

**T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**VIDEO GÖRÜNTÜLERİNDEN TRAFİK KAZASI RİSKİNİ GERÇEK ZAMANLI
BELİRLEYEN BİR SİSTEM TASARIMI**

UYGAR ER

**YÜKSEK LİSANS TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI
BİLGİSAYAR MÜHENDİSLİĞİ PROGRAMI**

**DANIŞMAN
YRD. DOÇ. DR. M. ELİF KARSLIGİL**

İSTANBUL, 2012

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**VIDEO GÖRÜNTÜLERİNDEN TRAFİK KAZASI RİSKİNİ GERÇEK ZAMANLI
BELİRLEYEN BİR SİSTEM TASARIMI**

Uygar ER tarafından hazırlanan tez çalışması 10.10.2012 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı'nda **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Tez Danışmanı

Yrd. Doç. Dr. M. Elif KARSLIGİL
Yıldız Teknik Üniversitesi

Jüri Üyeleri

Yrd. Doç. Dr. M. Elif KARSLIGİL
Yıldız Teknik Üniversitesi

Doç. Dr. Yusuf Sinan AKGÜL
Gebze Yüksek Teknoloji Enstitüsü

Prof. Dr. Nizamettin AYDIN
Yıldız Teknik Üniversitesi

Çağımızda, kapasitesinin üzerinde gelişen ve insan yoğunluğu barındıran metropol şehirlerde trafik sorunu, çözülmesi ve kontrolü zor unsurlar barındırmaktadır. Bu çalışmada, olağandışı veya kaza riski içeren trafik davranışlarında bulunan araçların tespit edilerek en kısa sürede müdahale edilmesini sağlayacak ve bu tespitler üzerinden çeşitli analiz çalışmalarının yapılmasına imkan tanıyacak bir sistem geliştirilmesi hedeflenmiştir.

Lisans ve yüksek lisans eğitimim boyunca ve bu tez çalışması sürecinde bana her konuda destek olan ve yol gösteren, değerli tecrübelerini ve bilgilerini esirgemeyen, problemlere farklı bakış açıları ile yaklaşmamızı sağlayan ve bu uzun süreçte karşılaştığımız her engelde bize moral kaynağı olan değerli tez danışmanım Sayın Yrd. Doç. Dr. M. Elif Karslıgil'e teşekkürlerimi sunarım.

Bu tez çalışmasında bana eğitimin sadece okulda değil hayatın her anında devam ettiğini bir kez daha hatırlatan, kişisel zamanını problemlerimize ayıran ve referans aldığımız doktora çalışması ile bu çalışmanın sonuçlanmasında büyük emeği bulunan Sayın Dr. Ömer Aköz'e teşekkürlerimi sunarım.

Yüksek lisans eğitimim boyunca bana her konuda desteğini esirgemeyen, çok farklı bakış açıları edinmemi sağlayan, bir eğitmen öğrenci ilişkisinin ötesinde arkadaş gibi yaklaşan Yıldız Teknik Üniversitesi Bilgisayar Mühendisliği Bölümü ve Fen Bilimleri Enstitüsü çalışanlarına teşekkürü bir borç bilirim.

Bu çalışmada karşılaştığım her türlü zorluğun üstesinden gelmede tüm özverisi ile yardımcı olan, gerçekleştirdiği olağandışı trafik olaylarının analizini referans olarak kullandığım ve tezin bu halini almasında büyük katkıda bulunan değerli arkadaşım Süleyman Yüksel'e sonsuz teşekkürlerimi sunarım.

Bu çalışmada sürecinde ihtiyaç duyduğum her anda yanımda olduğunu hissettiren değerli arkadaşlarım Ülkü Vural, Nalan Öztürk, Özgür Meral ve Alp Eren Bal'a teşekkürlerimi sunarım.

Hayatta ihtiyaç duyduğum her anda beni koşulsuz destekleyen, moral veren ve kendime gelmemi sağlayan sevgili aileme sonsuz teşekkürlerimi sunarım.

Ekim, 2012

Uygar ER

İÇİNDEKİLER

	Sayfa
SİMGE LİSTESİ.....	vii
KISALTMA LİSTESİ.....	viii
ŞEKİL LİSTESİ.....	ix
ÇİZELGE LİSTESİ	xi
ÖZET.....	xii
ABSTRACT.....	xiv
BÖLÜM 1	
GİRİŞ.....	1
1.1 Literatür Özeti	2
1.2 Tezin Amacı	9
1.3 Hipotez	10
BÖLÜM 2	
SİSTEM TASARIMI... ..	11
2.1 Trafik Kazalarına Ait Video Veritabanının Hazırlanması	12
BÖLÜM 3	
GENEL YOL MODELLERİNİN ÖĞRENİLMESİ.....	14
3.1 Araçların Belirlenmesi, Takip Edilmesi ve Hareket Yörüngelerinin Üretilmesi.....	16
3.1.1 Video Görüntüsünün İyileştirilmesi.....	17
3.1.2 Adaptif Gauss Karışım Modeli Yöntemi İle Görüntü Çerçevelerinin Arka ve Ön Planların Çıkarılması ve Araç Temsil Noktasının Tespiti	19

3.1.3	Optik Akış Yöntemi İle Araç Takibi.....	23
3.2	Hareket Yörüngelerinin Kümelenmesi ve Genel Yol Modellerinin Üretilmesi.....	29
3.2.1	Hareket Yörüngelerinin Kümelenmesi	31
3.2.2	HMM ve Gauss Karışımı Yöntemi ile Hareket Yörüngesi Kümeleme .	31
3.2.3	Saklı Markov Modeli.....	32
3.2.3.1	İleri-Geri Algoritması.....	33
3.2.3.2	Viterbi Algoritması	35
3.2.3.3	Baum-Welch Algoritması	36
3.2.4	Sürekli Saklı Markov Modeli	37
3.2.5	Sürekli Saklı HMM Kullanılarak Genel Yol Modellerinin Öğrenilmesi	38
BÖLÜM 4		
	ANOMALİ DURUMLARININ BELİRLENMESİ VE KAZA TAHMİNİ....	42
4.1	Kısmi Hareket Yörüngelerinin Üretilmesi ve Genel Yol Modelleri ile Sınıflandırılması.....	43
4.1.1	Sınıflandırma Benzerlik Değerinin Hesaplanması.....	44
4.2	Anomali Trafik Davranışlarının Belirlenmesi.....	48
4.3	Kaza Risk Faktörünün Hesaplanması	51
4.3.1	Anlık Doğrultunun Belirlenmesi	52
4.3.2	Anlık Hızın Hesaplanması	53
4.3.3	İlgi Alanının Belirlenmesi	53
4.3.4	Kaza Riskinin Hesaplanması.....	55
4.3.5	Kaza Risk Faktörünün Sınıflandırılması.....	56
4.3.6	Anomali Durumların Kaza Risk Kategorisine Etkisi.....	57
4.3.7	Kaza Riskinin Kavşak Modelinde İncelenmesi	58
BÖLÜM 5		
	DENEYSEL SONUÇLAR..	60
5.1	Araç Hareket Yörüngelerinin Üretilmesi ve Kümelenmesi	60
5.2	Kısmi Hareket Yörüngelerinin Sınıflandırılması	64
5.2.1	Komşuluğu Olmayan Genel Yol Modelleri Arasındaki Geçiş Durumu	69
5.2.2	Aracın Öğrenilen Genel Yol Modellerinin Dışına Çıkma Durumu.....	71
5.2.3	Aracın Ters Yönde İlerleme Durumu	73
5.3	Trafik Kazası Tahmin Süreci	75

5.3.1	Araçların Işık İhlali Nedeniyle Oluşan Kaza Durumu	75
5.3.2	Aracın Yanlış Dönüş Yapması Sonucu Oluşan Kaza Durumu	79
5.3.3	Kaza Olasılığı Oluşan Araç Davranışları	82
5.3.4	Kaza Durumlarının İncelendiği İlişkili Genel Yol Modelleri.....	84
5.4	DeneySEL Sonuçların Değerlendirilmesi	85
BÖLÜM 6		
SONUÇ VE ÖNERİLER....		88
KAYNAKLAR.....		90
ÖZGEÇMİŞ		93

SİMGE LİSTESİ

σ	Gauss dağılımının standart sapması
W	Görüntü çerçevesinin bir noktasının komşu noktaları
η	Gauss olasılık yoğunluk fonksiyonu
$w_{i,t}$	t anında i. Gauss karışımının ağırlığı
$\mu_{i,t}$	t anındaki i. Gauss dağılımının ortalaması
$\Sigma_{i,t}$	Kovaryans matrisi
u	Takip edilmek istenilen nokta
d	Yer değiştirme
Π	Saklı Markov başlangıç durumu olasılıkları
λ	Markov parametreleri
$\xi_t(i,j)$	Baum-Welch birleşik olasılık parametresi
S	Markov modelinin saklı durumları
M	Markov modelde gözlemlenebilecek durumlar
μ	Gauss karışım modeli sınıf ortalama değeri
θ	Kısmi yörünge açısı
D	Kısmi yörünge genel yol modellerine dik uzaklığı
R	Yörünge genel benzerlik değeri

KISALTMA LİSTESİ

GYM	Genel Yol Modeli
HMM	Hidden Markov Model
WHO	World Health Organization
GMM	Gaussian Mixture Model
SVM	Support Vector Machines
PW	Parzen Window
NN	Neural Network
DTW	Dynamic Time Wrapping
ROI	Region of Interest
PDF	Probability Density Function
SONN	Self-Organizing Neural Network
KNN	K-Nearest Neighborhood
NGSIM	Next Generation Simulation
TRIMARC	Traffic Response and Incident Management Assisting the River Cities

ŞEKİL LİSTESİ

	Sayfa
Şekil 1.1	Hu ve arkadaşlarının aracın 3D modellemesi ve ilgi alanı gösterimi 3
Şekil 1.2	Trivedi'nin hareket yörüngesi tahmini 4
Şekil 1.3	Sha'nın hareket yörüngesi kümelemesi gösterimi..... 5
Şekil 1.4	Jouneau ve Carincotte'un önerdikleri araç takibi ve trafik modelleri 6
Şekil 1.5	Araçların t ve $t+1$. sürelerde çarpışma risk durumları 6
Şekil 1.6	Ammoun'un kaza modellemesi 7
Şekil 1.7	Potansiyel çarpışma bölgelerinin olasılıksal yoğunluk fonksiyonları 9
Şekil 2.1	Sistemin genel akışı 12
Şekil 3.1	Genel yol modellerini öğrenen alt sistemin blok şeması 15
Şekil 3.2	Orjinal, Gauss filtresi ve Medyan filtresi uygulanmış görüntü çerçeveleri.. 18
Şekil 3.3	Görüntü çerçevelerinden araç segmentasyonu 20
Şekil 3.4	Araçların arka plandan ayrılması..... 23
Şekil 3.5	Dış çevritleri belirlenmiş aracın merkez noktasının belirlenmesi 23
Şekil 3.6	Optik akış yönteminde t . ve $t+1$. zamanda takip noktasının değişimi 24
Şekil 3.7	Piramitsel optik akışın gösterimi..... 26
Şekil 3.8	Video görüntüsünün piramitsel olarak gösterilmesi 27
Şekil 3.9	Takip edilen ve takipleri tamamlanmış araçların hareket yörüngeleri 29
Şekil 3.10	HMM ve Gauss Karışımı yapısının kavşak modeli üzerinde gösterimi 39
Şekil 3.11	Üretilen hareket yörüngeleri ve kümelenmiş genel yol modelleri..... 41
Şekil 4.1	Anomali durumların tespiti ve kaza risk hesabı 43
Şekil 4.2	Kısmi yörünge pencere boyutunun gösterimi 44
Şekil 4.3	Araçların uzaklık benzerliklerinin hesaplanması..... 45
Şekil 4.4	Araçların açısal benzerliklerinin hesaplanması 47
Şekil 4.5	Anomali senaryoları 49
Şekil 4.6	Risk faktörü hesabı yarı kodu 52
Şekil 4.7	Takip edilen aracın hareket doğrultusunun bulunması 53
Şekil 4.8	Araçların ilgi alanları kesişimlerinin ve parametrelerinin gösterimi 54
Şekil 4.9	Kaza risk faktörünün kategorizasyonu 57
Şekil 4.10	Örnek kaza senaryosu 58
Şekil 5.1	Araç takibi ve hareket yörüngesinin oluşturulması 61
Şekil 5.2	Hareket yörüngelerinin ve genel yol modelinin bulunması..... 62
Şekil 5.3	3 durumlu 3 Gauss karışımı genel yol modeli 63
Şekil 5.4	HMM iterasyon sayılarının gösterimi..... 64
Şekil 5.5	Kısmi yörüngeler ve sınıflandırılacakları genel yol modelleri 65

Şekil 5.6	Takip edilen aracın hareketi sırasında kısmi yörüngelerin sınıflandırılması	66
Şekil 5.7	Genel yol modellerinin kesişim noktasında sınıflandırma başarısı.....	68
Şekil 5.8	Komşuluğu olmayan genel yol modelleri arasında geçiş anomali durumu .	69
Şekil 5.9	Hatalı dönüş yapan aracın sınıflandırma parametrelerinin değişimi.....	71
Şekil 5.10	Aracın öğrenilen yol modellerinin dışına çıkması	72
Şekil 5.11	Aracın ters yönde ilerlemesi	73
Şekil 5.12	Ters yöne u-dönüşü yapan araç.....	74
Şekil 5.13	Işık ihlali nedeniyle kaza durumunun gelişimi	76
Şekil 5.14	Kaza risk faktörü bileşenleri.....	77
Şekil 5.15	Işık ihlali nedeniyle kaza durumunun gelişimi	78
Şekil 5.16	Aracın yanlış yönde dönüşü sebebiyle kaza durumunun gelişimi	79
Şekil 5.17	Kaza risk faktörü bileşenleri.....	80
Şekil 5.18	Aracın yanlış yönde dönüşü sebebiyle kaza durumunun gelişimi	81
Şekil 5.19	Çarpışmaya yaklaşan araçların incelenmesi	82
Şekil 5.20	Çarpışma, anomali ve toplam risk faktörlerinin değişimi	84
Şekil 5.21	İlişkili genel yol modellerindeki kaza durumu	85

ÇİZELGE LİSTESİ

	Sayfa
Çizelge 2.1	Tez çalışmasında kullanılan veri kümeleri ve açıklamaları..... 13
Çizelge 5.1	Kısmi yörüngelerin genel yol modelleri ile benzerlikleri..... 67
Çizelge 5.2	Kısmi yörüngelerin genel yol modelleri ile yaptığı açılar 67
Çizelge 5.3	Takip edilen araca en yakın yörüngelerin uzaklık benzerlikleri 68
Çizelge 5.4	Takip edilen araca en yakın yörüngelerin uzaklık benzerlikleri 69
Çizelge 5.5	Takip edilen araca en yakın yörüngelerin uzaklık benzerlikleri 70
Çizelge 5.6	Takip edilen araca en yakın yörüngelerin açısal benzerlikleri 70
Çizelge 5.7	Kısmi yörüngeler ile 1. genel yol modeli arasında benzerliğin değişimi .. 72
Çizelge 5.8	Kaza riski olan iki aracın kaza risk faktörleri..... 76
Çizelge 5.9	Kaza riski olan iki aracın kaza risk faktörleri..... 78
Çizelge 5.10	Kaza riski olan iki aracın kaza risk faktörleri 80
Çizelge 5.11	Kaza riski olan iki aracın kaza risk faktörleri 81
Çizelge 5.12	Araçların olağandışı durumlar ile birlikte kaza risklerinin belirlenmesi... 83
Çizelge 5.13	Sistemin doğru pozitif, yanlış pozitif, doğruluk ve hassasiyet oranları.... 86

VIDEO GÖRÜNTÜLERİNDEN TRAFİK KAZASI RİSKİNİ GERÇEK ZAMANLI BELİRLEYEN BİR SİSTEM TASARIMI

Uygar ER

Bilgisayar Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

Tez Danışmanı: Yrd. Doç. Dr. M. Elif KARSLIGİL

Trafikteki can ve mal güvenliğini tehlikeye atan davranışların gözlemlenmesi, nedenlerinin anlaşılması ve bununla ilgili gerekli önlemlerin alınması günümüzde önemli araştırma konularından biridir. Trafik akışının düzenli bir şekilde sağlanması, sürücü davranışlarının caydırıcı önlemler geliştirilerek kontrol altına alınması ile mümkündür. Trafik düzeninin sağlanması trafiği oluşturan tüm unsurlar için psikolojik, zamansal ve maddi kazancı beraberinde getirir. Ancak bu durumun belki de en büyük getirisi hiç kuşkusuz insan hayatının korunması ile ilgilidir. Bu çalışmanın ana amaçlarından biri araç davranışlarının analizinde bir otomasyon sağlayarak trafik akışının ve düzeninin kontrol altına alınmasını kolaylaştırmaktır.

Bu çalışmada trafik görüntülerini kullanarak takip edilen araçların hareket yörüngelerini inceleyen, bu yörüngelerden trafik kamerasının görüntü alanındaki yol modellerini öğrenebilen, öğrenilen bu yol modelleri yardımıyla araçların olağandışı davranışlarını tespit eden ve birbirleri ile ilişkilerine göre de kaza olasılıklarını tahmin eden bir sistem tasarlanmış ve gerçekleştirilmiştir. Bu amaçla öncelikle, trafik kamerasının görüş açısındaki yolda hareket eden araçların davranışlarının öğrenilmesi sağlanmıştır. Video görüntüleri çeşitli ön işlemlerden geçirildikten sonra, Adaptif Gauss Karışım Modeli yöntemi ile ön plan, arka plandan ayrıştırılır. Sonrasında tüm araçların merkez noktası tespit edilir ve Lucas-Kanade Optik Akış yöntemi kullanılarak takip edilir. Araçların takibi sonucu üretilen hareket yörüngeleri kullanılarak kamera açısı dahilindeki yolun, araçların hareketlerine göre modellenmesi sağlanır. Bu amaçla üretilen tüm hareket

yörüngeleri kümelandikten sonra her kümeyi temsil eden ve Gauss Karışımı destekli Saklı Markov Modeli olarak ifade edilen genel yol modelleri bulunur. Sistemin uygulama aşamasında ise takip edilen araçların üretilen genel yol modellerine göre davranışları incelenir ve bu incelemelerin sonuçlarına göre anomali trafik durumları kolaylıkla tespit edilir. Bu işlemlerin ardından uygulama sürecinde takip edilen araç için üretilen kısmi yörüngelerin genel yol modelleri ile yaptığı açı ve uzaklık bilgileri kullanılarak sınıflandırma işlemi yapılır. Araçların sınıflandırıldığı yol modelindeki durumuna ve diğer araçlarla olan ilişkilerine göre anlık hız, konum, ve hareket doğrultusu parametrelerinin değerlendirilmesi sonucunda bir kaza risk faktörü değeri elde edilir. Kaza risk faktörü düşük, orta ve yüksek risk olmak üzere 3 kategoride değerlendirilir. Kaza risk faktörünün zamana göre değişimine göre de kaza riskini belirten bir alarm üretilir. Genel yol modelinin öğrenilmesi sonucu kaza risk faktörü sadece kaza yapma olasılığı bulunan yol modellerinde hareket eden araçlar arasında incelenerek sistemin çalışma performansı artırılır.

Çalışma kapsamında elde edilen deneysel sonuçlara göre sistemin %80 doğruluk ve %68 hassasiyet oranı ile kaza riskini belirlediği sonucuna ulaşılmıştır. Testlerde kazaların 2.9 ile 1 saniye öncesinden tahmin edilebildiği sonucuna ulaşılmıştır. Sistemin başarımının kamera görüş açısı, trafik yoğunluğu, hareket eden araçların doğru tespit ve takip edilmesi gibi parametrelere göre değişebildiği gözlemlenmiştir.

Araç trafiğini oluşturan unsurların otomatik olarak incelenmesi ve kaza risk faktörlerinin üretilmesi ile trafik koordinasyon merkezlerinde operatör bağımlı yapıdan daha esnek ve geliştirilebilir bir yapıya geçilebilecektir. Sistemin en önemli özelliklerinden biri yol modelinin otomatik olarak öğretilebilir olmasıdır. Bu sayede mevcut trafik kameraları kullanılarak anomali durumlarının ve kaza riskinin olduğu anlarda ilgili noktalara odaklanma sağlanabilecektir. Bu da kamera ağının insan kaynağına minimum ölçüde bağımlı hale gelmesini sağlayacak ve genişletilmesine yardımcı olacaktır. Ayrıca anomali yaratan durumların belirlenmesi ve kazaların tahmini sonrasında ihtiyaca göre polis ekiplerinin veya sağlık ekiplerinin bölgeye sevk edilmesi süreci hızlandırılabilir. Hali hazırda birçok büyük şehirde trafik kameralarının kurulu olması da bu sistemin uygulanabilirliği açısından büyük bir avantaj oluşturmaktadır.

Anahtar Kelimeler: Trafik kazası risk analizi, anomali tespiti, hareket yörüngesi kümeleme ve sınıflandırma, trafik görüntülerinde araç tespiti ve takibi

**A SYSTEM DESIGN FOR DETERMINING TRAFFIC ACCIDENT RISK FROM
REAL-TIME VIDEO IMAGES**

Uygar ER

Department of Computer Engineering

MSc. Thesis

Advisor: Assist. Prof. Dr. M. Elif KARSLİGİL

Observation of behaviors that endanger the safety of life and goods in traffic, understanding its causes and take the necessary precautions associated with it is one of the important research topics nowadays. Provision of traffic flow on a regular basis may be possible with controlling driver behaviors by improved deterrent precautions. Provision of traffic flow also brings psychological, temporal and material gain for all the elements that make up traffic. However, perhaps the greatest yield of this condition is undoubtedly related to the protection of human life. One of the main goals of this study is to facilitate the control of the traffic flow and scheme by providing an automated analysis of the vehicle behaviors.

In this study, a system is designed and implemented for examining the motion trajectories of the vehicles that are tracked by using the traffic videos, learning road models of these trajectories lead to traffic camera field of view, detecting abnormal behaviors of the vehicles with the help of road models and also estimating the probabilities of accidents according to relations with each other. For this purpose, firstly, behaviors of the vehicles that are moving on traffic camera viewing angle are learned. After application of various pre-processing methods to the video frames, foreground segmented from the background by using Adaptive Gaussian Mixture Model. Then, the central point of all the vehicles are detected and tracked by using Lucas-Kanade optical flow method. The road is modelled by using trajectories of vehicles that are produced after tracking process. For this purpose after clustering all

motion trajectories, common road models that are representing each cluster and expressed as Hidden Markov Model with Gaussian Mixture are found. In the implementation phase of the system, the behavior of the vehicles is examined according to produced common road models and, according to the result of these examining, anomaly traffic conditions are easily detected. Therefore, angle and distance information between partial trajectories of vehicles that are tracking, and common road models, are used for classification process. Following this process, an accident risk factor value is obtained in consequence of assessment of current speed, position, movement direction parameters of vehicles and detected anomalies of vehicles. Then accident risk factor is evaluated in three categories consisting of low, medium and high risk level. According to the variation of accident risk factor over time, an alarm indicating the risk of an accident is generated. As a result of learning common road models, working performance of the system is increased by examining accident risk factor only in the road models that an accident can possibly happen.

According to experimental results within the scope of this study, %80 accuracy and %68 precision rates were obtained for determining traffic accident risk. The tests concluded that accidents can be estimated 2.9 to 1 second before. It's observed that the performance of the system can be changed according to camera viewing angle, traffic density, correctly detection and tracking of moving vehicles.

As a result of the implementation of the proposed process, operator-dependent structure can be replaced by a structure that is more flexible and improved with an automatic analysis of the elements that make the traffic and production of risk factors in the traffic co-ordination centers. One of the most important features of this model is that road model is automatically trainable. In this way, by using traffic cameras installed presently, it will be possible to focus on the relevant points when only abnormal situations and the risk of accidents are formed. This helps the camera network to become dependent on minimum human resources and also will help to extend. In addition, after the identification of situations that create anomalies and prediction of accidents, dispatching police teams and medical teams to the region may accelerate the process. Currently, in many metropolitans, installed traffic cameras are a great advantage in terms of the applicability of this system.

Keywords: Traffic accident risk analyse, anomaly detection, trajectory clustering and classification, vehicle detection and tracking

BÖLÜM 1

GİRİŞ

Ulaşım sektörü, günümüzde insanlara demiryolu, denizyolu, havayolu gibi oldukça fazla seçenek sunmasına rağmen karayolu insanların gündelik hayatında en çok kullandığı ulaşım şeklidir. Karayolu trafiği insanların hayatlarında zamansal olarak önemli bir yer tutan ve ulaşım imkanlarının artması ile sürekli gelişen ve büyüyen bir olgudur. Gündelik trafiğin büyümesi mevcut şehirsels altyapıların sınırlarını zorlamakta ve trafiğin gittikçe insan hayatının planlanmasında daha önemli bir yer almasına neden olmaktadır. İnsanın, trafiğin en büyük bileşenlerinden biri olduğunu düşünürsek, büyüyen ve her geçen gün daha da karmaşıklaşan trafik ortamında insanların can ve mal güvenliğinin korunması çok önemli bir konudur.

