduğu Graf-Kesme algoritması ile araştırılmıştır. Hangi bölgeler yüksek risk taşıyorsa sürücüye o bölge için uyarı verilmesi tasarlanmıştır.


6.1. Metodun Teorisi ve Aşamaları

Sürücüler için bir trafik sahnesindeki oyuncuların sebep olabileceği risk miktarı üzerinde üç faktör etkilidir:

1. Oyuncunun türü: Yaya, Trafik İşareti, Trafik Işığı, Yaya Geçidi ve Araçlar
2. Oyuncunun konumu: Oyuncunun kaldırımda olması, yol üzerinde olması
3. Oyuncunun sürücünün aracına olan mesafesi: Seviye 1, Seviye 2, Seviye 3

Geliştirilen yaklaşım bu üç faktör düşünülerek her bir oyuncuya bir ağırlık verilerek bölgesel bir hesap yapmaktadır. Ağırlıklar oyuncunun hareketli olması durumunda dinamik olarak değişebilmektedir. Cadde, her biri bir hücre olarak düşünülen bölümlere ayrılmaktadır. Bu hücreler trafik sahnesinin bir grafa dönüştürülerek risk hesabının daha

basit bir şekilde yapılmasını sağlamak için kullanılmaktadır. Geliştirilen yöntemin adımları Şekil 6.1’ de gösterilmiştir.



Şekil 6.1. Metodun aşamaları [177, 178].

Buradaki nihai hedef bir trafik sahnesinin en riskli bölgesinin tespit edilmesidir. Bu hedef gerçekte cadde üzerindeki unsurların sebep olduğu risk için bir optimizasyon problemidir. Bu çalışmada bu problem Graf-Kesme ile enerji minimizasyonu yoluyla çözülmeye çalışılmıştır.

Yöntem üç ana bölümden oluşmaktadır. İlk önce trafik sahnesi, oyuncuların ağırlıklarının hesaplanabilmesi için bölümlere ayrılmıştır. Oyuncuların ağırlıklarının ve potansiyel risklerinin hesaplanmasının ardından ikinci bölümde sahne her bir bölümü bir hücre (düğüm) olacak şekilde bir grafa dönüştürülmektedir. Her bir graf düğümünün, yani sahne bölümünün kendi riski hesaplanmaktadır. Bunun yanı sıra komşu bölümlerden

gelebilecek hareketli oyuncuların kaynaklanan potansiyel risk transferleri de hesaplanarak tüm bölümlerin ayrı ayrı toplam riskleri hesaplanmaktadır. Son aşamada ise sahnedeki riskli bölgeler, hücre ve kenarların risklerini içeren Garaf-Kesme tabanlı risk minimizasyonu ile hesaplanmaktadır.

6.2. Trafik Sahnesi Tasarımı

6.2.1. Trafik Sahnesinin Bölümlere Ayrılması

Şehir içindeki bir cadde genel olarak kaldırım ve yoldan oluşur. Şekil 6.2’ de bir kaldırım, yol ve trafik unsurlarının yer aldığı bir cadde taslağı ve örneği verilmiştir.



Şekil 6.2. Basit bir trafik sahnesi [177, 178].

Bir trafik sahnesinde yer alan oyuncular sürücü için sahnenin farklı bölümlerinde farklı risk ağırlıklarına sahiptir. Dolayısıyla oyuncuların risk ağırlıklarını hesaplamak için sahne bölümlere ayrılmalıdır. Sahnenin bölümlere ayrılması işlemine iki açıdan bakılabilir:

1. Sahnenin kaldırım ve yol bölümleri
2. Sürücüye göre sahnenin uzaklık seviyeleri

İlk kriterde kaldırımdaki trafik unsurları ile daha aktif bir bölge olan yoldaki unsurların birbirinden ayrılması amaçlanmıştır. İkinci kriterde ise sahnedeki trafik unsurlarının sürücüye olan uzaklıklarının farklı riskler oluşturacağı fikriyle hareket edilerek sahne uzaklık olarak seviyelere ayrılmıştır.

Şekil 6.3’ de bu iki kritere göre bir yolun bölümlere ayrılması gösterilmiştir. Çalışmada model alınan caddenin iki kaldırım ve bir yoldan oluştuğu ve uzaklık mesafesinin üç seviye olduğu kabul edilmiştir.

	Seviye 1	Seviye 2	Seviye 3
A	Bölüm A^1	Bölüm A^2	Bölüm A^3
B	Bölüm B^1	Bölüm B^2	Bölüm B^3
C	Bölüm C^1	Bölüm C^2	Bölüm C^3

Şekil 6.3. Bölümlere ayrılmış bir trafik sahne taslağı [177, 178].

Burada A ve C kaldırımların bölüm tiplerini, B ise yolun bölüm tiplerini temsil etmektedir. Aynı şekilde Seviye 1, Seviye 2 ve Seviye 3 ise sahnenin yol boyunca sürücüyeye olan mesafe derecelerini temsil etmektedir. Seviye 1 sürücüyeye en yakın, yani sahnenin girişi ve Seviye 3 de sürücüyeye göre en uzak mesafeli olandır. Yatay ve dikey olarak yukarıdaki gibi bölümlere ayrılan sahne bir ızgara görünümündedir. Her bir hücre, bölüm tipi ve seviye numarası kullanılarak etiketlenmiştir. Örneğin A^1 bölümü A tipinde (kaldırım) ve Seviye 1 mesafesinde bir bölümdür. Benzer şekilde B^2 bölümü B tipinde (yol) ve mesafesi Seviye 2’ de olan bir bölümdür. Sonuç olarak trafik sahnesi $A=\{A^1, A^2, A^3\}$, $B=\{B^1, B^2, B^3\}$ ve $C=\{C^1, C^2, C^3\}$ olarak bölümlere ayrılmıştır. Burada A ve C kaldırımı belirten aynı türden bölümler, B ise onlardan farklı olarak yolu göstermektedir.

6.2.2. Bölümlerdeki Oyuncu Kümelerinin Tanımlanması

Çalışmada kullanılan trafik sahnesi oyuncuları Tablo 6.1’ de verilmiştir. Yaklaşımın daha basit ve açık olabilmesi için oyuncular sıradan bir caddede görülen en çok bilinen oyuncularla sınırlandırılmıştır. Bununla birlikte sistem ölçeklenebilir şekilde tasarlandığı için sonradan başka oyuncular da dahil edilebilir. Çalışmada trafik sahnesindeki oyuncular

kümesi $Y = \{y_1, y_2, \dots, y_i, \dots, y_n\}$ şeklinde tanımlanmıştır. Buradaki y_i oyuncuları temsil etmektedir. Bu çalışmada tanımlanan oyuncular ise $Y=\{P, H, S, L, K\}$ şeklindedir.


Buradaki notasyon tüm çalışmada $P \rightarrow$ Yaya (Pedestrian), $H \rightarrow$ Araç (Vehicle), $S \rightarrow$ Trafik İşareti (Traffic Sign), $L \rightarrow$ Trafik Işığı (Traffic Light) ve $K \rightarrow$ Yaya Geçidi (Crosswalk) şeklinde tanımlanmıştır.

Oyuncular hareketli ve hareketsiz olarak sınıflandırılmıştır. Hareketli olan P (Yaya) ve H (Araç) oyuncuları bulunduğu bölümden bir başka komşu bölüme geçebilir. Bu geçişi araçlar sadece yol boyunca yapabilirken yayalar hem kaldırım hem de yola geçiş yapabilen en hareketli özelliğe sahip oyuncudur. Örneğin bir araba sadece B tipi bölümler arasında geçiş yapabilir. A^2 'de bulunan bir yaya ise hem A^1 ve A^3 bölümlerine geçebilir hem de B^2 bölümüne geçebilir. Hareketsiz olan S (İşaret), L (Işık) ve K (Yaya Geçidi) ise sabit nesneler olduğundan dolayı bir başka bölüme geçemezler.

Tablo 6.1. Çalışmada tanımlanmış olan trafik sahnesi oyuncuları [177, 178].

Trafik Sahnesi Oyuncuları (Y)			Hangi oyuncu hangi bölümde bulunabilir?
Hareketli Oyuncular		Yaya (Pedestrian) - P	A, B, C tipi bölümlerde bulunabilir
		Araç (Vehicle) - H	Sadece B tipi bölümlerde bulunabilir
Hareketsiz Oyuncular		Trafik İşaretleri (Traffic Sign) - S	A ve C tipi bölümlerde bulunabilir
		Trafik Işıkları (Traffic Light) - L	
		Yaya Geçidi (Crosswalk) - K	Sadece B tipi bölümlerde bulunabilir

Tablo 6.1 aynı zamanda oyuncuların yer alabileceği bölüm tiplerini de vermektedir. Örneğin H ve K oyuncularını sadece B tipi bölümlerde olabilir çünkü araç ve yaya geçitleri sadece yolda bulunabilir. S ve L oyuncularını ise A ve C tipi bölümlerde yer alabilir. Çünkü trafik ışığı ve işaretleri yolun dışındadır. Yaya olan P oyuncusu ise tüm bölümlere gidebilmektedir. Çünkü yayalar çoğunlukla kaldırımlarda bulunsalar da karşıdan karşıya geçmek için yola da girebilirler. Bu durumlar Şekil 6.4’ de hangi bölümde hangi oyuncuların yer alabileceği şeklinde verilmiştir.



Şekil 6.4. Bölümlerde hangi oyuncuların bulunabildiğini gösteren bölümlere ayrılmış sahne taslağı. Burada komşular arasındaki risk transferi de oklarla gösterilmiştir [177, 178].

Burada her bir sahne bölümünün içerebildiği oyuncu kümeleri ayrı ayrı belirtilecek olursa, $Y^A = Y^C = \{P \rightarrow \text{Yaya}, S \rightarrow \text{Trafik İşareti}, L \rightarrow \text{Trafik Işığı}\}$ oyuncu kümelerine sahip oldukları görülmektedir. B bölümlerinde bulunabilen oyuncu listesi ise $Y^B = \{H \rightarrow \text{Araç}, P \rightarrow \text{Yaya}, K \rightarrow \text{Yaya geçisi}\}$ şeklinde yazılabilir.


Buna ilave olarak Şekil 6.4’ deki oklar hareketli oyuncuların komşu bölümlere geçebilmesini temsil etmektedir.

6.3. Grafın Yapılandırılması

6.3.1. Sahne-Graf Dönüşümü

Bu aşamada, trafik sahnesindeki bölümler için risk miktarının hesaplanmasını kolaylaştırmak amacıyla sahne, graf şeklinde yapılandırılmıştır. Bilindiği gibi graflar

düğümlerden (vertex) ve kenarlardan (edge) oluşan yapılardır. Bölmelere ayrılmış trafik sahnesi aslında bir graf yapısına sahiptir. Her bir sahne bölümü bir graf hücresi gibi, bölümler arasındaki risk transferleri de graf kenarları gibi düşünülebilir. Dolayısıyla bölümlere ayrılarak incelenecek olan trafik sahnesinin iyi bilinen bir başka yapıya dönüştürülmesi, sahne üzerinde herhangi bir hesap yapabilme veya sahne üzerinde risk hesaplama işlemlerinde oldukça kolaylık sağlayacaktır. Çünkü grafların çalışma biçimi ve yapısı ile ilgili iyi bilinen birçok yöntem mevcuttur [220, 221]. Örneğin bu çalışmada Graf-Kesme metodu [222] tercih edilerek bölgesel risk hesaplama yapılmıştır. Şekil 6.5’ de sahne-graf dönüşümünün nasıl yapıldığı gösterilmiştir.



Şekil 6.5. Trafik sahnesinden grafa dönüşüm. Her bir sahne bölümü grafın bir hücresine, risk transferleri de grafın kenarlarına denk gelmektedir [177, 178].


Graflar, V düğüm ve E kenar olmak üzere iyi bilinen ifadeleriyle yani $G = (V, E)$ şeklinde gösterilirler [220]. Bununla birlikte, bu çalışmadaki graf farklı özellikler içermektedir. Çalışmadaki graf düğümleri *Akıllı Hücre* (Intelligent Cell) ve bu hücrelerden oluşan graf da *Akıllı Graf* (Intelligent Graph) olarak adlandırılmıştır. Çünkü her bir hücre, eşleştirildiği trafik sahnesi bölümündeki oyuncuları ve o oyuncuların risk ağırlıklarını taşıdığı gibi, komşu bölgelerden gelebilecek veya komşulara etki edecek potansiyel risk transfer bilgilerini de içermektedir. Bu özellikleriyle bu graf dinamik bir bilgi saklayan ve bilgi haberleşmesini sağlayan yapısıyla *Akıllı* olarak kabul edilebilir.

Yöntemde kullanılan grafın hücre yapısı Şekil 6.6’ da verilmiştir. Her bir hücre ilgili sahne bölümündeki oyuncuların (Y) bilgilerini ve onların toplam risk ağırlıklarını (weight) içerir. Bir hücredeki oyuncuların toplam risk ağırlığı $\forall y_i \in Y$ olmak üzere $\sum w(y_i)$, şeklinde hesaplanabilir.

Graf kenarları komşu bölümlerin birbirlerine yaptıkları risk transferlerini temsil etmektedir. Bu çalışmada kullanılan grafta iki türlü kenar bulunmaktadır:


1. Hücreden komşulara risk transferi yapan kenar (Gönderici kenar - Sender edge)
2. Komşulardan gelen risk transferini alan kenar (Alıcı kenar - Receiver edge)

Sahne bölümlerinin dinamik yapısından dolayı bu risk bağlantısı potansiyel risk kestirimine imkan sağlamaktadır.



Şekil 6.6. Akıllı grafa ait akıllı hücre yapısı [177, 178].

Her bir hücrenin bir sahne bölümünü gösterdiği graf tasarımı Şekil 6.7’ de verilmiştir.



Şekil 6.7. Her bir hücrenin bir bölümü gösterdiği ve kenarlarının komşu bölümlerdeki risk transferlerini temsil ettiği akıllı graf [177, 178].

Burada hücre kümesi $V = \{v_1, v_2, \dots, v_9\}$ şeklinde etiketlenmiştir. Her bir hücre bir oyuncu kümesi ve onların risk ağırlıklarını içermektedir. Bir başka ifadeyle, her bir hücre ilgili sahne bölümünün güncel toplam riskini tutmaktadır. Grafta hücelere ait oyuncu listesi $Y^{X^j} = \{y_1, y_2, \dots, y_i, \dots, y_n \mid \forall y_i \in Y\}$ şeklinde ifade edilmiştir. Bu terim $X \in \{A, B, C\}$ olmak üzere X bölüm tipine sahip j . seviyeye ait oyuncu listesi anlamına gelmektedir. Örneğin A tipine sahip 1 nolu bölüme ait, yani A^1 bölümüne ait oyuncu listesi $Y^{A^1} = \{P, L\}$ şeklinde gösterilecektir. Burada oyuncular $y_1 = P$ ve $y_2 = L$ şeklindedir ve bu hücrenin temsil ettiği bölümde sırasıyla yaya ve trafik ışığı bulunduğu anlaşılmaktadır.

