

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

**TRAFİK VİDEOLARINDA ARAÇLARIN OLAĞANDIŞI DAVRANIŞLARININ
TESPİT EDİLMESİ**

SÜLEYMAN YÜKSEL

**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

**TRAFİK VİDEOLARINDA ARAÇLARIN OLAĞANDIŞI DAVRANIŞLARININ
TESPİT EDİLMESİ**

Süleyman YÜKSEL 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 Karslıgil
Yıldız Teknik Üniversitesi

Jüri Üyeleri

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

Prof. Dr. Nizamettin Aydın
Yıldız Teknik Üniversitesi

Doç. Dr. Yusuf Sinan Akgül
Gebze Yüksek Teknoloji Enstitüsü

Günümüzde, ölümlere, yaralanmalara, maddi ve manevi hasarlara sebebiyet veren trafik kazalarının sayısı her geçen gün artmaktadır. Bu sayıların daha da artmasının engellenebilmesi amacıyla çeşitli projeler yürütülmektedir. Bu çalışmada trafikteki olağandışı araç davranışlarının tespit edilmesi sağlanarak gerek meydana geldiği anda kazaların tespitinin, gerekse kazalara sebebiyet verebilecek sürücülerin veya yapısal yol bozukluklarının tespitinin yapılması amaçlanmıştır.

Almış olduğum lisans ve yüksek lisans eğitimine ek olarak bu tez çalışmasının konu belirlenmesi aşamasından tamamlanmasına kadar geçen süreçte değerli bilgi ve tecrübelerini benimle paylaşarak önemli bir yol gösterici olan tez danışmanım Sayın Yrd. Doç. Dr. M. Elif Karslıgil'e sonsuz teşekkürlerimi sunarım.

Tez çalışmasının geliştirilmesi sürecinde daha önce gerçekleştirmiş olduğu "Kısmi Araç Yörüngeleri Kullanımı İle Kavşaklarda Trafik Olaylarının Görüntü Tabanlı Çözümlemesi" isimli doktora çalışmasını referans olarak aldığım ve bu çalışma ile ilgili video görüntülerini benimle paylaşmanın yanında, fikirleri ve problem çözümlerinde desteğini benden esirgemeyen Yıldız Teknik Üniversitesi Bilgisayar Mühendisliği doktora programı mezunu Ömer Aköz'e şükranlarımı borç bilirim.

Başlangıç aşamasından son safhasına dek tez çalışmam sırasında bana verdiği her türlü desteğin yanında bu çalışma ile bağlantılı olarak "Video Görüntülerinden Trafik Kazası Riskini Gerçek Zamanlı Belirleyen Bir Sistem Tasarımı" isimli yüksek lisans tez çalışmasını gerçekleştiren sevgili ev arkadaşım Uygur Er'e sonsuz teşekkür ederim.

Tez çalışmamın her aşamasında özellikle moral olarak desteklerini esirgemeyen sevgili arkadaşlarım Tuğçe Çömez, Alp Eren Bal, Özgür Meral, Ülkü Vural ve Hasan Çakar'a teşekkürü borç bilirim.

Ayrıca bu günlere gelmemde büyük pay sahibi olan ve hayatım boyunca her zaman beni destekleyen sevgili aileme şükranlarımı sunarım.

Ekim, 2012

Süleyman YÜKSEL

İÇİNDEKİLER

Sayfa

SİMGE LİSTESİ.....	vi
KISALTMA LİSTESİ.....	vii
ŞEKİL LİSTESİ.....	viii
ÖZET	xi
ABSTRACT.....	xiii
BÖLÜM 1	
GİRİŞ.....	1
1.1 Literatür Özeti	3
1.2 Tezin Amacı	10
1.3 Hipotez	10
BÖLÜM 2	
SİSTEM TASARIMI.....	12
2.1 İlgili Trafik Görüntülerini İçeren Video Veri Tabanlarının Hazırlanması ...	13
BÖLÜM 3	
KARAYOLU HAREKET MODELLERİNİN ÖĞRENİLMESİ	15
3.1 Trafik Görüntüsünde Araçların Belirlenmesi	18
3.1.1 Görüntülerdeki Parazitlerin Temizlenmesi.....	18
3.1.2 Trafik Görüntülerinde Arka Plan Çıkarımı.....	20
3.1.3 Arka Plan Çıkarımı Sonrası Araçların Belirlenmesi	25
3.2 Araç Temsil Noktalarının Belirlenmesi.....	26
3.3 Görüntülerde Belirlenen Araçların Takibi	27
3.4 Araçlara Ait Hareket Yörüngelerinin Elde Edilmesi.....	35
3.5 Karayolu Hareket Modellerinin Belirlenmesi.....	36