Dünya Sağlık Örgütü'nün (WHO) açıkladığı verilere göre dünyada her yıl yaklaşık 1.3 milyon insan trafik kazaları nedeniyle hayatını kaybetmektedir [13]. Ancak gerçek rakamın kayıt dışı veriler ve ülkeler hesaba katıldığında bundan çok daha yüksek olduğu belirtilmektedir. Trafik ile ilgili sorunlar ve kazalar trafik kurallarının uygulama stratejisi ve sıklığına göre azaltılabilmektedir. Avrupa Birliği dahilindeki ülkelerde yol güvenliğinden sorumlu komisyonun yayınladığı rapora göre 1991 de 1.5 milyona yakın olan kayıtlı trafik kazalarının sayısı 2010 yılına geldiğinde gelişen ve değişen koşullara bağlı olarak 1.1 milyona gerilemiştir. Bu trafik kazalarındaki yaralanmalar ise aynı yıllar arasında yaklaşık 1.9 milyondan 1.5 milyon düzeyine inmiştir. 1991 yılında 75 bin insan bu kazalar sonucunda hayatını kaybederken 2010 yılında bu rakam 35 bin düzeyine gerilemiştir [17].

Türkiye’de trafikle ilgili istatistiksel veriler dahilinde, 2001 yılında 450 bin dolayında trafik kazası kaydedilirken, bu sayı 2010 yılına gelindiğinde 1.1 milyona ulaşmıştır. 2010

yılında ülkemizde trafik kazaları nedeniyle 4 bin dolayında insan ölmüş 210 bin dolayında insan ise yaralanmıştır [14].

Avrupa ve Türkiye için yayınlanan bu istatistiklere göre trafik kazaları Avrupa’da azalma Türkiye’de ise bir artış trendi içerisinde. Kuşkusuz insanların bilinçlendirilmesi, trafik kazalarını ve etkilerini azaltmak için en önemli faktördür. Ancak caydırıcı önlemler ve denetleme mekanizmalarının kurulması, trafik kazalarını hem önlemede hem de kazalara mümkün olduğunca çabuk müdahale edilmesinde büyük pay sahibidir.

Bu tez çalışmasında trafik kameralarından elde edilen görüntülerin, görüntü işleme ve şekil tanıma teknikleri yardımıyla analiz edilmesi sonucu trafikte tehlike yaratan araç hareketlerinin tespit edilmesi hedeflenmiştir. Bu çalışma önerdiği sistemin üreteceği sonuçları itibari ile caydırıcı, denetleyici ve kaza sonrasında gerekli önlemlerin alınma sürecini hızlandırıcı faktörleri barındırmaktadır. Sonuç olarak bu çalışma trafiğin denetleme sürecindeki insan faktörünün etkisini düşürerek, olağandışı olayları veya kazaları tahmin ve tespit etmeyi hedefler.


Bu çalışma Yıldız Teknik Üniversitesi Bilgisayar Mühendisliği Bölümü Akıllı Sistemler Laboratuvarında, trafik kazalarının analizine yönelik yapılan araştırma projesi kapsamında gerçekleştirilen üç lisansüstü tezinden biridir. Projenin ilk bölümünde bir doktora çalışması olarak “Kısmi Araç Yörüngeleri Kullanımı ile Kavşaklardaki Trafik Olaylarının Görüntü Tabanlı Çözümlemesi” çalışması yapılmıştır [18]. Bu tez çalışmasında projenin ikinci bölümü olan, olağandışı trafik davranışlarının belirlenmesi [28] kapsamında yapılan çalışmalar kaynak alınarak, tespit edilen olağandışı olaylar trafik kazası riskini arttırıcı faktörler olarak değerlendirilmektedir.

1.1 Literatür Özeti

Bu bölümde araçların hareket karakteristiklerini ve kaza risklerini inceleyen önceki çalışmalar hakkında bilgi verilmiştir.

Hu ve arkadaşlarının yaptıkları çalışmada [1] üç boyutlu model tabanlı araç takibi yöntemi kullanılarak trafik kazası tahmini yapılan olasılıksal bir model önerilmiştir. Hareket yörüngeleri üç boyutlu model tabanlı araç takibi yaparak oluşturulmuştur. Oluşturulan hareket yörüngelerinden kendi kendini düzenleyen Sinir Ağları yöntemi


(Self-Organizing Neural Network-SONN) kullanılarak aktivite desenleri üretilmiştir. Sonuç olarak takip edilen araçların kısmi yörüngeleri ile öğrenilen yörüngeler eşleştirilerek trafik kazası olma olasılıkları tahmin edilmeye çalışılmıştır. Kaza tahmini sırasında ilgili alanı sadece araç çerçeveleridir ve kaza uyarısı bu çerçevelerin kesişmeleri durumunda üretilmiştir. Bu çalışmada Kohonen yapay sinir ağları ile kendi kendini düzenleyen sinir ağları karşılaştırılmış ve kendi kendini düzenleyen yapay sinir ağlarının kaza sınıflandırmasında daha efektif sonuç verdiği sonucuna ulaşılmıştır. Yapılan çalışma kapsamında deneyler, yapay bir trafik ortamında sentetik data üzerinde gerçekleştirilmiştir. Şekil 1.1’de kaza durumu incelenen aracın ilgi alanı (Region of Interest-ROI) ve 3D modellemesi gösterilmiştir.



Şekil 1.1 Hu ve arkadaşlarının aracın 3D modellemesi ve ilgi alanı gösterimi [1]

Lin ve arkadaşları tarafından nesne sınıflandırması ve kaza tahmini fonksiyonları olan çeşitli türden nesneleri takip edebilen bir sistem önerilmiştir [2] . Bu çalışmada hareket eden nesneler Adaptif Arkaplan Restorasyonu (Adaptive Background Reconstruction) yöntemi ile belirlenmiştir. Nesneleri takip ederken çalışma kapsamında önerilen özellik tabanlı takip yöntemi kullanılmıştır. Bu yöntemde hareket eden nesneler büyük araçlar, normal araçlar bisikletler ve yayalar olarak sınıflandırılmıştır. Araçların takip noktaları arasında deneysel olarak belirlenen bir uzaklık eşik değeri kullanılarak araçların takip noktalarının üst üste gelip gelmedikleri ve önceki takip izlerinin kesişip kesişmedikleri belirlenip kaza olasılığı değerlendirilmiştir. Takip edilen araçlarla ilgili önceden yapılan bir öğrenme işlemi bulunmamakta, kaza tahmini anlık takip verilerine göre yapılmaktadır. Bu çalışmada kavşak noktalarından elde edilmiş gerçek trafik görüntülerinden oluşan bir görüntü veri tabanı kullanılmıştır.


Trivedi ve Morris tarafından araç takibine dayanan iki farklı aktivite analizi çalışması yapılmıştır [3]. Otoyoldaki araç türlerini inceleyen analizde araçları sekiz farklı gruba sınıflandıran ve araçların takip yörüngelerinden yararlanarak trafik akış istatistikleri ile ilgili bilgi toplayan bir yöntem önerilmiştir. Araç türlerinin sınıflandırılması için k-en yakın komşuluk yöntemi (K-Nearest Neighborhood-KNN) kullanılmıştır. Bu yöntemde araçların merkez noktaları belirlenerek Kalman Filtresi ile takip edilmiştir. Takip edilen araçlarla ilgili elde edilen veriler ve ulaşılan istatistiksel bilgiler sisteme sürekli geri beslenmiştir. Araçların hareket desenlerinin karakteristik özellikleri ise Saklı Markov Modeli (Hidden Markov Model-HMM) kullanılarak öğrenilmiştir. Öğrenilen aktivite sistemi kullanılarak, daha sonra takip edilen araçlarla ilgili olağandışı aktiviteler ve gelecekteki hareket yörüngesi tahmin edilmeye çalışılmıştır. Sistemin başarımlarını elde edebilmek için gerçek ortam kameraları ve simülasyon görüntülerinin her ikisiyle de çalışılmıştır. Şekil 1.2’de Trivedi ve Morris’in çalışmasında bir aracın hareketi sırasında daha önce öğrenilen genel yol modellerine aitlik oranlarının değişimi gösterilmiştir.



Şekil 1.2 Trivedi'nin hareket yörüngesi tahmini [3]

Sha ve arkadaşları tarafından kavşak noktalarından geçen araçların davranışlarını analiz eden bir sistem önerilmiştir [4]. Burada ilgi alanına giren araçların hareket yörüngeleri GPS vericilerden gelen konum ve hız bilgisi ile elde edilmiştir. Elde edilen hareket yörüngeleri için aykırı örneklerin temizlenmesi sonrasında Gauss dağılımı kullanılarak rota modellemesi yapılmıştır. Kavşak için tüm rota modellerin öğrenilmesi sonrasında Olasılıksal Bayes yöntemi kullanarak takip edilen araçların hareket yörüngelerinin rota modelleri ile benzerlik oranları çıkartılmış ve olağandışı trafik davranışları belirlenmiştir. Yapılan sınıflandırma işleminde deneysel olarak belirlenen bir benzerlik eşik değeri dışındaki sonuçlar olağandışı davranış olarak nitelendirilmiştir. Bu

çalışmadaki sonuçlar sentetik trafik ortamından elde edilmiştir. Şekil 1.3’de çalışmada üretilen hareket yörüngeleri, bu yörüngelerin sınırları ve bu yörüngelerin kümelenmesi ile oluşturulan merkez yörünge gösterilmiştir.




Şekil 1.3 Sha’nın hareket yörüngesi kümelemesi gösterimi [4]

Jouneau ve Carincotte tekrarlayan trafik aktivitelerini otomatik olarak belirleyen ve bu aktiviteler arasındaki ilişkileri inceleyen yeni bir sistem önermişlerdir [5]. Bu çalışmada yalnızca kavşaklardaki trafik davranışları ile ilgilenilmiştir. Bu çalışmada araçlar parçacık tabanlı takip yöntemi (Particle-Based Tracking) ile takip edilmiştir. Bu yöntemle göre ardışık çerçevelerin farkları alınarak, çerçeve üzerine rastgele dağıtılan parçacıklardan hareket eden nesneler üzerine denk gelenleri tespit edilmeye çalışılmıştır. Bu sayede tekrar arka plan modelleme işlemi yapılmamıştır. Ancak takip işlemi görüntü gürültülerine oldukça açık hale gelmiştir. Ayrıca duraklayan nesnelerin izinin kaybedilmesi olasılığı artmıştır. Oluşturulan hareket yörüngelerini kaynak olarak alan bu çalışmada sınıflandırma için Gauss Karışımı (Gaussian Mixture) destekli Saklı Markov Modeli kullanılmıştır. Benzer trafik davranışlarının tekrarlarının tespit edilmesi işlemi Saklı Markov Modelinin parametrik olmayan Bayes versiyonu kullanılarak yapılmıştır. Sonuç olarak yanlış yöne dönme, ters yönde gitme gibi daha önce öğrenilmeyen trafik davranışları tespit edilmiştir. Önerilen sistem tek bir gerçek trafik görüntüsü ile test edilmiştir. Hatalı durumların tespitinde yaklaşık %70 başarımlı oranı verilmiştir. Şekil 1.4’de soldaki görüntüde parçacık tabanlı takip yöntemi ile takip edilen araçlar, sağdaki görüntüde ise bu araçların hareket yörüngeleri gösterilmiştir.




Şekil 1.4 Jouneau ve Carincotte'un önerdikleri araç takibi ve trafik modelleri [5]

Kiang ve Tu'nun yaptığı çalışmada, iki aracın konum, hız ve hızlanma bilgileri incelenerek kaza riskleri tahmin edilmeye çalışılmıştır [6]. Bu çalışmada araçların geçmiş hareket yörüngeleri incelenmemiş, sadece anlık çarpışma riskleri tespit edilmeye çalışılmıştır. Araçların radyal uzaklık, hız ve ivme bilgilerinin sensörler vasıtası ile elde edildiği kabul edilmiştir. Bu çalışmada lineer Kalman Filtresi, iki durumlu (two-stage) Kalman Filtresi, genişletilmiş (extended) Kalman Filtresi ve gürbüz (robust) Kalman filtrelerinin kaza tahmini sırasındaki performansları incelenmiştir. Gürbüz Kalman filtresi, diğer yöntemler ile karşılaştırıldığında hızlanma ve ani dönüş durumlarında kaza tahmin performansını arttıran yöntem olarak önerilmiştir. Önerilen sistem farklı yöntemlerle karşılaştırılarak simulasyon ortamında test edilmiştir. Şekil 1.5'de araçların t ve $t+1$ zamanında bulundukları konumlar ve araçların ilgi alanları gösterilmiştir.



Şekil 1.5 Araçların t ve $t+1$. sürelerde çarpışma risk durumları [6]

Ammoun ve Nashashibi'nin çalışmasında araçların birbirleri ile iletişime geçtiği ve birbirlerinin durumlarına göre kaza risklerinin hesaplanmasını amaçlayan bir sistem önerilmiştir [7]. Bu çalışmada araçlarla ilgili hız ve konum bilgisi sensörler yardımı ile alınarak araç takibinde yaşanabilecek hataların önlenmesi amaçlanmıştır. Araçların doğrusal yörünge tahmini Kalman Filtresi kullanılarak yapılmıştır. Çarpışma riski, konumu belirlenen araçların etrafına uydurulan elipslerin kesişme durumlarına göre belirlenmiştir. Önerilen sistem simulasyon ortamında ve kavşak yol modelinde yörüngeleri birbirini dike yakın kesen araçlar için denenmiştir. Şekil 1.6'da soldaki şekilde, araçlar için oluşturulan elipsler ve bunların kesişim durumları, sağdaki şekilde ise araçların simulasyon ortamındaki hareket yörüngeleri ve hareket doğrultularının kesişimleri gösterilmiştir.



Şekil 1.6 Ammoun'un kaza modellemesi [7]


Desheng ve Jia araçların hareket yörüngelerinden genel araç aktivitelerini çıkaran eğitimsiz bir model önermişlerdir [8]. Üretilen hareket yörüngeleri, hareket yönleri, uzunlukları ve ortalama hızlarına göre Hausdorff uzaklık yöntemi kullanılarak gruplandırılmışlardır. Eğitimsiz davranış analizi yöntemlerinden Sinir Ağları(Neural Network-NN), Dinamik Zaman Eşleştirmesi (Dynamic time warping-DTW) ve Saklı Markov Modeli karşılaştırılmıştır. Bu yöntemler arasından Baum-Welch Saklı Markov Modeli tercih edilerek, gruplanan hareket yörüngeleri için aktivite modelleri üretilmiştir. Üretilen aktivite yörüngeleri ile benzerlik göstermeyen yörüngeler, olağandışı araç aktiviteleri olarak işaretlenmiştir. Önerilen sistem 20 dakikalık tek bir video görüntüsü ile test edilmiş ve eğitmenli, yarı eğitmenli ve eğitimsiz yöntemlerin performans karşılaştırmaları yapılmıştır. Uygulanan eğitimsiz yöntemin, performansı en yüksek sonuçları ürettiği belirlenmiştir.

Piciarelli ve Micheloni olağandışı olayların tespit edilmesi için kümeleme ve Karar Destek Makineleri (Support Vector Machine-SVM) tekniklerinin birlikte kullanıldığı bir yöntem önermişlerdir [9]. Parzen Penceresi (Parzen Window-PW) yoğunluk tahmini yöntemi kullanılarak hareket yörüngelerinin benzer yoğunluğa sahip olanlarının aynı gruba dahil edilmesi sağlanmıştır. Gruplanan hareket yörüngeleri Karar Destek Makinesi yöntemi kullanılarak eşit uzunluklu alt sınıflara örneklendirilmiş ve aykırı hareket yörüngelerinden temizlenmiştir. Sonrasında n küme sayısı göstermek üzere n -sınıflı Karar Destek Makineleri kullanılarak yörünge kümeleme ve olağandışı olayların tespiti yapılmıştır. Önerilen sistem sentetik data üzerinde test edilmiş ve ortalama %75 oranında anomaliler doğru tespit edilmiştir.

Barria ve Thajchayapong kendi geliştirdikleri kovaryans matrisinin en küçük eigen vektör değerini (smallest eigenvalue of covariance matrix) temel alan yöntemi kullanarak araçların hareketlerindeki mikroskopik karakteristik değişiklikler ve şiddetleri hakkında çıkarım yapabilen bir sistem önermişlerdir [27]. Araçların hız ve konum bilgileri gps vericiler aracılığı ile alınmış ve dolayısıyla ayrıca bir takip algoritması kullanılmamıştır. Araçların bağıl hızları, araçlar arası mesafe ve zaman aralıkları şerit değiştirmeler mikroskopik trafik değişkenleri olarak ele alınmıştır. Bu değişkenler araçların davranışlarını ve birbirleri ile ilişkilerini belirleyen değerler olarak değerlendirilmiş ve buradan anomali durum çıkarımları yapılmaya çalışılmıştır. Bu çalışmada ani hız değişimi gibi geçici anomalilerin ve trafik akışında problem yaratan ve kaza olasılığına neden olan araç davranışlarının incelenmesi amaçlanmıştır. Mikroskopik trafik değişkenlerindeki olasılıksal değişimler Bayes teoremi kullanılarak tespit edilmiş ve bu değişimlerin boyutuna göre anomaliler üretilmiştir. Önerilen sistem gerçek ve simulasyon ortamındaki görüntüler kullanılarak farklı anomaliler için test edilmiş ve %90'ı aşan bir anomali tespit başarımından bahsedilmiştir.

Lambert ve Gruyer, Hızlı Monte Carlo (Fast Monte Carlo) yöntemini kullanarak araçların hareket eden ve sabit nesneler ile çarpışma durumlarını olasılıksal modelleme ile tahmin etmeye çalışan bir yöntem önermişlerdir [10]. Çarpışma olasılıkları Gauss integrallerini hesaplayan Monte Carlo yöntemi kullanılarak hesaplanmıştır. Önerilen sistem simulasyon ortamında uygulandığı için araçların koordinat bilgileri ve merkez takip noktaları manuel olarak belirlenmiştir. Sabit ve hareketli nesneler ile hareket

eden nesnelerin doğrultularına göre oluşan çarpışma riski Olasılıksal Yoğunluk Fonksiyonu (Probability Density Function-PDF) hesaplanarak modellenmiştir. Şekil 1.7’de araç engel ve çarpışma noktası için olasılıksal yoğunluk fonksiyonları gösterilmiştir.



Şekil 1.7 Potansiyel çarpışma bölgelerinin olasılıksal yoğunluk fonksiyonları [10]

1.2 Tezin Amacı

Bu çalışma, trafikte hareket halindeki araçların genel davranış modellerinin çıkartılarak, bu çıkarımlara göre, araçların kaza yapma olasılıklarının tahmin edilmesi için yeni bir yöntem önermektedir. Bu sonuca ulaşmak için, sistemin öğrenme aşamasında görüntü işleme ve örüntü tanıma yöntemleri ile araçlar olağan trafik akışında takip edilerek, araçların olağan hareket modellerini temsil eden genel yol modelleri çıkartılmaktadır. Sistemin uygulama aşamasında, öğrenme sonucunda elde edilen genel yol modellerinin ilişkilerine ve araçların genel yol modellerinde anomali (olağandışı) olayları yaratan hareketlerinin mevcudiyetine göre kazaya sebep olabilecek araçların risk faktörü belirlenmektedir. Diğer kaza tahmini yapan çalışmaların aksine bu çalışmada araçların hareket modelleri öğrenildiğinden, araçların hangi yol modellerinde hareket etmesi gerektiği ve hangi yol modelleri ile ilişkisi bulunduğu bilgilerinin çıkarımı kolaylıkla yapılabilir. Bu bilgiler kullanılarak sadece kaza yapma riski bulunan araçların kaza riski incelenmektedir. Ayrıca öğrenilen genel yol modellerine aykırı olduğu tespit edilerek anomali olarak belirlenen araç hareketleri, araçların kaza riskini arttırıcı bir faktör olarak ele alınmaktadır.

Önerilen bu sistemin tam otomasyonla kurulması halinde, trafikteki anomali durumlar ve kazaya sebebiyet verebilecek davranışlar tespit edilerek trafik koordinasyon merkezleri için trafik denetlemesinin kolaylaştırılması hedeflenmiştir. Bu sayede trafik koordinasyon merkezlerindeki operatörler, sadece trafik güvenliği tehlikede olduğu zaman ilgili trafik bölgesine odaklanabilecek ve gerekli aksiyonların ivedilikle alınmasına aracılık edebileceklerdir. Bunun sonucunda daha az insan kaynağı ile daha geniş bir trafik alanı kontrol edilebilecek, böylece zaman ve maliyet kazancı sağlanabilecektir. Ayrıca insan kaynağına olan ihtiyacın azalması sonucunda sistemin genişletilmesi daha kolay gerçekleştirilebilecektir. Trafik kazalarına yol açan davranışlara göre trafik düzeninde ve kavşaklarda sorunların çözümüne yardımcı aksiyonlar alınabilecektir. Bu çalışmada araçların hareket yörüngelerinin kümelenmesi, sınıflandırılması ve kaza durumlarının incelenmesi için gerçek trafik görüntüleri kullanılmıştır.

1.3 Hipotez

Trafik kameralarından alınan gerçek zamanlı görüntüler kullanılarak, araçların trafikteki normal veya anomali yaratan hareketleri ve buna bağlı olarak kaza riskleri incelenebilir. Araçların genel yol modellerindeki hareketleri ile anlık bağıl hızları ve hareket doğrultuları kaza risk faktörünün hesaplanması için en önemli etkenlerdir. Risk faktörünün belirli bir eşik seviyesinin üzerinde seyretmesi aracın kaza yapma olasılığının sürekli ve yüksek olduğu sonucunu doğuracağından trafik koordinasyon merkezlerindeki operatörlerin uyarılmasını ve dikkatlerin trafik güvenliğinin tehlikede olduğu bölgelere verilmesi sağlanabilir. Bu sayede kaza sonrası ihtiyaç duyulan ilk yardım hizmetlerinin hızlandırılması amaçlanmaktadır. Trafikte tehlike yaratan olayların incelenmesi, kaza analizlerinin yapılmasını ve yol yapılarının revize edilmesini kolaylaştırır.

BÖLÜM 2

SİSTEM TASARIMI

Bu çalışmada gerçek trafik görüntülerini kullanarak, takip edilen araçların hareket yörüngelerini inceleyen, bu yörüngelerden trafik kamerasının görüntü alanındaki yol modellerini öğrenen, öğrenilen bu yol modelleri yardımıyla araçların olağandışı davranışlarını tespit eden ve birbirleri ile ilişkilerine göre kaza olasılıklarını tahmin eden bir sistem tasarlanmış ve gerçekleştirilmiştir. Tasarlanan sistem, genel yol modellerinin öğrenilmesi ile anomali (olağandışı) trafik hareketlerinin belirlenmesi ve tespit edilen olağandışı durumların yarattığı kaza riski ile desteklenmiş trafik kazası tahmini olmak üzere iki ana bölümden oluşmaktadır. Ön işlemler, araçların tespiti ve takibi ile genel yol modellerinin öğrenilmesi sistemin birinci bölümü olan eğitim bölümünü oluşturur. İkinci bölümde ise gerçek zamanlı görüntüler ve öğrenilen yol modelleri değerlendirilerek, araçların anomali destekli kaza tahmin işlemleri yapılmaktadır. Bu çalışma trafik kazası riskinin, öğrenilen yol modellerinin yardımıyla yalnızca kaza riski bulunan araçlar için incelenmesi ve anomali tespitleri ile kaza riskinin artırılması açılarından özgün bir tasarıma sahiptir. Sistemi oluşturan ana bölümler ile bunları oluşturan alt bölümlerin genel akışı Şekil 2.1’de gösterilmiştir.



Şekil 2.1 Sistemin genel akışı

2.1 Trafik Kazalarına Ait Video Veritabanının Hazırlanması

Tez çalışmasında iki farklı video veri kümesi kullanılmıştır. NGSIM organizasyonu [12] tarafından sağlanan birinci veri kümesinde gerçek trafik görüntülerindeki normal trafik akışı incelenmiş ve araçların takibi, araçların hareket yörüngelerinin elde edilmesi ve hareket yörüngelerinin kümelenmesi ile genel yol modellerinin üretilmesi ile ilgili çalışmalar gerçekleştirilmiştir. Sadece normal trafik akışı görüntülerinin bulunduğu bu veri kümesinde, araçların hareketi sırasında üretilen kısmi hareket yörüngeleri, öğrenilen yol modelleri ile sınıflandırılarak test edilmiştir.

İkinci veri kümesi TRIMARC organizasyonu [11] tarafından sağlanan anomali ve kaza durumlarını içeren gerçek trafik görüntülerinden oluşmaktadır. Bu görüntüler kullanılarak kaza risk analizi çalışması yapılmıştır. Görüntülerde sadece araçların hareketleri incelenmiştir. Yayalar, motosikletler gibi diğer nesneler kaza risk analizi hesabına dahil edilmemiştir. Çizelge 2.1’de tez çalışmasında kullanılan veri kümeleri ve içerdiği video görüntülerinin özellikleri ile ilgili açıklamalar verilmiştir.