Çalışmadaki metodun yaklaşımında sahne bölümlerindeki bir oyuncunun bir tane olması ile birden fazla olmasının etkisinin aynı olduğu kabul edilmiştir. Örneğin bir bölümde bir araba olması ile üç tane olması aynı şekilde değerlendirilmektedir. Bir başka ifadeyle bir bölümde bir oyuncu türünden bir tane olması, o bölümdeki risk hesabında kullanılması için yeterlidir. Dolayısıyla örneğin bir tane yaya tek başına her komşu bölüme gidebilir ve potansiyel risk oluşturabilir. Bu nedenle bu çalışmanın asıl konusu olan bölgesel risk hesabında oyuncuların sayısı değil türü ve varlığı önemlidir. Bir oyuncu türünün tümünün

tek tek tespit edilmesi bu çalışmanın konusu dışındadır. Çünkü bir sahne analizinde eğer yüzlerce oyuncu tek tek tespit edilmeye çalışılırsa oldukça yüksek olacak işlem maliyeti nedeniyle sistemin başarı oranı düşecek ve hatta başarısız olacaktır. Bu çalışmada kullanılan yaklaşıma göre herhangi bir bölümde herhangi bir oyuncu türüne rastlanırsa kaç tane olduğuna bakılmaksızın o tür için bir birimlik hesap yapmak oldukça kolaylık sağlamaktadır. Bu sayede işlem maliyetinin düşürülmesinin yanında yöntem daha uygulanabilir ve daha az karmaşık hale getirilebilmektedir.

6.3.2. Hücre Riskinin ve Transfer Risklerinin Hesaplanması

Her hücre eşleştiği sahne bölümünün oyuncu listesini (Y^{X^j}) tutar. Oyuncu listesindeki oyuncuların risk ağırlıklarının toplamı hücredeki *lokal riski* (ξ) verir.

$X \in \{A, B, C\}$ olmak üzere X tipinde j seviyesindeki bölüm için *lokal risk* (ξ^{X^j}) Denklem 6.1' deki gibi hesaplanmaktadır.


$$\xi^{X^j} = \sum_i w(y_i^{X^j}), \quad \forall y_i \in Y^{X^j} \quad (6.1)$$

Burada $w(y_i^{X^j})$ ifadesi X^j bölümündeki i . oyuncunun ağırlığıdır. Her bir oyuncunun ağırlıklarının toplanması ile hücredeki *lokal risk* elde edilir. Oyuncular için atanmış olan ağırlıklar Tablo 6.2' de verilmiştir.

Tablo 6.2. Oyunculara atanmış ağırlıklar [177, 178].

Oyuncular	A Tipi Bölümlerdeki Oyuncuların ağırlıkları (w)			B Tipi Bölümlerdeki Oyuncuların ağırlıkları (w)			C Tipi Bölümlerdeki Oyuncuların ağırlıkları (w)		
	A^1	A^2	A^3	B^1	B^2	B^3	C^1	C^2	C^3
P : Yaya	5	2	1	10	6	4	5	2	1
H : Araç	-	-	-	10	8	6	-	-	-
S : Trafik İşareti	3	2	1	-	-	-	3	2	1
L : Trafik Işığı	10	8	6	-	-	-	10	8	6
K : Yaya Geçidi	-	-	-	8	6	4	-	-	-
Toplam Kapasite	18	12	8	28	20	14	18	12	8

Şekil 6.8’ de hücrelerin hem lokal risklerini hem de bölümlerarası transfer risklerini içeren graf verilmiştir. Bu aşamada graf, *Kesme (Cut)* işlemine hazır hale gelmiş olmaktadır.



Şekil 6.8. Hücrelerinin lokal riski ve hücrelerarası transfer edilen riski hesaplanmış olan graf [177, 178].

Trafik sahnesindeki bir oyuncunun rolü bulunduğu konuma ve test sürücüsüne olan mesafeye bağlıdır. Dolayısıyla Tablo 6.2’ de bu durum gözönüne alınmıştır. Örneğin A^1 ’deki oyuncuların risk ağırlıkları A^1 bölümündekilerden daha fazladır. Çünkü A^1 bölümü sürücüye A^3 bölümüne göre daha yakındır. Dolayısıyla taşıdıkları risk daha fazladır. A tipine sahip bir yerdeki bir oyuncu için ağırlık her bölümde aynı değildir. Bir başka ifadeyle, aynı oyuncu bölüm değiştirince yeni bölümün şartlarına göre ağırlığı değişir. Bu durum A tipi bölümler için $w(A^1) > w(A^2) > w(A^3)$ şeklinde tanımlanabilir. Benzer şekilde B tipi ve C tipi bölümlerdeki aynı oyuncunun diğer bölümlere geçmesi halinde risk ağırlıkları arasında da sırasıyla $w(B^1) > w(B^2) > w(B^3)$ ve $w(C^1) > w(C^2) > w(C^3)$ ilişkileri tanımlanabilir. Bunun yanısıra bir oyuncunun bulunduğu bölümün tipi de anlamlıdır. Örneğin kaldırımdaki (A ve C Tipi Bölüm) bir yaya ile yol üzerindeki (B Tipi) bir yaya farklı risklere sahiptir. Dolayısıyla ağırlıklara değer atanırken $w(B^j) > w(A^j) = w(C^j)$

ilişkisi de düşünülmüştür. A ve C tipli bölümler kaldırım olduğu için değerleri aynıdır ancak yoldaki (B tipi) olan bir oyuncunun risk ağırlığı daha fazladır.

Oyuncuların ağırlıklarının belirlenmesindeki bir başka faktör de oyuncuların tipidir. Örneğin trafik ışığı yolda seyreden araçlar kadar önemli bir unsurdur. Trafik ışıkları kent trafiğinde hem araçlar hem de yayalar için trafik akışını düzenleyen en yaygın bileşendir. Dolayısıyla eğer trafik ışığı farkedilemezse veya kaçırılırsa sahnedeki diğer oyuncuların ve özellikle diğer araçların onu farkedebilmesi için geç kalınmış olacaktır. Kentteki trafik kazalarının çoğunun ana sebebi trafik ışığı ihlalidir.

Bir diğer hesap da hücrelerarası risk transferinin gerçekleştirilmesidir. Hareketli oyuncu içeren her bölüm komşu bölümler için bir *potansiyel risk* (ρ) taşır. Örneğin B^2 ' deki bir araç B^1 ve B^3 bölümleri için potansiyel bir risk taşımaktadır. Çünkü araç her iki bölüme de geçebilir. Bununla birlikte, araçlar kaldırımlarda seyredemeyeceği için A ve C tipi bölümler için potansiyel risk taşımazlar. Öte yandan bir yaya, potansiyel riski en fazla olan trafik unsurudur. Çünkü yayalar her tipteki bölüme geçebilir. Kaldırımda da yürüyebilir, yola girerek karşıdan karşıya da geçebilir. Grafta potansiyel risk, kenarlar vasıtasıyla diğer hücrelerle bağlıdır. Buradaki kritik konu potansiyel risk ağırlığını elde etmek için referans olarak hangi hücrenin seçileceğidir. Bir başka ifadeyle bir hücreden diğer hücreye geçebilecek bir oyuncunun potansiyel riski, geldiği hücrenin mi riskini taşır yoksa varacağı hücreninkini mi taşır sorusu cevap bulmalıdır. Bunun için önerilen yaklaşım, risk transferinde oyuncunun varacağı hücredeki ağırlığının alınmasıdır. Yani grafta okun işaret ettiği hücredeki ağırlığın alınmasıdır. Örneğin bir yayanın B^1 bölümünden B^2 bölümüne doğru olan potansiyel risk ağırlığı alınırken yayanın B^2 bölümündeki ağırlık değeri seçilir. Çünkü oyuncunun taşınması öngörülen risk gideceği yerdeki rolü ile değer kazanmaktadır.

Bir hücrenin *lokal riski* (ξ) ve *potansiyel riski* (ρ) hesaplandıktan sonra toplandığında o hücrenin yani bölümün *total riski* (τ) ortaya çıkmış olur. *Total risk* Denklem 6.2' deki gibi hesaplanmaktadır.

$$\tau^{X^j} = \xi^{X^j} + \sum_i^n \rho_i^{X^j} \quad (6.2)$$

Burada ξ^{X^j} ifadesi Denklem 6.1' de belirtilen *lokal risk* olmaktadır. $\sum_i^n \rho_i^{X^j}$ terimi ile X^j hücresinin n tane komşudan gelen potansiyel risk toplamı hesaplanmaktadır. Sonuç

olarak bir hücre için, yani bir trafik sahnesi bölümü için *total risk* (τ), *lokal risk* ile *potansiyel risk* toplamına eşittir ve $\tau = \xi + \rho$ şeklinde sembolize edilebilir.

6.4. Risk Hesaplama

6.4.1. Graf-Kesme Teorisi ve Enerji Minimizasyonu


Çalışmadaki hedef, bölünmüş sahnedeki en riskli bölgeyi hesaplamaktır. Aslında bu problem, her hücre için hem potansiyel risk (ρ) hem de lokal risk (ξ) ile ilişkili bir optimizasyon problemidir. Dolayısıyla bu problem Graf-Kesme [223] kullanılarak gerçekleştirilen bir enerji minimizasyonu olarak tanımlanabilir. Bir başka ifadeyle bölgelerin riskleri hesaplanacak, ardından da ξ ve ρ risk faktörlerini içeren bir maliyet fonksiyonu geliştirilerek minimize edilecektir. Şekil 6.9’ da bölünmüş bir sahneden grafa dönüştürülerek grafa uygulanan Graf-Kesme metodu gösterilmiştir. Bu çalışmada kullanılan Graf-Kesme metodu geleneksel yaklaşıma benzerdir. Geleneksel Graf-Kesme kullanılarak resim bölmeleme (Image Segmentation) için her bir piksel bir graf hücresi olarak düşünülmektedir. Benzer yaklaşımla bu çalışmada her bir sahne bölümü graf hücresi şeklinde düşünülmüştür.

Yöntemde iki tür düğüm bulunmaktadır:

1. Kaynak (s) ve Hedef (t) olarak etiketlenen düğümler
2. Sahne bölümlerinin yerine geçen hücreler

Aynı zamanda iki tür kenar bulunmaktadır:

1. t-bağlantı etiketli kenar
2. n-bağlantı etiketli ve hücreler arası risk transferini temsil eden kenarlar



Şekil 6.9. Bölümlere ayrılmış trafik sahnesindeki risk optimizasyonu için Graf-Kesme işlemi uygulanması. (a) Bölümlere ayrılmış sahne ve graf yapılandırmanın başlangıcı, (b) Bölümden hücreye dönüşüm vasıtasıyla sahnenin graf şeklinde gösterilmesi. Burada, n-link graf kenarıdır, bölümler arası risk transferini temsil eder; t-link (s-v) ise kaynaktan hücrelere etiketlemedir ve 1 etiketi verir, t-link (v-t) hücrelerden hedefe olan etiketlemedir ve 0 etiketi verir, (c) Graf-Kesme işleminin uygulanması, (d) Graph-Kesme işlemi ile riskli bölge hesabı [177].

Geleneksel Graf-Kesme tabanlı resim bölmelemede maliyet fonksiyonu (cost function) resimdeki sınırları ve bölgeleri minimize eder [217]. Bu çalışmadaki yaklaşımda maliyet fonksiyonu, Etiket-1 olarak etiketlenmiş bölge için risk minimizasyonu gerçekleştirilir. Sahnenin bölmelenmesi ise hücreleri arasındaki kenarlar kesilerek gerçekleştirilir. Böylece sahne, biri 1 ve diğeri 0 olarak etikenlenen iki bölgeye ayrılmış olur. Graf-Kesme metodundaki bölge ve sınır risk faktörlerinin minimize edilmesi bu çalışmada, Etiket-1 olarak işaretlenmiş bölge için risk hesabı gerçekleştirmektir.

6.4.2. Risk Enerji Minimizasyonu

P tüm hücreler kümesini gösterir. N ise $\{p, q\}$ ile gösterilen tüm komşu çiftler kümesini gösterir. $L = \{l_1, l_2, \dots, l_p, \dots, l_{|P|}\}$ kümesi, her biri 1 veya 0 olan etiket kümesidir. Örneğin l_p elemanı, 1 ya da 0 değerine sahip olan p hücresinin etiketidir. Kesme işlemi ile iki bölgeye ayrılan grafın bir bölgesinin hücreleri 0, diğer bölgesinin hücreleri de 1 ile etiketlenir. Çalışmadaki hedef, Etiket-1 olarak işaretlenmiş bölgenin risk minimizasyonunun gerçekleştirilmesi, bir başka ifadeyle maliyet fonksiyonu $E(L)$ ' nin $\argmin_L E(L)$ şeklinde ifade edilen minimize edilmesi işlemidir. Maliyet fonksiyonu Denklem 6.3' de verilmiştir.

$$E(L) = \lambda_R \cdot R(L) + \lambda_B \cdot B(L) \quad (6.3)$$

Burada $R(L)$ bölgesel terimi gösterir ve $B(L)$ sınır terimini gösterir ve sırasıyla Denklem 6.4 ve Denklem 6.5' de tanımlanmışlardır.

$$R(L) = 1 / \left(\frac{1}{n} \sum_{p \in P} (R_p(l_p) \cdot \delta_{l_p}) \right) \quad (6.4)$$

$$B(L) = \sum_{\{p,q\} \in N} (B_{p,q} \cdot \delta_{l_q} \cdot \delta_{l_p \neq l_q}) \quad (6.5)$$

Denklem 6.4' deki $R_p(l_p)$ terimi Denklem 6.6' da tanımlanmıştır. Buna göre bu terim, l_p etiketli bir hücrenin (yani bölgenin) *total riski* olan $\tau_p^{X^j}$ olarak atanmıştır. Burada $X \in \{A, B, C\}$ ve $j \in \{1, 2, 3\}$ ' dir.

$$R_p(l_p) = \tau_p^{X^j} \quad (6.6)$$

$$\delta_{l_p} = \begin{cases} 1, & l_p = \text{etiket } 1 \\ 0, & l_p = \text{etiket } 0 \end{cases} \quad (6.7)$$