3.5.1	Markov Zinciri	37
3.5.2	Saklı Markov Modeli	38
3.5.2.1	Saklı Markov Modelinin Üç Temel Problemi.....	40
3.5.3	Markov Karar Süreçleri	44
3.5.4	Kısmi Gözlemlenebilir Markov Karar Süreçleri.....	44
3.6	Saklı Markov Modeli ve Gauss Karışımı Yörünge Kümeleme	44
BÖLÜM 4		
ARAÇLARIN OLAĞANDIŞI DAVRANIŞLARININ TESPİT EDİLMESİ		49
4.1	Kısmi Hareket Yörüngesi Sınıflandırma.....	50
4.1.1	Trafik Görüntüsünde Araçların Belirlenerek Takibinin Yapılması.....	51
4.1.2	Takip Edilen Araçların Kısmi Hareket Yörüngelerinin Elde Edilmesi..	51
4.1.3	Kısmi Yörüngelerin KHM'ler Arasında Sınıflandırılması.....	52
4.2	Yörüngeye Bağlı Olağandışı Araç Davranışlarının Belirlenmesi	55
4.3	Bağıl Hıza Bağlı Olağandışı Araç Davranışlarının Belirlenmesi	58
BÖLÜM 5		
UYGULAMA VE DENEYSEL SONUÇLAR		60
5.1	Doğal Ortam Verileri İle Karayolu Hareket Modellerinin Belirlenmesi	60
5.1.1	Eğitim Kümesinin Hazırlanması	60
5.2	Kısmi Hareket Yörüngesinin Elde Edilmesi Ve Sınıflandırma	64
5.3	Yörüngeye Bağlı Olağandışı Araç Davranışlarının Belirlenmesi	66
5.3.1	Şerit Dışında Hareket Eden Araçların Belirlenmesi	67
5.3.2	Ters Şeritte Hareket Eden Aracın Belirlenmesi	70
5.3.3	Komşuluğu olmayan KHM'ler arasında geçiş yapan aracın tespiti....	72
5.4	Bağıl Hıza Bağlı Olağandışı Araç Davranışlarının Belirlenmesi.....	72
5.5	Deney Sonuçlarının Değerlendirilmesi.....	73
BÖLÜM 6		
SONUÇ VE ÖNERİLER		77
KAYNAKLAR		79
ÖZGEÇMİŞ		83

SİMGE LİSTESİ

F_g	Görüntüde ön plandaki nesneler
B_g	Görüntüde arka plandaki nesneler
W	Gauss karışım modeli tabanlı arka plan çıkarımı sınıf ağırlık değeri
M	Gauss karışım modeli tabanlı arka plan çıkarımı sınıf ortalama değeri
Σ	Gauss karışım modeli tabanlı arka plan çıkarımı sınıf varyansı
K	Gauss karışım modeli tabanlı arka plan çıkarımı sınıf sayısı
S	Gauss karışım modeli tabanlı arka plan çıkarımı sınıf adı
$P(x j)$	Gauss karışım modeli sınıf aidiyet olasılığı
$\epsilon(d)$	Lucas-Kanade optik akış vektörü fonksiyonu
u_L	Lucas-Kanade optik akış yönteminde L seviyesindeki konum
N	Saklı Markov yöntemi durum sayısı
P_{ij}	Saklı Markov yöntemi i durumunda j durumuna geçiş olasılığı
π	Saklı Markov yöntemi başlangıç durum dağılımı
D	Karayolu hareket modeli uzaklık benzerlik değeri
θ	Karayolu hareket modeli açısal benzerlik değeri
R	Karayolu hareket modeli genel benzerlik değeri