Çizelge 2.1 Tez çalışmasında kullanılan veri kümeleri ve açıklamaları [18]

Veri kümesi	Açıklama
NGSIM (Next Generation Simulation)	Trafik görüntüleri NGSIM organizasyonu tarafından sağlanmıştır. Görüntüler, 2005 yılında California, Lankershim Bulvarının 5 farklı bölgesinden 5 farklı kamera ile kayıt edilmiştir. Görüntüler ile beraber her aracın yörünge bilgisi de sağlanmıştır.
AIRS (TRIMARC)	AIRS veri kümesi aynı kavşak üzerinde 75 farklı olağandışı trafik olayının görüntülerini içermektedir. Görüntüler TRIMARC organizasyonu tarafından sağlanmıştır. Olaylar farklı açılardan iki farklı kamera ile kaydedilmiş ve mikrofon düzeneği ile olay yerindeki sesler de alınmıştır. Görüntüler, trafik olaylarından 4 saniye öncesini ve sonrasını gösterecek şekilde kayıt edilmişlerdir.


GENEL YOL MODELLERİNİN ÖĞRENİLMESİ

Her yol modeli farklı sayıda şeritlerden, yol ayrımlarından veya yol katılımlarından oluşur. Bu durumun sonucu olarak araçlar her yolun yapısına göre farklı hareket yörüngelerini takip edebilirler. Bu nedenle araç trafiğinin işleyişi ile ilgili yorum yapma amacı olan bir sistemin, farklı yol modellerine göre kendini uyarlaması gerekmektedir. Böylece, önerilen sistemin farklı yol modelleri için uygulamaya geçirilmesi, sistemin çalışma parametrelerine insan müdahalesinin minimuma indirilerek kurulması ve sistemin kolaylıkla genişletilmesi mümkündür. Ayrıca, hareketli trafik kameralarının kullanıldığı yol modelleri için, görüntüleme açısı değiştiğinde sistemin yeniden eğitilmesi sağlanarak, kendini yeni yol koşullarına göre adapte etmesi sağlanabilir.

Bir trafik kamerasından elde edilen görüntüde bir aracın görüntüye giriş ve çıkış yapabileceği farklı yol modelleri vardır. Yol modelleri kabaca yoldaki şeritlere göre ve yolun yapısına göre değişir. Bir yol modelinde ilerleyen her araç, olağandışı durumlar haricinde farklı ve küçük sapmalar ile yaklaşık olarak aynı yörüngeyi izler. Bu durumun bir sonucu olarak takip edilen araçların benzer yörüngelerinin gruplandırılarak sisteme yolun karakteristiği hakkında bilgi veren genel yol modellerinin üretilmesi gerekmektedir.

Bu bölümde, trafik kameralarındaki görüntüler kullanılarak, araçların genel yol modellerinin öğrenilmesi hedeflenmektedir. Özet olarak ifade edilecek olursa, trafik görüntüsünde tespit ve takip edilen tüm araçlar için üretilen hareket yörüngeleri, görüntüye giriş ve çıkış noktaları benzer olanların birlikte gruplandırılması ve kümelenmesi sonucunda genel yol modelleri elde edilir. Bu aşamada sistemin eğitimi

için belirlenen tüm araçların, sadece bir genel yol modeli dahilinde hareket ettikleri ve şerit değiştirmedikleri kabul edilmiştir. Her bir hareket yörüngesi grubu Saklı Markov Modeli (Hidden Markov Model – HMM) algoritması ile kümelenecek, o kümeyi ifade eden tek bir genel yol modeli üretilmiştir. Her bir genel yol modeli bir Gauss Karışımı destekli HMM olarak ifade edilmektedir. Şekil 3.1’de yol modellerinin öğrenilmesini sağlayan alt sistemin blok şeması gösterilmiştir.



Şekil 3.1 Genel yol modellerini öğrenen alt sistemin blok şeması

Sistemin eğitilerek genel yol modellerinin öğrenilmesi, gerçek zamanlı görüntülerde anomali (olağandışı) durumların yakalanması için kolaylık sağlar. Uygulama aşamasında, kaynak araç olarak takip edilen aracın kısmi hareket yörüngesi üretilip mevcut genel yol modelleri ile sınıflandırılarak, daha önceden öğrenilen yol davranışlarına aykırı bir durum olup olmadığı tespit edilir. Belirlenen olağandışı durumlar, kaza tahmini aşamasında kaza risk kategorisini arttırıcı bir faktör olarak değerlendirilir. Bu konu ilerleyen bölümlerde detaylandırılmıştır.

Görüntü veri tabanındaki kaza durumları incelendiğinde, kazaların genellikle birbirleri ile kesişen veya yanyana paralel olan yollarda hareket eden araçlar arasında olduğu sonucuna ulaşılmıştır. Bu bölümde, genel yol modellerinin birbirleri ile kesişim veya paralellik ilişkisi içinde olup olmadığı belirlenerek, kaza riskinin sadece birbirleri ile ilişkili genel yol modellerindeki araçlar için hesaplanması sağlanır. Bu sayede görüntüdeki bir aracın diğer tüm araçlarla kaza riskini incelemek yerine, sadece kaza yapma riski bulunan ilişkili genel yol modelleri üzerinde hareket eden araçlarla olan kaza riskleri incelenir. Bunun sonucunda gerçekte kaza riski bulunmayan araçlar için risk hesaplamasının gereksiz işlem yükünden kurtularak gerçek zamanlı görüntüde işlem yapma performansını arttırır.

3.1 Araçların Belirlenmesi, Takip Edilmesi ve Hareket Yörüngelerinin Üretilmesi

Görüntü işleme teknikleri açısından nesne hareketleri, belirli konularda çıkarımlar yapabilmek için en önemli bilgi kaynaklarının başında gelir. Trafik kazalarının ve anomali durumlarının tespitinde, sistemin yüksek başarımla çalışması için karmaşık arka plandan, takip edilecek aracın başarılı bir şekilde ayrılması önemlidir. Ancak ortamdaki parazit etkisine neden olan yağmur, kar, sis gibi hava durumları ile doğal ortamdaki ağaç, köprü, üstgeçit, trafik ışığı gibi nesnelerin araçların hareket ettiği yol üzerindeki gölge izdüşümlerinin araçların renklerinde meydana gelen değişimler gibi nedenlerle araçların takibi olumsuz etkilenebilmektedir. Bunun yanında ortam aydınlanmasının değişimi de bir noktadan sonra araç belirleme ve takip başarımını düşürebilmektedir. Bu nedenlerle parazit etkisine neden olan faktörlerin etkisini en aza indirebilmek için görüntü çerçevelerinin bazı ön işlemlerden geçirilmesi zorunludur.

Bu çalışmada araç takibini engelleyen ağaç, üst geçit, trafik ışığı gibi oblejlerden kaynaklanan problemler ile ilgilenilmemiş, ancak takip başarımını arttırabilmek ve görüntü kalitesinden kaynaklı sorunları azaltmak için filtreleme ön işlemleri uygulanmıştır. Bu ön işlemlerden sonra araçların takip noktalarının seçimi yapılmaktadır. Bu çalışmada nesne takibi, öğrenme aşamasında araçların hareket yörüngelerini çıkarmak, uygulama aşamasında ise araçların anlık doğrultu ve hızlarını tespit edebilmek için kullanılmıştır.

3.1.1 Video Görüntüsünün İyileştirilmesi

Video görüntüsünün ardışık her çerçevesi için tüm işlemlerden önce, Gauss ve Medyan yumuşatma filtreleri kullanılarak, araç belirleme ve takip aşamalarının başarımını düşüren detayların kaybedilmesi amaçlanmıştır. Kullanılan yumuşatma filtreleri gereksiz detayları ve parazitleri görüntülerden temizleyip başarımı arttırırken, bir dezavantaj olarak nesnelerin kenar ve köşe bilgilerinin olumsuz etkilenmesinden bahsedilebilir. Görüntü çerçevelerinde yumuşatma algoritmalarının şiddeti arttırıldıkça tespit edilen köşeler azalmaktadır. Ancak araç takibinde köşe ve kenar bilgisine kesin olarak sahip olunmasına gerek olmadığından, bu durumun sisteme olumsuz etkisi minimum seviyede kalmaktadır.

Medyan filtreleme benekli ve karıncalı görüntülerde, görüntüdeki eksik bölgelerin tamamlanması açısından başarılı ve hızlıdır. Gauss filtresi ile karşılaştırıldığında belirlenen çekirdek boyutu dahilindeki piksellerin medyan değeri ile filtreleme yapıldığından, aykırı piksel değerlerinden daha az etkilenir. Bu nedenle tuz ve biber etkisi de denilen sorunlu görüntülerde oldukça etkili bir filtreleme tekniği olarak kabul edilmektedir. Çalışma mantığında, belirlenen bir çekirdek boyutunda merkez seçilen piksel ve etrafındaki pikseller küçükten büyüğe sıralanır ve orta değer merkez pikselin yeni değeri olarak atanır [19]. W görüntü çerçevesinin (m,n) noktasındaki komşularını belirtmek üzere Medyan filtresinin matematiksel bağıntısı Eşitlik 3.1 ile gösterilmiştir.

$$y[m,n] = \text{median}\{x(i,j), (i,j) \in W\} \quad (3.1)$$

Gauss yumuşatma filtresi, büyük boyutlu görüntülerde görüntüyü düzleştirme ve bulanıklık etkisi oluşturması bakımından oldukça etkili çalışmaktadır [19]. Gauss dağılım

fonksiyonu kullanılarak, standart sapmanın genişliğine göre değişen bir filtre üretilir. Gauss dağılımının sayısal olarak iki boyutlu ifade edilmiş hali, Eşitlik 3.2'deki gibidir. σ gauss dağılımının standart sapmasını belirtir ve fitlemenin bulanıklık etkisini belirler. Gauss dağılım merkezinin, Gauss dağılım fonksiyonunun sınırlarına yatay ve düşey eksenlerdeki uzaklıkları x ve y değişkenleri ile belirtilmiştir. Üretilen çekirdek konvolusyonla orjinal görüntüye uygulanırsa yumuşatılmış yeni görüntü çerçevesi elde edilir. Bu durum Eşitlik 3.3'de ifade edilmiştir.

$$G_{\sigma} = \frac{1}{2\pi\sigma^2} \exp\left(-\frac{|x|^2+|y|^2}{2\sigma^2}\right) \quad (3.2)$$

$$I(x, y) = I_0(x, y) * G(x, y) \quad (3.3)$$

Şekil 3.2(a)'da orjinal resim, 3.2(b)'de gauss filtresi ve 3.2(c)'de medyan filtreleri uygulandığında görüntü çerçevesinin durumu gösterilmiştir. Bu çalışma kapsamında her iki filtrede de 5x5 lik çekirdekler kullanılmıştır.



(a)

(b)




(c)

Şekil 3.2 Orjinal, Gauss filtresi ve Medyan filtresi uygulanmış görüntü çerçeveleri

3.1.2 Adaptif Gauss Karışım Modeli Yöntemi İle Görüntü Çerçevelerinin Arka ve Ön Planların Çıkarılması ve Araç Temsil Noktasının Tespiti

Hareket eden nesneler, görüntüde ön plandaki nesneler olarak adlandırılırlar. Arka planın sabit olduğu görüntülerde en basit yaklaşım olarak, ardışık çerçevelerin farkları alınarak, hareket halinde olan piksel gruplarının durumlarına göre nesneler belirlenebilir. Ancak doğal ortam görüntülerinde, farklı hava durumlarının ve bulutların yarattığı farklı gölge desenlerinin görüntü üzerindeki etkileri nedeniyle adaptif yöntemler tercih edilmektedir. Arka planda hareket eden nesne yoğunluğunun yüksek olması ve görüntülerde ilgilenilen bölge dışında, ağaç dalları gibi sürekli hareket eden nesnelerin bulunması ön plandaki nesne çıkarımını ve bunların yorumlanmasını zorlaştıran etmeler olarak sıralanmaktadır.

Ön plan nesnelerinin arka plandan ayrılması için kullanılan genel yöntemler; yoğunluk histogramlarının bulunması, ardışık çerçevelerin farkının alınması, anlık çerçevenin arka plandan farkının alınması, ortalama ve adaptif arka plan modeli çıkarımı yapılması şeklinde sıralanabilir. Bu çalışmada doğal ortam görüntülerinde oldukça başarılı sonuçlar veren Adaptif Gauss Karışım Modeli (Adaptive Gaussian Mixture-AGMM) [20] ile arka plan modelleme yöntemi kullanılarak hareket eden nesneler belirlenmeye çalışılmıştır. Bu bölümde araç segmentasyonu için yapılan işlemlerin genel akışı Şekil 3.3'de gösterilmiştir. Araçların segmentasyonundan sonra ayrıca bir gölge ayrıştırma işlemi yapılmamıştır.



Şekil 3.3 Görüntü çerçevelerinden araç segmentasyonu

Adaptif Gauss Karışımı yönteminde görüntü üzerindeki her piksel birden çok Gauss karışımı algoritması ile modellenir. Her X_t pikselinin gözlemlenebilme olasılığı Eşitlik 3.4'deki gibi ifade edilir [20].

$$P(X_t) == \sum_{i=1}^K w_{i,t} \eta_{\mu_{i,t}, \Sigma_{i,t}}(X_t) \quad (3.4)$$

Formüldeki parametreler ve açıklamaları aşağıdaki şekilde ifade edilmektedir.

k: Gauss dağılım sayısı

$w_{i,t}$: t anında i. Gauss karışımının ağırlığı

η : Gauss olasılık yoğunluk fonksiyonu (Probability Density Function, PDF)

$\mu_{i,t}$: t anındaki i. Gauss dağılımının ortalaması

$\Sigma_{i,t}$: Kovaryans matrisi

Dağılım fonksiyonu Eşitlik 3.5'deki gibi hesaplanmaktadır.

$$\eta_{(\mu, \Sigma)}(X_t) = \frac{1}{\sqrt{2\pi}^d \sqrt{\det(\Sigma)}} e^{-\frac{1}{2}(X_t - \mu)^T \Sigma^{-1} (X_t - \mu)} \quad (3.5)$$

Adaptif arka plan modelleme işlemi aşağıdaki adımlardan oluşur. Görüntü çerçevesindeki her X_t pikseli için aşağıdaki işlemler tekrarlanır [20].

- X_t piksel değerine uyan en iyi k-Gauss dağılımı ve ağırlığı k-Ortalama veya Beklenti Maksimizasyonu (Expectation Maximization-EM) yöntemlerinden biri kullanılarak bulunur.
- $|X_t - \mu_{i,t-1}| \leq D \cdot \sigma_{i,t-1}$ koşulu sağlandığında eşleştirilmiş dağılım olarak belirlenir. D değeri küçük pozitif sapma eşik değerini ifade eder.
- Dağılım parametreleri Eşitlik 3.6'daki gibi hesaplanır. α öğrenme sistemin oranını belirtir. ρ dağılım parametresi ise yaklaşık $p \approx \frac{\alpha}{w_{i,t}}$ değeri ile hesaplanır.

$$\begin{aligned} w_{i,t} &= (1 - \alpha) \cdot w_{i,t-1} + \alpha \\ \mu_{i,t} &= (1 - \rho) \cdot \mu_{i,t-1} + \rho \cdot X_t \\ \Sigma_{i,t} &= (1 - \rho) \cdot \Sigma_{i,t-1} + \rho \cdot (X_t - \mu_{i,t})^2 \end{aligned} \quad (3.6)$$

- Herhangi bir dağılım eşleştirilemediyse, X_t ortalaması ile en küçük ağırlığa sahip dağılım yer değiştirir. Diğer dağılımlar aynı ortalama değeri ve kovaryans matrisi ile işleme devam eder. Bu dağılımlar Eşitlik 3.7'deki ağırlıklarla güncellenir.

$$w_{k,t} = (1 - \alpha) w_{k,t-1} \quad (3.7)$$

- X_t 'nin ön plan pikseli olup olmadığını anlayabilmek için tüm eşleştirilmiş dağılımlar sıralandırılırlar. Bu sıralamaya göre aşağıdaki eşitliği sağlayan dağılımlar arka plan olarak belirlenir. Eşitlik 3.8'deki ifadede Γ ağırlık eşik değeri olarak ifade edilir.


$$\sum_{k=i_1}^{i_M} w_{k,t} \geq \Gamma \quad (3.8)$$

- X_t pikselinin arka plan dağılımlarının D katı standart sapma aralığında olması durumunda ön plan olarak işaretlenmesi sağlanır. Eşitlik 3.9'daki gibi ifade edilir.

$$\left| D.\sigma_{i,t} - \mu_{i,t} \right| \leq X_t \leq \left| D.\sigma_{i,t} + \mu_{i,t} \right| \quad (3.9)$$


Ön plan çıkarımı yapıldıktan sonraki aşamada, araçların ön plandan ayrılması ve her aracın dış çevritlerinin bulunması sağlanır. Araçların takibini yapabilmek için, o aracı temsil eden bir takip noktasının bulunması gerekmektedir. Takip noktasının bulunabilmesi için bulunan çevritlerin her biri için, çevriti içine alan bir dörtgen oturtularak bu dörtgenin orta noktaları araç temsil noktası olarak işaretlenir. Sonraki bölümde araçların belirlenen temsil noktaları Lucas & Kanade Optik Akış yöntemi ile takip edilerek her bir araç için hareket yörüngesi üretilir. Şekil 3.4'de sol sütunda görüntüde belirlenen araçların dış çevritleri ve sağ sütunda ise araçların bölütlenmesi sonucu elde edilen siyah beyaz görüntüler ile verilmiştir.





Şekil 3.4 Araçların arka plandan ayrılması

Şekil 3.5’de dış çevritleri belirlenen araçların temsil noktası olarak seçilen, aracın dış çevritini kapsayan en küçük dikdörtgenin merkez noktası gösterilmiştir.



Şekil 3.5 Dış çevritleri belirlenmiş aracın merkez noktasının belirlenmesi [24]


3.1.3 Optik Akış Yöntemi İle Araç Takibi

Araçların temsil noktalarının doğru bir şekilde takibi, sonuca giden yoldaki en önemli aşamayı oluşturmaktadır. Nesne takip işlemleri amacıyla en çok kullanılan iki yöntem, Kalman Filtresi [21] ve Lukas & Kanade Optik Akış [22] yöntemleridir. Kalman Filtresi yönteminde, önceki görüntü çerçevelerinde gözlemlenen durumlara ve girdilere göre yeni bir çerçevede takip edilen nesnenin pozisyonu tahmin edilmeye çalışılmaktadır. Bu yöntem, elde edilen sonuçların gözlemlerle karşılaştırdığı ve hesaplanan kazançlara göre öz yinelenmeli olarak sistemin geri beslenerek optimize edildiği bir yapıya sahiptir. Bu çalışmada kullanılan Lucas & Kanade optik akış algoritması ise yoğunluk tabanlı nesne takip yöntemlerinden biridir. Belirli bir bölgede, ardışık çerçevelerde bir piksel grubunun takibi için oldukça yaygın kullanılan bir yöntemdir. Bu yönetime göre takip edilen resim içeriğinin, yerel bir bölgede küçük değişimlerle yer değiştirdiği kabul edilmektedir. Optik akış algoritmasında iki temel problemle karşılaşılır. Bunlardan ilki

izlenecek görüntü özelliğinin veya parçasının tespittir. Diğerisi ise bu özelliğin nasıl izleneceği ile ilgilidir.

Optik akışı açıklamak için öncelikle bir $I(x,y,t)$ noktasının iki boyutlu bir görüntü çerçevesinde $n \times n$ 'lik bir matrisin merkez noktası olduğunu düşünülür [23]. Bu merkez noktasının δx ve δy küçük değişimleri ile x ve y doğrultusunda δt sürede hareket ettiği ve yüzey parlaklığının zamanla değişmeyeceği varsayıldığında Eşitlik 3.10 doğrulanmaktadır. Belirlenen bir $I(x,y)$ takip noktasının t . süreden $t+1$. süreye değişimi Şekil 3.6'da olduğu gibi ifade edilmiştir.

$$I(x, y, t) = I(x + \delta x, y + \delta y, t + \delta t). \quad (3.10)$$



Şekil 3.6 Optik akış yönteminde t . ve $t+1$. zamanda takip noktasının değişimi [23]

Eşitlik 3.10'un birincil katman Taylor serisi olarak açılımı Eşitlik 3.11'deki gibi gösterilmektedir. Bu eşitlikte H.O.T. daha yüksek mertebeli taylor katmanlarını ifade etmektedir. Bu katmanlardaki birim zamandaki yer değiştirmelerin çok küçük olduğu düşünüldüğünden bu aşamadan sonrası dikkate alınmaz.

$$I(x + \delta x, y + \delta y, t + \delta t) = I(x, y, t) + \frac{\partial I}{\partial x} \delta x + \frac{\partial I}{\partial y} \delta y + \frac{\partial I}{\partial t} \delta t + H.O.T., \quad (3.11)$$

Yer değiştirmenin ardışık çerçeveler arasında çok küçük olacağı düşünüldüğünde Eşitlik 3.12 sağlanır. Eşitliğin değişen zamana göre türevi alındığında ise optik akışın hız vektörünün x ve y doğrultularındaki hız vektörleri elde edilir.

$$\begin{aligned} \frac{\partial I}{\partial x} \delta x + \frac{\partial I}{\partial y} \delta y + \frac{\partial I}{\partial t} \delta t &= 0 \\ \frac{\partial I}{\partial x} \frac{\delta x}{\delta t} + \frac{\partial I}{\partial y} \frac{\delta y}{\delta t} + \frac{\partial I}{\partial t} \underbrace{\frac{\delta t}{\delta t}}_{=1} &= 0 \\ \frac{\partial I}{\partial x} v_x + \frac{\partial I}{\partial y} v_y + \frac{\partial I}{\partial t} &= 0. \end{aligned} \quad (3.12)$$

Yukarıdaki kısmi türevler daha bütünleşik olarak Eşitlik 3.13'deki şekilde ifade edilebilir.

$$I_x = \frac{\partial I}{\partial x}, \quad I_y = \frac{\partial I}{\partial y} \quad \text{and} \quad I_t = \frac{\partial I}{\partial t}.$$

$$(I_x, I_y) \cdot (v_x, v_y) = -I_t$$

$$\nabla I \cdot \vec{v} = -I_t, \quad (3.13)$$


$\nabla I = (I_x, I_y)$ eşitliği görüntü uzayındaki yoğunluk değişimini, $\vec{v} = (v_x, v_y)$ ise t süresinde $I(x, y)$ pikselindeki hız veya optik akış vektörünü belirtmektedir.

Eşitlik 3.14'de ise Lucas & Kanade yöntemi ile optik akış eşitliği verilmiştir. Bu yöntemde yerel en küçük kareler algoritması kullanılmaktadır. Buna göre ardışık çerçevelerde ve yerel bir bölgede, belirli bir pencerenin yoğunluk değişiminin minimum olduğu bölge aranır. Eşitlik 3.14'deki W , belirli bir sigma komşuluğundaki x ve y değerleri için pencere fonksiyonlarını ifade etmektedir. Bu ifadeye göre, yerel bir

bölgede hesaplanan yoğunluk değişimini gösteren W değerini minimum yapan x ve y noktası, takip edilen nesnenin yeni koordinatı olarak belirlenir.

$$\sum_{x,y \in \Omega} W^2(x,y) [\nabla I(x,y,t) \cdot \vec{v} + I_t(x,y,t)]^2, \quad (3.14)$$

Optik akış yöntemi ile takip edilen her pikselin hareket vektörü çıkartılır. Bu vektörün açısı ve büyüklüğü hareketin karakteristiği hakkında bilgi vermektedir. Takip edilen pikseller aynı araç üzerinde ise aynı yönlü bir hareket sergileyecekler ve bunun sonucunda benzer optik akış vektörlerine sahip olacaklardır. Optik akış yöntemi, takip edilen temsil noktasının küçük bir alanda yer değiştirdiği ve kameranın görüş açısına giren parazitler nedeniyle büyük desen değişikliklerine uğramadığı durumlarda yüksek başarımla çalışmaktadır. Takip noktasının görüntü çerçevesi geçişlerindeki yer değiştirmesinin büyük olduğu durumlarda ise başarımla düşmektedir. Bu durumlarda başarımla yüksek tutabilmek için piramitsel optik akış yöntemi önerilmektedir.



Şekil 3.7 Piramitsel optik akışın gösterimi

Piramitsel optik akış, ardışık çerçevelerin farklı seviyelerde ölçeklenerek akış vektörlerinin hesaplanması üzerine kurulu bir yöntemdir [22]. Bu yöntemde görüntünün kalitesine veya takip edilen nesnenin optik akışın hızına göre farklı seviyeler


belirlenebilmekle birlikte, genellikle 3 veya 4 seviyeli piramitler uygulanmaktadır. Piramitsel optik akış yöntemi Şekil 3.7’de ardışık olan H ve J görüntü çerçeveleri ile görsel olarak ifade edilmiştir.