Denklem 6.7' de δ_{l_p} ile işlem yapılacak bölge işaretlenir. Çalışmadaki yaklaşımda işlem yapılacak bölge, etiket-1 olarak işaretlenen bölgedir. Eğer l_p hücresi etiket-1 ise o hücrenin total risk hesaplanır, dolayısıyla δ_{l_p} terimine 1 değeri atanır; değilse yani etiket-0 ile işaretlenmiş bir hücre ise hesap yapılmaz, bu yüzden Denklem 6.4' deki terimde işlem

yapılmamasını sağlaması için δ_{l_p} terimi sıfır olarak atanır. Dolayısıyla $R(L)$ terimine sahip olan ve kesilerek elde edilen iki bölgeden 1 etiketine sahip olanında bulunan tüm hücrelerin *total risk* (τ^{X^j}) toplamı minimize edilmiştir. Denklem 6.5’ deki $B_{p,q}$ terimi Denklem 6.8’ de tanımlanmıştır.

$$B_{p,q} \propto e^{-\sum q_E^{gönderici}} \quad (6.8)$$

Burada q_E^{sender} terimi, E kenarı için diğer bölgenin q hücresinden komşusu olan p hücresine olan risk transfer değerini gösterir ve burada $q_E^{gönderici} = p_E^{alıcı}$ ‘dir.


$$\delta_{l_p \neq l_q} = \begin{cases} 0, & l_p = l_q \\ 1, & l_p \neq l_q \end{cases} \quad (6.9)$$

$$\delta_{l_q} = \begin{cases} 1, & l_q = \text{etiket 0} \\ 0, & l_q = \text{etiket 1} \end{cases} \quad (6.10)$$

Burada $\delta_{l_p \neq l_q}$ kesme işlemi uygulanacak kenarların yerlerini göstermektedir. $l_p \neq l_q$ olan bu yerler, bölgelerin birbirlerine komşu olduğu hücreler arasındaki kenarlardır ve kesme işleminin uygulanacağı sınır yerleridir. Eğer $l_p = l_q$ ise her iki hücre de aynı bölgededir ve bu kenar bölgeler arasındaki sınırdaki bir kenar değildir. δ_{l_q} denklemi etiket-0 ile işaretlenen bölgeden gelen risk transfer değerini seçmek için kullanılmaktadır. Eğer $l_q = \text{etiket-0}$ ise komşu hücre etiket-0 ile işaretlenmiş bölgedeki komşu hücredir ve bu hücresinden gelen risk transferi hesaplanmak üzere eklenir. Eğer $l_q = 1$ ise bu komşu hücre zaten etiket-1 işaretli aynı bölge hücresidir ve buradan gelen risk transferi farklı bir bölgeden gelmediği için hesaplama katılmaz. Dolayısıyla $B(L)$ terimi etiket-0 olan bölgeden etiket-1 olan bölgeye doğru olan total risk transferinin toplamını Kesme işlemi ile minimize eder. λ_R ve λ_B katsayıları sırasıyla bölgesel terim ve sınır terimi için kullanılan ağırlıklardır. 0-1 arasında herhangi bir değer alırlar. Bu değer 1’ e yaklaştıkça ağırlık arttırılmış olmaktadır. Algoritması aşağıda verilen Graf-Kesme tabanlı enerji minimizasyonu işlemi Şekil 6.10’ da gösterilmiştir.

Algoritma: *Graf-Kesme metoduyla risk enerji minimizasyonu*


Input: $G = (E, V)$, $V = \{v_1, v_2, \dots, v_i, \dots, v_n\}$, $E = \{E_1, E_2, \dots, E_j, \dots, E_m\}$ **Output:** $\text{argmin}_L E(L)$ $N = \{p, q\}$ // hücre çiftleri kümesi $\lambda_R = (0-1]$, $\lambda_B = (0-1]$, $\lambda_R > \lambda_B$ $\text{minL} \leftarrow$ Başlangıç Değeri //Positif ve Büyük bir sayı**for** all possible $\text{cut}(G1, G2)$ Yeni Kesme: $\text{cut}(G1, G2) : G \leftarrow G1 \cup G2$ Yeni etiketleme: $L = \{\{l_p^{G1}\}, \{l_p^{G2}\}\}$, $\{l_p^{G1}\} \leftarrow 1$, $\{l_p^{G2}\} \leftarrow 0$ $n \leftarrow$ Cell number of region G1 $R(L) = 0$ // Bölgesel (regional) terim hesabı**foreach** vertices(V) (yani p)**if** $l_p = 1$ **then** $\delta_{l_p} = 1$ **else** $\delta_{l_p} = 0$ **endif** $R(L) = R(L) + (\tau_p^{X^j}) \cdot \delta_{l_p}$ **endfor** $R(L) = 1/(R(L)/n)$ $B(L) = 0$ // Sınır (boundary) terimi hesabı**foreach** $\{p, q\}$ çiftlerine ait kenarlar(Edge) için**if** $(l_p \neq l_q)$ **and** $l_q = 0$ **then** $\delta_{l_p \neq l_q} = 1$, $\delta_{l_q} = 1$ **else** $\delta_{l_p \neq l_q} = 0$, $\delta_{l_q} = 0$ **endif** $B(L) = B(L) + e^{-\sum q_E^{sender}} \cdot \delta_{l_p \neq l_q} \cdot \delta_{l_q}$ **endfor** $E(L) = \lambda_R \cdot R(L) + \lambda_B \cdot B(L)$ **if** $E(L) < \text{minL}$ **then** $\text{minL} = E(L)$ **endif****endfor**



Şekil 6.10. Risk hesaplama için Graf-Kesme metodunun uygulanması [177].

6.5. Bilgisayar Simülasyonları

Şekil 6.11' de örnek bir sahne problemi verilmiştir. Burada trafik sahnesi, test aracı sürücüsünün bakış alanı olarak kabul edilmiştir. Çalışmada kullanılan yöntem aracılığıyla sahnedeki oyuncuların tipleri, konumları gibi özellikleri değerlendirilerek sahne analizleri yapılabilir.



Şekil 6.11. Örnek bir cadde taslağı [177].

Graf-Kesme yoluyla risk enerji minimizasyonu adımları aşağıdaki gibi verilmiştir:

A. Trafik Sahnesinin Tasarımı

Adım 1: Trafik sahnesinin bölümlere ayrılması

Adım 2: Bölgelerdeki oyuncu kümelerinin tanımlanması

B. Graf Yapılandırma

Adım 3: Trafik sahnesinin grafa dönüştürülmesi


Adım 4: Hücre risklerinin ve transfer risklerinin hesaplanması

C. Risk Hesaplama

Adım 5: Graf-Kesme teorisi ve enerji minimizasyonu

Adım 6: Trafik sahnesi risklerinin enerji minimizasyonu

Adım 1. Trafik Sahnesinin Bölümlere Ayrılması:




Şekil 6.12. Bölümlere ayrılmış trafik sahnesi [177].

Adım 2. Bölümlerdeki Oyuncu Kümelerinin Tanımlanması:

	Sevive 1	Sevive 2	Sevive 3
A	$\{P\}$	$\{P, S\}$	$\{P, L\}$
B	$\{H\}$	$\{H\}$	$\{H, P, K\}$
C	$\{S\}$	$\{P\}$	$\{P, L\}$


Şekil 6.13. Bölümlerdeki oyuncuların tanımlanması [177].

Adım 3. Trafik Sahnesinin Grafa Dönüştürülmesi:




Şekil 6.14. Trafik sahnesinin grafa dönüştürülmesi [177].

Adım 4. Hücre Lokal Risklerinin ve Transfer Risklerinin Hesaplanması:




Şekil 6.15. Hücrelerdeki risklerin ve transfer risklerinin hesaplanmış halı [177].

Yapılandırılmış Graph:



Şekil 6.16. Sahne-graf dönüşümünün sonucunda elde edilen graf [177].



Şekil 6.18. Trafik sahnesindeki en riskli bölgenin gösterimi [177].

Burada pembe ile belirtilen bölge en riskli bölge olarak belirlenmiştir. Bu sonuç, tüm bölge kombinasyonları için yukarıdaki hesaplar yapılarak elde edilmiştir.

7. SONUÇLAR, TARTIŞMALAR, ÖNERİLER VE KONU İLE İLGİLİ GELECEKTEKİ ÇALIŞMALAR

Ulaşım alanında en önemli problemlerden biri güvenli sürüştür. Bu güvenlik probleminde Çevre-Araç-Sürücü üçgeni içerisinde en önemli rolü sürücü üstlenmektedir. Çünkü sürücü hem aracı kontrol etmekle hem de çevre şartlarını dikkate alarak hareket etmekle yükümlüdür. Dolayısıyla güvenli bir sürüşün gerçekleşmesi büyük ölçüde sürücünün performansına bağlıdır. Bununla birlikte sürücülerin dikkatsizlik, yorgunluk, uykusuzluk, kurallara uymama gibi davranışları ideal sürüşün gerçekleşmesi için önemli bir engeldir. İdeal sürüş tüm olumsuzlukların sıfıra indirilmesi anlamına gelmektedir. Her ne kadar eğitim ve cezalarla bu problemler giderilmeye çalışılsa da hemen hemen her gün binlerce trafik kazası meydana gelmeye devam etmektedir. Kazaların tamamen engellenmesi ve sıfır hata ile tam güvenli sürüşün sağlanması, sürücülü araçlar için çok zordur. Dolayısıyla tamamen sürücülerin kontrolünde olan araçların yerini uykusu gelmeyen, yorulmayan, dikkatsiz davranmayan ve kurallara uymamakta ısrar etmeyen, kısacası hata yapmayan sürücüsüz tam otonom araçların alması durumunda güvenliğin tam ve kazanın sıfır olacağı kabul edilerek, bu ideal duruma ulaşabilmek için gerekli olan sistemleri içeren İleri Sürücü Destek Sistemleri (İSDS) üzerine yeni yaklaşımlar geliştirmek ve İSDS' leri daha da akıllı hale getirerek araçların kontrolünde sürücünün kontrolünü en aza indirmek düşüncesi bu tez çalışmasına ilham kaynağı olmuş ve bu kapsamda yeni İSDS yaklaşımları geliştirilmiştir. İSDS' ler sürücüye yardımcı olması amacıyla geliştirilmiş aktif güvenlik sistemleridir. Günümüzdeki bir çok modern araçta hava yastığı, çelik barlar, emniyet kemerleri, özel koltuk tasarımları gibi kaza sonrası düşünülerek geliştirilmiş pasif güvenlik elemanları bulunsa da, tam güvenli sürüş için gerekli olan sistemler kaza olmasını önleyen aktif güvenlik sistemleridir.

İSDS onbinlerce çalışmanın yapıldığı ve yapılmaya devam edildiği, teknoloji ve otomotiv sanayi geliştikçe daha da devam edecek olan oldukça geniş bir çalışma alanıdır. Bu nedenle bu tez çalışmasında İSDS' ler Düşük Seviye SDS ve Yüksek Seviye SDS olmak üzere iki ana başlık altında sınıflandırılmış ve bu sınıflandırma tez çalışması aşamasında oldukça kolaylık sağlayarak tez çalışmasının varmak istediği noktaya önemli derecede ışık tutmuştur. İSDS çalışmalarına bakıldığında DS-SDS çalışmaları oldukça fazla yapılmış ve OpenCV kütüphanesinde tek bir komutla dahi gerçekleştirilecek yöntemler haline gelmeye başlamıştır. Ayrıca günümüz araçlarının bir çoğunda şerit

değiştirme asistanı, kör nokta uyarıcısı, lastik basınç takibi gibi sensörle algılanabilen veya bir kameranın bir cismi tespit etmesiyle gerçekleştirilebilen karmaşık olmayan DS-SDS sistemleri bulunmaktadır. Ancak bu özellikler aracın tam otonom olması için yeterli değildir. Otonom sürüşe ulaşılması ve tam güvenli sürüşün sağlanabilmesi için aracın kontrolünü sağlayan, risk hesaplayabilen, trafik olaylarını analiz edebilen ve bir kazayı ön kestirim yaparak engelleyebilen YS-SDS sistemlerine ihtiyaç duyulmaktadır. Bundan dolayı bu tez çalışmasının ilk bölümünde bir DS-SDS çalışması yapılmış ve daha sonra büyük ölçüde YS-SDS yaklaşımlarına ağırlık verilmiştir.

7.1. Tezde Yapılan Çalışmalar ve Yorumlar

Tez çalışması esnasında yapılan çalışmalar DS-SDS ve YS-SDS başlıkları altında aşağıdaki gibi sıralanabilir:

A. DS-SDS Çalışmaları:

- Arkadan takip eden araç tespiti ve takibi

B. YS-SDS Çalışmaları:

- Sollama esnasında meydana gelebilecek risk analizi
- Sürücünün agresif veya sakin sürücü olup olmadığının tespit edilmesi
- Yol profilinin tespit edilmesi
- Virajı güvenli bir şekilde almak için virajın risk durumunun tespit edilmesi
- Trafik sahnesindeki en riskli bölgelerin analiz edilmesi

7.1.1. Arkadan Takip Eden Araç Tespiti ve Takibi

Amaç: Çalışmada bir aracın arkasına yerleştirilmiş kameradan alınan görüntülerden faydalanılarak arkadan takip eden araçların tespit edilmesi işlemi gerçekleştirilmiştir. Tez çalışmasında her ne kadar YS-SDS sistemlerine ağırlık verilse de sonraki çalışmaya altyapı oluşturmak amacıyla yoldaki bir aracın tespit edilmesi çalışması yapılmıştır.

Yöntem: Çalışma hareket eden bir nesnenin takibi temeline dayandığı için optik akış hareket vektörleri kullanılmıştır. Hareket vektörlerinden yola çıkılarak sınıflandırma ve

kümeleme yöntemleri ile resim çerçevesindeki araç tespiti gerçekleştirilmiştir. Dolayısıyla geometrik olmayan metodlar kullanılmıştır.

Çalışmadaki yenilikler:

1. Resim çerçevesine optik akış hareket vektörleri çıkarılmadan önce resmin kenar algılayıcıdan geçirilmesi yeni bir yaklaşımdır. Bu sayede optik akış hareket vektörlerinin getirdiği karmaşıklık ve işlem yükü azaltılmıştır.
2. Optik akış vektörlerinden oluşan kümelerin sınırlarının belirlenmesinde bu çalışmada geliştirilen düşey ve yatay tarama algoritmasının temelini oluşturan Küme Sütunlarının Yoğunluk Histogramı (DHCC-Density Histogram of Columns Cluster) ve Küme Satırlarının Yoğunluk Histogramı (DHCR-Density Histogram of Rows Cluster) kullanılmıştır. Bu histogramların işaret ettiği bölgelerin kesişimleri resim çerçevesindeki araç olabilecek aday vektör kümelerinin sınırlarını göstermektedir.
3. Ayrıca bu çalışmada bir yol görüntüsüne ait çerçevelerdeki aracın konumu ile ilgili bir başvuru tablosu (Look-up Table) kullanılmış ve o görüntüdeki bir kümenin araç olup olamayacağı eleme işleminde kullanılmıştır.