KISALTMA LİSTESİ

KHM	Karayolu Hareket Modeli
GMM	Gaussian Mixture Model
HMM	Hidden Markov Model
DTW	Dynamic Time Wrapping
LCSS	Longest Common Subsequence
SOM	Self Organizing Maps
HDP	Hierarchical Dirichlet Process
SVM	Support Vector Machine
NGSIM	Next Generation Simulation
TRIMARC	Traffic Response and Incident Management Assisting the River Cities
KHM	Karayolu Hareket Modeli

ŞEKİL LİSTESİ

	Sayfa
Şekil 1.1	California I5 karayoluna ait modelleme işlemi 4
Şekil 1.2	Parçacık tabanlı yörünge analizine dayalı aykırı davranış belirleme 6
Şekil 1.3	Normal ve aykırı yörüngelerin tespiti 7
Şekil 1.4	SVM ile aykırı davranış belirleme..... 9
Şekil 2.1	Sistem tasarım diyagramı..... 13
Şekil 2.2	Çalışmada kullanılan trafik video veri tabanlarından örnek görüntüler 14
Şekil 3.1	Trafikte araçların belirli yörüngeler içerisinde hareketi 16
Şekil 3.2	Karayolu hareket modellerinin öğrenilmesi için gerekli işlem adımları 17
Şekil 3.3	Ortanca yumuşatma filtresinin çalışma mantığı 19
Şekil 3.4	Adaptif GMM ile elde edilen ön plan görüntüsü 24
Şekil 3.5	Bağlı bileşenler analizi ve çevrit belirleme işlemi ile araçların belirlenmesi 25
Şekil 3.6	Araç merkez noktanın belirlenmesi 26
Şekil 3.7	Araç temsil noktasının belirlenmesi..... 26
Şekil 3.8	Nesne takip yöntemleri..... 28
Şekil 3.9	Gerçek dünyada 3 boyutlu harekete ait optik akış vektörü 30
Şekil 3.10	Çeşitli hareket yönlerine göre optik akış yönleri 31
Şekil 3.11	Görüntünün t-1 ve t anındaki iki çerçevesi için Gauss Piramidi gösterimi ... 34
Şekil 3.12	Araç yörüngelerinin elde edilmesi 35
Şekil 3.13	HMM ve Gauss Karışımı yapısının örnek kavşak modeli üzerinde gösterimi 46
Şekil 3.14	Sürekli HMM ile karayolu hareket modellerinin elde edilmesi 48
Şekil 4.1	Olağandışı araç davranışlarının belirlenmesi için gerekli işlem adımları 50
Şekil 4.2	Kısmi Hareket Yörüngesi Sınıflandırma İşlem Adımları..... 51
Şekil 4.3	Bağımsız ardışık kısmi hareket yörüngeleri 52
Şekil 4.4	Kısmi hareket yörüngesinin KHM'lere olan uzaklığının belirlenmesi 53
Şekil 4.5	Kısmi hareket yörüngesinin KHM'ler ile olan açısının belirlenmesi..... 55
Şekil 4.6	Karayolu hareket modellerinin dışında hareket eden aracın tespiti 56
Şekil 4.7	Ters şeritte hareket eden aracın tespiti..... 57
Şekil 4.8	Komşuluğu olmayan KHM'ler arasında geçiş yapan aracın tespiti 58
Şekil 4.9	Araçlar için bağıl hız hesaplaması 59
Şekil 5.1	Araçların takip edilmesi ve araç hareket yörüngesinin elde edilmesi 61
Şekil 5.2	Bir şerit için elde edilen araç hareket yörüngelerinin gösterimi 62
Şekil 5.3	Sürekli Saklı Markov Yöntemi ile KHM'nin elde edilmesi 63
Şekil 5.4	TRIMARC videoları için karayolu hareket modellerinin elde edilmesi 64