Bu yöntemde, ardışık çerçevelerin aynı seviyede ölçeklendirilmiş örnekleri arasında, en üst seviyeden başlamak üzere Lucas & Kanade optik akış algoritması uygulanmaktadır. Her seviyede bulunan optik akış vektörü bir piramidin bir alt seviyesine göre yeniden ölçeklendirilmekte ve bu seviyede elde edilen yeni optik akış vektörü ile birlikte değerlendirmeye alınıp, yeni akış vektörü üretilmektedir. Son aşamada ise çıkış vektörü olarak gerçek görüntüdeki optik akış vektörlerine ulaşılmaktadır. Piramid modelindeki ölçekleme sayesinde, hızlı hareket eden nesnelerin takip edilmesindeki problemler çözülmeye çalışılmıştır. Bu çalışmada araçların temsil noktalarının takibi OpenCV görüntü işleme kütüphanesi [16] dahilindeki piramitsel optik akış yöntemi kullanılarak yapılmıştır. Piramitsel Optik Akış [22] algoritmik olarak aşağıdaki işlem sırasında ifade edilebilir.

- I_1 ve I_2 çerçevelerinin piramid gösterimleri Eşitlik 3.15’deki gibi ifade edilir. m piramidin seviye sayısını ifade etmektedir.

$$\left\{ I_1^L \right\}_{L=0, \dots, L_m} \quad \left\{ I_2^L \right\}_{L=0, \dots, L_m} \quad (3.15)$$

I^0 , 0. seviye görüntü çerçevesi, I^L , L. seviye görüntü çerçevesini göstermek üzere, I^1, I^0 dan, I^2 ise I^1 den elde edilir. $I^0 \rightarrow I^1 \rightarrow I^2 \rightarrow I^3 \rightarrow \dots \rightarrow I^L$ ilişkisi Şekil 3.8’deki gibi gösterilir [18].



Şekil 3.8 Video görüntüsünün piramitsel olarak gösterilmesi [18]

I^L , L. seviye görüntüsü olmak üzere Eşitlik 3.16’daki gibi hesaplanır.

$$\begin{aligned}
I^L(x, y) = & \frac{1}{4} I^{L-1}(2x, 2y) + \\
& \frac{1}{8} (I^{L-1}(2x-1, 2y) + I^{L-1}(2x+1, 2y) + I^{L-1}(2x, 2y-1) + I^{L-1}(2x, 2y+1)) + \\
& \frac{1}{16} (I^{L-1}(2x-1, 2y-1) + I^{L-1}(2x+1, 2y+1) + I^{L-1}(2x-1, 2y+1) + I^{L-1}(2x+1, 2y-1))
\end{aligned} \quad (3.16)$$

I görüntü çerçevesinde u takip edilmek istenen nokta olmak üzere, ardışık çerçevede u noktasına karşılık gelen nokta Eşitlik 3.17'deki gibi tanımlanır. Eşitlikte yer alan d yerdeğiştirmeyi belirtir.

$$\mathbf{v} = \mathbf{u} + \mathbf{d} \quad (3.17)$$

$L = 0, \dots, L_m$ olmak üzere, $\mathbf{u}^L = [u_x^L \ u_y^L]$ L seviyesinde u noktasının koordinatlarını belirtir. u noktasının L seviyesindeki konumu Eşitlik 3.18'deki şekilde bulunur.

$$\mathbf{u}^L = \frac{\mathbf{u}}{2^L} \quad (3.18)$$

L başlangıç seviyesini göstermek üzere bu aşamadaki optik akış tahmini Eşitlik 3.19'daki gibi ifade edilir.

$$\mathbf{g}^L = [g_x^L \ g_y^L]^T \quad (3.19)$$

L seviyesindeki optik akış vektörünü hesaplayabilmek için görüntü eşleştirme hata fonksiyonu olarak ifade edilen ϵ^L değerini minimuma çeken yerdeğiştirme fonksiyonunun Eşitlik 3.20-3.21'deki gibi hesaplanması gerekmektedir.

$$\mathbf{d}^L = [d_x^L \ d_y^L]^T \quad (3.20)$$

$$\epsilon^L(\mathbf{d}^L) = \epsilon^L(d_x^L, d_y^L) = \sum_{x=u_x^L-\omega_x}^{u_x^L+\omega_x} \sum_{y=u_y^L-\omega_y}^{u_y^L+\omega_y} (I^L(x, y) - J^L(x + g_x^L + d_x^L, y + g_y^L + d_y^L))^2 \quad (3.21)$$


$L-1$ seviyesinde yeni optik akış tahmini Eşitlik 3.22'deki şekilde hesaplanır. Bu hesaplama $L=0$ seviyesinde $\mathbf{g}^{L_m} = [0 \ 0]^T$ olana kadar devam eder.

$$\mathbf{g}^{L-1} = 2(\mathbf{g}^L + \mathbf{d}^L) \quad (3.22)$$

En son adımda Optik akış vektörü Eşitlik 3.23'deki gibi hesaplanır.

$$d = \sum_{L=0}^{L_m} 2^L d^L \quad (3.23)$$

Optik akış yöntemi ile bir aracın görüntüye girdiği andan çıktığı ana kadar geçen her çerçevede bir araç takip noktası bulunur. Bununla birlikte araçların görüntüye giriş yaptığı ve çıkış yaptığı noktalar da belirlenir. Bir araç için bulunan takip noktalarının tamamının birleşimi, aracın hareket yörüngesini oluşturur. Hareket yörüngeleri üretilirken araçların görüntü üzerindeki yer değiştirmeleri ve hızları dikkate alınır. Sistemin eğitim aşamasında optimum yörüngede hareket ettiği ve doğru takip edildiği düşünülen tüm araçlar için hareket yörüngeleri üretilir. Şekil 3.9’da takip edilen araçlar, hareket yörüngeleri ile birlikte gösterilmişlerdir. Mavi hareket yörüngeleri mevcutta takip edilen araçların, yeşil hareket yörüngeleri ise kamera açısına girmiş ve çıkmış, yani takibi tamamlanmış araçların hareket yörüngelerini göstermektedir.



Şekil 3.9 Takip edilen ve takipleri tamamlanmış araçların hareket yörüngeleri

3.2 Hareket Yörüngelerinin Kümelenmesi ve Genel Yol Modellerinin Üretilmesi

Kara trafiğindeki araçlar yol modellerine ve şeritlerine göre farklı hareket yörüngeleri izleyebilmektedir. Araçların geneli izlendiğinde aynı yol modelinde, aynı şeritte hareket

eden araçlar benzer hareket yörüngeleri üretmektedir. Trafik görüntüsü belirli bir süre izlendiğinde ve görüntüdeki araçlar takip edildiğinde, araçların hangi yörüngelerde hareket ettiği, bir başka ifade ile hareket karakteristiği ve dolayısı ile bu bilgiden yolun modeli ile ilgili çıkarım yapılabilmektedir. Araçların genel hareket karakteristiklerinin öğrenilmesi, bu karakteristikte hareket yörüngesi üretmeyen, yani olağandışı hareket yörüngesine sahip araçların kolaylıkla tespit edilmesine imkan tanımaktadır. Örneğin aracın yol dışına çıkması, bir şeritte ters yönde ilerlemesi, u-dönüşü yapması veya yanlış bir yöne dönmesi durumları, olağandışı, yani anomali durumlar arasında sayılmaktadır. Olağandışı hareket durumları, diğer bir ifade ile anomaliler trafiğin genelini ilgilendiren bir risk oluşturdıklarından, kaza riskini arttıran etmenler olarak değerlendirilmektedir.

Bu çalışmada araçların olağan hareket yörüngeleri kullanılarak genel yol modelleri bilgisi elde edilmektedir. Genel yol modelinin öğrenilmesi, trafik görüntüsündeki araçların hareket yörüngelerinin gruplandırılarak HMM ile kümelenmesi işlemidir. Bunun sonucunda, benzer hareket yörüngelerini temsil eden ve genel yol modeli olarak adlandırılan tek bir hareket yörüngesi elde edilmektedir. Öğrenilen genel yol modeli, olağan araç davranışları için bir referans noktası oluşturmaktadır. Daha önce öğrenilen genel yol modellerine aykırı hareket yörüngesine sahip bir aracın, olağandışı hareket ettiği sonucuna ulaşılmaktadır.

Belirlenen temsil noktası ile takip edilen bir araç için hareket yörüngesi $T_k = \{f_1, f_2, f_3, \dots, f_n\}$ vektör dizisi ile ifade edilmektedir. Her bir $f_i = \{x_i, y_i, v_{xi}, v_{yi}\}_t$ özellik fonksiyonu, t anındaki koordinat bilgisi (x_i, y_i) ve hız bilgilerinden (v_{xi}, v_{yi}) oluşmaktadır [18].

Takip edilen araçların anlık hızı olarak, görüntü üzerinde her çerçeve geçişindeki yer değişimleri V_i olarak ifade edilmektedir. Optik akış ile bulunan hareket vektörünün büyüklüğü V_i Eşitlik 3.24 ile gösterilmiştir.

$$\begin{aligned} V_{xi} &= (x_{i,t} - x_{i,t-1})^2 \\ V_{yi} &= (y_{i,t} - y_{i,t-1})^2 \\ V_i &= \sqrt{V_{xi} + V_{yi}} \end{aligned} \tag{3.24}$$

Hareket yörüngeleri her araç için farklı sayıda f_n alt vektörlerinden oluşmaktadır. Bu durumun sebebi olarak her aracın farklı hızda olması ve dolayısıyla hareketini farklı sürede tamamlaması gösterilir. Aracın daha uzun süre görüntüde kalması, araç için daha fazla f_n alt vektörünün üretilmesine neden olmaktadır.

3.2.1 Hareket Yörüngelerinin Kümelenmesi

Hareket yörüngelerinin HMM kullanılarak kümelenmesi işlemi sonucunda, birbirine benzerliği yüksek olan hareket yörüngelerini temsil eden bir genel yol modelinin üretilmesi sağlanmaktadır. Bu işlem araçların kaza yapma riskinin incelenmesi ve anomali durumlarının tespit edilebilmesi için oldukça önemlidir. Çünkü araçların geçmiş hareket davranışları sonraki davranışları ile ilgili bir ipucu olarak değerlendirilmektedir. Kümeleme işleminin belirli aralıklarla tekrarlanması, en güncel hareket yörüngelerine ulaşılmasını ve bunun sonucu olarak daha doğru tahminleme yapılabilmesini sağlamaktadır. Kümeleme işlemi sonucunda ulaşılan genel yol modelleri, sistemin gerçek zamanlı çalışması yani uygulama sürecinde, takip edilen araçların kısmi hareket yörüngeleri ile sınıflandırma işlemine tabi tutularak bir benzerlik oranına ulaşılmaktadır. Bu benzerlik oranının değerlendirilmesine göre anomali durumlar ile ilgili çıkarımlar yapılmaktadır.

Bu çalışmada farklı sayıda hareket vektöründen oluşan yörüngeler üzerinde çalışıldığından ve aracın kısmi yörüngesinin sınıflandırılması sürecinde HMM'in saklı durumlarının aracın hareket karakteristiği açısından verdiği bilgi göz önüne alınarak kümeleme için HMM algoritması kullanılmıştır [18]. Yöntemin uygulama süreci öncesinde HMM saklı durum sayıları ve Gauss Karışım sayıları gibi başlangıç parametrelerinin belirlenmesi gerekmektedir. İlerleyen bölümlerde sırasıyla Gauss Karışım yöntemi ve Markov Modelleri incelenmiş ve sonrasında birlikte kullanımları açıklanmıştır.

3.2.2 HMM ve Gauss Karışımı Yöntemi ile Hareket Yörüngesi Kümeleme

Bu bölümde yapılan çalışmalar şu şekilde özetlenebilir. Sistemin genel yol modellerini belirlemek üzere, trafik görüntüsündeki araçlar takip edilerek üretilen hareket yörüngeleri, görüntü üzerindeki başlangıç ve bitiş noktalarının aynı veya yakın noktalar

olmasına göre gruplandırılmaktadır. Sonrasında oluşturulan her bir grup için, o grubu temsil eden ve genel yol modeli olarak isimlendirilen bir HMM bulunmaktadır. Her bir genel yol modeli, bir HMM olarak ifade edilmektedir. Bu çalışmada üretilen tüm HMM'ler, 3 saklı durum ile ifade edilmiştir. Her bir HMM saklı durumu için 3 Gauss karışımı ortalaması hesaplanmıştır. HMM saklı durum sayısı ve Gauss karışımı sayısı deneysel sonuçlara göre belirlenmiştir. Saklı durumların veya Gauss karışım ortalamalarının 5 veya 7 olarak kullanılması hareket yörüngelerini kümeleme ve araç hareketinin sınıflandırılma maliyetinin gereksiz yere artmasına sebep olduğu görülmüştür. İlerleyen bölümlerde Markov Modelleri ve Gauss Karışımı detaylıca incelenmiştir.

Araçların üzerinde hareket ettikleri tüm genel yol modelleri çıkartıldıktan sonra, yol modellerinin kesişim veya yanyana paralellik ilişkisinde olup olmadıkları belirlenmektedir. Bu sayede kaza riskinin, sadece ilişkili genel yol modellerindeki araçlar için hesaplanmasını sağlayarak, gerçek hayattaki kaza durumlarının daha iyi modellenmesine imkan tanımaktadır.

Markov süreçleri, bir dizi durum ve herhangi bir an için bu durumlardan birinden diğerine geçişin o anda bulunulan durumun ile birlikte önceki bulunulan durumlara da bağlı olarak tanımlandığı stokastik süreçlerdir. Markov modelleri, Markov Zinciri ve Saklı Markov Modelleri olarak iki alanda geniş kullanıma sahiptir. Sistem durumları tam gözlemlenebilir olan Markov özelliğine sahip ayrık zaman süreçleri, Markov Zinciri olarak tanımlanmaktadır. Sistem durumları kısmen gözlemlenebildiğinde ise model, Saklı Markov Modeli olarak ifade edilmektedir [25].

3.2.3 Saklı Markov Modeli

Bir Saklı Markov Modeli aşağıdaki model parametrelerinden oluşur.

- N: Modeldeki saklı durum sayısı

$$S=\{S_1, S_2, S_3, \dots, S_N\}$$

- M: Modelde gözlemlenebilecek durum sayısı

$$O=\{O_1, O_2, O_3, \dots, O_M\}$$

- A: Saklı durum geçiş olasılıkları matrisi

$$A=\{a_{i,j}\}, a_{i,j}=P\{q_{t+1}=S_j \mid q_t=S_i\} \ 1 \leq i,j \leq N, q_t: t \text{ anındaki durum}$$

- B: Gözlem olasılıkları matrisi

$$B=[b(j,m)]=P(O_t=o_i \mid q_t=S_j)$$

- Π : Başlangıç durum olasılıkları

$$\Pi = \{\pi_i\}, \pi_i: P(q_1=S_i)$$

N ve M değerleri belirlendikten sonra $\lambda=(A,B,\Pi)$ markov parametreleri Markov modeli olarak ifade edilmektedir. Yapılan tanımlamalar çerçevesinde Saklı Markov Modeli için üç problem tanımlanmaktadır [25]. Bunlar aşağıdaki gibi ifade edilmektedir.

1. λ modeli verildiğinde gözlem dizisi $O=O_1O_2...O_T$ 'nin gerçekleşme olasılığı $P(O|\lambda)$ 'nin hesaplanması durumu değerlendirme (Evaluation) problemi olarak ifade edilir. Problemin çözümü için ileri-geri algoritması kullanılır.
2. λ modeli ve gözlem dizisi $O=O_1O_2...O_T$ verildiğinde bu gözlem dizisini oluşturma ihtimali en yüksek $Q=q_1q_2...q_T$ durum dizisinin $P(Q|O, \lambda)$ bulunması durumu Kod çözme (Decoding) problemi olarak ifade edilir. Problemin çözümü için Viterbi algoritması kullanılır.
3. Verilen $O=O_1O_2...O_T$ gözlem sırası ve $\lambda=\{A,B,\pi\}$ modeli için $P(O|\lambda)$ olasılığını maksimize edecek şekilde model parametrelerinin tahmin durumu Öğrenme (Training) probleminin konusudur. Problemin çözümü için Baum-Welch algoritması kullanılır.

3.2.3.1 İleri-Geri Algoritması

Saklı Markov Modeli'nde $O=o_1o_2...o_T$ gözlem dizisi ile bu gözlem dizisine karşılık gelen N^T sayıda farklı saklı durum dizisi $Q=q_1q_2...q_M$ üretilebilir [29]. Bu durumda O gözlem dizisinin elde edilme olasılığı, olası tüm saklı durum dizileri için Eşitlik 3.25'deki gibi gösterilmektedir.

$$P(O|\lambda) = \sum P(O,Q|\lambda) \quad (3.25)$$

Ancak olası tüm saklı durum dizilerini değerlendirmek işlem karmaşıklığını arttıracığından, $P(O|\lambda)$ olasılığının hesaplanması amacıyla İleri-Yön veya bazı

durumlarda Geri-Yön algoritması kullanılmaktadır. Eşitlik 3.26'da $\alpha_t(i)$, t anına kadar kısmi gözlem dizisinin elde edilme ve t anında S_i durumunda olma olasılığı gösterilmiştir.

$$\alpha_t(i) \equiv P(o_1 \cdots o_t, q_t = S_i \mid \lambda) \quad (3.26)$$

İleri-Yön algoritması Eşitlik 3.27-3.30 arasındaki işlem adımlarından oluşmaktadır. Yineleme adımında $\alpha_t(i)$, t anındaki ilk gözlemi ve sistemin S_i durumunda olma olasılığını belirtmektedir. a_{ij} , S_i durumundan S_j durumuna geçiş olasılığını, $b_j(o_{t+1})$ ise o_{t+1} gözleminin $t+1$ anında oluşma olasılığını göstermektedir.

- Başlangıç durumu değerlerinin belirlenmesi.

$$\begin{aligned} \alpha_1(i) &\equiv P(o_1, q_1 = S_i \mid \lambda) \\ \alpha_1(i) &= P(o_1 \mid q_1 = S_i, \lambda) P(q_1 = S_i) \\ \alpha_1(i) &= \pi_i b_i(o_1), \quad t = 1 \text{ ve } i = 1, \dots, N \end{aligned} \quad (3.27)$$

- Yineleme adımı.

$$\alpha_{t+1}(j) \equiv P(o_1 \cdots o_{t+1}, q_{t+1} = S_j \mid \lambda) \quad (3.28)$$

$$\alpha_{t+1}(j) = \left[\sum_{i=1}^N \alpha_t(i) a_{ij} \right] b_j(o_{t+1}), \quad j = 1, \dots, N \quad (3.29)$$

- Sonlandırma adımı.

$$P(O \mid \lambda) = \sum_{i=1}^N \alpha_T(i) \quad (3.30)$$

İleri-Yön algoritmasına benzer şekilde Geri-Yön algoritmasında $\beta_t(i)$ geri-yön değişkeni kullanılmaktadır. Geri-Yön, İleri-Yön algoritmasından farklı olarak gözlem dizisinde geriye doğru yinelemeli olarak çalışmaktadır [29]. Eşitlik 3.31'deki $\beta_t(i)$ değeri, t anında S_i durumunda olma ve $O=(o_{t+1} \dots o_T)$ kısmi gözlemini elde etme olasılığını göstermektedir.

$$\beta_t(i) \equiv P(o_{t+1} \cdots o_T \mid q_t = S_i, \lambda) \quad (3.31)$$

Geri-Yön algoritması Eşitlik 3.32-3.34 arasındaki işlem adımlarından oluşmaktadır. Yineleme adımında a_{ij} , S_i durumunda iken, olası N farklı S_j durumuna geçme olasılığını

belirtmektedir. $b_j(o_{t+1})$ ise, S_j durumunda o_{t+1} gözleminin oluşma olasılığıdır. $t+1$ anından sonraki tüm gözlem olasılıkları ise $\beta_{t+1}(i)$ ile ifade edilmiştir

- Başlangıç durumu değerlerinin belirlenmesi.

$$\beta_{T-1}(i) = \sum_{j=1}^N a_{ij} b_j(o_T), \quad i = 1, \dots, N \quad (3.32)$$

- Yineleme adımı.

$$\beta_t(i) = \sum_{j=1}^N a_{ij} b_j(o_{t+1}) \beta_{t+1}(j), \quad i = 1, \dots, N \quad (3.33)$$

- Sonlandırma adımı.

$$P(O|\lambda) = \sum_{i=1}^N \beta_1(i) \pi_i b_i(o_1) \quad (3.34)$$

3.2.3.2 Viterbi Algoritması

Viterbi algoritması λ modeli ve $O=o_1o_2...o_T$ gözlem dizisi verildiğinde, bu gözlem dizisini oluşturma ihtimali $P(Q|O,\lambda)$ en yüksek durum dizisi $Q=q_1q_2...q_T$ 'nin bulunmasını hedeflemektedir [29]. Eşitlik 3.35-3.36'da $\gamma_t(i)$ değişkeni ile sistemin S_i durumunda olma olasılığı gösterilmiştir.

$$\gamma_t(i) \equiv P(q_t = S_i | O, \lambda) \quad (3.35)$$

$$\gamma_t(i) = \frac{\alpha_t(i) \beta_t(i)}{\sum_{j=1}^N \alpha_t(j) \beta_t(j)} \quad (3.36)$$

Her t anı için, en yüksek olasılığa sahip olan durumlar alınarak, bir durum dizisi elde edilmektedir. Bu durum Eşitlik 3.37 ile ifade edilir.

$$q_t^* = \arg \max_i \gamma_t(i) \quad (3.37)$$

Tüm durumlar arasında en yüksek olasılığa sahip durumu almak her kod çözme probleminde mümkün değildir. Çünkü her durumdan, her duruma geçişin olmadığı problemler mevcuttur. Bu gibi durumlarda, durumlar arası geçiş olasılıklarını da değerlendiren Viterbi algoritması kullanılmaktadır. Viterbi algoritması, çalışma mantığı

açısından İleri-Yön algoritması ile benzerlik göstermektedir. Çalışma mantığındaki tek fark olarak, Viterbi algoritmasında, t anındaki bir durum için, bu durumun öncesindeki tüm durumların olasılıklarını hesaba katmak yerine, sadece en yüksek olasılığa sahip durum değerlendirilir. Eşitlik 3.38’de ifade edilen $\delta_t(i)$ değeri, t anında S_i durumuna ulaşıncaya kadar olasılığı maksimum olan saklı durum dizisini gösterir.

$$\delta_t(i) \equiv \max_{q_1 q_2 \dots q_{t-1}} p(q_1 q_2 \dots q_{t-1} q_t = S_i, o_1 \dots o_t | \lambda) \quad (3.38)$$

Viterbi algoritmasının işlem adımları Eşitlik 3.39-3.42’deki gibi ifade edilmektedir. Buna göre $t=1$ anından itibaren her t anı için, yapılan gözleme göre durum olasılığının maksimum olduğu yol bulunur.

- Başlangıç durumu değerlerinin belirlenmesi.

$$\begin{aligned} \delta_1(i) &= \pi_i b_i(o_1), \quad i = 1, \dots, N \\ \Psi_1(i) &= 0 \end{aligned} \quad (3.39)$$

- Yineleme adımı.

$$\begin{aligned} \delta_t(j) &= \max_i \delta_{t-1}(i) a_{ij} \cdot b_j(o_t) \quad i = 1, \dots, N \\ \Psi_t(i) &= \arg \max_i \delta_{t-1}(i) a_{ij} \end{aligned} \quad (3.40)$$

- t anında yinelemeyi sonlandırma.

$$\begin{aligned} path^* &= \max_i \delta_T(i), \quad i = 1, \dots, N \\ q_T^* &= \arg \max_i \delta_T(i) \end{aligned} \quad (3.41)$$

- $t=t-1$ anından $t=1$ anına doğru geriye gitme

$$q_t^* = \Psi_{t+1}(q_{t+1}^*) \quad (3.42)$$

3.2.3.3 Baum-Welch Algoritması

Baum-Welch algoritması $\lambda=(A,B,\Pi)$ model parametrelerinin tahmin edilmesini diğer bir ifade ile öğrenilmesini sağlar [29]. Model parametreleri Beklenti Maksimizasyonu (Expectation Maximization-EM) algoritması kullanılarak hesaplanır. $\xi_t(i,j)$ birleşik olasılık parametresi, $O = O_1 O_2 \dots O_T$ gözlem dizisi olmak üzere, sistemin t anında S_i ve $t+1$ anında S_j saklı durumunda olması olasılığını gösterir. Bu durum Eşitlik 3.43-3.44’deki gibi ifade edilmiştir.

$$\xi_t(i, j) \equiv P(q_t = S_i, q_{t+1} = S_j | O, \lambda) \quad (3.43)$$

$$\xi_t(i, j) = \frac{\alpha_t(i) a_{ij} b_j(o_{t+1}) \beta_{t+1}(j)}{\sum_{k=1}^N \sum_{l=1}^N \alpha_t(k) a_{kl} b_l(o_{t+1}) \beta_{t+1}(l)} \quad (3.44)$$

Baum-Welch Algoritması aşağıdaki işlem adımlarından oluşmaktadır.