Çalışmadan çıkarılan sonuçlar ve öneriler:

1. Bir resim çerçevesine uygulanan optik akış yönteminin ham verilere uygulanmasının çerçevenin ebatlarının değişmesine de bağlı olarak gerçek zaman uygulamalarında sorun olabileceği gözlemlenmiştir. Bu yüzden, optik akış işleminden önce resimlerin kenar algılamadan geçirilmesi ile bu gürültülerin ve karmaşıklığın azaldığı gözlemlenmiştir. Ayrıca, kenar uygulanırken en iyi sonucun Prewitt maskesi ile elde edildiği görülmüştür. Sobel, Roberts, Canny gibi maskeler uygulandığında gürültünün yeteri kadar azalmadığı gözlemlenmiştir.
2. Çalışmada kullanılan düşey ve yatay tarama algoritmasının başarısı kümelerin birbirini kapaması (occlusion) durumunda ilk adımda azalmaktadır. Ancak, her t zaman diliminde algoritmanın uygulanmaya devam etmesi durumunda araç ile birbirini kapayan nesnelerin kaybolduğu görülmüştür. Arka arkaya gelen birden fazla araç olması durumunda kapama tekrar meydana gelebilmektedir. Bununla birlikte çalışmadaki temel amacın arkadan yaklaşan araç veya araçların sürücüyü uyarmak

için tespit edilmesi olduğundan dolayı kapamadan dolayı tek bir araç gibi algılanan birden fazla araç sorun olmamaktadır.

7.1.2. Sollama Esnasında Meydana Gelebilecek Kaza Risk Hesabı

Amaç: Çalışmanın amacı özellikle şehirlerarası bir yolda sollama esnasında meydana gelebilecek bir kazanın önüne geçebilmek için kaza risk hesabı yapılmasıdır.

Yaklaşım ve Yöntem: Bu çalışmada kazayı en kolay, sollanan aracın önleyebileceği düşünülmüştür. Sollanan aracın ön ve arkasına yerleştirilen kameralarla sollayan aracın, kendisinin ve önündeki aracın (3-Araba modeli) pozisyonları tespit edilmiştir. Ardından, tespit edilen pozisyonların risk durumları Bayes Ağı ile hesaplanmıştır.

Çalışmanın Yenilikleri:

1. Çalışmada kazayı önleyecek olan aracın sollanacak araç olarak düşünülmesi yeni bir yaklaşımdır. Çalışmadaki 3-Araba senaryosunda ortada olan araç yüksek risk hesaplandığında kazayı önlemek için güvenli bir mesafe açabilecek olan araçtır.
2. Çalışmada aracın ön ve arkasındaki kameralardan elde edilen araç pozisyonlarının tanımlanması ve Bayes Anlam Ağı kullanılarak risk hesabı yapılması yeni bir yaklaşımdır.
3. Ayrıca, ilk çalışmadaki kenar-optik, yatay düşey tarama ve araç tespiti için geliştirilen yöntemler bu çalışmada da kullanılmaktadır.

Çalışmadan çıkarılan sonuçlar ve öneriler:

1. Gerçek zamanlı uygulamalarda ön ve arka kameradaki araçların durumlarının değerlendirilmesi için geliştirilen yazılımın hızlı bir platformda koşturulması gerekmektedir.
2. Bayes ağının dikkatli oluşturulması gerekmektedir. Ağın yanlış oluşturulması halinde işlem doğruluğunun azalması yanında işlem maliyeti artabilir. Ayrıca, Bayes ağındaki temel ağırlıkların başlangıçta verilmesi için sistematik bir yöntem bulunmamaktadır. Dolayısıyla bu değerler verilirken risk yaratma faktörüne göre ağırlıkların büyüklüklerinin ayarlanması gerekmektedir. Örneğin sollayan aracın sol

şeritte olması ve karşıdan gelen aracın da aynı şeritte olması kaza riskinin en yüksek olduğu durumdur ve ağırlığının diğer durumlara göre daha büyük olması gerekir.

3. Çalışma, 3-Araba modeli üzerine kurulmuştur. Dolayısıyla çoklu araç ortamında bu modelin kullanılmasında işlem maliyeti en önemli problem olacaktır. Çünkü araç sayısının artması ile birlikte durum sayısı da, sollama senaryolarının sayısı da artacaktır ve risk değerlendirme işlemi zaman alıcı bir işlem olacaktır.

7.1.3. Sürücünün Agresif veya Sakin Sürücü Olup Olmadığının Tespit Edilmesi

Amaç: Çalışmada seyir halindeki bir sürücünün agresif mi yoksa sakin sürüş mü yaptığı probleminin CAN bus verileri kullanılarak çözülebilmesi için gereksiz verilerin elenmesi üzerine bir öznitelik seçimi algoritması geliştirilmiştir.

Yöntem: Çalışmada aracın CAN-bus verileri kullanılmıştır. CAN-bus verileri tork, devir, hız, gaz pedalı seviyesi, yakıt tüketimi gibi birçok dahili veriyi içermektedir. Bu verilerin seyir halindeki değişimi ve birbirlerini nasıl etkilediği sürüşün nasıl yapıldığı bilgisini verebilir. Bununla birlikte gereksiz veya etkisiz olan verilerin elenmesi işlemlerin kısılmasını ve karmaşıklığı önlemektedir. Örneğin 15 CAN-bus verisinin 5 tanesi gereksiz ise, yani 10 tanesi ile de bu problem çözülebiliyorsa 15 verinin getirdiği işlem maliyetinden kurtulmak yöntemi daha verimli hale getirecektir. Bu yüzden çalışmada verilerin birbirleri ile ilişkileri çapraz korelasyon ile çıkarılmıştır ve geliştirilen yeni algoritma ile gereksiz olanlar elenmiştir. Sonunda ise regresyon denklemleri ile doğrulama yapılmıştır.

Çalışmadaki yenilikler:

1. Öncelikle CAN-bus verileri ile sürücünün agresif veya sakin sürüş yaptığıının anlaşılması yeni bir yaklaşımdır. CAN-bus verilerinin kullanılması ek donanımlara ihtiyaç duyulmadan problemin çözülmesini sağlayabilmektedir.
2. CAN-bus verilerinden gereksiz olanların elenmesi için geliştirilen algoritma yeni bir yaklaşımdır. İkili korelasyonların aynı etkiyi her yerde veren veya hiçbir yerde vermeyen değişkenlerin tespit edilerek elenmesi yeni bir yaklaşımdır.

Çalışmadan çıkarılan sonuçlar ve öneriler:

1. CAN-bus verilerinin sayısının fazla olması çapraz korelasyon matrisinin büyümesine ve işlemde yavaşlamaya neden olmaktadır.
2. CAN-bus verilerinin değişik türden araçlarda kullanılması ile yöntemin her araca uyarlanabildiği görülmüştür. Burada dikkat edilmesi gereken husus her araçta olabilecek devir, tork gibi verilerin üzerinde durulması gerekliliğidir. Örneğin otomatik şanzımanlı bir araçta debriyaj pedalı bulunmamaktadır. Dolayısıyla debriyaj verisinin de içinde bulunduğu bir çözüm tüm araçları kapsamaz. Bu yüzden problem çözülürken hem verilerin sayısını düşürmek adına hem de mümkün olduğunca geniş bir araç kitlesini kapsayacak verilerin seçilmesi yöntemin başarısını arttıracaktır.
3. Aracı kullanan sürücü profilleri veya test güzergahı farklı olsa bile metodun çalışmasının olumsuz etkilenmediği gözlemlenmiştir.
4. Yöntemin bir ileri düzeyi, çoklu korelasyon ile eleme işlemi yapmaktır. Bu durumda işlem maliyeti daha da artacaktır.

7.1.4. Yol Profilinin Tespit Edilmesi

Amaç: Çalışmada seyir halindeyken aracın rampa mı çıktığı yokuş aşağı mı indiğinin tespit edilmesi probleminde kullanılan CAN-bus verilerinden gereksiz olanların elenmesi amaçlanmıştır. Bu hedef için yeni bir algoritma geliştirilmiştir.

Yöntem: Bir önceki çalışma olan agresif/sakin sürücü problemindeki yöntem bu probleme uyarlanmıştır. İniş ve rampa olan yollarda farklı araçlar ve sürücüler kullanılarak test verileri hazırlanmış ve algoritmada kullanılmıştır.

Yenilikler ve çalışmadan çıkarılan sonuçlar ve öneriler:

1. Çalışmadaki algoritmanın ikili (binary) olarak düzenlenebilen tüm problemlerde başarılı olduğu tespit edilmiştir. İkili düzenlenebilen problemlerden kastedilen şey, agresif (1) - sakın (0) veya rampa (1) - iniş (0) gibi 1 ve 0 olarak kodlanabilen durumlardır. Örneğin bu algoritmanın kanserli olan (1) - olmayan (0) hücreler için de uygulanabildiği görülmüştür.

2. Algoritmanın eğitici olması gerekliliği, kısıtlayıcı bir unsurdur. Önceden 1 ya da 0 olarak kodlanmış verilerin algoritma tarafından öğrenilmesi gerekmektedir. Problemimizde rampa ve iniş durumları, test sürüşleri esnasında ayrı ayrı etiketlenmiştir.

7.1.5. Viraj Risk Durumunun Tespit Edilmesi

Amaç: Çalışmanın amacı bir viraja girmeden önce viraj özellikleri ve aracın durumları birlikte değerlendirilerek kaza riskinin hesaplanmasıdır.

Yöntem: Aracın arkasına ve önüne yerleştirilen iki kameradan elde edilen görüntülerden elde edilen virajın yön, keskinlik ve eğim parametreleri ile aracın hız bilgisi Bayes ağı yoluyla değerlendirilerek risk hesabı yapılmaktadır.

Yenilikler:

1. Virajın güvenli bir şekilde alınmasının arka ve ön kameralarla elde edilen viraj parametrelerinin Bayes Ağı ile değerlendirilmesi yeni bir yaklaşımdır.
2. Virajın iniş mi yoksa çıkış mı olduğunun tespiti bu çalışmada arka ve ön kamera bilgilerinin birleştirilmesi ile elde edilmiştir. Çünkü sadece ön kamera ile alınan bilgiler yanıltıcı olabilmektedir. Arka kamera bilgisinin de katılması ile elde edilen viraj ve yol açıları arasındaki ilişkilerin gözönünde bulundurulması, eğim tipinin tespit edilmesi doğruluk oranını büyük ölçüde arttırmaktadır.
3. Virajın keskinliği hesabı için kullanılan yöntem yeni bir yaklaşımdır.

Çalışmadan çıkarılan sonuçlar ve öneriler:

1. Viraj parametrelerinin tespitinde en çok problem yaşanan konu yolun iniş mi çıkış mı olduğunun tespitidir. Arka kameranın da kullanılması ile bu sorun aşılmıştır.
2. Arazi şartları çalışmanın başarısını etkileyebilmektedir. Örneğin virajın döndüğü yönde orta bölümde bulunan ağaç gibi yükseltiler virajın ufuk noktasını tespit etmekte problem oluşturabilmektedir.
3. Çalışmanın başarısı viraj parametrelerinin doğru tespit edimesine bağlıdır. Çalışmada çevre şartları ve aracın hızından kaynaklanan dezavantajlar nedeniyle hatalar olabilmektedir. Ancak her t anında yapılan bu hesap bir anlamda t-1, t-2,... gibi

yakın zamanda yapılan hesapları doğrulama açısından bir avantajdır. Gerçek zamanlı uygulamalarda bu durum bir avantaj olacaktır. Örneğin t-2 anında yöntemin hesabı hatalı olsa bile t-1 ve t anındaki hesaplarla hata giderilebilir. Bu zaman aralıkları gerçek zamanda saniye düzeyinde çok kısa zaman aralıklarıdır.

7.1.6. Bir Trafik Sahnesindeki Riskli Bölgelerin Analizi

Amaç: Özellikle şehir içindeki bir caddedeki sürücüye yardımcı olması için o caddenin hangi bölgelerinde riskin fazla olduğunun tespiti amaçlanmıştır.

Yöntem: Yol sahnesi, içerisinde bulunan araç, yaya, trafik ışıkları, trafik işaretleri, yaya geçitleri gibi unsurlarla karmaşık bir yapıdır. Özellikle yaya ve araç gibi hareketli unsurların yer değiştirmesi ve sayılarının fazla olması bu karmaşıklığı daha da arttırmakta, dolayısıyla sahneye dinamik bir yapı getirmektedir. Bu yüzden çalışmada sahne bölümlere ayrılmıştır. Her bir bölüm bir grafin düğümleri olarak tanımlanmış ve iyi bilinen graf-kesme yöntemi ile bölgesel risk hesabı yapılmıştır. Sahnedeki her bir unsur bir oyuncu olarak tanımlanmış ve her bir oyuncunun ağırlığı bulunduğu bölüme göre tanımlanmıştır. Ayrıca yer değiştiren oyuncuların yarattığı ve komşu bölümleri etkileyen potansiyel riskler de toplam riske dahil edilmiştir.

Çalışmadaki yenilikler:

1. Caddenin bir sahne ve içerisindekilerin de birer oyuncu olarak kabul edilmesi, sahnenin bölümlere ayrılması ve oyuncuların caddede yer aldığı bölgeye göre ağırlıklandırılması yeni bir yaklaşımdır.
2. Caddedeki hareketli oyuncuların yer değiştirmesi olasılıklarının düşünülerek komşu bölgeler için potansiyel risklerinin hesaplanması yeni bir yaklaşımdır.
3. Sahnenin bölümlere ayrılarak bir grafa dönüştürülmesi ve Graf-Kesme metodunun uygulanarak riskli bölgelerin hesaplanması yeni bir yaklaşımdır.

Çalışmadan çıkarılan sonuçlar ve öneriler:

1. Çalışmada her bir oyuncunun tek tek tespit edilmesi büyük bir işlem karmaşıklığına yol açmaktadır. Dolayısıyla her bir bölümdeki oyuncuların herhangi bir türün tespit

edilmesi yeterli görülmüştür. Örneğin bir bölümde bir yaya olması ile iki yaya olması arasında yöntem açısından bir fark yoktur. O bölümde yayanın var olması veya olmaması durumunun düşünülmesi yeterlidir. Aksi halde yüksek-seviye olan bu çalışmanın tamamen düşük-seviye bir nesne tespiti çalışmasına dönüşmesi ve aynı zamanda gerçek zaman uygulamalarında işlem maliyetini arttırması kaçınılmaz olacaktır.