Şekil 5.5	Araç takibi ile elde edilen kısmi yörüngeler	65
Şekil 5.6	Kısmi hareket yörüngelerinin sınıflandırılması	65
Şekil 5.7	Belirli bir KHM'ye uygun hareket eden aracın şerit dışında kalma durumu .	67
Şekil 5.8	Emniyet şeridinden hareket eden aracın belirlenme durumu	69
Şekil 5.9	Ters şeritte hareket eden aracın belirlenmesi	71
Şekil 5.10	U dönüşü yaparak ters yönde hareket eden aracın tespiti	72
Şekil 5.11	Kaza sırasında araçların hızında meydana gelen ani değişimin tespiti	73
Şekil 5.12	Araç takip probleminin olağandışı hareketin belirlenmesine etkisi	76

ÇİZELGE LİSTESİ

	Sayfa
Çizelge 2.1 Tezde kullanılan veri kümeleri ve açıklamaları [4]	14
Çizelge 3.1 Nesne takip yöntemleri ve ilgili çalışmalar	30
Çizelge 3.2 Markov modelleri.....	37
Çizelge 5.1 Deney-1 için araç kısmi yörüngesi ve KHM'ler arası uzaklık bilgileri	66
Çizelge 5.2 Deney-1 için araç kısmi yörüngesi ve KHM'ler arası aç ı bilgileri.....	66
Çizelge 5.3 Deney-2 için araç kısmi yörüngesi ve KHM'ler arası uzaklık bilgileri	68
Çizelge 5.4 Deney-2 için araç kısmi yörüngesi ve KHM'ler arası aç ı bilgileri.....	68
Çizelge 5.5 Deney-3 için araç kısmi yörüngesi ve KHM'ler arası uzaklık bilgileri	70
Çizelge 5.6 Deney-3 için araç kısmi yörüngesi ve KHM'ler arası aç ı bilgileri.....	70
Çizelge 5.7 Deney-4 için araç kısmi yörüngesi ve KHM'ler arası uzaklık bilgileri	71
Çizelge 5.8 Deney-4 için araç kısmi yörüngesi ve KHM'ler arası aç ı bilgileri.....	71
Çizelge 5.9 Kaza sırasında araçlara ait hız değ iş im bilgisi.....	73
Çizelge 5.10 Türe göre olağ andış ı davranış belirleme deney sonuçları	74
Çizelge 5.11 Olağ andış ı davranış belirleme deney sonuçları	75

**TRAFİK VİDEOLARINDA ARAÇLARIN OLAĞANDIŞI DAVRANIŞLARININ
TESPİT EDİLMESİ**

Süleyman YÜKSEL

Bilgisayar Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

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

Karayolları trafik akışında sürücüler, güvenli bir şekilde seyahat edebilmek için daha önce belirlenen kurallar çerçevesinde araçları hareket ettirirler. Bu kurallar, karayollarında hareket halinde veya duran vaziyetteki araç ve yayaaların birbirlerine zarar vermeden trafik akışının devam edebilmesi için belirlenmiş olup, gerek yaya gerekse araç sürücülerinin bu kurallara uymaması durumunda araç içerisinde veya dış ortamda can ve mal kaybına sebep olabilecek trafik kazaları meydana gelebilmektedir.

Bu tez çalışmasında, trafik videoları kullanılarak araçların normal trafik akışından farklı olarak yapmış oldukları olağandışı davranışların tespit edilmesini sağlamak üzere bir sistem tasarımı ve gerçekleştirilmesi yapılmıştır. Trafik videolarında araçların yapmış oldukları olağandışı davranışların tespiti amacıyla öncelikle normal trafik akışı sisteme öğretilmiştir. Bu amaçla normal trafik akışında bulunan araçların hareketleri izlenerek elde edilen araç hareket yörüngeleri, karayoluna ait hareket modellerini belirlemek amacıyla Sürekli Saklı Markov Yöntemi kullanılarak kümelendirilmiştir.