- Başlanlangıç model parametreleri $\lambda = \{A, B, \pi\}$ kullanılarak $\xi_t(i, j)$ ve $\gamma_t(i)$ değerleri elde edilir.
- Başlangıç durumunda elde edilen $\xi_t(i, j)$ ve $\gamma_t(i)$ değerleri ile yeni model parametreleri $\lambda_{yeni} = \{A, B, \pi\}$ Eşitlik 3.45-3.47'ye göre hesaplanır.

$$a_{ij} = \frac{\sum_{k=1}^K \sum_{t=1}^{T_k-1} \xi_t^k(i, j)}{\sum_{k=1}^K \sum_{t=1}^{T_k-1} \gamma_t^k(i)} \quad (3.45)$$

$$b_j(m) = \frac{\sum_{k=1}^K \sum_{t=1}^{T_k-1} \gamma_t^k(j) 1(o_t^k = v_m)}{\sum_{k=1}^K \sum_{t=1}^{T_k-1} \gamma_t^k(j)} \quad (3.46)$$

$$\pi_i = \frac{\sum_{k=1}^K \gamma_1^k(i)}{K} \quad (3.47)$$

- Durma koşulu, diğer bir ifade ile öğrenmenin tamamlanması $P(O | \lambda) \geq P(O | \lambda_{yeni})$ olduğu zaman gerçekleşmektedir. Aksi durumda ilk adımdan itibaren yapılan işlemler tekrarlanır.

3.2.4 Sürekli Saklı Markov Modeli

Saklı Markov Modellerinde gözlemlerin, sonlu bir alfabeden alınan ayrık semboller olduğu ve her bir durum için gözlem olasılık dağılımlarının ayrık olduğu

düşünülmektedir. Konuşma veya hareket yörüngesi tanıma gibi bazı uygulamalarda ise gözlemler sürekli. Bu tip sinyaller kod defterleriyle nicemlenebilmektedir. Bununla birlikte nicemlemeden kaynaklanan hatalar ortaya çıkabilir. Bu tip durumlarda HMM’lerde sürekli olasılık yoğunlukları kullanmak avantajlı olabilir [18].

Bu projede HMM’deki emisyon dağılımları diğer bir ifade ile gözlem olasılıkları Gauss karışımı olarak ifade edilmiştir. Bu sayede araçların hareket yörüngesini oluşturan özellik vektörleri, vektör niceme veya süre eşitleme işlemlerinin kullanılmasına gerek kalmadan HMM’e gözlem dizileri olarak verilir. Bu tez çalışmasında sahne üzerindeki araç yörüngelerinin kümelenmesi ve olağan yol modellerinin belirlenmesi işlemlerinde bu yöntem kullanılmıştır [18].

Sürekli HMM’de, modelin ürettiği gözlemlerin olasılık yoğunluk fonksiyonlarının Eşitlik 3.48’de verilen Gauss normal dağılımına uygun olduğu kabul edilmiştir. $b_j(o_t)$, t anında S_j durumunun o_t gözlemini oluşturma olasılığını ifade etmektedir.

$$\eta(o, \mu, \Sigma) = \frac{1}{\sqrt{(2\pi)^{|\Sigma|}}} e^{-\frac{1}{2} \frac{(o-\mu)^2}{\Sigma}} \quad (3.48)$$


$$b_j(o_t) = \eta(o_t, \mu_j, \Sigma_j)$$

3.2.5 Sürekli Saklı HMM Kullanılarak Genel Yol Modellerinin Öğrenilmesi

Trafik görüntülerindeki genel yol modellerinin belirlenebilmesi için kümeleme işlemlerinde kullanılan model parametreleri aşağıdaki şekilde tanımlanmıştır.

- $T_k: \{f_1, f_2, f_3, \dots, f_n\}$, n değişken hareket yörüngesi boyutu olmak üzere her bir hareket yörüngesi T_k ile ifade edilir.
- $f_i: \{x_i, y_i, vx_i, vy_i\}_{t_i}$, bir hareket yörüngesinin t anında konum ve hız bilgilerinden oluşan özellik vektörü f_i ile ifade edilir.
- $S: \{S_1, S_2, S_3, \dots, S_N\}$ Saklı Markov Modelinin N adet Saklı durumunu ifade eder.
- M : Bir Saklı durumu ifade eden Gauss bileşeni sayısını gösterir.
- $A=\{a_{ij}\}$ Saklı durum geçiş olasılıkları matrisini gösterir.
 - $a_{ij} = P\{q_{t+1} = S_j \mid q_t = S_i\} \quad 1 \leq i, j \leq N, q_t: t \text{ anındaki durumu}$

- $B=\{o_t, \mu_j, \Sigma_j\}$ Gözlem olasılıklarının dağılımını gösterir.
 - o_t , t anındaki gözlem
 - μ_j ve Σ_j , S_j durumundaki ortalama ve kovaryans matrisi
- $\Pi=\{\pi_i\}$ Başlangıç durum dağılımları, $1 \leq i \leq N$
- *İterasyon_Sayısı*: Beklenti Maksimizasyonu işlemi için iterasyon sayısını ifade eder.
- *Stop*: Beklenti Maksimizasyonu işlemi ile öğrenmenin tamamlanacağı yakınsama noktasını gösterir
- $\lambda_m = \{A_m, B_m, \Pi_m\}$, öğrenilen Saklı Markov Modeli için m adet olağan yol modelini ifade eder.



Şekil 3.10 HMM ve Gauss Karışımı yapısının kavşak modeli üzerinde gösterimi [18]

HMM ve Gauss karışımı yönteminin yapısı Şekil 3.10'da kavşak modeli üzerinde örneklendirilmiştir. Kavşaktaki genel yol modelinin bir giriş ve çıkış noktası ve 3 saklı durumu bulunmaktadır. Her bir saklı durum 3 farklı $\eta(\mu_k, \Sigma_k)$ Gauss karışımı ile modellenmiştir [18]. Benzer giriş ve çıkış noktalarına göre gruplanan hareket yörüngelerinden genel yol modellerinin üretilebilmesi için Beklenti Maksimizasyonu yönteminden yararlanılmaktadır. Algoritmanın işlem adımları aşağıdaki gibi açıklanmıştır [18].

- Tüm S_j Saklı durumları için başlangıç Gauss modelleri $\eta(\mu_k, \Sigma_k)$ belirlenir.
- Varsayılan ilk olasılık değerleri $P(q_k) = 1/K$ ayarlanır.

- Başlangıç modeli $\lambda_m=(A,B,\Pi)$ seçilir ve $\alpha_t(i)$, $\beta_t(i)$, $\xi_t(i,j)$ ve $\gamma_t(i)$ Saklı markov parametreleri hesaplanır.
- Beklenti adımında her O_t gözleminin $q_j = t$ Saklı durumunda olma olasılığı araştırılır. Bu ifade Eşitlik 3.49'de gösterilmiştir.

$$P(q_t = j | o_t, \lambda_m) = \frac{P(q_t = j | \lambda_m) \cdot p(o_t | q_t = j, \lambda_m)}{P(o_t | \lambda_m)} \quad (3.49)$$

- Maksimizasyon adımında genel yol modeli λ_m 'e ait S_j saklı durumundaki $\eta(\mu_k, \Sigma_k)$ Gauss modellerinin yeni ortalama μ_j ve kovaryans matrisleri Σ_j ve a_{ij} durum geçiş matrisi güncellenir. Elde edilen son markov parametreleri ile yeni $\lambda_{m,yeni}$ modeli oluşturulur. Bu ifade Eşitlik 3.50'de gösterilmiştir.

$$\begin{aligned} \bar{\mu}_j &= \frac{\sum_{k=1}^n \sum_{t=1}^{T_k} \gamma_t^k(j) \cdot o_t^k}{\sum_{k=1}^n \sum_{t=1}^{T_k} \gamma_t^k(j)} \\ \bar{\Sigma}_j &= \frac{\sum_{k=1}^n \sum_{t=1}^{T_k} \gamma_t^k(j) (o_t^k - \bar{\mu}_j)(o_t^k - \bar{\mu}_j)^T}{\sum_{k=1}^n \sum_{t=1}^{T_k} \gamma_t^k(j)} \\ \bar{a}_{ij} &= \frac{\sum_{k=1}^n \frac{1}{P_k} \sum_{t=1}^{T_{k-1}} \alpha_t^k(i) a_{ij} b(o_{t+1}^k) \beta_{t+1}^k(j)}{\sum_{k=1}^n \frac{1}{P_k} \sum_{t=1}^{T_{k-1}} \alpha_t^k(i) \beta_t^k(i)}, i = 1 \dots N, j = 1 \dots N \end{aligned} \quad (3.50)$$


- Eşitlik 3.51 sağlandığı sürece beklenti adımından itibaren yapılan işlemler ve hesaplamalar tekrarlanır. Eşitliğin sağlanmadığı durumda ise öğrenme işlemi tamamlanmıştır.

$$\text{Log}[P(O | \lambda_{m,yeni})] > \text{Log}[P(O | \lambda_m)] \quad (3.51)$$

Her genel yol modelinin öğrenilmesi aşamasında saklı durum sayısı, Gauss karışım sayısı, iterasyon ve yakınsama sayısı gibi Saklı Markov parametreleri aynı değerlerle kullanılmıştır. Saklı durum sayısı kavşak üzerinde bulunan bölgelere göre belirlenmiştir. Kavşaklarda genellikle giriş, orta ve çıkış bölgeleri bulunduğundan [26], her bölge için bir adet saklı durum trafik karakteristiğini yansıtmaya yeterli olmaktadır. Saklı durum ve Gauss karışım sayıları deneyler sırasında elde edilen başarılarla göre değerlendirilmiş

ve denemeler sırasında her ikisi de 3 olarak alınmıştır. Saklı durum ve Gauss karışımı sayısının arttırılması işlem yükünü arttıracığından gerçek zamanlı çalışmalarda çalışma performansını olumsuz etkileyebilmektedir. Saklı Markov modelleri ile ilgili işlemlerin detayları için (Rabiner, 1989) incelenebilir.

Genel yol modellerinin öğrenilmesi ile araçların olağan trafik davranışları m farklı λ_m genel yol modeli ile ifade edilir. Her bir λ_m genel yol modelinin saklı durumlarına ait Gauss bileşenlerinin μ ortalama değerlerin, görüntü çerçevesi üzerinde birleştirilmesi ile genel yol modelleri Şekil 3.11'deki gibi gösterilmiştir. Sağ sütundaki görüntüler üretilen hareket yörüngelerini, sağ sütundaki görüntüler ise öğrenilen genel yol modellerini ifade etmektedir. Şekildeki görüntülerde 6'şar farklı genel yol modeli üretilmiştir. Her bir genel yol modeli 3 HMM saklı durumundan ve her HMM saklı durumu da 3 Gauss karışımından oluşturulmuştur. Bu nedenle her bir genel yol modeli için görüntülerde 9 Gauss karışım noktası (mavi renkli noktalar) bulunmaktadır. Görüntülerdeki siyah noktalar, araçların görüntüye giriş ve çıkış noktalarını ifade etmektedir.




Şekil 3.11 Üretilen hareket yörüngeleri ve kümelenmiş genel yol modelleri

ANOMALİ DURUMLARININ BELİRLENMESİ VE KAZA TAHMİNİ

Bu bölümde sistemin eğitim sürecinden sonra takip edilen araçlar için hangi anomali (olağandışı) durumların değerlendirildiği, bunların nasıl tespit edildiği ve kaza riskinin nasıl hesaplandığı ile ilgili sistem tasarımı anlatılmıştır.

Kaza riskleri, takip edilen araçlar arasında ikili eşleştirmeler ile hesaplanmıştır. Kaza riskinin araştırılacağı araca kaynak araç, kaynak araç ile kazaya karışma olasılığı bulunan araca ise hedef araç adı verilmiştir. Bir araç, kaynak araç olarak belirlendikten sonra öncelikle hangi genel yol modelinde hareket ettiği bulunur diğer bir ifade ile sınıflandırılır. Kaynak aracın hangi genel yol modelinde hareket ettiğinin belirlenebilmesi için kısmi hareket yörüngesi ile öğrenilen tüm yol modellerinin benzerliği hesaplanmış ve değerlendirmesi yapılmıştır. Kaynak aracın bulunduğu yol modeli ile hiçbir ilişkisi olmayan yol modellerindeki araçlar, hedef araç olarak belirlenmez ve kaza riski hesaplamasına dahil edilmez. Kaynak aracın sınıflandırıldığı genel yol modelinin kesişiminde veya yanyana paralelinde bulunan diğer yol modelleri kaza riskinin hesaplanacağı ilişkili genel yol modelleri olarak işaretlenir. Kaynak araç ile ilişkili yol modellerinde bulunan her bir hedef araç için kaza riski hesaplaması yapılarak, araçların hareket doğrultularına ve anlık hızlarına göre ilgi alanları (Region of Interest-ROI) bulunur. Sonuçta ise kaynak ve hedef araçların ilgi alanlarının kesişimine ve anomali olup olmaması durumuna bağlı olarak bir risk faktörü değeri elde edilir. Sistemin uygulama sürecinin girdileri, işlem adımları ve çıktıları Şekil 4.1’de açıklanmıştır.




Şekil 4.1 Anomali durumların tespiti ve kaza risk hesabı

4.1 Kısmi Hareket Yörüngelerinin Üretilmesi ve Genel Yol Modelleri ile Sınıflandırılması

Kısmi hareket yörüngeleri, aracın öğrenilen genel yol modelleri ile sınıflandırılması için araç hareket halindeyken elde edilen alt hareket parçalarıdır. Alt hareket parçaları aracın son takip noktalarından belirli sayıda örnek alınması ile oluşturulur. Bu çalışmada deneysel sonuçların değerlendirilmesi sonucunda hareket eden aracın her 1/4 saniyede, 1 defa sınıflandırılması yeterli görülmüştür [28]. Araç hareket halindeyken her görüntü çerçevesi geçişinde araç için bir takip izi noktası bulunur. Dolayısı ile işlenen videonun 1 saniyedeki görüntü çerçevesi sayısının 1/4'ü kadar takip

izi noktası elde edildiği anda kısmi yörünge oluşturulmuş kabul edilir ve öğrenilen genel yol modelleri ile sınılandırma işlemi yapılır. Şekil 4.2’de her bir kısmi yörünge penceresinin 6 takip noktasından oluştuğu bir örnek gösterilmiştir. Kesikli sarı çizgiler öğrenilen genel yol modellerini ifade etmektedir. 1 saniyedeki toplam görüntü çerçevesi sayısının 24 olduğu durumda, 4 farklı kısmi yörünge penceresi üretilmiştir. Araç hareketi boyunca pencere boyutunu tamamladığı anda yeni kısmi yörünge penceresi oluşturulur.




Şekil 4.2 Kısmi yörünge pencere boyutunun gösterimi

Kısmi hareket yörüngesinin değerlendirilmesinde, seçilen pencerenin boyutu olağandışı davranışların oluşma anının yakalanmasında ve olay şiddetlerinin ortaya çıkartılmasında önemli rol oynamaktadır. Araç için her kısmi hareket yörüngesi üretildiğinde, mevcut genel yol modelleri ile sınılandırma işlemi yapılır. Sınılandırma işlemi için, kısmi hareket yörüngelerinin öğrenilen genel yol modellerine öklid uzaklıklarının ve aracın hareket doğrultusunun mevcut genel yol modelleri ile yaptığı açı bilgilerinin birlikte değerlendirilmesinden elde edilen benzerlik oranından yararlanılır [28]. Aracın kısmi hareketinin öğrenilen tüm genel yol modelleri ile benzerlik değerleri hesaplandıktan sonra karşılaştırılarak, aracın kısmi yörünge benzerliğinin maksimum olduğu genel yol modeli üzerinde hareket ettiği sonucuna ulaşılır. Diğer bir ifade ile aracın kısmi hareketi sınılandırılmış olur. İlerleyen bölümde araçların genel yol modellerine benzerliklerinin hesaplanma yöntemi açıklanmıştır.

4.1.1 Sınılandırma Benzerlik Değerinin Hesaplanması

Bir aracın hareketinin sınılandırılması için kısmi yörüngelerin genel yol modellerine uzaklıkları ve kısmi yörüngelerinin doğrultuları ile genel yol modellerinin doğrultularının benzerlikleri birlikte değerlendirilmektedir.

Bu bölümde takip edilen bir aracın, öğrenilen tüm genel yol modellerine piksel cinsinden uzaklıklarının bulunması hedeflenmiştir. Bu durum Şekil 4.3’de yer alan örnek ile açıklanmıştır. Şekilde GYM_A’dan, GYM_E’ye kadar isimlendirilmiş 5 farklı genel yol modeli sarı renkli doğrular ile ifade edilmiştir. Takip edilen mavi renkli arac için üretilen kısmi yörüngeler kırmızı kesikli doğru ile gösterilmiştir. Aracın kısmi yörüngesini oluşturan noktaları temsil eden C geometrik merkez noktası şekilde açık mavi renkle gösterilmiştir.



Şekil 4.3 Araçların uzaklık benzerliklerinin hesaplanması

Sınıflandırma işleminde öncelikle aracın başlangıç noktası X, bitiş noktası Y olan kısmi yörüngesi için diğer 5 genel yol modeli ile oklid uzaklıklarının hesaplanması gerekmektedir. Ancak öğrenilen genel yol modelleri aracın hareketine göre genellikle doğrusal değil, eğrisel bir hareket yörüngesi olarak oluşmaktadır. Bu nedenle C merkez noktasının genel yol modellerine dik uzaklığını bulabilmek için, öğrenilen genel yol modellerini doğrusal olarak ifade edilebilecek alt parçalara ayırmak gerekmektedir [28]. Bunun için her bir genel yol modelini oluşturan 9 gauss karışım noktasından yararlanılır. Her bir genel yol modeli için C merkez noktasına en yakın 2 gauss karışım noktası seçilir ve bu noktalardan geçen doğrunun denklemi bulunur. Sonrasında C merkez noktasının, oluşturulan doğru denklemine olan dik uzaklığı d_n hesaplanır. μ_1 ve μ_2 değerleri bir genel yol modelinin C merkez noktasına en yakın gauss karışım

noktaları olmak üzere Eşitlik 4.1 kullanılarak iki gauss karışım noktası bilinen doğrunun denklemi elde edilir [28].


$$\frac{\mu_{2y}-\mu_{1y}}{\mu_{2x}-\mu_{1x}} = \frac{y-\mu_{2y}}{x-\mu_{2x}} \quad (4.1)$$

Aşağıdaki Eşitlik 4.2 kullanılarak bir C noktasının genel yol modelinden Eşitlik 4.1 kullanılarak elde edilen doğruya dik uzaklığı d_n hesaplanır [28].

$$d_n = \frac{|a.C_x + b.C_y + c|}{\sqrt{a^2 + b^2}} \quad (4.2)$$

Şekil 4.3’de yer alan örnekte C merkez noktasının öğrenilen tüm genel yol modellerine dik uzaklıkları olan $D = \{d_a, d_b, d_c, d_d, d_e\}$ hesaplanmaktadır. Benzerlik oranları, bulunan uzaklık değerleri ile ters orantılıdır [28].

Sadece piksel cinsinden uzaklığın hesaplanarak benzerliğin değerlendirilmesi ve kısmi hareket yörüngesinin kendisine en yakın genel yol modeline sınıflandırılması yeterli ve her zaman doğru değildir. Örneğin Şekil 4.4’de $d_e < d_b$ şeklinde hesaplandığı anda C merkez noktası, araç gerçekte GYM_B üzerinde hareket ederken GYM_E modeline sınıflandırılabilir. Özellikle genel yol modellerinin kesişim noktalarında yaşanabilecek bu türden yanlış sınıflandırmaları önlemek için uzaklığın yanı sıra aracın açisal doğrultusunun da benzerlik için değerlendirilmesi gerekmektedir. Bu sayede aracın kendisine en yakın genel yol modeli ile aynı doğrultuda hareket edip etmediği anlaşılır.



Şekil 4.4 Araçların açısal benzerliklerinin hesaplanması

Araçların öğrenilen genel yol modelleri ile açısal benzerlik değerlerinin bulunması Şekil 4.4'deki örnek ile açıklanmıştır. Araçlar öğrenilen genel yol modelleri ile ne kadar küçük açı yaparak hareket ederse doğrultusal olarak o modele o kadar fazla benzemektedir. Araçların açısal benzerliklerini belirlemek için öncelikle başlangıç noktası X ve bitiş noktası Y olarak iki noktası bilinen kısmi yörünge, koordinat düzeleminde X eksenine ile yaptığı açı θ_C Eşitlik 4.3'deki gibi hesaplanır [28].

$$m_C = \frac{E_y - S_y}{E_x - S_x}$$

$$m_C = \tan(\theta_C) \quad (4.3)$$

$$\theta_C = \tan^{-1}(m_C)$$

Eşitlik 4.4 kullanılarak şekilde tüm genel yol modellerinin kısmi hareket yörüngesine en yakın iki noktasından geçen doğruların X eksenine ile yaptığı açılar $\theta_{GYM[A,B,C,D,E]}$ hesaplanır. θ_C ile $\theta_{GYM[A,B,C,D,E]}$ genel yol modellerinin X eksenine göre yaptığı açılarının farkları genel benzerlik oranlarını hesaplamak için kullanılır. Bu durum Eşitlik 4.4'de $F_{[A,B,C,D,E]}$ ile gösterilmiştir. Buna göre aracın genel yol modelleri ile yaptığı açıları ifade eden $F_{[A,B,C,D,E]}$ değerlerinin sıfıra yakınsadığı oranda araçların ile genel yol modellerinin aynı doğrultuda olduğu ifade edilir [28].

$$F_{[A,B,C,D,E]} = (\theta_C - \theta_{GYM[A,B,C,D,E]}) \quad (4.4)$$

Şekil 4.4'deki örnekte hareket eden aracın kısmi yörüngesi ile birbirleri yaklaşık dik açıyla kesişen GYM_B ve GYM_E arasındaki açısal benzerlikler değerlendirilmiştir. Buna göre şekilde, GYM_B için C merkez noktasına en yakın noktalar olan $P1_b$ ve $P2_b$ noktaları ile GYM_E için $P1_e$ ile $P2_e$ noktalarından geçen doğruların koordinat düzlemine göre açıları olan θ_{GYM_B} ve θ_{GYM_E} hesaplanmaktadır. Bu örnekte araç yaklaşık olarak GYM_B doğrultusunda hareket ediyor olduğundan, F_B açısal fark değeri sıfır dereceye yakınsayacaktır. Aracın hareket hareket açısının GYM_E ile yaptığı açısal fark değeri F_E ise 90 dereceye yakınsayacağından aracın GYM_E ile farklı doğrultularda hareket ettiği anlaşılır. Bu sayede aracın genel yol modellerine piksel cinsinden uzaklık değeri, genel yol modellerinin kesişim noktalarında farklı genel yol modellerine daha yakın çıkması

durumunda aracın doğrultusu da değerlendirildiğinden doğru sınıflandırma yapılmış olur.

Tüm genel yol modelleri için açılar hesaplandıktan sonra kısmi yörünge için hesaplanan açı ile farkları alınır. Bu açısal fark ne kadar küçük ise aracın kısmi yörüngesinin genel yol modeline o kadar benzediği sonucuna ulaşılır. Ancak hesaplanan açısal benzerlik uzaklık benzerliği ile birlikte değerlendirilerek genel benzerlik oranı elde edilmektedir. Genel benzerlik oranları araçların uzaklık benzerlikleri ile açısal benzerliklerinin çarpımı olarak ifade edilmektedir. Bu durum Eşitlik 4.5’de $R_{[A,B,C,D,E]}$ genel benzerlik değeri ile gösterilmiştir. Aracın hesaplanan $R_{[A,B,C,D,E]}$ değerlerinin en düşük çıktığı genel yol modeli üzerinde hareket ettiği kabul edilir ve bu genel yol modeline sınıflandırılır [28].

$$R_{[A,B,C,D,E]} = D_{[A,B,C,D,E]} \cdot F_{[A,B,C,D,E]} \quad (4.5)$$


Bu sayede genel yol modellerinin kesişim bölgelerinde uzaklık benzerliklerinin birbirine yakın çıktığı durumlarda genel yol modellerinin açısal farklılıklarının dikkate alınması ile yanlış sınıflandırmanın önüne geçilmektedir. Hesaplanan benzerlik oranları belirli bir eşik değerinin altında ise aracın bu genel yol modelinde hareket ettiği kabul edilir [28]. Eğer kısmi yörünge benzerlik oranı belirli bir oranın üzerinde ise bir anomali durumundan söz edilebilir. Bu durum ile ilgili inceleme ilerleyen bölümlerde açıklanmıştır.

4.2 Anomali Trafik Davranışlarının Belirlenmesi

Anomali trafik davranışları, araçların normal trafik akışına uymayan, diğer bir ifade ile olağandışı hareketlerini ifade eder. Anomali davranışları trafiğin güvenliğini tehlikeye atan ve kazalara sebebiyet veren nedenler arasında değerlendirilir. Bu çalışmada aracın yanlış yönde ilerlemesi, yol dışına çıkması, U-dönüşü veya yasak bir dönüş yapması durumları Şekil 4.5 üzerinde gösterildiği gibi incelenmiştir. Her araç birbirinden bağımsız bir senaryoyu göstermektedir. Bu bölümdeki çalışmalar [28] referans alınarak açıklanmıştır.