2. Çalışmadaki yol, bölünmüş bir yol değildir. Ancak yöntem ölçeklenebilir olacak şekilde geliştirilmiştir. Bir başka ifadeyle farklı tür yol ve caddeler için dinamik bir bölmeleme algoritması uygulanabilir. Bu dinamik bölmeleme yöntemin ileri aşamalarda geliştirilecek ilk özelliğidir. Bu çalışmada sahne dokuz parçaya bölünmüştür ve üç seviyeli bir yol uzunluğu söz konusudur. Çalışmada bu seviyenin dört ve daha fazla olmasının işlem maliyetini arttıracığı ve yöntemin gerçekleştirilebilirliğine engel olabileceği gözlemlenmiştir. Çünkü sürücünün çok fazla tanımlanan bölümlere ayrı ayrı odaklanması beklenemez. Buna ilave olarak, her t anında yapılan risk hesabı ile yol ne kadar uzun olursa olsun tüm yol değerlendirmeye alınabilecek, sürücü her seferinde önündeki üç seviyeye odaklanacağı için gereksiz işlem karmaşıklığının da önüne geçilmiş olacaktır.
3. Çalışmada Graf-Kesme yönteminin uygulanması bir seçim yapmayı gerektirmiştir. Dokuz bölüme ayrılmış sahnenin bölümlerinin tek tek, ikişer ikişer, üçer üçer değerlendirilmesi yeterli olabilmektedir. Aksi halde tüm bölge kombinasyonlarının hesaplanması gerçek zaman için uygun olmayacaktır.
4. Çalışmada bazı oyuncuların iki bölümde de görülmesi, yani bir kısmının bir bölümde diğer kısmının da diğer bölümde olması gibi sorunlarla karşılaşmış, çözüm olarak o oyuncunun her iki bölümde de var olduğu kabul edilmiştir. Çünkü t zaman sonra o oyuncunun bölümü değişecektir. Dolayısıyla anlık belirsizliklerin problemin çözülmesi açısından çok önemli olmadığı görülmüştür.
5. Oyuncuların sahnedeki rolüne göre ağırlıklandırılması için bir yöntem bulunmamaktadır. Bunun için her oyuncunun hareketli olup olmaması, trafikteki önemi, kaza için oynadıkları roller ve yoldaki konumunun seviyesi dikkate alınarak ağırlık tablosu oluşturulmuştur. Bir oyuncunun t zaman sonra ağırlığı sahne içerisinde değişmektedir. Çünkü test sürücüsü sahnede ilerlediği için sabit bir trafik

unsuru bile sürücüye daha da yaklaşıcağı için risk ağırlığı artmaktadır. Sonuç olarak dinamik bir sahne ve risk hesabı yapılmaktadır.

7.2. Konu ile ilgili Gelecekteki Çalışmalar

Konu ile ilgili gelecekte yapılacak çalışmaların iki doğrultuda ilerlemesi planlanmıştır:


1. Tez çalışması esnasında geliştirilen yeni yöntem ve yaklaşımların ilerletilmesi:

- Arkadan yaklaşan aracı tespit etme çalışmasında; araç sayısının birden fazla olması durumunda kapama probleminin aşılması için DHCR ve DHCC histogramlarının kullanıldığı kümeleme algoritmasının daha da geliştirilmesi,
- Sollama probleminde; 3-Araba modelinin N-Araba için uyarlanması, Bayes Ağının yerine farklı yöntemlerin de performanslarının ölçülmesi,
- Agresif/Sakin sürücü ve Yol Profili probleminde; gereksiz verilerin elenmesi için kullanılan algoritmanın çoklu korelasyon kullanılarak geliştirilmesi ve deneylerin çok daha çeşitli araç sınıflarında da yapılması,
- Viraj riskinin hesaplanması probleminde; risk hesaplamanın Bayes Ağı dışında bir yöntemle hesaplanması, risk hesabına farklı faktörlerin de katılması,
- Trafik sahnesindeki riskli bölgelerin hesaplanması çalışmasında; değişik sahne ve yol türlerine göre dinamik bir bölmeleme yöntemi geliştirilmesi, farklı oyuncuların da yöneme dahil edilmesi planlanmıştır.

2. Otonom sürüş için yeni çalışmaların yapılması ve yeni kavramlar üzerinde durulması:


Teknolojinin gelişmesi ve insanların ihtiyaçlarının değişim göstermesi ile birlikte otonom araçların da yenilenmesi ve ihtiyaçlara cevap verebilecek yeni yaklaşımlarla donatılması gerekmektedir. Dolayısıyla ilerleyen zamanlarda öngörülen otonom araçlardan beklenen, sadece bir noktadan diğer noktaya kendi kendine güvenli bir şekilde gidebilmek değil, aynı zamanda bunu insan beyninin verdiği kararlarla benzer davranışlar göstererek tam güvenli biçimde gerçekleştirmek ve insanların hayatını kolaylaştırabilecek bağlantılı olma (connectivity) ve kişisel taşınabilirlik (personal mobility) imkanlarını da sağlamaktır. Bu nedenle tam otonomluk hedefi için İSDS' lerle donatılmış sensör-tabanlı akıllı sürücüsüz araçlar tam güvenlik ve taşınabilirlik sağlayamaması nedeniyle değişen ihtiyaçlara tam anlamıyla cevap veremeyebilir. Sensörler tespit, algılama, tanıma

işlemlerini gerçekleştirmektedirler, hatta sahne analizleri ve risk önkestirimleri de yapabilmektedirler. Ancak insan-tarzı davranışları henüz gösterememektedirler. Örneğin yola giren bir topun arkasından bir çocuğun gelebileceği yorumu bir insan tarafından rahatlıkla yapılabilir. Fakat sensör-tabanlı sistemlerde bu yorum söz konusu değildir. Dolayısıyla sensörlerden daha etkili olabilecek iletişim teknolojilerin araçlarda kullanılması fikri ortaya atılmış ve bunun ardından Bağlantılı-Araçlar (Connected-Vehicles) kavramı geliştirilmiştir [5].



Şekil 7.1. Yeni nesil otonom araçlarda Bağlantılı-Araçların (Connected Vehicle) sistem üzerindeki konumu. Bağlantılı-Araçlar aktif güvenlikte İSDS sistemlerini destekleyen ve araçların haberleşmesini sağlayarak tam güvenlik sağlayan topluluk zekasına sahip sistemlerdir

Bağlantılı-Araçlar sistemlerinde, tüm araçların birbirleriyle iletişim teknolojileri ile haberleşmesi ve oluşan bilgi ağı sayesinde araçlarda Tam-Güvenlik sağlanması ve Kişisel-Taşınabilirlik ihtiyaçlarının sağlanması amaçları vardır. Bağlantılı-Araçlar teknolojisinde iletişim teknolojileri ile araçtan yayın (vehicle broadcast) yapılması veya bire-bir (peer-to-peer) bilgi alışverişi yapılabilmesi amaçlanmaktadır. Trafik sıkışmalarının yarattığı zaman maliyeti, trafik kazalarının ve çakışmaların yarattığı maddi kayıplar ve can kayıpları Trafik Yönetimi (Traffic Management) ve Bilgi-Tabanlı Uyarı sistemleri ile önlenabilir. Ayrıca Bağlantılı-Araçlar hedefinde, tüm dünyaya bağlı olacak olan araçlar kişilerin iş ve ev imkanlarını araçlarda bulması ile Kişisel Taşınabilirlik yer almaktadır [5, 224-229].



Şekil 7.2. Birbiri ile haberleşebilen araçlar ve yol altyapısı [5].

Sonuç olarak gelecek nesil araç sistemlerinde eğilimin Bağlantılı-Araçlara doğru kayması nedeniyle gelecek çalışmalarda; İSDS sistemlerinin iletişim teknolojileriyle donatılarak araçların birbirleriyle haberleşmesinin sağlanması ve araçların özellikle trafik yönetimi gibi uygulamalarda bir Topluluk Zekası davranışı gösterecek şekilde tasarlanması, haberleşme sayesinde güvenliğin tam olmasının sağlanması amaçlı çalışmaların yapılması planlanmaktadır.

KAYNAKLAR

- [1] <http://www.tuik.gov.tr>
- [2] <http://www.nhtsa.gov>
- [3] http://www.who.int/topics/injuries_traffic/en/
- [4] <http://www.volvocars.com/ae/top/about/newsevents/pages/default.aspx?itemid=44>
- [5] <http://web.stanford.edu/class/me302/PreviousTerms/>
- [6] Bertolazzi, E., Biral, F., and Da Lio, M., 2004. Future advanced driver assistance systems based on Optimal Control: the influence of risk functions on overall system behavior and on prediction of dangerous situations, *IEEE In Intelligent Vehicles Symposium*, pp. 386-391.
- [7] Kitt, B., Geiger, A., and Lategahn, H., 2010. Visual odometry based on stereo image sequences with ransac-based outlier rejection scheme, *IEEE Intelligent Vehicles Symposium (IV)*, pp. 486-492.
- [8] Roessing, C., Reker, A., Gabb, M., Dietmayer, K., and Lensch, H., 2013. Intuitive visualization of vehicle distance, velocity and risk potential in rear-view camera applications, *IEEE Intelligent Vehicles Symposium (IV)*, pp. 579-585.
- [9] Kichun, J., Junsoo, K., and S., Myoungho, 2013. Real-time road-slope estimation based on integration of onboard sensors with GPS using an IMMPDA filter, pp. 1-15.
- [10] Yang, Z., Huang, J., Cao, C., and Su, Y., 2004. Intelligent control method of vehicle's starting on slope road, *IEEE Intelligent Control and Automation*, vol. 3, pp. 2391-2395.
- [11] Sivaraman, S., Trivedi, M. M., Toppelhofer, M., and Shannon, T., 2013. Merge recommendations for driver assistance: A cross-modal, cost-sensitive approach, *IEEE Intelligent Vehicles Symposium (IV)*, pp. 411-416.
- [12] Prioletti, A., Møgelmoose, A., Grislieri, P., Trivedi, M., Broggi, A., and Moeslund, T. B., 2013. Part-based pedestrian detection and deature-based tracking for driver assistance: real-time, robust algorithms and evaluation, *IEEE Transactions on Intelligent Transportation Systems*, vol. 14-3, pp. 1346-1359.

- [13] Bellino, M., De Meneses, Y., L., Kolski, S., and Jacot, J., 2005. Calibration of an embedded camera for driver-assistant systems, *IEEE Intelligent Transportation Systems Proceedings*, pp. 354-359.
- [14] <http://www.kpmg.com/US/en/IssuesAndInsights/ArticlesPublications/Documents/self-driving-cars-next-revolution.pdf>
- [15] <http://www.opencv.org>
- [16] Pavlic, M., Belzner, H., Rigoll, G., and Ilic, S., 2012. Image based fog detection in vehicle, *IEEE Intelligent Vehicles Symposium (IV)*, pp. 1132-1137.
- [17] Hautière, N., Tarel, J., P., and Aubert, D., 2010. Mitigation of visibility loss for advanced camera-based driver assistance, *IEEE Intelligent Transportation Systems*, vol 11-2, pp. 474-484.
- [18] Hegeman, G., Brookhuis, K., and Hoogendoorn, S., 2005. Opportunities of advanced driver assistance systems towards overtaking, *EJTIR*, vol. 5-4, pp. 281-296.
- [19] Cheng, S., Y., and Trivedi, M., M., 2006. Turn-intent analysis using body pose for intelligent driver assistance, *IEEE Pervasive Computing*, vol. 5-4, pp. 28-37.
- [20] Zhu, J., Yuan, L., Zheng, Y., F., and Ewing, R., L., 2012. Stereo visual tracking within structured environments for measuring vehicle speed, *IEEE Transactions on Circuits and Systems for Video Technology*, vol. 22-10, pp. 1471-1484.
- [21] Garcia, F., Cerri, P., Broggi, A., De La Escalera, A., and Armingol, J., M., 2012. Data fusion for overtaking vehicle detection based on radar and optical flow, *IEEE Intelligent Vehicles Symposium (IV)*, pp. 494-499.
- [22] Zinoune, C., Bonnifait, P., and Ibanez-Guzman, J., 2012. Detection of missing roundabouts in maps for Driving Assistance Systems, *IEEE Intelligent Vehicles Symposium (IV)*, pp. 123-128.
- [23] Golban, C., Istvan, S., and Nedevschi, S., 2012. Stereo based visual odometry in difficult traffic scenes, *IEEE Intelligent Vehicles Symposium (IV)*, pp. 736-741.
- [24] Suchitra, S., Satzoda, R., K., Srikanthan, T., 2012. Detection and classification of arrow markings on roads using signed edge signatures, *IEEE Intelligent Vehicles Symposium (IV)*, pp. 796-801.
- [25] Fukagawa, Y., and Yamada, K., 2013. Estimating driver awareness of pedestrians from driving behavior based on a probabilistic model, *IEEE Intelligent Vehicles Symposium (IV)*, pp. 1155-1160.

- [26] http://en.wikipedia.org/wiki/Nicolas-Joseph_Cugnot
- [27] Jill, C., Wheeler, 2010, *Mercedes Benz*, *ABDO Publishing Company*.
- [28] <http://en.wikipedia.org/wiki/Airbag>
- [29] [http://wikicars.org/en/Anti-Lock_Brakes_\(ABS\)](http://wikicars.org/en/Anti-Lock_Brakes_(ABS))
- [30] http://en.wikipedia.org/wiki/Electronic_stability_control
- [31] http://en.wikipedia.org/wiki/Lane_departure_warning_system
- [32] http://en.wikipedia.org/wiki/Intelligent_Parking_Assist_System
- [33] http://www.bmw.com/com/en/insights/technology/technology_guide/articles/bmw_night_vision.html?source=index&article=bmw_night_vision
- [34] <http://www.volvocars.com/us/about/our-company/heritage/innovations>
- [35] http://en.wikipedia.org/wiki/Google_driverless_car
- [36] Choi, J., Lee, J., Kim, D., Soprani, G., Cerri, P., Broggi, A., and Yi, K., 2012. Environment-detection-and-mapping algorithm for autonomous driving in rural or off-road environment, *IEEE Transactions on Intelligent Transportation Systems*, vol. 13-2, pp. 974-982.
- [37] Jang, J., H., Bae, S., H., Park, M., W., and Kim, J., H., 2010. Research of velocity control on the slope road for Unmanned Ground Vehicle, *IEEE International Conference on Control Automation and Systems (ICCAS)*, pp. 1085-1088.
- [38] He, W., Wang, X., Chen, G., Guo, M., Zhang, T., Han, P., and Zhang, R., 2011. Monocular based lane-change on scaled-down autonomous vehicles, *IEEE Intelligent Vehicles Symposium (IV)*, pp. 144-149.
- [39] Unterholzner, A., and Wuensche, H., J., 2013. Selective attention for detection and tracking of road-networks in autonomous driving, *IEEE Intelligent Vehicles Symposium (IV)*, pp. 277-284.
- [40] E., R., M., Faizal, et al., 2009. Virtual Mid-Line Detection on Curve Road for User Guidance Using Simulation Model, *Computer Technology and Development ICCTD'09*, vol. 1.
- [41] Seibert, A., Hahnel, M., Tewes, A., and Rojas, R., 2013. Camera based detection and classification of soft shoulders, curbs and guardrails, *IEEE Intelligent Vehicles Symposium (IV)*, pp. 853-858.