Trafik videolarında normal karayolu trafik akışı sırasındaki görüntüler kullanılarak karayoluna ait hareket modelleri belirlendikten sonra diğer aşamada araçların anormal davranışların tespit edilmesi için çalışma yapılmıştır. Bu kısımda yörüngeye bağlı olağandışı araç hareketleri (şerit dışında hareket etme, ters şeritte ilerleme, yanlış U-dönüşü durumları) ve bağlı hıza bağlı olağandışı araç hareketleri (ani yavaşlama ve

hızlanma durumları) tespit edilmiştir. Bu amaçla araçların kısmi yörüngelerinin hareket modelleri ile olan benzerliği belirlenerek hareket modelleri arasında sınıflandırma işlemi yapılmış ve sınıflandırıldığı hareket modeli ile benzerlik oranı belirli bir eşik seviyesinden düşük olan kısmi yörüngeye sahip araçların davranışları olağandışı davranışlar olarak tespit edilmiştir. Ayrıca görüntüdeki araçların hızlarında beklenmedik şekilde meydana gelen ani değişimler de, araçların gerçekleştirmiş olduğu olağandışı davranış olarak belirlenmiştir.

Yapılan deneylerde olağandışı davranışlar %85 doğruluk ve %87 hassasiyet oranı ile tespit edilmiştir. Tespit edilemeyen veya yanlış olarak tespit edilen olağandışı araç davranışlarına ise genellikle araç takibinin tamamlanamaması, araç takibi sırasında merkez noktadaki aşırı kayma gibi etkenlerin neden olduğu görülmüştür.

Anahtar Kelimeler: Olağandışı hareketlerin tespiti, araç tespiti, araç takibi, hareket yörüngesi kümeleme, hareket yörüngesi sınıflandırma

**DETECTION OF ABNORMAL VEHICLE BEHAVIOURS USING
TRAFFIC VIDEOS**

Süleyman YÜKSEL

Department of Computer Engineering

MSc. Thesis

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

On highway traffic flow, drivers move their vehicles to be able to travel safely by complying with certain rules. These rules are determined to maintain the traffic flow without damaging to each other of moving or stationary vehicles and pedestrians on highways. Unless the rules are obeyed by the vehicles or pedestrians, traffic accidents that can cause loss of lives and properties in vehicle or external environment may occur.

In this study, design and implementation of a system to detect the abnormal behaviors of vehicles by using videos is done. Firstly, the normal traffic flow is learned by the system. Therefore, trajectories of vehicles which were tracked in the normal traffic flow are clustered using continuous Hidden Markov Model to determine the highway movement patterns.

After the determination of the highway movement patterns using the camera captures of normal traffic flow, study was progressed to detect the abnormal behaviors of vehicles. In this section, trajectory based abnormal vehicle behaviors (moving outside of the lane or in the opposite lane, wrong U-turns) and relative velocity based abnormal vehicle behaviors (sudden deceleration or acceleration) are detected. For this purpose, classification of the partial vehicle trajectories between highway

movement patterns is done by using the similarity between movement patterns and partial trajectories. Furthermore, sudden unexpected changes in vehicle speeds are also detected as vehicle abnormal behaviors.

According to experimental results, abnormal behaviors of vehicles that have accuracy ratio of 85% precision ratio of 87% are detected. Undetected or wrong detected abnormal vehicle behaviors are caused by factors such as uncompleted vehicle tracking and extreme shift of the center point of the vehicle during the vehicle tracking.

Keywords: Anomaly detection, vehicle detection, vehicle tracking, trajectory clustering, trajectory classification

BÖLÜM 1

GİRİŞ

İnsanların, malların ve hizmetlerin bir amaç için yer değiştirmesi ulaşım olarak adlandırılır. Ulaşım karayolu, havayolu, denizyolu ve demiryolu olarak dört farklı türde gruplandırılırken, maliyet ve bir yerden bir yere varma süresi göz önüne alındığında diğerlerine göre düşük maliyetle kısa sürede yer değiştirmeyi sağladığı için insanlar tarafından en çok karayolu ulaşımı tercih edilmektedir. Karayolları Genel Müdürlüğü tarafından 2010 yılında yapılan araştırmaya göre [1], Türkiye’de yolcu taşımacılığında %90 oranla karayolu ulaşımı kullanılırken, %7.90 oranla havayolu, %1.80 oranla demiryolu ve %0.30 oranla denizyolu ulaşımı tercih edilmektedir. Bu oranlar ulaşım sektöründe karayolu ulaşımının öneminin daha iyi şekilde anlaşılmasına yardımcı olmaktadır.