Aracın sınıflandırma sırasında elde edilen benzerlik oranının en yüksek olduğu genel yol modelinde hareket ettiğini düşünmek her zaman doğru değildir. Örneğin araç hareket halindeyken öngörülme bir noktadan yoldan çıkabilir veya emniyet şeridinde

hareket etme durumundaki gibi yolun tamamen dışından seyredebilir. Bu anomali durumlarını tespit edebilmek için benzerlik oranlarının deneysel olarak belirlenen bir eşik değerinden yüksek olması beklenmektedir. Bu durumda aracın belirlenen yolun dışına çıktığı varsayılır. Bu bilgi genel yol modellerinin önceden öğrenilmesinin getirdiği en önemli avantajlardandır. Bu durum Şekil 4.5’de mavi renkli araç ile gösterilmiştir. GYM_E modelinde hareket eden araç GYM_D , GYM_E modellerinde ters yönde ilerledikten sonra yol dışına çıkmıştır. Aracın hareketi sırasında sınıflandırıldığı en yakın genel yol modeli ile uzaklığının ve yaptığı açının arttığı görülmektedir. Bu sayede hesaplanan benzerlik oranları belirlenen eşik seviyesinden yüksek olduğu anda takip edilen aracın yolun dışına çıkmış olduğu anlaşılmaktadır [28].



Şekil 4.5 Anomali senaryoları

Aracın öğrenilen yola ters yönde hareket etmesi de trafik ortamında karşılaşılabilecek ve kazaya neden olabilecek anomali durumlarından biridir. Genel yol modellerinin öğrenilmesi bu durumun da kolaylıkla tespit edilebilmesine imkan tanır. Genel yol modellerinin başlangıç ve bitiş noktaları, araçların görüntüye girdiği ve çıktığı noktalar olarak belirlenir. HMM olarak ifade edilen genel yol modelinde başlangıç ve bitiş noktası arasındaki her bir saklı durumunun ve saklı durumların içerdiği Gauss karışım

ortalamalarının takip sıralaması belirlidir. Diğer bir ifade ile araçlar başlangıç ve bitiş noktaları arasındaki Gauss karışım noktalarını öğrenilen sırada geçmelidir. Kaynak araç hareket ederken, kısmi hareket yörüngesinin, genel yol modelini temsil eden bir HMM'e çok yüksek oranda benzemesi, o aracın doğru yönde hareket ettiği sonucunu vermez. Bu nedenle araç hareket halindeyken sınıflandırıldığı HMM'deki saklı durumları ve Gauss karışımı ortalama noktalarını sırasıyla takip etmelidir [28]. Özetle her durum sadece kendisinden bir sonraki gözlenen duruma geçmeye izin verir. Durumlar arasında öğrenilen sıralamanın tersi yönde bir geçiş yoktur. Bu durumla ilgili örnek Şekil 4.5'de kırmızı renkli araç ile ifade edilmiştir. Şekilde GYM_B genel yol modelinde ilerleyen bir araç, ters yönde ilerleyen araçların hareket yörüngelerine göre eğitilen GYM_D modeline geçmektedir. Bu nedenle araç sınıflandırıldığı HMM durumlarını oluşturan Gauss karışım noktalarından öğrenilenin tersi sırada geçmektedir. Bu sayede ters yöne giren ve ters yönde hareket eden araçlar kolaylıkla belirlenir.

Kazalara neden olan bir diğer anomali durumu olarak araçların birbirleri ile komşuluğu olmayan genel yol modelleri arasındaki geçişleri örnek verilebilir. U-dönüşü bu anomali durumunu en iyi açıklayan örnektir. Takip edilen araçların u-dönüşü yapması durumunda sistemin uyarı alarmı üretebilmesi için araçların kısmi yörüngelerinin sınıflandırıldığı genel yol modelleri arasında komşuluk ilişkisi (şerit değiştirme veya kesişim durumu) olup olmadığına bakılır [28]. Komşuluğun olmadığı durumlar anomali yaratan senaryolara örnek olarak verilebilir. Bu durum Şekil 4.5'de yeşil renkli araç ile ifade edilmiştir. Şekilde GYM_A modelindeki araç komşuluğunun bulunmadığı ve ters yönde hareket eden araçların hareketleri ile eğitilen GYM_E modeline geçiş yapmıştır. Bu durum trafiğin akışını ve güvenliğini bozan bir davranış olarak değerlendirilmektedir.

Bu çalışma kapsamında anomali olarak değerlendirilen durumlardan bir diğeri de araçların beklenmedik bir şekilde ani yavaşlama ve hızlanma durumlarıdır. TRIMARC [11] video veri tabanındaki görüntüler incelendiğinde kaza yapmaya yaklaşan veya kaza yapan araçların yaklaşık %60'ının hızında ani yavaşlama olduğu tespit edilmiştir [28]. Bunun sebebi kaza olasılığını farkedenden araç sürücülerinin, kazayı engellemek için ani bir refleks ile frene basmaları ve en kısa sürede durmaya çalışmalarıdır. Bu anomali durumunu tespit edebilmek için, aracın hareketi sırasında görüntü üzerindeki

yerdeğiřtirmesi ile elde edilen baęıl hız bilgisinden yararlanılmaktadır. Araların hız deęiřimleri deneysel sonulara gre belirlenen bir eřik seviyesinin zerindeki bir oranda olduęu anda, bu durum trafięin akıřını bozan bir anomali olarak deęerlendirilmektedir.

Anomali durumları sistem tarafından kaza riskini artırıcı bir etken olarak kabul edilir. Bařka bir ifade ile rnek kaza veri tabanı incelendięinde aracın yol dıřına ıkması, ters ynde ilerlemesi veya U-dnř yapması gibi durumların kaza ile sonulanma olasılıęını artırdıęı gzlemlenmiřtir. Bu nedenle bu tez alıřmasında anomali durumları kaza riskini artırıcı faktrler olarak deęerlendirilmiřtir. Bir sonraki blmde kaza risk faktrnn kaynak ve hedef aracın anomali durumlarına artırılması ile ilgili bilgi verilmiřtir.

4.3 Kaza Risk Faktrnn Hesaplanması

Kaza risk faktr araların hareketleri sırasında karřılařtıkları kaza risklerinin lsdr. Bu deęer hesaplandıktan sonra kategorize edilerek yksek kaza riski ieren durumlarda alarm retilmesi saęlanır. Bu durum ilerleyen alt konu bařlıklarında detaylı olarak aıklanmıřtır.

Kaza risk faktrn hesaplamak iin bir kaynak ara ve kaynak aracın ait olduęu genel yol modeli ile iliřkili bir yol modelinde bulunan bir hedef ara belirlenir. Bu yaklařımda sadece iliřkili yol modellerindeki aralar iin kaza riski hesaplanacaęından gerekte kaza riski bulunmayan řeritlerde ilerleyen aralar iin kaza riski hesabı yapılmaz. Sonraki ařamada belirlenen kaynak ve hedef ara iin birer İlgi Alanı (Region of Interest-ROI) hesaplanmaktadır. Bir ara iin ilgi alanı o anki doęrultusu ve anlık hızı kullanılarak t sre sonra aracın muhtemelen bulunacaęı yer olarak ifade edilir. Bu nedenle ilgili alanını belirleyebilmek iin ncelikle her iki aracın hareket doęrultusu ve anlık hızı hesaplanmaktadır. İlerleyen blmlerde anlık hızın, hareket doęrultusunun ve ilgi alanının nasıl hesaplandıęı detaylı olarak anlatılmıřtır. Risk faktr hesabına ait yarı kod genel hatları ile řekil 4.6'daki gibi ifade edilmektedir.

```

FOR tespit edilen her araç için BEGIN;

- Her aracın kısmi yörüngesi için öğrenilen Genel Yol Modelleri(GYM) ile
benzerlik oranını hesapla;

IF ( benzerlik oranı < minimum eşik benzerlik oranı OR
    araç sınıflandırıldığı GYM'de ters yönde ilerliyor ise OR
    araç komşuluğu olmayan GYM'ler arasında geçiş yaptı ise) THEN
    - Anomali üret;
END;

- İlişkili GYM'lerdeki kaynak ve hedef araçları belirle;
- İlgilenilen kaynak ve hedef araçlar için anlık hızı hesapla;
- İlgilenilen kaynak ve hedef araçlar için anlık doğrultuyu hesapla;
- Araçlar için anlık hız ve doğrultu bilgisi ile İlgili Alanını hesapla;
- İlgili alanlarının kesişim noktasını hesapla;

IF (kesişim noktası bulundu ise) THEN

    - Araçların anlık hızları ile kesişim noktasına ulaşma sürelerini hesapla;
    - Araçların kesişim noktasına ulaşma sürelerini kullanarak çarpışma
    olasılıklarını belirten Risk Faktörünü hesapla;

    IF (kaynak ve hedef araç için anomali üretildi ise) THEN
        - Risk Faktörü += Anomali durumunun yarattığı kaza riski;
    IF (Çarpışma Risk Faktörü > Çarpışma olasılığı eşik değeri) THEN
        - Çarpışma riski üret;
    ELSE
        - Çarpışma riski bulunamadı;
    END;
END;


```

Şekil 4.6 Risk faktörü hesabı yarı kodu

4.3.1 Anlık Doğrultunun Belirlenmesi

Anlık doğrultu kaza riski incelenen kaynak ve hedef araç için ilgi alanını belirlemek için kullanılır. Normal şartlarda aracın anlık doğrultusu aracın t anındaki takip noktası ile $t-1$ anındaki takip noktalarından geçen bir doğru şeklinde ifade edebilir. Ancak aracın hareket doğrultusu belirlenirken optik akış ile aracın takip noktasının hatalı bulunması, doğrultunun belirlenmesinde başarımı düşürebilmektedir. Bu nedenle aracın doğrultusu belirlenirken aracın t ile $t-6$ arasındaki takip noktaları referans olarak alınmıştır. Bu durum Şekil 4.7'de gösterilmiştir. Şekilde beyaz ve sarı renkli takip noktaları doğrusal olmadığı için son iki takip noktasının referans olarak kabul edilmesi durumunda hareket doğrultusu yanlış hesaplanabilmektedir. Bu nedenle şekilde takip noktaları iki ayrı gruba kümelenecek $t=[2,3,4]$ anındaki ve $t=[5,6,7]$ anındaki takip noktalarının ayrı ayrı geometrik ortalamaları alınarak C_1 ve C_2 küme orta noktaları

bulunur. Bu küme noktalarının merkezinden geçen doğru aracın anlık doğrultusunu verir. Aracın son altı takip noktasının seçilerek genel doğrultunun belirlenmesi optik akış ile araç takibi yapılırken oluşabilecek potansiyel sapmaların önüne geçebilmek için etkili bir yöntem olmuştur. Aracın son iki takip izine göre hareket doğrultusunun seçilmesinin, yanlış doğrultular bulunmasına ve kazaların efektif olarak belirlenememesine sebep olduğu görülmüştür.



Şekil 4.7 Takip edilen aracın hareket doğrultusunun bulunması

4.3.2 Anlık Hızın Hesaplanması


Belirlenen kaynak ve hedef araçların ilgi alanları hesaplanırken bir diğer önemli faktör anlık hızın doğru bir şekilde elde edilmesidir. Anlık hız, optik akış yöntemi kullanılarak takip edilen araçların görüntü üzerindeki ardışık her çerçeve geçişindeki piksel cinsinden yer değiştirmeleri ile doğru orantılıdır. Burada araçların anlık hızı, görüntü üzerindeki yer değiştirmeden hesaplandığı için gerçek hızların bir türevi olan bağıl hız olarak ifade edilir. $t=1$ anında $P(x_1, y_1)$, $t=2$ anında $P(x_2, y_2)$ noktasında olan bir aracın anlık hızı Eşitlik 4.6'daki gibi piksel cinsinden hesaplanır.

$$V = \sqrt{(x_1 - x_2)^2 + (y_1 - y_2)^2} \quad (4.6)$$

4.3.3 İlgi Alanının Belirlenmesi

Araçların doğrultuları ve hızları elde edildikten sonra aracın belirli bir süre sonra tahmini olarak nerede olabileceği diğer bir ifade ile ilgi alanı belirlenmelidir. Bu

çalışmada deneysel çıkarımlar sonrasında aracın üç saniyelik periyod içerisinde kaza durumunun incelenmesi yeterli görülmüştür. Üç saniyelik periyodun artırılması gerçekte kaza olmayacak durumlar için de kaza incelemesi yapılmasına neden olduğundan hata oranının artmasına neden olmuştur. İlgili alanının belirlenmesi için takip edilen kaynak ve hedef aracın hızlarına ve doğrultularına göre üç saniye sonrasında olabileceği yerler belirlenmiş ve o an bulundukları yerler ile arasında kalan bölge belirlenmiştir. Şekil 4.8’de kaynak ve hedef araç için ilgi alanları $ROI(S_{start}, S_{end})$ ve $ROI(T_{start}, T_{end})$ şeklinde gösterilmiştir.



Şekil 4.8 Araçların ilgi alanları kesişimlerinin ve parametrelerinin gösterimi

Aşağıda, Şekil 4.8’de bulunan değişkenlerin anlamları ifade edilmiştir.

S_{start} : Takip edilen kaynak aracın başlangıç noktası

S_{end} : Takip edilen kaynak araç için hesaplanan ilgi alanının son noktasını

T_{start} : Takip edilen hedef aracın başlangıç noktası

T_{end} : Takip edilen hedef araç için hesaplanan ilgi alanının son noktası

$P_{accident}$: İlgi alanlarının kesişim noktası (Tahmin edilen olası kaza noktası)

V_s, V_t : Kaynak ve hedef araç için hesaplanan anlık hızlar.

Eşitlik 4.7-4.10’da kaynak araç başlangıç noktası S_{start} ve hedef araç başlangıç noktası T_{start} ’a göre, araçların ilgi alanlarının bitiş noktaları olan S_{end} ve T_{end} noktalarının araçların anlık hızlarına göre nasıl belirlendiği ifade edilmiştir.

$$S_{end_x} = S_{start_x} + V_{S_x}t \quad (4.7)$$

$$S_{end_y} = S_{start_y} + V_{S_y} t \quad (4.8)$$

$$T_{end_x} = T_{start_x} + V_{T_x} t \quad (4.9)$$

$$T_{end_y} = T_{start_y} + V_{T_y} t \quad (4.10)$$

Araçların ilgili alanları, araçların o anki pozisyonları ile anlık hız ve hareket doğrultularına göre üç saniye sonra olacakları nokta arasında bir doğru olarak ifade edilir. Araçların ilgi alanlarının kesişim noktası $P_{accident}(x,y)$ potansiyel kaza bölgesini belirtir. Kaza riski araştırılan araçların ilgi alanlarının başlangıç ve bitiş noktaları ile anlık doğrultu ve hızlarına göre $P_{accident}(x,y)$ noktasının bulunması Eşitlik 4.11-4.12'deki gibi ifade edilmektedir.

$$P_{Accident_x} = \frac{(S_{s_x} S_{e_y} - S_{s_y} S_{e_x})(T_{s_x} - T_{e_x}) - (S_{s_x} - S_{e_x})(T_{s_x} T_{e_y} - T_{s_y} T_{e_x})}{(S_{s_x} - S_{e_x})(T_{s_y} - T_{e_y}) - (S_{s_y} - S_{e_y})(T_{s_x} - T_{e_x})} \quad (4.11)$$

$$P_{Accident_y} = \frac{(S_{s_x} S_{e_y} - S_{s_y} S_{e_x})(T_{s_y} - T_{e_y}) - (S_{s_y} - S_{e_y})(T_{s_x} T_{e_y} - T_{s_y} T_{e_x})}{(S_{s_x} - S_{e_x})(T_{s_y} - T_{e_y}) - (S_{s_y} - S_{e_y})(T_{s_x} - T_{e_x})} \quad (4.12)$$

4.3.4 Kaza Riskinin Hesaplanması

Kaza riski araçların aynı anda aynı yerde bulunma olasılıklarıdır. Bu amaçla kaynak ve hedef aracın $P_{accident}(x,y)$ noktasına ulaşma süreleri Eşitlik 4.13-4.14'deki gibi belirlenmektedir. Bu eşitliğe göre kaynak ve hedef aracın, anlık konumları ile $P_{accident}(x,y)$ arasındaki mesafeyi, araçların anlık hızlarına göre ne kadar sürede alabileceği hesaplanır.

$$t_S = \frac{\sqrt{(P_{Accident_x} - S_{start_x})^2 + (P_{Accident_y} - S_{start_y})^2}}{V_S} \quad (4.13)$$

$$t_T = \frac{\sqrt{(P_{Accident_x} - T_{start_x})^2 + (P_{Accident_y} - T_{start_y})^2}}{V_T} \quad (4.14)$$

Risk faktörü $P(AccidentRisk)$ Eşitlik 4.15-4.16'deki gibi kaynak ve hedef araçların $P_{accident}(x,y)$ potansiyel kaza noktasına ulaşma süreleri t_T ve t_S değerlerinin oranlanması

ve eğer varsa anomali olasılığı $P(Abnormality_{[T,S]})$ değerinin eklenmesi ile elde edilir. Sonuç olarak elde edilen $P(AccidentRisk)$ değeri 0 ile 1 arasında değişen bir olasılık değeridir. $P(AccidentRisk)$ değeri 1'e ne kadar yakınsa araçların kesişim noktasında aynı anda bulunma olasılığı diğer bir ifade ile kaza olasılığı o kadar yükselmektedir.

$$\text{if}(t_S > t_T) \quad P(AccidentRisk) = \frac{t_T}{t_S} + P(Abnormality_S) + P(Abnormality_T) \quad (4.15)$$

$$\text{else } P(AccidentRisk) = \frac{t_S}{t_T} + P(Abnormality_S) + P(Abnormality_T) \quad (4.16)$$

Her kesişim noktası kesinlikle kaza olacağı anlamına gelmez. Çünkü kaza riskleri araştırılan araçlar, ilgi alanlarının kesişim noktası olan $P_{accident}(x,y)$ noktasından birbirlerine çarpmadan yani farklı zamanlarda da geçebilir. Bu nedenle araçların anlık hızlarına göre kesişim noktasına varış süreleri, kaza olasılığının belirlenmesinde en önemli faktörü oluşturur. Eğer kaynak ve hedef aracın ilgi alanlarının kesişim noktasına ulaşma süreleri eşit veya birbirine yakınsa kaza olasılığı yükselir. Kaza olasılığı $P(AccidentRisk)$ yüksek veya düşük çıkan ya da kaza olasılığı belirli bir süre için beliren ancak kaza ile sonuçlanmayan örneklerde, araçlar için hesaplanan risk faktörünün zamana göre değişimlerinin birbirinden ayırt edici bir şekilde farklı olduğu sonucuna ulaşılmıştır.

4.3.5 Kaza Risk Faktörünün Sınıflandırılması

Gerçek hayattaki kaza örneklerini daha iyi modelleyebilmek ve daha doğru sonuçlar üretebilmek için risk faktörü düşük risk, orta risk ve yüksek risk olmak üzere 3 kategoride incelenmiştir. TRIMARC [11] video veri tabanındaki kaza durumları için hesaplanan risk faktörleri değerlendirildiğinde %0-%35 aralığında hesaplanan risk faktörü değerleri düşük risk, %35-%70 aralığındaki risk faktörü değerleri orta risk, %70 ve üzerindeki risk faktörü değerleri ise yüksek risk kategorilerini oluşturmaktadır. Bu durum Şekil 4.9'daki gibi ifade edilmiştir.



Şekil 4.9 Kaza risk faktörünün kategorizasyonu

Yapılan deneyler sonucunda, bir kaza incelemesi için ardarda hesaplanan en az 3 kaza risk faktörü %70'in üzerinde ise diğer bir ifade ile yüksek risk kategorisine dahil ediliyorsa kaza alarmı üretilmesine karar verilmiştir. Bu durum düşük risk ve orta risk kategorileri için de geçerlidir. Örneğin araç orta risk kategorisine dahil edildiğinde risk faktörünün bu kategoride en az 3 kez ardarda hesaplanmış olması gerekmektedir. Risk faktörünün bu şekilde değerlendirmenin hatalı sınıflandırmaları önlediği sonucuna varılmıştır.

Değerlendirmeler sonucunda yüksek risk kategorisine dahil edilen kaza incelemelerinin %76 oranında kaza ile sonuçlandığı belirlenmiştir. İncelemelere göre kaza olduğu halde tespit edilemeyen yani yüksek risk kategorisine hiç dahil edilmeyen örnekler için düşük ve orta risk kategorisi arasında değişen sınıflandırmalar yapılmıştır. Bu denemelerde sadece düşük risk kategorisine dahil edilen hiçbir örnek bulunmamıştır. Ancak kaza durumu tespit edilemeyen 4 örnek de en fazla orta risk kategorisinde sınıflandırılmıştır. Kaza riskinin düşük veya orta risk kategorisine dahil edildiği incelemelerde anomali durumlarının risk kategorisine etkisi bir sonraki bölümde açıklanmıştır. Sonuç bölümünde kaza risk faktörünün değişimleri detaylı olarak incelenmiş ve sonuçları paylaşılmıştır.


4.3.6 Anomali Durumların Kaza Risk Kategorisine Etkisi

Kaza riskini belirlemek için araçların ilgi alanlarının kesişim durumları tek başına yeterli olmayabilir. Bu nedenle araçların öğrenilen genel yol modellerine aykırı hareketleri bu projede kaza riskini arttıran faktörler olarak değerlendirilmiştir. Özellikle birbirleri arasında geçiş olmayan genel yol modelleri arasında geçiş yapma diğer bir ifade ile U-dönüşü, ters yönde hareket etme, yol dışına çıkma, yanlış yerden dönme gibi durumlar gerçek hayatta kaza riski oluşturan anomali durumlarıdır. Kaynak ve hedef araçlarda tespit edilen anomali durumları için kaza riskinin dahil edildiği kategori bir üst

kategoriye yükseltilir. Örneğin ters yönde hareket eden bir kaynak araç için orta risk kategorisinde hesaplanan risk faktörü anomali durumu nedeniyle yüksek risk kategorisine dahil edilmektedir. Her iki araç için de anomali tespit edildiği durumlarda ise risk faktörü iki kategori birden artırılabilir. Bu durumda düşük risk veya orta risk kategorisinde bulunan bir risk faktörü, yüksek risk kategorisine dahil edilmektedir. Böylece tespit edilen anomali durumları gerçek hayattaki örneklerdeki gibi kaza riski $P(AccidentRisk)$ değerini artırıcı bir etken olarak değerlendirilmekte ve Eşitlik 4.66-4.67’de $P(Abnormality_{[T,S]})$ olarak denkleme dahil edilmektedir.

4.3.7 Kaza Riskinin Kavşak Modelinde İncelenmesi

Şekil 4.10’da muhtemel bir trafik kazası senaryosu açıklanmıştır. İki farklı yöndeki kavşak modeli 3 gidiş, 2 geliş şeridi olacak şekilde tasarlanmıştır. Şeritlerin üzerinde her bir genel yol modeli [A-J] aralığındaki harfler kullanılarak gösterilmiştir.



Şekil 4.10 Örnek kaza senaryosu

Bu senaryoda GYM_A modelinde hareket eden sarı renkli araç, kaynak araç olarak belirlenmiştir. Şekilde GYM_A yol modeli, GYM_B ile paralel, $GYM_{[J,I,H,G,F]}$ yol modelleri ile

ise kesişim durumundadır. Bu yol modelleri sarı renkli aracın kaza riskinin incelendiği durumda ilişkili genel yol modelleri olarak belirlenir. Sarı renkli kaynak araç, yüksek olasılıkla Şekil 4.10'da sarı kesik çizgilerle belirtilen genel yol modellerinde hareket eden araçlarla kazaya karışabilir. Bu durumda kaza riski, yalnızca ilişkili GYM'lerde hareket eden kırmızı ve mavi renkli araçlar için incelenir ve bu iki araç hedef araç olarak seçilir. Bu senaryonda GYM_A modeli ile ilişkili olmayan diğer $GYM_{[E,D,C]}$ genel yol modellerindeki araçlar, sarı renkli kaynak araç ile kaza riski hesaplama işlemine dahil edilmez. Böylece gerçekte kaza riski bulunmayan araçlar için risk hesaplaması yapılmaz.

Şekil 4.10'da sarı renkli aracın hareket ettiği GYM_A modeli ile ilişkili GYM_J modelindeki kırmızı renkli araç, potansiyel bir kaza riski için hedef araç olarak belirlenir. Kırmızı araç ile sarı aracın kaza olasılıkları incelendiğinde, araçların anlık hızlarına ve doğrultularına göre hesaplanan ilgi alanlarının yeşil renkli noktada kesiştiği görülmektedir. Ancak yeşil renkli kesişim noktasına sarı renkli araç daha yakın olduğundan, daha önce geçecektir. Kırmızı renkli araç ise sarı renkli araç geçtikten sonra yeşil noktaya ulaşabilir. Bu nedenle, kaynak ve hedef aracın ilgi alanları kesişmesine rağmen, araçların bu kesişim noktasına ulaşma süreleri farklı olduğundan araçların kaza yapma olasılıkları yani risk faktörü düşük bir yüzde olarak hesaplanır.

Bir diğer hedef araç olarak belirlenen mavi renkli araç ile sarı renkli aracın durumu incelendiğinde ilgi alanları kırmızı kesişim noktası üzerinde kesişmektedir. Bu örnekte araçların o anki hızları ile belirlenen ilgi alanlarına göre kesişim noktasına varış sürelerinin birbirine yakın olduğu görülmektedir. Kesişim noktasına varış sürelerinin oranı 1'e ne kadar yakın çıkarsa, araçların çarpışma ihtimali o kadar yüksektir. Eğer çarpışma sürelerinin oranı yüksek risk kategorisinin eşik sınırı olan %70'in üzerinde ise sistemin alarm üretmesi sağlanır.