- [42] Guo, C. Z., Yamabe, T., and Mita, S., 2013. Drivable Road Boundary Detection for Intelligent Vehicles based on Stereovision with Plane-induced Homography, *Acta Automatica Sinica*, vol 39-4, pp. 371-380.
- [43] Yan J., Gao F., and Xu., G., 2010. Computer vision-based multiple-lane detection on straight road and in a curve, *IEEE International Conference on Image Analysis and Signal Processing (IASP)*.
- [44] Sayanan., S., and Trivedi., M., M., 2013. Integrated lane and vehicle detection, localization, and tracking: A synergistic approach, *IEEE Intelligent Transportation Systems*, pp. 1-12.
- [45] Jung, H., Min, J., and Kim, J., 2013. An efficient lane detection algorithm for lane departure detection, *IEEE Intelligent Vehicles Symposium (IV)*, pp. 976-981.
- [46] Wennan, Z., Qiang, C., and Hong, W., 2006. Lane detection in some complex conditions, *IEEE International Conference on Intelligent Robots and Systems*, pp. 117-122.
- [47] Bottazzi, V., S., Borges, P., V., and Jo, J., 2013. A vision-based lane detection system combining appearance segmentation and tracking of salient points, *IEEE Intelligent Vehicles Symposium (IV)*, pp. 443-448.
- [48] Mammar, S., Glaser, S., and Netto, M., 2006. Time to line crossing for lane departure avoidance: A theoretical study and an experimental setting, *IEEE Transactions on Intelligent Transportation Systems*, pp. 226-241.
- [49] Hunjae, Y., Yang, U., and Sohn, K., 2013. Gradient-enhancing conversion for illumination-robust lane detection, *IEEE Transaction on Intelligent Transportation Systems*, pp. 1-12.
- [50] Yu, B., Zhang, W., and Cai, Y., 2008. A lane departure warning system based on machine vision. *IEEE Pacific-Asia Workshop on Computational Intelligence and Industrial Application, PACIIA'08*, vol. 1, pp. 197-201.
- [51] Eidehall, A., Pohl, J., and Gustafsson, F., 2005. A new approach to lane guidance systems, *IEEE Transactions on Intelligent Transportation Systems*, pp. 108-112.
- [52] Blaschke, C., Breyer, F., Färber, B., Freyer, J., and Limbacher, R., 2009. Driver distraction based lane-keeping assistance, *Transportation research part F: traffic psychology and behaviour*, vol. 12-4, pp. 288-299.

- [53] Yao, W., Zhao, H., Davoine, F., and Zha, H., 2012. Learning lane change trajectories from on-road driving data, *IEEE Intelligent Vehicles Symposium (IV)*, pp. 885-890.
- [54] Yao, W., Zhao, H., Bonnifait, P., and Zha, H., 2013. Lane change trajectory prediction by using recorded human driving data, *IEEE Intelligent Vehicles Symposium (IV)*, pp. 430-436.
- [55] Hur, J., Kang, S., N., and Seo, S., W., 2013. Multi-lane detection in urban driving environments using conditional random fields, *IEEE Intelligent Vehicles Symposium (IV)*, pp. 1297-1302.
- [56] Doshi, A., and Trivedi, M., M., 2009. On the roles of eye gaze and head dynamics in predicting driver's intent to change lanes, *IEEE Transactions on Intelligent Transportation Systems*, vol. 10-3, pp. 453-462.
- [57] Hillel, A., B., Lerner, R., Levi, D., and Raz, G., 2014. Recent progress in road and lane detection: a survey, *Machine vision and applications*, vol. 25-3, pp. 727-745.
- [58] Zhao, K., Meuter, M., Nunn, C., Muller, D., Muller-Schneiders, S., and Pauli, J., 2012. A novel multi-lane detection and tracking system, *IEEE Intelligent Vehicles Symposium (IV)*, pp. 1084-1089.
- [59] Rahman, M., Chowdhury, M., Xie, Y., and He, Y., 2013. Review of Microscopic Lane-Changing Models and Future Research Opportunities, *IEEE Transactions on Intelligent Transportation Systems*, vol. 14-4 pp. 1942-1956.
- [60] McCall, J., C., and Trivedi, M., M., 2006. Video-based lane estimation and tracking for driver assistance: survey, system, and evaluation, *IEEE Transactions on Intelligent Transportation Systems*, vol 7-1, pp. 20-37.
- [61] Kim, Z., 2006. Realtime lane tracking of curved local road. *IEEE Intelligent Transportation Systems Conference, ITSC'06*, pp. 1149-1155.
- [62] Ohn-Bar, E., Sivaraman, S., and Trivedi, M., 2013. Partially occluded vehicle recognition and tracking in 3D, *IEEE Intelligent Vehicles Symposium (IV)*, pp. 1350-1355.
- [63] Sivaraman, S., and Trivedi, M., M., 2013. Integrated lane and vehicle detection, localization, and tracking: A synergistic approach, *IEEE Transactions on Intelligent Transportation Systems*, vol. 14-2, pp. 906-917.
- [64] Sivaraman, S., and Trivedi, M., M., 2011. Combining monocular and stereo-vision for real-time vehicle ranging and tracking on multilane highways, *IEEE*

International Conference on Intelligent Transportation Systems (ITSC), pp. 1249-1254.

- [65] Sivaraman, S., and Trivedi, M., M., 2012. Real-time vehicle detection using parts at intersections, *IEEE Intelligent Transportation Systems (ITSC)*, pp. 1519-1524.
- [66] Sivaraman, S., and Trivedi, M., M., 2010. A general active-learning framework for on-road vehicle recognition and tracking, *IEEE Transactions on Intelligent Transportation Systems*, vol. 11-2, pp. 267-276.
- [67] Wang, T., and Zhu, Z., 2012. Real time moving vehicle detection and reconstruction for improving classification, *IEEE Workshop on Applications of Computer Vision (WACV)*, pp. 497-502.
- [68] Hu, Q., Li, S., He, K., and Lin, H., 2010. A robust fusion method for vehicle detection in road traffic surveillance, *IEEE Advanced Intelligent Computing Theories and Applications, With Aspects of Artificial Intelligence, Springer Berlin Heidelberg*, pp. 180-187.
- [69] Muffert, M., Pfeiffer, D., and Franke, U., 2013. A stereo-vision based object tracking approach at roundabouts, *IEEE Intelligent Transportation Systems Magazine*, vol. 5-2, pp. 22-32.
- [70] Rios-Cabrera, R., Tuytelaars, T., and Van Gool, L., 2012. Efficient multi-camera vehicle detection, tracking, and identification in a tunnel surveillance application, *Computer Vision and Image Understanding*, vol. 116-6, pp. 742-753.
- [71] Sivaraman, S., and Trivedi, M., M., 2013. A review of recent developments in vision-based vehicle detection, *IEEE Intelligent Vehicles Symposium*, pp. 310-315.
- [72] Strigel, E., Meissner, D., and Dietmayer, K., 2013. Vehicle detection and tracking at intersections by fusing multiple camera views, *IEEE Intelligent Vehicles Symposium (IV)*, pp. 882-887.
- [73] Morris, B., T., and Trivedi, M., M., 2008. Learning, modeling, and classification of vehicle track patterns from live video, *IEEE Transactions on Intelligent Transportation Systems*, vol. 9-3, 425-437.
- [74] Makris, A., Perrollaz, M., and Laugier, C., 2013. Probabilistic Integration of Intensity and Depth Information for Part-Based Vehicle Detection, *IEEE Transactions on Intelligent Transportation Systems*, vol. 14-4, pp. 1896-1906.

- [75] Shan, M., Worrall, S., and Nebot, E., 2013. Probabilistic long-term vehicle motion prediction and tracking in large environments, *IEEE Transactions on Intelligent Transportation Systems*, vol. 14-2, pp. 539-552.
- [76] Li, Y., Li, B., Tian, B., and Yao, Q., 2013. Vehicle Detection Based on the AND-OR Graph for Congested Traffic Conditions, *IEEE Transactions on Intelligent Transportation Systems*, vol. 14-2, 984-993.
- [77] Sivaraman, S., and Trivedi, M., M., 2013. Vehicle detection by independent parts for urban driver assistance, *IEEE Transactions on Intelligent Transportation Systems* vol. 14-4, pp. 1597-1608.
- [78] Hasberg, C., Hensel, S., Westenkirchner, M., and Bach, K., 2008. Integrating spline curves in road constraint object tracking, *IEEE International Conference on Intelligent Transportation Systems*, pp. 1009-1014.
- [79] Himmelsbach, M., and Wuensche, H., J., 2012. Tracking and classification of arbitrary objects with bottom-up/top-down detection, *IEEE Intelligent Vehicles Symposium (IV)*, pp. 577-582.
- [80] Lefebvre, S., and Ambellouis, S., 2012. Vehicle detection and tracking using mean shift segmentation on semi-dense disparity maps, *IEEE Intelligent Vehicles Symposium (IV)*, pp. 855-860.
- [81] Kramm, S., and Bensch, A., 2012. Obstacle detection using sparse stereovision and clustering techniques, *IEEE Intelligent Vehicles Symposium (IV)*, pp. 760-765.
- [82] Mendes, C., C., T., Osório, F., S., and Wolf, D., F., 2013. An efficient obstacle detection approach for organized point clouds, *IEEE Intelligent Vehicles Symposium (IV)*, pp. 1203-1208.
- [83] Li, B., Wang, Y., and Fairhurst, M., 2010. Multiple Condensation filters for road detection and tracking, *Pattern Analysis and Applications*, vol. 13-3, pp. 251-262.
- [84] Bai, L., and Wang, Y., 2011. Road tracking using particle filters with partition sampling and auxiliary variables, *Computer Vision and Image Understanding*, vol. 115-10, pp. 1463-1471.
- [85] Rasmussen, C., 2004. Grouping dominant orientations for ill-structured road following, *Computer Vision and Pattern Recognition (CVPR), IEEE*, vol.1, pp. 470-477.

- [86] Eidehall, A., and Gustafsson, F., 2006. Obtaining reference road geometry parameters from recorded sensor data, *IEEE Intelligent Vehicles Symposium*, pp. 256-260.
- [87] Kluge, K., and Thorpe, C., 1992. Representation and recovery of road geometry in YARF, *IEEE Intelligent Vehicles Symposium*, pp. 114-119.
- [88] Wang, B., and Frémont, V., 2013. Fast road detection from color images, *IEEE Intelligent Vehicles Symposium (IV)*, pp. 1209-1214.
- [89] Aufrere, R., Chapuis, R., and Chausse, F., 2001. A model-driven approach for real-time road recognition, *Machine Vision and Applications*, vol. 13-2, pp. 95-107.
- [90] Oliveira, H., and Correia, P., L., 2013. Automatic road crack detection and characterization, *IEEE Transactions on Intelligent Transportation Systems*, vol. 14-1, pp. 155-168.
- [91] Guo, C., Z., Yamabe, T., and Mita, S., 2013. Drivable Road Boundary Detection for Intelligent Vehicles based on Stereovision with Plane-induced Homography, *Acta Automatica Sinica*, vol. 39-4, pp. 371-380.
- [92] Gackstatter, C., Heinemann, P., Thomas, S., Rosenhahn, B., and Klinker, G., 2010. Fusion of clothoid segments for a more accurate and updated prediction of the road geometry, *IEEE Intelligent Transportation Systems (ITSC)*, pp. 1691-1696.
- [93] Vitor, G., B., Lima, D., A., Victorino, A. C., and Ferreira, J., V., 2013. A 2d/3d vision based approach applied to road detection in urban environments, *IEEE Intelligent Vehicles Symposium (IV)*, pp. 952-957.
- [94] Mnih, V., and Hinton, G., E., 2010. Learning to detect roads in high-resolution aerial images, *European Conference Computer Vision (ECCV)*, Springer Berlin Heidelberg, pp. 210-223.
- [95] Chapuis, R., Aufrere, R., and Chausse F., 1999. Recovering the 3D shape of a road by vision, *IET International Conference on Image Processing and its Applications*, pp. 686-690.
- [96] Seibert, A., Hahnel, M., Tewes, A., and Rojas, R., 2013. Camera based detection and classification of soft shoulders, curbs and guardrails, *IEEE Intelligent Vehicles Symposium (IV)*, pp. 853-858.

- [97] Alvarez, J., M., A., and Lopez, A., M., 2011. Road detection based on illuminant invariance, *IEEE Transactions on Intelligent Transportation Systems*, vol. 12-1, pp. 184-193.
- [98] CSIR, 2000. Guidelines for Human Settlement Planning and Design, *Pretoria, Compiled under the patronage of the Department of Housing, by CSIR Building and Construction Technology*.
- [99] <http://www.raeng.org.uk/publications/other/4-road-alignment>
- [100] Tarel, J., P., and Guichard, F., 2000. Combined dynamic tracking and recognition of curves with application to road detection, *IEEE International Conference on Image Processing (ICIP)*, vol. 1, pp. 216-219.
- [101] Sebsadji, Y., Glaser, S., Mammar, S., and Dakhllallah, J., 2008. Road slope and vehicle dynamics estimation, *In American Control Conference*, pp. 4603-4608.
- [102] Raffone, E., 2013. Road slope and vehicle mass estimation for light commercial vehicle using linear Kalman filter and RLS with forgetting factor integrated approach, *IEEE International Conference on Information Fusion*, pp. 1167-1172.
- [103] Se, S., and Brady, M., 2003. Road feature detection and estimation, *Machine Vision and Applications*, vol. 14-3, pp. 157-165.
- [104] Peterson, K., Ziglar, J., and Rybski, P., E., 2008. Fast feature detection and stochastic parameter estimation of road shape using multiple LIDAR, *IEEE Intelligent Robots and Systems (IROS)*, pp. 612-619.
- [105] Alvarez, J., M., Salzmann, M., and Barnes, N., 2013. Learning appearance models for road detection, *IEEE Intelligent Vehicles Symposium (IV)*, pp. 423-429.
- [106] Hervieu, A., and Soheilian, B., 2013. Road side detection and reconstruction using LIDAR sensor, *IEEE Intelligent Vehicles Symposium (IV)*, pp. 1247-1252.
- [107] Shinzato, P., Y., Grassi, V., Osório, F., S., and Wolf, D., F., 2012. Fast visual road recognition and horizon detection using multiple artificial neural networks, *IEEE Intelligent Vehicles Symposium (IV)*, pp. 1090-1095.
- [108] Qin, B., Chong, Z., J., Bandyopadhyay, T., Ang, M., H., Frazzoli, E., and Rus, D., 2013. Road detection and mapping using 3d rolling window, *IEEE Intelligent Vehicles Symposium (IV)*, pp. 1239-1246.
- [109] Wu, T., and Ranganathan, A., 2012. A practical system for road marking detection and recognition, *IEEE Intelligent Vehicles Symposium (IV)*, pp. 25-30.