Karayolu trafik akışının normal bir şekilde seyredebilmesi için sürücüler, bir takım kurallara uygun şekilde kullandıkları taşıtları hareket ettirirler. Bu kurallar, kazaların meydana gelmesini önleyerek can ve mal kayıplarının yaşanmasının önüne geçer. Karayolunda hareket halindeki taşıtların, bir araca, yayaya, hayvana ya da nesneye çarpması trafik kazası olarak adlandırılır. Ülkemizde ve dünyada karayolu ulaşımında kullanılan taşıt sayısının özellikle 2000’li yıllardan itibaren hızlı bir şekilde artış göstermesiyle birlikte, meydana gelen trafik kazası sayıda giderek artmıştır. Trafik Hizmetleri Başkanlığı tarafından Türkiye geneli için hazırlanmış olan istatistiki verilere göre [2], 2011 yılı sonu itibariyle motorlu araç sayısı 16.089.528 olarak açıklanmıştır. Yine 2011 yılına ait kaza istatistikleri incelendiğinde araç sayısındaki yüksek rakamların, ölümlü ve yaralı kaza sayısına yansıdığı görülmüştür. 2011 yılında meydana gelen

ölümlü kaza sayısının 3082 olduğu ve bu kazalarda toplam 3821 kişinin hayatını kaybettiği açıklanırken, 113.589 yaralamalı trafik kazasının meydana geldiği aynı dönemde, yaralı sayısı 237.027 kişi olarak belirtilmiştir. Bu döneme ait maddi hasarlı trafik kazası sayısı ise 1.097.083 olarak istatistiklerdeki yerini almıştır.

Karayollarında meydana gelen trafik kazalarının nedenlerinde ise sürücülerin yapmış olduğu hataların öne çıktığı görülmektedir. Karayolu Trafik ve Yol Güvenliği Araştırma derneğinin yapmış olduğu araştırmada [3], 2010 yılında Türkiye genelinde meydana gelen kazaların %87'si sürücü, %11'i yaya, %2'si ise araç, yol ve yolcu hatalarından/kusurlarından meydana gelmiştir. Bu oranlardan da anlaşıldığı gibi trafik akışının sorunsuz şekilde sürdürülebilmesi, kaza oranlarının minimum düzeye indirilebilmesi için özellikle sürücülerin kazaya sebebiyet verebilecek her türlü davranışlarının azaltılmaya çalışılması ve trafik akışındaki olağandışı davranışlarının tespit edilerek gerekli cezalandırma işlemlerinin yapılması gerekmektedir.

Ülkemizde çeşitli kurumlar tarafından sürücü hatası nedeniyle meydana gelen trafik kazalarının sayısının azaltılabilmesi, can ve mal kayıplarının önüne geçilmesi amacıyla çeşitli çalışmalar yapılmaktadır. Bunlardan en önemlisi trafik akışının sürekli izlenmesidir. Bu amaçla eskiden sadece trafik polisi gibi insanın olay yerinde bulunarak gerçekleştirmiş olduğu trafik akışını izleme işlemi, günümüzde trafik kameralarının trafik akışının iyi bir şekilde izlenebileceği uygun yerlere koyulması ile birlikte, uzaktan daha kolay bir şekilde yapılmaktadır. Kamera görüntülerinin incelenerek, videoların yorumlanması ve trafik kazalarının, trafik akışını bozan sürücülerin tespit edilmesi işlemleri için ayrı bir gözlemciye ihtiyaç duyulurken, bu gözlemci ihtiyacının ortadan kalkması, kazaların ve olağandışı trafik davranışlarının otomatik olarak ayrı bir sistem olarak tespit edilmesi amacıyla da çalışmalar sürdürülmektedir.