DENEYSEL SONUÇLAR

Bu bölümde önerilen sistemin çeşitli kaza veya anomali durumları için farklı parametrelerle gerçekleştirilen deneyler ve bunlara ait sonuçlar incelenmiştir. Deneylerde doğal trafik ortamından alınan TRIMARC [11] ve NGSIM [12] organizasyonlarına ait görüntüler kullanılmıştır. Bu bölümde ilk olarak olağan trafik akışını öğrenme ve yörünge kümeleme ile genel yol modellerinin üretilmesi, sonrasında ise trafik kazası tahmini ile ilgili farklı durum senaryolarının incelenmesi ile ilgili çalışmalar yapılmıştır.

5.1 Araç Hareket Yörüngelerinin Üretilmesi ve Kümelenmesi

Araçların hareket yörüngelerinin doğru bir şekilde kümelenmesi, uygulama sürecinde trafik kazalarının analizinde önemli rol oynamaktadır. Kümeleme işlemindeki örnek sayısının artırılması, kümeyi temsil eden en doğru genel yol modelinin bulunmasında önemli bir faktördür. Kümeleme işleminde, hareket yörüngelerinin özellik vektörü olarak araçların hareketleri boyunca sahip oldukları koordinat bilgileri (x_i, y_i) kullanılmıştır.

Şekil 5.1(a)'daki görüntü çerçevesinde takip edilen aracın anlık hızları sarı renk ile hareket yörüngesi ise mavi renk ile gösterilmiştir. Takibi tamamlanmış aracın hareket yörüngesi Şekil 5.1(b)'deki görüntü çerçevesinde yeşil renkte gösterilmiştir. Yörünge üzerindeki siyah noktalar aracın piramitsel optik akış yöntemiyle takibi sırasında her bir pencere geçişi sürecinde bulunan noktaları ifade etmektedir. Aracın anlık hızı, aracın kaza tahmini sırasında t süre sonra alacağı yolun bulunmasında ve bu sonuca göre kaza risk faktörünün hesaplanmasında önemli bir parametredir.



(a) Hareket eden araç



(b) Hareketi tamamlanmış araç

Şekil 5.1 Araç takibi ve hareket yörüngesinin oluşturulması

Şekil 5.2’de hareket yörüngelerinin bulunması ile ilgili bir görüntü zaman çizelgesi gösterilmektedir. Şekilde takibi tamamlanan araçların sayısı arttıkça yeşil renkli tamamlanmış hareket yörüngelerinin belirli bir şeritte bir araya toplandığı görülmektedir. Araçların görüntüye giriş ve çıkış noktaları ile izledikleri hareket yörüngeleri birbirleriyle benzer özellikler göstermektedir. Şekilde çerçeve #918’de araçların takibi tamamlanmıştır. Elde edilen toplam 8 hareket yörüngesi HMM yöntemi ile modellenerek çerçeve #1180’de gösterilen herbiri 3 Gauss karışımından oluşan 3 saklı durumlu genel yol modeli üretilmiştir.



(a) Çerçeve #161



(b) Çerçeve #319



(c) Çerçeve #528



(d) Çerçeve #734



(e) Çerçeve #918




(f) Çerçeve #1180

Şekil 5.2 Hareket yörüngelerinin ve genel yol modelinin bulunması


Genel yol modellerinin öğrenilmesi için gerekli olan HMM parametrelerinin seçimine yoldaki trafik yoğunluğuna ve üretilen hareket yörüngelerinin özelliklerine göre karar verilir. Hareket yörüngelerinin farklı sürelerde katedilmiş olması ve dolayısı ile farklı sayıda takip noktasından oluşması nedeniyle genel yol modellerinin farklı sayıda HMM saklı durumundan oluşturulması mümkündür. Saklı durum sayısının ve saklı durumları oluşturan Gauss karışım sayılarının belirlenmesi sistemin performansı açısından oldukça önemlidir. Bu parametrelerin yüksek değeri belirlenmesi gerçek zamanlı kısmi hareket yörüngesi sınıflandırma sürecinde işlem zamanını artırmaktadır. Bu projede genel yol modelleri, kavşağa giriş, kavşağın orta noktası ve kavşağın çıkış noktası şeklinde 3 farklı bölüm olarak kabul edilmiş ve 3 farklı HMM saklı durumu ile temsil edilmiştir. Her saklı durumun da 3 Gauss karışım fonksiyonu ile oluşturulması yeterli görülmüştür. Bu parametrelerin daha yüksek belirlenmesi gerçek zamanlı kısmi hareket yörüngesi sınıflandırma sürecinde işlem zamanını artırmıştır. Şekil 5.3'de 5 farklı

hareket yörüngesi kümelenmiş ve oluşturulan HMM durumları ile birlikte görüntülenmiştir. Şekil 5.3(b) ve 5.3(c)'de eksenler koordinat düzlemindeki x ve y eksenlerini ifade etmektedir.



(a)Gruplanmış hareket yörüngeleri


(b)Hareket yörüngelerinin gösterimi



(c) Oluşan gizli durumlar ve Gauss Karışım Noktaları

Şekil 5.3 3 durumlu 3 Gauss karışımli genel yol modeli


Öğrenme sürecinde HMM'in iterasyon sayısının belirlenmesi de doğru genel yol modelinin öğrenilmesinde önemli faktörlerden biridir. Şekil 5.4'de mavi renk ile gösterilen Gauss karışım noktaları HMM iterasyon sayısı 1 iken, kırmızı ile gösterilen noktalar HMM iterasyon sayısı 5 iken, sarı ile gösterilen noktalar ise HMM iterasyon sayısı 9 iken belirlenen noktaları ifade etmektedir. Şekilde eksenler koordinat düzlemindeki x ve y eksenlerini ifade etmektedir. İterasyon sayısının daha arttırılması ile Gauss dağılım noktalarındaki değişikliğin sınırlı kaldığı görülmüştür. Yapılan testler sonucunda HMM iterasyon sayısının 5 olarak belirlenmesinin yeterli olduğu görülmüştür.



Şekil 5.4 HMM iterasyon sayılarının gösterimi


5.2 Kısmi Hareket Yörüngelerinin Sınıflandırılması

Araçların kısmi yörüngelerinin sınıflandırma performanslarının artırılması açısından en önemli parametre, araçların kısmi yörüngelerinin boyutlarının belirlenmesidir. Araçların kısmi yörüngelerinin, çok küçük parçalar şeklinde üretilmesi, aracın sınıflandırma başarısının olumsuz etkilenmesine neden olmaktadır. Kısmi yörüngelerin çok büyük parçalar şeklinde üretilmesi ise sınıflandırma başarımını arttırmakla birlikte aracın hareketi boyunca daha az sınıflandırılmasına neden olduğu için olağandışı durumların yakalanmasındaki hassasiyeti düşürmektedir [28]. Öğrenilen genel yol modelleri ile araçların kısmi yörüngelerinin sınıflandırılabilmesi için hareketleri sırasındaki belirli aralıklarda takip izlerinin örnekleri alınarak üretilen kısmi hareket yörüngeleri Şekil 5.5’deki gibi koordinat düzleminde gösterilmiştir.



(a) Hareket yörüngeleri

(b) Öğrenilen genel yol modelleri




(c) Kısmi yörüngeler

Şekil 5.5 Kısmi yörüngeler ve sınıflandırılacakları genel yol modelleri

Bu proje kapsamında kullanılan görüntülerin saniyedeki çerçeve sayısına ve araçların hızlarına göre farklı kısmi yörünge boyutları ile çalışılmıştır. Şekil 5.5(c)'de 8'er takip izinden oluşan 11 adet kısmi hareket yörüngesi görüntülenmiştir.

Şekil 5.6'da kısmi yörüngelerin sınıflandırılması ile ilgili görüntü zaman çizelgesi gösterilmiştir. Görüntü çerçeveleri soldan sağa, yukarıdan aşağıya ardışık olarak sıralanmıştır.





Şekil 5.6 Takip edilen aracın hareketi sırasında kısmi yörüngelerin sınıflandırılması

Bu örnekte sınıflandırması tamamlanmış hareket yörüngesi mavi, o görüntü çerçevesinde sınıflandırılacak kısmi yörüngeler ise yeşil renk ile ifade edilmektedir. Bu örnekte bir aracın hareketi boyunca 8 farklı kısmi yörünge üretilmiş ve sınıflandırılmıştır. Görüntülerde 1. genel yol modeli kırmızı, 2. genel yol modeli ise sarı renkle ifade edilmiştir. Aracın hareketi boyunca öğrenilen genel yol modellerine olan piksel cinsinden uzaklıkları Çizelge 5.1’de gösterilmiştir. Bu sonuçlara göre aracın 2. genel yol modeline daha yakın hareket ettiği görülmektedir. Çizelge 5.2’de ise aracın her bir görüntü çerçevesi için, öğrenilen iki yol modeli ile açısal benzerlikleri gösterilmiştir. Yaklaşık olarak paralel olan bu iki genel yol modeli için açısal benzerlikler birbirine yakın olmasına rağmen genel olarak 2. genel yol modeli ile aynı hareket açısında hareket ettiği görülebilir. Ancak aracın genel yol modellerine D piksel uzaklıkları ve F açısal benzerlikleri, $R_{[GYM1, GYM2]} = D_{[GYM1, GYM2]} \cdot F_{[GYM1, GYM2]}$ eşitliğine göre birlikte değerlendirildiğinde aracın kesin olarak 2. genel yol modelinde hareket ettiği sonucuna ulaşılır.


Çizelge 5.1 Kısmi yörüngelerin genel yol modelleri ile benzerlikleri

Veri kümesi	Aracın kısmi yörüngesinin piksel cinsinden uzaklık değerleri							
	t=1	t=2	t=3	t=3	t=4	t=5	t=7	t=8
Genel Yol Modeli 1	29.82	26.20	21.98	17.81	16.86	17.70	18.67	19.68
Genel Yol Modeli 2	1.43	0.04	0.44	1.34	1.68	1.46	0.72	0.91

Çizelge 5.2 Kısmi yörüngelerin genel yol modelleri ile yaptığı açılar

Veri kümesi	Aracın kısmi yörüngesi ile GYM'lerin açısıl farkları							
	t=1	t=2	t=3	t=4	t=5	t=6	t=7	t=8
Genel Yol Modeli 1	0.58	1.20	6.91	2.82	0.83	0.18	0.26	3.5
Genel Yol Modeli 2	3.16	2.22	3.48	0.31	0.37	0.07	1.01	0.81

Şekil 5.7'de ise farklı bir kamera ortamında takip edilen aracın 8 farklı hareket yörüngesi arasındaki sınıflandırma başarısı örneği verilmiştir.





Şekil 5.7 Genel yol modellerinin kesişim noktasında sınıflandırma başarısı

Örnekte 5. genel yol modeli sarı renkli yörünge, 4. genel yol modeli pembe renkli yörünge, 2. genel yol modeli ise kırmızı renkli yörünge ile temsil edilmiştir. Bu örnekte incelemeye dahil edilmeyen diğer genel yol modelleri ise beyaz renk ile gösterilmiştir. Çizelge 5.3’de takip edilen aracın kısmi yörüngelerinin genel yol modellerine piksel cinsinden uzaklıklar, Çizelge 5.4’de ise aracın değerlendirilen üç genel yol modeli ile yaptığı açısal benzerlikler verilmiştir. Örnekte takip edilen araç için üretilen kısmi yörüngeler $t=1$ ile $t=6$ arasında doğru bir şekilde 5. genel yol modeline sınıflandırılmıştır. $t=5$ anındaki sınıflandırma işleminde takip edilen araç, 2. genel yol modeline 0.74 uzaklıktadır. Ancak aracın hareketi bu genel yol modeli ile 64.6 derecelik bir açı ile gerçekleşmiştir. Araç, 5. genel yol modeline 1.67 uzaklıkta ve bu yol modeline 1.4 derecelik açı ile hareket etmektedir. Bu nedenle araç 5. genel yol modeline sınıflandırılmıştır. Bu örnekte takip edilen araç 2., 4. ve 5. genel yol modellerinin kesişiminin tam üzerinden geçmesine rağmen açısal benzerliklerin değerlendirilmesinden dolayı sınıflandırma %100 başarımla sonuçlandırılmıştır. Çizelge 5.3 ve 5.4’deki değerlere göre araç hareketinin en çok 5. genel yol modeli ile benzer olduğu görülmektedir.


Çizelge 5.3 Takip edilen araca en yakın yörüngelerin uzaklık benzerlikleri

Veri kümesi	Aracın uzaklık benzerlikleri					
	t=1	t=2	t=3	t=4	t=5	t=6
Genel Yol Modeli 2	88.68	79.91	65.18	38.60	0.74	23.96
Genel Yol Modeli 4	78.38	69.09	55.57	32.62	4.11	56.29
Genel Yol Modeli 5	4.00	4.60	4.87	3.40	1.67	0.21

Çizelge 5.4 Takip edilen araca en yakın yörüngelerin uzaklık benzerlikleri

Veri kümesi	Aracın açısal benzerlikleri					
	t=1	t=2	t=3	t=4	t=5	t=6
Genel Yol Modeli 2	42.8	61.3	69.4	63.9	64.6	1.2
Genel Yol Modeli 4	107.8	123.7	131.8	126.2	122.6	121.8
Genel Yol Modeli 5	8.1	10.3	0.6	4.4	1.4	4.2

5.2.1 Komşuluğu Olmayan Genel Yol Modelleri Arasındaki Geçiş Durumu



Şekil 5.8 Komşuluğu olmayan genel yol modelleri arasında geçiş anomali durumu

Şekil 5.8’de takip edilen aracın birbirleri ile komşuluğu olmayan genel yol modelleri arasında geçiş yaparak olağandışı bir duruma sebebiyet verdiği görüntü zaman çizelgesi

görülmektedir. Kısmi yörüngelerin sınıflandırılması sırasında aracın ancak birbirleri ile komşuluğu olan genel yol modelleri arasında geçişine izin verilmektedir. Şekil 5.8'deki görüntü zaman çizelgesinde aracın t anında sınıflandırıldığı genel yol modelleri sarı renk ile gösterilmiştir. Görüntü zaman çizelgesinde sırasıyla 3 farklı genel yol modeli sarı renk ile gösterilmiştir. Bir başka ifade ile takip edilen araç hareketi sırasında $t=2$ anına kadar 5. genel yol modelinde sınıflandırılmakta, sonrasında $t=4$ anına kadar 0. genel yol modelinde sınıflandırılmakta ve en son olarak da $t=6$ anına kadar 4. genel yol modelinde sınıflandırılmaktadır. Bu örnekte aracın 5. genel yol modelinden, bu yol modeli ile komşuluğu olmayan 0. genel yol modeline geçtiği anlaşıldığı anda anomali durumu tespit edilir. Çizelge 5.5 ve Çizelge 5.6 aracın hareketi boyunca sınıflandırıldığı genel yol modellerine uzaklık ve açısal benzerlik değerlerini göstermektedir.

Çizelge 5.5 Takip edilen araca en yakın yörüngelerin uzaklık benzerlikleri


Veri kümesi	Aracın uzaklık benzerlikleri					
	t=1	t=2	t=3	t=4	t=5	t=6
Genel Yol Modeli 5	6.14	1.27	16.10	43.76	117.60	152.80
Genel Yol Modeli 0	28.87	12.62	0.35	8.26	23.15	30.46
Genel Yol Modeli 4	55.94	39.57	27.54	17.73	0.52	4.33

Çizelge 5.6 Takip edilen araca en yakın yörüngelerin açısal benzerlikleri

Veri kümesi	Aracın açısal benzerlikleri					
	t=1	t=2	t=3	t=4	t=5	t=6
Genel Yol Modeli 5	7.47	44.3	104.59	118.91	103.32	99.86
Genel Yol Modeli 0	125.25	88.38	28.13	11.84	8.84	15.36
Genel Yol Modeli 4	123.6	86.82	26.56	14.77	10.26	10.52

Şekil 5.9'da bu değerlerin grafik üzerindeki değişimleri gösterilmiştir. Bu değerlere göre uzaklık değerleri sırasıyla 5., 0. ve 4. genel yol modellerinde en düşük bulunmuştur. Açısal benzerliklerin ise aracın dönüş yaptığı andan itibaren birbirini yaklaşık dik olarak kesen 5. genel yol modeli ile 0. ve 4. genel yol modelleri arasında ters orantılı olarak değişmekte olduğu görülmektedir. Bu durum Şekil 5.9 (b)'de gösterilmiştir. Bu

değerlere göre araç dönüş yapmaya başladığı $t=2$ anından itibaren 5. genel yol modeli ile yaptığı açı artışa geçmiş ve dolayısı ile aracın bu genel yol modeli ile benzerliği düşüşe geçmiştir.




(a) En yakın yörüngelere uzaklıklar

(b) En yakın yörüngelere açılabilir benzerlikler

Şekil 5.9 Hatalı dönüş yapan aracın sınıflandırma parametrelerinin değişimi

5.2.2 Aracın Öğrenilen Genel Yol Modellerinin Dışına Çıkma Durumu





Şekil 5.10 Aracın öğrenilen yol modellerinin dışına çıkması

Şekil 5.10'da takip edilen araç hareketinin sonunda öğrenilen yol modelinin dışına çıktığı durum incelenmiştir. Çizelge 5.7'de kısmi yörünge ve genel yol modeli arasındaki piksel cinsinden uzaklık ve açısal benzerlik değerlerinin değişimi görülmektedir.


Çizelge 5.7 Kısmi yörüngeler ile 1. genel yol modeli arasında benzerliğin değişimi

Genel Yol Modeli 1	Görüntü Çerçeveleri					
	t=1	t=2	t=3	t=4	t=5	t=6
Araç ile Aradaki Uzaklık	3.93	6.95	12.35	15.94	20.24	25.8
Araç ile Aradaki Açı	3.87	7.88	7.99	10.29	9.54	15.41
Uzaklık*Açı	15.24	54.87	98.77	164.10	172.96	398.04

Bu örnekte aracın hareketi sırasında kendisine en yakın genel yol modeline uzaklığı ve genel yol modeli ile aracın doğrultuları arasındaki açısal fark artmakta yani benzerlik düşmektedir. Aracın belirlenen genel yol modelinin dışına çıktığını saptayabilmek için kısmi yörünge ile genel yol modeli ile yaptığı açı ve uzaklık bilgisi kullanılır. Kısmi yörünge ile genel yol modeli arasındaki açısal fark ve uzaklığın çarpımı, benzerlik ile ters orantılı değerler üretmektedir. Bu değerler gözleme dayalı olarak belirlenen ve genel yol modelinin dışına çıkma durumu olarak kabul edilen eşik değerini geçtiği anda anomali durum tespit edilmektedir. Açısal fark ile uzaklığın çarpımı olarak belirlenen benzerlik eşik değeri bu örnekte elde edilen deneysel sonuçlara göre 150 olarak alınmıştır. t=4 anında açısal fark ve uzaklık çarpımı olan 164.10 benzerlik değerinin 150 benzerlik eşik değerini geçtiği görülmüş ve bu andan itibaren aracın yol dışına çıktığı kabul edilmiştir. Şekil 5.10'da bu durum takip edilen araca en benzer yörüngeyi sarı


renkten kırmızı renge dönüşmesi ile gösterilmiştir. Aracın yol dışına çıkma durumları ile ilgili yapılan testler sonucunda, benzerlik eşik değerinin başarıma oldukça etken olduğu görülmüştür. Testler sonucunda incelenen 4 araç için de doğru bir şekilde yol dışına çıktığı tespit edilmiştir.

5.2.3 Aracın Ters Yönde İlerleme Durumu



Şekil 5.11 Aracın ters yönde ilerlemesi

Şekil 5.11’de takip edilen araç, şeridindeki araçların park etmelerinden dolayı karşı şeritten ilerleyerek olağandışı bir davranışa sebep olmuştur. Bu durumda aracın sınıflandırıldığı genel yol modeli üzerindeki hareketi incelenerek HMM’in durumları üzerinde doğru sırada hareket etmesi beklenmektedir. Ancak bu örnekte araç karşı şeride geçmiş ve dolayısı ile karşı şerit için öğrenilen yol modelinin ters yönünde hareket ettiği tespit edilmiştir. Görüntü zaman çizelgesinde aracın ters yönde ilerlediği genel yol modeli kırmızı ile gösterilmiştir. Belirli bir süre sonunda araç kendi şeridine geçmiş ve görüntülerdeki sarı renkli genel yol modelinde doğru yönde hareketine devam etmiştir. Aracın hareketi sırasında sınıflandırıldığı genel yol modelinde kendisine en yakın nokta görüntülerde beyaz renk ile ifade edilmiştir. Bu örnekte araç $t=1$ ve $t=4$ arasında ters yönde ilerlemekte, son $t=5$ ve $t=6$ anında ise kendi şeridine geçtiği görülmektedir. Ters yönde ilerleme durumları için yapılan testler çerçevesinde olağandışı durumların tamamının tespit edildiği gözlemlenmiştir.




Şekil 5.12 Ters yöne u-dönüşü yapan araç


Şekil 5.12’de u-dönüşü yapan ve ters yönde ilerleyen araç ile ilgili örnek görüntü çerçeveleri bulunmaktadır. İlk çerçevede takip edilen aracın sarı renkli genel yol modeline uygun hareket ettiği görülmektedir. Ancak, aracın 2. görüntü çerçevesinden itibaren yol dışına çıkmaya başladığı ve 3. ve 4. görüntü çerçevelerinde tamamen yolun normal gidiş yönüne ters hareket ettiği tespit edilmiştir. Bu durum şekilde kırmızı renki genel yol modelleri ile gösterilmiştir.

5.3 Trafik Kazası Tahmin Süreci

Bu bölümde araçların, ışık ihlali veya yanlış dönüşleri sonucunda oluşan iki temel kaza durumu ve kaza olmadığı halde kaza gibi tespit edilen durumlar incelenmiştir. Toplam 14 kaza videosu incelenmiş ve bunlarla ilgili analiz sonuçları paylaşılmıştır.

5.3.1 Araçların Işık İhlali Nedeniyle Oluşan Kaza Durumu






Şekil 5.13 Işık ihlali nedeniyle kaza durumunun gelişimi

Şekil 5.13’de iki aracın kaza durumları incelenmiştir. Araçlar daha önce öğrenilen yollarında ve normal doğrultularında herhangi bir olağandışı duruma sebep olmadan ilerlemektedirler. Ancak bu durumda bir kırmızı ışık ihlali söz konusu olduğu için araçlar aynı anda kesişen bir yoldan geçmek durumunda kalmışlardır. Araçlar takip edilirken anlık hızlarına göre belirlenen ilgi alanları(ROI) kesişmektedir. Bu araçlar için ilgi alanlarının kesişim noktasına olan uzaklıkları ve bu uzaklık değerlerinin birbirine oranlanması ile hesaplanan risk faktörü değerleri Çizelge 5.8’deki gibi hesaplanmıştır. Kaza alarmı üretilen yüksek risk kategorisindeki durumlar için risk faktörü değerleri kırmızı ile işaretlenmiştir.

Çizelge 5.8 Kaza riski olan iki aracın kaza risk faktörleri

İlgi Alanı Kesişim Noktasına Uzaklık	Görüntü Çerçeveleri							
	t=1	t=2	t=3	t=4	t=5	t=6	t=7	t=8
1. Araç uzaklığı	2.85	2.06	1.84	1.66	1.14	0.72	0.45	0.36
2. Araç uzaklığı	2.41	2.25	1.77	1.60	1.33	0.87	0.56	0.42
Risk Faktörü/100	0.84	0.91	0.96	0.96	0.85	0.82	0.81	0.81

Çizelge 5.8'deki değerler, Şekil 5.15'de grafik olarak gösterilmiştir. Çizelgeye göre, $t=1$ anında araçlar arası mesafe yüksek iken araçların kesişim noktasına ulaşma süreleri ortalama 2.6 sn olarak hesaplanmıştır. Zaman ilerledikçe araçlar arasındaki mesafe kışalmasına bağlı olarak tahmin edilen çarpışma noktasına ulaşma sürelerinde düşüş gözlemlenmiştir. $t=8$ anında araçların çarpıştıkları görülmektedir. Araçların hareketleri boyunca risk faktör değerlerinin %96 ile % 80 arasında seyrettiği belirlenmiştir. Bu çalışmada araçların %70'in üzerinde çarpışma riski oluşması durumunda olay yüksek risk grubuna dahil edilerek alarm üretilmiştir.