- [110] Woung, P., J., Lee, J., W., and Jhang, K., Y., 2003. A lane-curve detection based on an LCF, *Pattern Recognition Letters*, vol. 24-14, pp. 2301-2313.
- [111] Jihoon K., Jeon, N., Jeon, and Lee, H., 2012. Development of optimization algorithm for green drive on roads with continuous curves, *38th Annual Conference on IEEE Industrial Electronics Society (IECON)*, pp. 2238-2244.
- [112] Fildes, B. N., and, Triggs T., J., 1985. The on effect of changes in curve geometry magnitude estimates of road-like perspective curvature, *Perception and psychophysics*, vol. 37-3, pp. 218-224.
- [113] Zhu, W., X., , and Zhang, Li, D., 2012. Friction coefficient and radius of curvature effects upon traffic flow on a curved Road, *Physica A: Statistical Mechanics and its Applications*, vol. 391-20, pp. 4597-4605.
- [114] Kluge, K., 1994. Extracting road curvature and orientation from image edge points without perceptual grouping into features, *IEEE Intelligent Vehicles Symposium*, pp.109-114.
- [115] Li, K., Tan, H., S., Misener, J., A., and Hedrick, J., K., 2008. Digital map as a virtual sensor–dynamic road curve reconstruction for a curve speed assistant, *Vehicle System Dynamics*, vol. 46-12, pp. 1141-1158.
- [116] Maojing, J., 2013. Improvement of Road-following Intelligent Speed Control Based on Road Curvature, *IEEE Intelligent System Design and Engineering Applications (ISDEA)*, pp. 870-873.
- [117] Ma, B., Lakshmanan, S., and Hero, A., O., 1997. Detection of curved road edges in radar images via deformable templates, *IEEE International Conference on Image Processing (ICIP)*, vol. 1, pp. 857-860.
- [118] http://www.transportlinks.org/transport_links/filearea//publications/1_810_CaSE%202.pdf
- [119] Slimi, H., Ichalal, D., Arioui, H., and Mammar, S., 2013. Motorcycle maximal safe speed in cornering situation, *IEEE Networking Sensing and Control (ICNSC)*, pp. 340-346).
- [120] Chan, M., Partouche, D., and Pasquier, M., 2007. An intelligent driving system for automatically anticipating and negotiating road curves, *IEEE/RSJ International Conference on Intelligent Robots and Systems*, pp. 117-122.

- [121] Faizal, E., R., M., and Mansor, H., M., A., H., 2009. Virtual Mid-Line Detection on Curve Road for User Guidance Using Simulation Model, *IEEE International Conference on Computer Technology and Development, ICCTD*, vol. 1, pp. 24-27.
- [122] Sasaki, M., Yamada, W., Ito, T., Kita, N., and Sugiyama, T., 2012. Path loss model between mobile terminals in residential area with a curved road, *European Conference on IEEE Antennas and Propagation (EUCAP)*, pp. 2016-2020.
- [123] BureS, P., 2003. Long distance lane boundary visualisation on curved roads with a slope, *Video/Image Processing and Multimedia Communications*, vol. 1, pp. 169-174.
- [124] Charlton, S., G., 2007. The role of attention in horizontal curves: A comparison of advance warning, delineation, and road marking treatments, *Accident Analysis & Prevention*, vol. 39-5, pp. 873-885.
- [125] Charlton, S., G., 2004. Perceptual and attentional effects on drivers' speed selection at curves, *Accident Analysis and Prevention*, vol. 36-5, pp. 877-884.
- [126] Findley, D., J., Hummer, J., E., Rasdorf, W., Zegeer, C., V., and Fowler, T., J., 2012. Modeling the impact of spatial relationships on horizontal curve safety, *Accident Analysis and Prevention*, vol. 45, pp. 296-304.
- [127] Abbas, S., K., S., Adnan, M., A., and Endut, I., R., 2011. Exploration of 85th Percentile Operating Speed Model on Horizontal Curve: A Case Study for Two-Lane Rural Highways, *Procedia-Social and Behavioral Sciences*, vol. 16, pp. 352-363.
- [128] Ibrahim, S., E., Sayed, T., and Ismail, K., 2012. Methodology for safety optimization of highway cross-sections for horizontal curves with restricted sight distance, *Accident Analysis and Prevention*, vol. 49, pp. 476-485.
- [129] Dickmanns, E., D., and Zapp, A., 1987. A curvature-based scheme for improving road vehicle guidance by computer vision, *International Society for Optics and Photonics, In Cambridge Symposium_Intelligent Robotics Systems*, pp. 161-168.
- [130] Haynes, R., Lake, I., R., Kingham, S., Sabel, C., E., Pearce, J., and Barnett, R., 2008. The influence of road curvature on fatal crashes in New Zealand, *Accident Analysis and Prevention*, vol. 40-3, pp. 843-850.
- [131] Mogelmose, A., Trivedi, M., M., and Moeslund, T., B., 2012. Learning to detect traffic signs: Comparative evaluation of synthetic and real-world datasets, *International Conference on Pattern Recognition (ICPR)*, pp. 3452-3455.

- [132] Mogelmose, A., Trivedi, M., M., and Moeslund, T., B., 2012. Traffic sign detection and analysis: Recent studies and emerging trends, *IEEE Intelligent Transportation Systems (ITSC)*, pp. 1310-1314.
- [133] Miyata, S., Nakamura, H., Yanou, A., and Takehara, S., 2008. Feature Extraction and Recognition for Road Sign Using Dynamic Image Processing, *IEEE Innovative Computing Information and Control*, pp. 193-193.
- [134] Hamaoka, H., Hagiwara, T., Tada, M., and Munehiro, K., 2013. A Study on the behavior of pedestrians when confirming approach of right/left-turning vehicle while crossing a crosswalk, *IEEE Intelligent Vehicles Symposium*, pp. 99-103.
- [135] González, A., Bergasa, L., M., Yebes, J., J., and Almazan, J., 2013. Traffic panels detection using visual appearance, *IEEE Intelligent Vehicles Symposium (IV)*, pp. 1221-1226.
- [136] Kong, H., Sarma, S., E., and Tang, F., 2013. Generalizing Laplacian of Gaussian filters for vanishing-point detection, *IEEE Transactions on Intelligent Transportation Systems*, vol. 14-1, pp. 408-418.
- [137] Rasmussen, C., RoadCompass: Following rural roads with vision+ladar using vanishing point tracking, *Autonomous Robots*, vol. 25-3, pp. 205-229.
- [138] Prioletti, A., Møgelmos, A., Grislieri, P., Trivedi, M., Broggi, A., and Moeslund, T., B., 2013. Part-based Pedestrian Detection and Feature-based Tracking for Driver Assistance: Real-Time, Robust Algorithms and Evaluation, *IEEE Transactions on Intelligent Transportation Systems*, vol. 14-3, pp. 1346-1359.
- [139] Prioletti, A., Grislieri, P., Trivedi, M., M., and Broggi, A., 2013. Design and implementation of a high performance pedestrian detection, *IEEE Intelligent Vehicles Symposium (IV)*, pp. 1398-1403.
- [140] Zhuang, X., and Wu C., 2013. Modeling Pedestrian Crossing Paths at Unmarked Roadways, *IEEE Transactions on Intelligent Transportation Systems*, pp. 1438-1448.
- [141] Köhler, S., Goldhammer, M., Bauer, S., Zecha, S., Doll, K., Brunsmann, U., and Dietmayer, K., 2013. Stationary Detection of the Pedestrians Intention at Intersections, *IEEE Intelligent Transportation Systems Magazine*, vol. 5-4, pp. 87-99.

- [142] Sanchez, N., and Menéndez, J., M., 2009. Video analysis architecture for enhancing pedestrian and driver safety in public environments, *IEEE Image Analysis for Multimedia Interactive Services*, pp. 288-291.
- [143] Alon, Y., and Bar-Hillel, A., 2012. Off-vehicle evaluation of camera-based pedestrian detection, *IEEE Intelligent Vehicles Symposium (IV)*, pp. 352-358.
- [144] Xu, J., Vázquez, D., López, A. M., Marin, J., and Ponsa, D., 2013. Learning a multiview part-based model in virtual world for pedestrian detection, *IEEE Intelligent Vehicles Symposium (IV)*, pp. 467-472.
- [145] Yoshida, H., Suzuo, D., Deguchi, D., Ide, I., Murase, H., Machida, T., and Kojima, Y., 2013. Pedestrian detection by scene dependent classifiers with generative learning, *IEEE Intelligent Vehicles Symposium (IV)*, pp. 654-659.
- [146] Yang, K., Du, E., Y., Delp, E., J., Jiang, P., Jiang, F., Chen, Y., and Takahashi, H., 2013. An Extreme Learning Machine-based pedestrian detection method, *IEEE Intelligent Vehicles Symposium (IV)*, pp. 1404-1409.
- [147] Wang, Y., and Zhang, Y., 2011. Lane detection method based on moving blurring feature and WMSE, *International Conference on Electrical and Control Engineering*, pp. 1607-1610.
- [148] He, Y., Wang, H., and Zhang, B., 2004. Color-based road detection in urban traffic scenes, *IEEE Transactions on Intelligent Transportation Systems*, vol. 5-4, pp. 309-318.
- [149] Sun, T., Y., Tsai, S., J., and Chan, V., 2006. HSI color model based lane-marking detection, *IEEE Intelligent Transportation Systems Conference*, pp. 1168-1172.
- [150] Crisman, J., D., and Thorpe, C., E., SCARF: A color vision system that tracks roads and intersections, *IEEE Transactions on Robotics and Automation*, vol. 9-1, pp. 49-58.
- [151] Bardet, F., and Chateau, T., 2008. MCMC particle filter for real-time visual tracking of vehicles, *IEEE Intelligent Transportation Systems*, pp. 539-544.
- [152] Wu, X., Peng, Y., Ding, D., Liu, H., He, K., and Sun, F., 2008. Color vision-based multi-level analysis and fusion for road area detection, *IEEE Intelligent Vehicles Symposium*, pp. 602-607.

- [153] Lee, J., W., and Cho, J., S., 2009. Effective lane detection and tracking method using statistical modeling of color and lane edge-orientation, *IEEE Computer Sciences and Convergence Information Technology*, pp. 1586-1591.
- [154] Saruwatari, K., Sakaue, F., and Sato, J., 2012. Detection of abnormal driving using multiple view geometry in space-time, *IEEE Intelligent Vehicles Symposium (IV)*, pp. 1102-1107.
- [155] Karaduman, O., Eren, H., Kurum, H., Celenk, M., 2012. Approaching Car Detection via Clustering of Vertical-Horizontal Line Scanning Optical Edge Flow, *15th International IEEE Conference on Intelligent Transportation Systems (ITSC)*, Alaska-Anchorage USA, September 16-19, pp. 502-507.
- [156] Karaduman, O., Eren, H., Kurum, H., Celenk, M., 2013. Interactive Risky Behavior Model for 3-Car Overtaking Scenario Using Joint Bayesian Network, *IEEE Intelligent Vehicles Symposium (IV'13)*, Gold Coast, Australia, June 23-26, pp. 1279-1284.
- [157] Eren, E., Makinist, S., Akin, E., Yilmaz, A., 2012. Estimating driving behavior by a smartphone, *IEEE Intelligent Vehicles Symposium (IV)*, pp. 234-239.
- [158] Karaduman, O., Eren, H., Kurum, H., and Celenk, M., 2013. An Effective Variable Selection Algorithm for Aggressive/Calm Driving Detection via CAN Bus. *IEEE International Conference on Connected Vehicles and Expo (ICCVE)*, Las Vegas, Nevada, USA, Dec 2-6, 2013, pp. 586-591.
- [159] Karaduman, O., Eren, H., Kurum, H., and Celenk, M., 2013. Similar association set based attribute selection algorithm for road profile detection, *IEEE Image and Signal Processing (CISP)*, vol. 3, pp. 1376-1381.
- [160] Ng, K., M., Reaz, M., B., I., and Ali, M., A., M., 2013. A Review on the Applications of Petri Nets in Modeling, Analysis, and Control of Urban Traffic, *IEEE Transactions on Intelligent Transportation Systems*, vol. 14-2, pp. 858-870.
- [161] Yang, J., and Ozawa, S., 1996. Road scene analysis from perspective image, *IEEE International Conference on Acoustics, Speech, and Signal Processing*, vol. 6, pp. 3474-3477.

- [162] Von Seelen, W., Curio, C., Gayko, J., Handmann, U., and Kalinke, T., 2000. Scene analysis and organization of behavior in driver assistance systems, *IEEE International Conference on Image Processing (ICIP)*, vol. 3, pp. 524-527.
- [163] Haltakov, V., Belzner, H., and Ilic, S., 2012. Scene understanding from a moving camera for object detection and free space estimation, *IEEE Intelligent Vehicles Symposium (IV)*, pp. 105-110.
- [164] Li, L., J., Socher, R., and Fei-Fei, L., 2009. Towards total scene understanding: Classification, annotation and segmentation in an automatic framework, *IEEE Computer Vision and Pattern Recognition (CVPR)*, pp. 2036-2043.
- [165] Graf, R., Deusch, H., Fritzsche, M., and Dietmayer, K., 2013. A learning concept for behavior prediction in traffic situations, *IEEE Intelligent Vehicles Symposium (IV)*, pp. 672-677.
- [166] Mabuchi, R., and Yamada, K., 2013. Prediction of driver's stop or go at yellow traffic signal from vehicle behavior, *IEEE Intelligent Vehicles Symposium (IV)*, 2013 pp. 1161-1166.
- [167] Morris, B., T., and Trivedi, M., M., 2011. Trajectory learning for activity understanding: Unsupervised, multilevel, and long-term adaptive approach, *IEEE Transactions on Pattern Analysis and Machine Intelligence (PAMI)*, vol. 33-11, 2287-2301.
- [168] Thomas, G., and Donikian, S., 2000. Virtual humans animation in informed urban environments, *IEEE Computer Animation 2000*, pp. 112-119.
- [169] Vatavu, A., and Nedeveschi, S., 2013. Modeling unstructured environments with dynamic persistence grids and object delimiters in urban traffic scenarios. *IEEE Intelligent Vehicles Symposium (IV)*, pp. 505-510.
- [170] Doshi, A., and Trivedi, M., M., Head and eye gaze dynamics during visual attention shifts in complex environments, *Journal of vision*, vol. 12-2, article 2, no 9.
- [171] Ohn-Bar, E., and Trivedi, M., M., 2013. Joint angles similarities and HOG2 for action recognition, *IEEE Computer Vision and Pattern Recognition Workshops (CVPRW)*, pp. 465-470.
- [172] Reilly, V., Idrees, H., and Shah, M., 2010. Detection and tracking of large number of targets in wide area surveillance. *European Conference Computer Vision (ECCV)*, Springer Berlin Heidelberg, pp. 186-199.