Bu tez çalışmasında, trafik videoları kullanılarak araçların normal trafik akışından farklı olarak gerçekleştirmiş oldukları olağandışı davranışların tespit edilmesi amacıyla bir sistem tasarımı ve gerçekleştirilmesi yapılmıştır. 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 İle Kavşaklarda Trafik Olaylarının Görüntü Tabanlı Çözümlemesi” yapılmıştır [4]. Bu tez çalışmasında, [4]’ de geliştirilen yol öğrenme modeli kullanılarak, araçların olağandışı davranışları tespit edilmiştir. Bu çalışmaya bağlı olarak yapılan diğer yüksek lisans çalışmasında ise [5], olağandışı davranışların belirlenmesinin ardından, o anda karayolundaki diğer araçların durumları da dikkate alınarak yapılan kaza riski tahmin etme işleminde, olağandışı davranışlar kaza riskini arttırıcı birer etmen olarak ele alınmıştır. Çalışmada elde edilen çıktılar ve çalışmanın gerçek hayatta uygulanması ile trafikte olağandışı davranışlarda bulunan sürücülere gerekli cezalandırılmanın yapılması, yapımının yanlış olduğu tespit edilen karayollarının yeniden düzenlenmesi gibi çeşitli yaptırımlar sayesinde meydana gelmesi muhtemel can ve mal kaybına neden olabilecek trafik kazalarının sayısının azaltılması hedeflenmektedir.


1.1 Literatür Özeti

Çalışmanın bu bölümünde trafik videolarında araçların olağandışı davranışlarının tespit edilmesi amacıyla daha önce yapılmış çalışmalar anlatılmıştır. Bu çalışmaları iki sınıf altında inceleyebiliriz. Bunlardan ilki karayollarındaki trafik akışının izlenerek, karayoluna ait hareket modellerinin çıkarıldığı çalışmaları, diğeri ise karayollarında meydana gelen olağandışı olayları tespit etme amacıyla yapılmış çalışmaları içermektedir.

Yalnızca karayolu hareket modellerinin çıkarıldığı birinci tip çalışmalarda amaç karayolunu en iyi şekilde temsil eden modelin çıkarılmasıdır. Bu çalışmalarda kümeleme yöntemleri kullanılarak karayolunda araçların takibi sonucunda elde edilen yörüngelerin kümelenmesi ile araçların hareket modelleri çıkarılmıştır. Bu çalışmalar, trafik video görüntülerinden karayolunda şeritlerinin belirlenmesini sağlayan çalışmalar olarak da belirtilebilir. Yörünge kümeleme işlemi üzerine yapılan çalışmalardan önemlileri aşağıda incelenmiştir.

Morris ve Trivedi, karayolunda trafik akışını gösteren videolar üzerinde gerçekleştirmiş oldukları çalışmada iki farklı konu üzerinde çalışmışlardır [6]. Bunlardan ilkinde takip ettikleri araçların tipini belirlemek için bir sistem geliştirmişlerdir. Videoda takip ettikleri araçların türünü tespit etmeye yönelik yaptıkları sınıflandırma işlemi

sonucunda araçların sedan, pikap, SUV, kamyonet, otobüs, motosiklet, tır ve ayrılamayan (birleşmiş) araçlar kategorilerinden hangisine ait olduğunu belirlemeye çalışmışlardır. Akşam ve gece elde ettikleri görüntüler üzerinde araç belirleme ve takip işlemlerinin hatalı sonuçlar vermesi nedeniyle, 06:00 ve 20:00 saatleri arasındaki video görüntüleri üzerinde değerlendirme işlemi yapmışlardır. Çalışmanın bu aşamasında takip edilen araçların %94'ünün doğru şekilde sınıflandırılarak, araç türünün doğru belirlendiği görülmüştür. Ayrıca sınıflandırma işlemi gerçekleştirildikten sonra çalışmanın bir sonraki adımında, hangi saatler arasında hangi tür araçların karayollarını kullandığına dair istatistiksel bilgi edinmeye yönelik olarak çalışmışlardır. Morris ve Trivedi bu çalışmanın ikinci kısmında ise karayollarına ait yol modellerinin belirlenmesi ile ilgili bir çalışma yapmışlardır. Belirli bir periyotta araçların takip edilmesi sonucu elde ettikleri araç yörüngelerini Bulanıksal C-Ortalama (Fuzzy C-Means) ve Gauss Karışımı – Saklı Markov Modeli (Gaussian Mixture Model – Hidden Markov Model(GMM-HMM)) kümeleme yöntemleri yardımıyla kümeleyerek karayoluna ait yol modellerinin öğrenilmesi işlemini gerçekleştirmişlerdir. Öncelikle Bulanıksal C-Ortalama yöntemi kullanılarak elde edilen yörünge kümelerinin verdiği düzlemsel sonuçlar araç davranış analizi için yeterli olmadığından dolayı Bulanıksal C-Ortalama yöntemi ile oluşturulan her aktivite yolu Markov modeline oturturulmuştur. Şekil 1.1'de yapılan çalışmada Bulanık C-Ortalama ve HMM sonucunda elde edilen yol modelleri gösterilmiştir.