Şekil 5.14 Kaza risk faktörü bileşenleri

Şekil 5.15'de ışık ihlali nedeniyle çarpışan araçlara ait 6 görüntü çerçevesi bulunmaktadır. Her görüntü çerçevesinde daha önce öğrenilen genel yol modelleri de gösterilmiştir. Araçların sınıflandırıldığı genel yol modelleri sarı renk ile gösterilmiştir. $t=6$ anındaki görüntüde araçların çarpıştığı ve bu nedenle sınıflandırıldığı genel yol modellerinin dışına çıktıkları görülmektedir. Bu durumda araçların sınıflandırıldığı genel yol modelleri kırmızı renk ile gösterilmiştir. Bu örnekte araçların kaza riskleri 0.97 ile 0.85 arasında değişmektedir. Araçların ilgi alanlarının kesişim noktasına ulaşma süreleri 1. araç için $t=1$ anında 2.95 saniyeden $t=5$ anında 0.65 saniyeye kadar düşmektedir. 2. araç için bu sürenin $t=1$ anında 2.76 saniyeden $t=5$ anında 0.73 saniyeye düştüğü belirlenmiştir. Çizelge 5.9'da kaza risk faktörleri ve araçların her bir görüntü çerçevesinde kaza noktasına ulaşma süreleri gösterilmiştir. Yüksek risk tespit edilen durumlarda kaza riski kırmızı, düşük risk tespit edilen durumda ise sarı renk ile gösterilmiştir.

Çizelge 5.9 Kaza riski olan iki aracın kaza risk faktörleri


İlgi Alanı Kesişim Noktasına Varış Süreleri	Görüntü Çerçevesi					
	t=1	t=2	t=3	t=4	t=5	t=6
1. Araç süre	2.95	1.85	1.61	1.05	0.65	0
2. Araç süre	2.76	2.17	1.64	0.86	0.73	0
Risk Faktörü/100	0.91	0.85	0.97	0.81	0.88	0



Şekil 5.15 Işık ihlali nedeniyle kaza durumunun gelişimi

5.3.2 Aracın Yanlış Dönüş Yapması Sonucu Oluşan Kaza Durumu

Şekil 5.16’da takip edilen aracın yanlış yönde dönüş yapmaya çalışması nedeniyle kaza durumu oluşmuştur.




Şekil 5.16 Aracın yanlış yönde dönüşü sebebiyle kaza durumunun gelişimi

Çizelge 5.10’da araçların hareketleri boyunca belirlenen muhtemel kaza noktasına olan varış süreleri ve risk faktörü gösterilmiştir. $t=1$ anında araçların muhtemel kaza noktasına olan varış süreleri değerlendirildiğinde kaza, meydana gelişinden yaklaşık 1.7 sn öncesinde tespit edilmiştir. Araçların hareketleri boyunca kaza riskleri %75 ile %91 arasında değiştiğinden yüksek risk kategorisine dahil edilmiş ve Çizelge 5.10’da kaza riskleri kırmızı renk ile gösterilmiştir.

Çizelge 5.10 Kaza riski olan iki aracın kaza risk faktörleri

İlgi Alanı Kesişim Noktasına Varış Süreleri	Görüntü Çerçevesi					
	t=1	t=2	t=3	t=4	t=5	t=6
1. Araç süre	1.67	1.49	0.99	0.87	0.61	0.46
2. Araç süre	2.20	1.63	1.21	0.73	0.47	0.40
Risk Faktörü/100	0.75	0.91	0.81	0.83	0.77	0.86

Şekil 5.17’de araçların çarpışma noktasına varış sürelerinin ve risk faktörü değerlerinin değişimleri grafik olarak gösterilmiştir.



(a) Çarpışma noktasına olan uzaklıkları (b) İki aracın kaza risk faktörü değişimi

Şekil 5.17 Kaza risk faktörü bileşenleri

Şekil 5.18’de bir başka yanlış yöne dönüş durumu takip edilen araçlar genel yol modelleri ile sınıflandırılarak incelenmiştir.






Şekil 5.18 Aracın yanlış yönde dönüşü sebebiyle kaza durumunun gelişimi

Araçların sınıflandırıldığı genel yol modelleri sarı renk ile gösterilmiştir. Bu örnekte yer alan 4 görüntü çerçevesi boyunca siyah renkli aracın yanlış dönüş yapmaya başladığı andan itibaren komşu genel yol modellerinde ilerleyen araçların ilgi alanları kesişmeye başladığı görülmektedir. $t=4$ anında araçların çarpıştığı ana kadar kaza riski %93 ile %70 arasında değişim gösterdiği sonucuna ulaşılmıştır. Çizelge 5.11’de 4 görüntü çerçevesi için risk faktörleri gösterilmiştir. $t=1$ anında 2. aracın kaza noktasına ulaşma süresi 2.7 saniye olarak hesaplanmıştır. Bu değerlere göre ilk kaza tespitinin yaklaşık olarak kaza oluşumundan 2.7 saniye öncesinde yapıldığı sonucuna ulaşılabilir.

Çizelge 5.11 Kaza riski olan iki aracın kaza risk faktörleri

İlgi Alanı Kesişim Noktasına Varış Süreleri	Görüntü Çerçevesi			
	t=1	t=2	t=3	t=4
1. Araç süre	2.90	2.95	1.01	0.32
2. Araç süre	2.70	2.07	1.06	0.42
Risk Faktörü/100	0.93	0.70	0.95	0.76

5.3.3 Kaza Olasılığı Oluşan Araç Davranışları



Şekil 5.19 Çarpışmaya yaklaşan araçların incelenmesi


Araçların kaza yapmaya yaklaştıkları, ancak olayın kaza ile sonuçlanmadığı bir diğer örnek Şekil 5.19’da, toplam altı görüntü çerçevesi ile gösterilmiştir. Bu örnekteki görüntü zaman çizelgesi boyunca hareketi gösterilen 1. araç siyah renk ile, 2. araç ise beyaz renk ile 1. çerçeve görüntüsünde işaretlenmiştir. 1. aracın olağandışı bir şekilde sola dönüş yapılması gereken yerden dönüş yapmaya çalışması kısa süreli bir kaza riski yaratmış ve bu durum tespit edilmiştir. Anomali durumların tespit edildiği zamanlarda araçların kaza riskleri bir üst kategoriye yükseltilmiştir. 1. aracın hareketi boyunca $t=2$, $t=3$ ve $t=4$ zamanlarında olağandışı davranış tespit edilmiştir. 2. araç ise hareketi boyunca yalnızca $t=6$ zamanında olağandışı davranış sergilemiştir. $t=6$ anında

2. aracın kazayı engellemek için şerit dışına çıkması nedeniyle anomali durumu oluşmuştur. Olağandışı davranış sergileyen araçların sınıflandırıldığı genel yol modelleri Şekil 5.19'da kırmızı renk ile gösterilmiştir. Çizelge 5.12'de toplam kaza riski, anomali durumlarının da kaza riskine dahil edilmesi ile hesaplanan son risk kategorisini ifade etmektedir. t=1 ve t=2 zamanlarında araçlar hareketlerine uygun genel yol modellerinde doğru sınıflandırılmış ve bu durum Şekil 5.19'da sarı renkli genel yol modelleri ile gösterilmiştir. t=6 anında araçların ilgi alanı doğrularının herhangi bir kesişim noktası bulunmadığı için çarpışma riski %0 yani düşük risk olarak belirlenmiştir. Ancak t=6 anında anomali tespit edildiği için toplam kaza riski %35'e yani orta risk kategorisine yükseltilmiştir. Çarpışmaya yaklaşan araçları gerçekten çarpışan araçlardan ayıran en önemli faktör araçların muhtemel çarpışma noktasına olan uzaklıklarının değişimidir. Çizelge 5.12'de 1. aracın t=2, 2. aracın ise t=3 anından itibaren, fren yapmaları ve doğrultularını değiştirmeye çalışmaları nedeniyle çarpışma noktası değişmektedir. Bu nedenle araçların çarpışma noktasına ulaşma sürelerinin bu noktalardan itibaren artışa geçtiği görülmüştür. t=5 anında kaza riski %61 olarak belirlenmiştir. Ancak t=5 anında 1. araçtan kaynaklanan bir anomali tespit edildiği için kaza riski, orta risk kategorisinden yüksek risk kategorisinin başlangıç değeri olan %70'e yükseltilmiştir.

Çizelge 5.12 Araçların olağandışı durumlar ile birlikte kaza risklerinin belirlenmesi

	Görüntü Çerçeveleri					
	t=1	t=2	t=3	t=4	t=5	t=6
1. Aracın çarpışma noktasına ulaşma süresi	2.95	1.38	1.77	1.84	2.91	0
2. Aracın çarpışma noktasına ulaşma süresi	2.96	2.13	1.52	1.61	1.79	0
Çarpışma Risk Faktörü/100	0.99	0.64	0.85	0.87	0.61	0
Anomali Tespit Edildi	Hayır	Hayır	Evet	Evet	Evet	Evet
Toplam Kaza Riski/100	0.99	0.64	0.85	0.87	0.70	0.35


Şekil 5.20’de araçların çarpışma risk faktörü anomali risk faktörü ve bu iki risk oranlarının toplamından oluşan toplam kaza risk faktörü değerleri gösterilmiştir. t=2 anından itibaren anomali tespit edilmesi nedeniyle risk faktörünün düşük ve orta risk kategorisinde olduğu durumlarda bir üst kategoriye artırılması sağlanmıştır.



Şekil 5.20 Çarpışma, anomali ve toplam risk faktörlerinin değişimi

5.3.4 Kaza Durumlarının İncelendiği İlişkili Genel Yol Modelleri

Şekil 5.21’de araçların kaza durumlarını incelemek için dikkate alınan genel yol modelleri gösterilmiştir. İlk görüntü çerçevesinde siyah renk ile işaretlenen araç ile kaza olasılığının oluşabileceği genel yol modelleri kırmızı ve sarı renklerle gösterilmiştir. Kırmızı renk ile gösterilen genel yol modelleri siyah ile işaretlenen aracın komşuluğunun bulunduğu yörüngelerdir. Sarı renk ile gösterilen genel yol modelleri ise takip edilen araçların sınıflandırıldığı yörüngeleri ifade etmektedir. Bu örnekte siyah renk ile işaretlenen araç için yapılan incelemede, toplamda 8 genel yol modelinden renklendirilen 5 tanesi içinde hareket eden araçlar için kaza risk analizi yapılmıştır. Böylece geriye kalan ve görüntü çerçevelerinde beyaz renkle gösterilen 3 genel yol modellerinde ilerleyen araçlar ve siyah ile işaretlenen araç arasında kaza olasılıkları hesaplanmamış ve işlem maliyeti düşürülmüştür.



Şekil 5.21 İlişkili genel yol modellerindeki kaza durumu

5.4 Deneyisel Sonuçların Değerlendirilmesi

Yapılan çalışmada TRIMARC[11] veri setindeki 46 farklı trafik durumu incelenmiştir. Bu durumlar için yapılan sınıflandırma incelemelerine göre, takip edilen araçların yaklaşık %95 oranında doğru genel yol modeline sınıflandırıldığı görülmüştür. Ancak genel yol modellerinin kesişim noktalarında ve genel yol modellerinin birbirine yakın olduğu durumlarda sınıflandırma başarımının nispeten düşüş gösterdiği gözlemlenmiştir. Özellikle yolu karşıdan gören kamera açılarında görüntünün derinliğinin artması ve şeritlerin birbirine yaklaşması nedeniyle sınıflandırma başarısı düşmektedir. Aracın doğru sınıflandırma başarımının aracın takip noktasının belirlendiği yere göre arttığı veya azaldığı anlaşılmıştır. Bazı örneklerde aracın dönüş yaptığı durumlarda takip noktasının aracın farklı noktalarına kaymasından dolayı takip ve sınıflandırma başarımı düşüş göstermiştir.

Trafik görüntülerinden 17 tanesi kaza durumlarını içermektedir. Bu kaza görüntülerinden 13 tanesinde kaza durumu doğru bir şekilde tespit edilmiştir. 29 kaza olmayan görüntüden ise kaza olmadığı halde 6 tanesi kaza olarak belirlenmiştir. Bu

sonuçlara göre Çizelge 5.13’de doğru pozitif ve yanlış negatif kaza tespit oranları ile doğruluk ve hassasiyet oranları gösterilmiştir.

Çizelge 5.13 Sistemin doğru pozitif, yanlış pozitif, doğruluk ve hassasiyet oranları

Tahmin Edilen	Doğru Referans	
	Kaza	Kaza Değil
Kaza	13	6
Kaza Değil	4	29
Doğru Pozitif Oranı (DPO)	%76	
Yanlış Pozitif Oranı (YPO)	%20	
Doğruluk (Accuracy)	%80	
Hassasiyet (Precision)	%68	

Testlerde doğru belirlenen kaza durumları 2.9 saniye ile 1 saniye öncesinden tahmin edilebildiği görülmüştür. Yapılan incelemelerde, kaza anına 1 saniyenin altında bir süre kaldığının belirlendiği ve kaza risk faktörünün %70’in üzerinde olduğu durumlarda kazaların yüksek oranda gerçekleştiği belirlenmiştir. Anomali durumlar tespit edildiğinde kaza risk faktörünün bir üst kategoriye yükseltilmesinin projedeki doğru pozitif oranını arttırdığı tespit edilmiştir.

Trafik yoğunluğunun yüksek olduğu durumlarda araç takibinde yanlışlıklar yapıldığı görülmüştür. Bunun sonucunda gerçekte normal olan trafik davranışları anomali olarak belirlenmiştir. Yine aynı nedenle kaza olmayan durumların kaza risk faktör oranları bu nedenle yüksek çıkabilmektedir.

Kamera görüş açısının kazaların önceden tespit edilmesinde önemli bir payı vardır. Kamera görüş açısının çok yatay olduğu durumlarda uzaktaki araçlar yaklaştıkça araçların hızları büyük oranda değiştiğinden araçların ilgi alanlarının belirlenmesinde hatalı durumlar ortaya çıkarabilmektedir. En yüksek başarımın izlenen yolu veya kavşağı dik veya dike en yakın şekilde görecektir şekilde ayarlanmış kamera görüntülerinden elde edildiği tespit edilmiştir.

Kaza durumlarının doğru tespitinde aracın takip noktasının seçimi ve bu noktanın doğru takip edilmesinin rolü büyüktür. Takip edilen noktanın ardışık çerçevelerde araç

üzerinde farklı yerlerde bulunması aracın hareket doğrultusunun yanlış bulunmasına sebep olmaktadır. Bunun sonucu olarak kaza durumlarının geç algılanması veya hiç algılanmaması olasılığı yükselmektedir.

Videonun görüntü kalitesinin aracın tespit edilmesinde ve bölütlenip takip edilmesinde oldukça önemli olduğu görülmüştür. Bu nedenle yol ile yakın renklerde olan veya kamera görüş alanının uzağında bulunan araçların takip, sınıflandırma ve kaza tespit başarımlarının düşük olduğu belirlenmiştir.

SONUÇ VE ÖNERİLER

Trafik kameraları yardımı ile araç trafiğinin incelenmesi ve yapılan çıkarımlara göre gerekli önlemlerin denetleyici sistemler tarafından alınmasının sağlanması, günümüzde önemli araştırma konuları arasındadır. Bu çalışmada doğal trafik ortamındaki araçların genel hareket modellerinin çıkarılarak olağandışı trafik hareketlerinin tespit edildiği ve bu hareket modellerinin birbirleri ile ilişkilerine göre, kaza olasılığının tahmin edildiği yeni bir sistem önerilmiş ve gerçekleştirilmiştir.

Araçların olağandışı trafik davranışlarının belirlenebilmesi için araçların normal hareketleri, kamera açısı dahilinde takip edilerek gruplandırılmış ve Sürekli Saklı Markov Modeli kümeleme yöntemi ile kümelenerek herbiri bir HMM olarak ifade edilen genel yol modelleri üretilmiştir. Sonrasında görüntüye giren her araç için aracın hareketi sırasında elde edilen kısmi hareket yörüngeleri öğrenilen genel yol modelleri içinde benzerliği en yüksek çıkan genel yol modeli ile sınıflandırılmıştır. Araçların sınıflandırılması sırasında genel yol modellerine benzerlik oranlarının belirli bir eşik değerinin altında olması, aracın normal trafik akışına ters yönde gitmesi, u-dönüşü yapması veya ilişkili olmayan genel yol modelleri arasında geçiş yapması anomali (olağandışı) durumlar olarak değerlendirilmiştir.

Araçların kaza risklerinin incelenmesi aşamasında, bir genel yol modeli ile sınıflandırılan aracın, ancak o genel yol modelinin ilişkili olduğu genel yol modellerinde hareket eden diğer araçlar ile kaza yapma olasılıkları incelenmiştir. Böylece görüntüdeki tüm araçların birbirleri ile kaza riskleri incelenmemiş ve işlem karmaşıklığı açısından önemli bir olumlu etki sağlanmıştır. Araçların kaza olasılıkları incelenirken aracın takip

noktasının görüntü üzerindeki her görüntü çerçevesindeki yerdeğiřtirmesi kullanılarak hesaplanan bağıl hız bilgisinden yararlanılmıştır. Kaza riskleri her zaman iki araç arasında incelenmiştir. Kaza riskinin şiddetini belirleyen risk faktörü hesaplanırken, aracın anlık doğırtusu, anlık bağıl hızı ve bir sistem parametresi olarak belirlenen ve ne kadarlık süre içindeki kaza riskinin hesaplanacağı bilgisi olan t süresi ilgi alanlarının belirlenmesindeki en önemli parametrelerdir. Bu parametrelere göre takip edilen kaynak ve hedef araçların belirli bir süre sonrasında nerede olacağı ve bu süre içerisinde aynı zamanda aynı yerde olma durumlarının olasılıkları incelenerek kaza risk faktörü belirlenmiştir. Gerçek hayatta olağıandışı trafik hareketlerinin kaza olasılığını arttırması nedeniyle hesaplanan kaza risk faktörü anomali durumların tespit edildiğı durumlarda bir üst risk kategorisine dahil edilir.

Bu çalışmada önerilen sistem, mevcut trafik kameraları altyapısının kullanılabilmesi nedeniyle kolaylıkla gerçekleştirilebilir. Sistemin farklı kamera açılarındaki farklı yol yapılarına göre yol modellerini öğrenebilmesi, sistemin adatif bir yapıda olmasını ve kolaylıkla genişletilebilmesini sağlamaktadır. Anomali durumların tespitinde ve kaza riskinin belirli bir oranı geçtiğı durumlarda üretilen uyarıcı alarmlar, sistemin denetleyicileri olan trafik operatörlerinin sadece riskli durumların olduğı bölgelere odaklanmasını sağlayabilir. Bu sayede gerekli önlemlerin ve kararların daha çabuk alınması sağlanırken an zamanda bir operatörün çok daha fazla trafik kamerası ile birden ilgilenebilmesinin yolu açılmaktadır.

KAYNAKLAR

- [1] Hu W., Xiao X., Xie D., Tan T. ve Maybank S., (2004). "Traffic Accident Prediction Using 3-D Model-Based Vehicle Tracking", IEEE Transactions on Vehicular Technology, 53(3).
- [2] Lin, C., Huang, Y., Mei, T., Pu, H. ve Hong, C., (2006). "Multi-objects Tracking System Using Adaptive Background Reconstruction Technique and Its Application to Traffic Parameters Extraction", 2006 IEEE International Conference on Systems, Man, and Cybernetics, Ekim 8-11, 2006, Taipei, Taiwan.
- [3] Morris, B. ve Trivedi, M., (2008). "Learning, Modeling, and Classification of Vehicle Track Patterns from Live Video", IEEE Transactions on Intelligent Transportation Systems, 9(3), Eylül 2008.
- [4] Sha, J., Zhao, Y., Wenda, X., Zhao, H., Cui, J. ve Zha, H., (2011). "Trajectory Analysis of Moving Objects at Intersection Based on Laser-Data", 2011 14th International IEEE Conference on Intelligent Transportation Systems Washington, DC, USA. Ekim 5-7, 2011.
- [5] Jouneau, E. ve Carincotte, C., (2011). "Particle-Based Tracking Model for Automatic Anomaly Detection", 18th IEEE International Conference on Image Processing 2011.
- [6] Tu, P. ve Kiang, J., (2010). "Estimation on Location, Velocity, and Acceleration With High Precision for Collision Avoidance", IEEE Transactions on Intelligent Transportation Systems, 11(2), Haziran 2010.
- [7] Ammoun, S. ve Nashashibi, F., (2009). "Real time trajectory prediction for collision risk estimation between vehicles", IEEE 5th International Conference on Intelligent Computer Communication and Processing, 2009. ICCP 2009.
- [8] Desheng, W. ve Jia, W., (2009). "A New Method of Vehicle Activity Perception from Live Video", International Symposium on Computer Network and Multimedia Technology, 2009. CNMT 2009.

- [9] Picciarelli, C., Micheloni, C. ve Foresti, G.L., (2008). "Anomalous Trajectory Patterns Detection", 19th International Conference on Pattern Recognition, 2008. ICPR 2008.
- [10] Lambert, A., Gruyer, D. ve Guillaume, S.P., (2008). "A Fast Monte Carlo Algorithm for Collision Probability Estimation", 2008 10th Intl. Conf. on Control, Automation, Robotics and Vision Hanoi, Vietnam, 17-20 Aralık 2008.
- [11] TRIMARC, Traffic Response and Incident Management Assisting the River Cities, <http://www.trimarc.org>, 10 Ağustos 2011.
- [12] NGSIM, Next Generation Simulation Community, <http://ops.fhwa.dot.gov/trafficanalysisistools/ngsim.htm>, 10 Ağustos 2011
- [13] WHO, World Health Organization, Road Traffic Injuries, <http://www.who.int>, 28 Temmuz 2012.
- [14] TUIK, (2009), Türkiye İstatistik Kurumu, Türkiye Karayolu Trafik Kazaları, <http://www.tuik.gov.tr>, 28 Temmuz 2012.
- [15] MATLAB, SVM Tool, <http://www.mathworks.ch/help/toolbox/bioinfo/ref/svmtrain.html> , 16 Ocak 2012.
- [16] OpenCV, (2011), <http://opencv.willowgarage.com/wiki/>, 8 Nisan 2012.
- [17] European Comission, Road Safety Organization, http://ec.europa.eu/transport/road_safety/specialist/statistics/index_en.htm 15 Ağustos 2012.
- [18] Aköz, Ö. ve Karşlıgil, M.E., (2011). Kısmi Araç Yörüngeleri Kullanımı ile Kavşaklardaki Trafik Olaylarının Görüntü Tabanlı Çözümlemesi", Y.T.Ü. FBE Bilgisayar Mühendisliği Anabilim Dalı, Doktora Tezi, İstanbul.
- [19] Gonzalez, R.C. ve Woods, R. E., (2008). Digital Image Processing, 3. Baskı, Prentice Hall.
- [20] Stauffer, C. ve Grimson, W.E.L., (1999). "Adaptive Background Mixture Models for Real-time Tracking", IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 23-25 Haziran 1999, Fort Collins, USA.
- [21] Welch, G., ve Bishop, G., (2006). "An Introduction to the Kalman Filter", TR 95-041, Temmuz 2006, North Carolina, USA.
- [22] Bouguet, J., (2002). Pyramidal Implementation of the Lucas Kanade Feature Tracker, Description of the algorithm, Intel Corporation, Microprocessor Research Labs.
- [23] Barron J.L., ve Thacker, N.A., (2005). Computing 2D and 3D Optical Flow, Imaging Science and Biomedical Engineering Division, Medical School, University of Manchester.

- [24] Bradski, G. ve Kaehler, A., (2008). Learning OpenCV, Computer Vision with the OpenCV Library, O'Reilly, CA.
- [25] Rabiner, L., (1989). "A Tutorial on Hidden Markov Models and Selected Applications in Speech Recognition", Proceedings of the IEEE, 77(2): 257-286, Şubat 1989.
- [26] Cano J., Kovaceva, J., Lindman, M. ve Brannstrom, M., (2009), "Automatic Incident Detection and Classification at Intersections", Volvo Car Corporation, 09-0245, Sweden.
- [27] Barria, J. A. ve Thajchayapong, S., (2011). "Detection and Classification of Traffic Anomalies Using Microscopic Traffic Variables", IEEE Transactions on Intelligent Transportation Systems, 12(3), Eylül 2011.
- [28] Yüksel, S. ve Karslıgil, M.E., (2012). Trafik Videolarında Araçların Olağandışı Davranışlarının Tespit Edilmesi, Y.T.Ü. FBE Bilgisayar Mühendisliği Anabilim Dalı, Yüksek Lisans Tezi, İstanbul.
- [29] Haberdar, H. ve Albayrak, S., (2005). Saklı Markov Model Kullanılarak Görüntüden Gerçek Zamanlı Türk İşaret Dili Tanıma Sistemi, Y.T.Ü. FBE Bilgisayar Mühendisliği Anabilim Dalı, Yüksek Lisans Tezi, İstanbul.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Uygur ER
Doğum Tarihi ve Yeri : 01.07.1987 / İZMİR
Yabancı Dili : İngilizce
E-posta : uygarer@gmail.com

ÖĞRENİM DURUMU

Derece	Alan	Okul/Üniversite	Mezuniyet Yılı
Lisans	Bilgisayar Müh.	Yıldız Teknik Üniv.	2009
Lise	Sayısal	Buca Anadolu Lisesi	2005

İŞ TECRÜBESİ

Yıl	Firma/Kurum	Görevi
2009-Halen	Garanti Teknoloji	Yazılım Uzmanı
2008-2009	Smartsoft Bilgi Teknolojileri	Yazılım Mühendisi

YAYINLARI

Bildiri

1. Uygur Er, Süleyman Yüksel, Ömer Aköz, Elif Karşıgil, (2012), “Traffic Accident Risk Analysis Based on Relation of Common Route Models”, International Conference on Pattern Recognition.