- [173] Weiss, T., Schiele, B., and Dietmayer, K., 2007. Robust driving path detection in urban and highway scenarios using a laser scanner and online occupancy grids, *IEEE Intelligent Vehicles Symposium*, pp. 184-189.
- [174] Schoepflin, T., N., and Dailey, D., J., 2003. Dynamic camera calibration of roadside traffic management cameras for vehicle speed estimation, *IEEE Transactions on Intelligent Transportation Systems*, vol. 4-2, pp. 90-98.
- [175] Kanhere, N., K., and Birchfield, S., T., 2010. A taxonomy and analysis of camera calibration methods for traffic monitoring applications, *IEEE Transactions on Intelligent Transportation Systems*, vol. 11-2, pp. 441-452.
- [176] Taghvaeeyan, S., and Rajamani, R., 2014. Portable Roadside Sensors for Vehicle Counting, Classification, and Speed Measurement, *IEEE Transactions on Intelligent Transportation Systems*, pp. 73-83.
- [177] Karaduman, O., Eren, H., Kurum, H. and Celenk, M., 2014. Graph-Cut Based Regional Risk Estimation for Traffic Scene, *IEEE Intelligent Transportation System Conference (ITSC 2014)*, Qingdao, China, 8-11 October, pp. 968-973.
- [178] Karaduman, O., Eren, H., Kurum, H. and Celenk, M., 2014. Regional Risk Estimation for Drivers Cutting Intelligent Graph with Intra-Cells Enabling Risk Transfer for Street Players, *IEEE International Conference on Connected Vehicle & Expo (ICCVE 2014)*, Vienna, Austria, 3-7 November.
- [179] Karaduman, O., Eren, H., Kurum, H. and Celenk, M., 2014. Probabilistic Risk Assessment using Major Features of Rural Road Curves via Rear and Front Car Cameras, *IEEE International Conference on Connected Vehicle & Expo (ICCVE 2014)*, Vienna, Austria. 3-7 November.
- [180] Llorca, D., F., Sotelo, M., A., Hellín, A., M., Orellana, A., Gavilan, M., Daza, I., G., and Lorente, A., G., 2012. Stereo regions-of-interest selection for pedestrian protection: A survey, Elsevier *Transportation research part C: Emerging technologies*, pp. 226-237.
- [181] Aliane, N., Fernández, J., Bemposta, S., and Mata, M., 2012. Driver behavior monitoring system based on traffic violation, *IEEE Intelligent Vehicles Symposium (IV)*, pp. 1096-1101.

- [182] Fox, D., Burgard, W., and Thrun, S., 1997. The dynamic window approach to collision avoidance, *IEEE Robotics & Automation Magazine*, vol. 4(1), pp. 23-33.
- [183] Wenjuan, E., Wang, Y., Lu, Y., Tian, D., and Lu, G., 2014. Vehicle Collision Avoidance Algorithm at Blind Crossing Based on Internet-Connected Vehicles, *CICTP*, pp. 1194-1203.
- [184] Reif, K., 2014. Adaptive cruise control, *Springer Fachmedien Wiesbaden, Fundamentals of Automotive and Engine Technology*, pp. 202-209.
- [185] Liu, Y., C., and Wu, T., J., 2009. Fatigued driver's driving behavior and cognitive task performance: Effects of road environments and road environment changes, *Safety Science*, vol. 47-8, pp. 1083-1089.
- [186] Akrouf, B., and Mahdi, W., 2013. A visual based approach for drowsiness detection. *IEEE Intelligent Vehicles Symposium (IV)*, pp. 1324-1329.
- [187] Bartra, A., Meca, P., Guaman, A., Pardo, A., Marco, S., and Montesi, A., 2012. A feasibility study of drowsiness detection using driving behaviour parameters, *IEEE Intelligent Vehicles Symposium (IV)*, pp. 111-116.
- [188] Ahlstrom, C., Kircher, K., and Kircher, A., 2013. A gaze-based driver distraction warning system and its effect on visual behavior, *IEEE Transactions on Intelligent Transportation Systems*, vol. 14-2, pp. 965-973.
- [189] Wang, J., Zhang, L., Zhang, D., and Li, K., 2013. An adaptive longitudinal driving assistance system based on driver characteristics, *IEEE Transactions on Intelligent Transportation Systems*, vol. 14-1, pp.1-12.
- [190] Yekshatyan, L., and Lee, J., D., 2013. Changes in the correlation between eye and steering movements indicate driver distraction, *IEEE Transactions on Intelligent Transportation Systems*, vol.14-1, pp. 136-145.
- [191] McCall, J., C., and Trivedi, M., M., 2007. Driver behavior and situation aware brake assistance for intelligent vehicles, *Proceedings of the IEEE*, vol. 95-2, pp. 374-387.
- [192] Blaschke, C., Breyer, F., Färber, B., Freyer, J., and Limbacher, R., 2009. Driver distraction based lane-keeping assistance, *Elsevier Transportation research part F: traffic psychology and behaviour*, vol. 12-4, pp. 288-299.
- [193] Karl, I., Berg, G., Rüger, F., and Farber, B., 2013. Driving Behavior and Simulator Sickness While Driving the Vehicle in the Loop: Validation of Longitudinal Driving Behavior. *IEEE Intelligent Transportation Systems Magazine*, vol. 5-1, pp. 42-57.

- [194] Angkititrakul, P., Miyajima, C., and Takeda, K., 2012. An improved driver-behavior model with combined individual and general driving characteristics, *IEEE Intelligent Vehicles Symposium (IV)*, pp. 426-431.
- [195] Kusano, K., D., and Gabler, H., C., 2012. Identification of target populations for current active safety systems using driver behavior, *IEEE Intelligent Vehicles Symposium (IV)*, pp. 655-660.
- [196] Van Ly, M., Martin, S., and Trivedi, M., M., 2013. Driver classification and driving style recognition using inertial sensors, *IEEE Intelligent Vehicles Symposium (IV)*, pp. 1040-1045.
- [197] Bando, T., Takenaka, K., Nagasaka, S., and Taniguchi, T., 2013. Unsupervised drive topic finding from driving behavioral data, *IEEE Intelligent Vehicles Symposium (IV)*, pp. 177-182.
- [198] Wang, K., Huang, W., Tian, B., and Wen, D., 2012. Measuring Driving Behaviors from Live Video, *IEEE Intelligent Systems*, vol. 27-5, pp. 75-80.
- [199] Saruwatari, K., Sakaue, F., and Sato, J., 2012. Detection of abnormal driving using multiple view geometry in space-time, *IEEE Intelligent Vehicles Symposium*, pp. 1102-1107.
- [200] Muehlfeld, Florian, et al., 2013. Statistical Behavior Modeling for Driver-Adaptive Precrash Systems, *IEEE Transactions on Intelligent Transportation Systems*, pp. 1764-1772.
- [201] Kircher, K., Larsson, A., and Hultgren, J., A., 2014. Tactical Driving Behavior With Different Levels of Automation, *IEEE Transactions on Intelligent Transportation Systems*, pp. 158-167.
- [202] Klauer, S., G., Dingus, T., A., Neale, V., L., Sudweeks, J., D., and Ramsey, D., J., 2006. The impact of driver inattention on near-crash/crash risk: An analysis using the 100-car naturalistic driving study data, *Transportation Research Board*, No. HS-810 594.
- [203] Taniguchi, T., Nagasaka, S., Hitomi, K., Chandrasiri, N. P., & Bando, T., 2012. Semiotic prediction of driving behavior using unsupervised double articulation analyzer, *IEEE Intelligent Vehicles Symposium (IV)*, pp. 849-854.

- [204] Martin, S., Tran, C., and Trivedi, M., 2012. Optical flow based head movement and gesture analyzer (ohmega), *International Conference on Pattern Recognition (ICPR)*, pp. 605-608.
- [205] Tran, C., Doshi, A., and Trivedi, M., M., 2012. Modeling and prediction of driver behavior by foot gesture analysis, *Computer Vision and Image Understanding*, vol. 116-3, pp. 435-445.
- [206] Tran, C., Doshi, A., and Trivedi, M., M., 2011. Pedal error prediction by driver foot gesture analysis: A vision-based inquiry, *IEEE Intelligent Vehicles Symposium (IV)*, pp. 577-582.
- [207] Ohn-Bar, E., and Trivedi, M., 2013. In-vehicle hand activity recognition using integration of regions. In *Intelligent Vehicles Symposium (IV)*, 2013 IEEE (pp. 1034-1039). IEEE. [15]
- [208] Berndt, H., Wender, S., and Dietmayer, K., 2007. Driver braking behavior during intersection approaches and implications for warning strategies for driver assistant systems, *IEEE Intelligent Vehicles Symposium*, pp. 245-251.
- [209] Gonzalez, R., C., Woods, R., E., Eddins, S., L., 2004. Digital image processing using MATLAB, *Pearson Prentice Hall*.
- [210] Horn, B., and Schunk, B., 1981. Determining optical flow, *Artificial Intelligent*, 17, 185–203.
- [211] Thompson, A., M., Brown, J., C., Kay, J., W. and Titterington, D., M., 1991. A study of methods of choosing the smoothing parameter in image restoration by regularization, *IEEE Transact On Pattem Analysis and Machine Intelligence*, vol. 13, pp. 326-339.
- [212] Duda, R., O., Hart, P., E., Stork, D., G., 2001. Pattern Classification, Second Edition, *Wiley-Interscience Publication*.
- [213] H. Z. Yin, F. Porikli, R. Collins, 2008. Likelihood map fusion for visual object tracking. *IEEE Workshop on Application of Computer Vision (WACV)*, Colorado.
- [214] J. Wang, G. Bebis, R. Miller, 2005, Overtaking Vehicle Detection Using Dynamic and Quasi-Static Background Modeling, *IEEE CVPR*, vol. 3, pp. 64-71.
- [215] K., S., Vedula, S., Baker, P., Rander, R. Collin, and T., Kanade, 2005. Three-Dimensional Scene Flow, *IEEE PAMI*, vol. 27.
- [216] <http://www.auterraweb.com/> , OBD Data Scan Tool.

- [217] Broggi, A., Cerri, P., Ghidoni, S., Grisleri, P., and Jung, H., G., 2009. A new approach to urban pedestrian detection for automatic braking, *IEEE Transactions on Intelligent Transportation Systems*, vol. 10-4, pp. 594-605.
- [218] De la Escalera, A., Armingol, J., M., and Mata, M., 2003. Traffic sign recognition and analysis for intelligent vehicles, *Image and Vision Computing*, vol. 21-3, pp. 247-258.
- [219] Boykov, Y., Veksler, O., and Zabih, R., 2001. Fast approximate energy minimization via graph cuts, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, pp. 1222-1239.
- [220] Bondy, J., A., and Murty, U., S., R., 1976. Graph theory with applications, vol. 6, London, Macmillan.
- [221] Ahuja, R., K., Magnanti, T., L., and Orlin, J., B., 1993. Network flows: theory, algorithms, and applications, *Prentice Hall*.
- [222] Boykov, Y., and Funka-Lea, G., 2006. Graph cuts and efficient ND image segmentation, *International journal of computer vision*, pp. 109-131.
- [223] Boykov, Y., and Jolly, M., P., 2001. Interactive graph cuts for optimal boundary and region segmentation of objects in ND images, *IEEE International Conference on Computer Vision (ICCV 2001)*, vol. 1, pp. 105-112.
- [224] Campbell, M., Egerstedt, M., How, J., P., and Murray, R., M., 2010. Autonomous driving in urban environments: approaches, lessons and challenges, *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, vol. 368-1928, pp. 4649-4672.
- [225] Kirk, B., and Eng, P., 2011. Connected Vehicles: An executive overview of the status and trends. *Globis Consulting*.
- [226] Schwarz Ph D., C., Thomas, Ph D., G., Nelson, B., S., McCrary, B., S., Schlarmann, N., and Powell, M., 2013. Towards Autonomous Vehicles, <http://digitalcommons.unl.edu/matcreports/92/>, *University of Nebraska-Lincoln*.
- [227] Ozguner, U., Acarman, T., and Redmill, K., A., 2011. Autonomous ground vehicles. *Artech House*.
- [228] Silberg, G., Wallace, R., Self-driving cars: Thenext revolution, *Center for automotive research, kpmg.com, cargroup.org*.

- [229] Furda, A., and Vlacic, L., 2011. Enabling safe autonomous driving in real-world city traffic using multiple criteria decision making, *IEEE Intelligent Transportation Systems Magazine*, vol. 3-1, pp. 4-17.

ÖZGEÇMİŞ

Özgür KARADUMAN, 1999 yılında Karadeniz Teknik Üniversitesi Mühendislik-Mimarlık Fakültesi Bilgisayar Mühendisliği Bölümünden mezun oldu. 2000 senesinde Fırat Üniversitesi Enformatik Bölümünde öğretim elemanı olarak akademik hayatına başladı. 2004 yılında Yüksek Lisans öğrenimini tamamladı. Doktora çalışmaları esnasında tamamı IEEE veritabanında yer alan 7 uluslararası konferansa katılım sağladı ve zaman zaman Akıllı Ulaşım Sistemleri üzerine IEEE organizasyonu olan bazı uluslararası konferanslarda hakem komitelerinde yer aldı. Doktora çalışmaları esnasında ayrıca, TÜBİTAK' ın 113M090 numaralı projesinde bursiyer olarak görev aldı. Halen Fırat Üniversitesi Teknik Bilimler MYO Bilgisayar Teknolojileri Bölümünde öğretim elemanı olarak çalışmaktadır.