Şekil 1.1 California I5 karayoluna ait modelleme işlemi [6]
(a) Görüntüye giriş/çıkış bölgeleri (b) Fuzzy C Means Yöntemi ile oluşan yol modelleri
(c) Saklı Markov Yöntemi ile oluşan yol modelleri

Buzan, Sclaroff ve Kollios, yapmış oldukları çalışmada, gerçek trafik video görüntüleri üzerinde araçları Kalman filtresi kullanarak takip etmiş ve araçlara ait hareket yörüngelerini çıkarmışlardır [7]. Daha sonra En Uzun Ortak Alt Dizi (Longest Common Subsequence (LCSS)) mesafe ölçme yöntemi ile yörüngelerin koordinat düzlemindeki uzaklıkları hesaplanmıştır. Hiyerarşik kümeleme yöntemlerinden biri olan Yığmacı Kümeleme (Agglomerative Clustering) yöntemi ile karayolunda araçların takibi sonucu elde edilen hareket yörüngelerinin kümelenmesi ve karayoluna ait hareket modellerinin belirlenmesi sağlanmıştır.

Heikkonen, Koikkalainen ve Schnörr, yapmış oldukları çalışmada Yapay Sinir Ağlarının öğrenmesiz özel biçimlerinden biri olan Özdüzenleyici Haritalar (Self Organizing Maps (SOM)) yöntemi ile yörünge kümeleme işlemini gerçekleştirmişlerdir [8].

Atev, Miller ve Papanikolopoulos, yörüngeler arası mesafe ölçüm tekniğinin ve kümeleme algoritmasının araçların hareket yörüngelerinin kümelenmesi işleminin sonucuna etkilerini belirlemek üzere gerçek trafik video görüntüleri üzerinde yaptıkları çalışmada görüntülerde GMM ile tespit ettikleri araçları, Kalman filtresi yöntemi ile takip etmişlerdir ve hareket yörüngelerini çıkarmışlardır [9]. Daha sonra Hausdorff, Dinamik Zaman Bükmesi (Dynamic Time Wrapping (DTW)) ve En Uzun Ortak Alt Dizi (Longest Common Subsequence (LCSS)) mesafe ölçme yöntemleri ile elde ettikleri yörüngeler arası uzaklıklar yardımıyla Yığmacı Kümeleme (Agglomerative Clustering) ve Spektral Kümeleme (Spectral Clustering) algoritmalarını kullanarak araçların hareket yörüngelerini kümelemişlerdir.

Karayollarında trafik video görüntüleri üzerine gerçekleştirilen ikinci tip çalışmalarda ise, görüntülerde olağandışı araç davranışlarının tespiti yapılmıştır. Öğrenmeli ve öğrenmesiz olarak gerçekleştirilebilen bu çalışmalardan öğrenmeli tipte olan çalışmalarda, birinci kısımda anlatılan yörünge kümeleme çalışmaları sonucu elde edilen karayoluna ait hareket yol modelleri ile test edilecek görüntülerdeki takibi sağlanan araçların yörüngelerinin benzerliği ele alınmakta ve bunun için çeşitli yöntemler kullanılmaktadır. Aşağıda araçların olağandışı davranışlarının belirlenmesine yönelik olarak yapılmış olan önemli çalışmalar incelenmiştir.

Jouneau ve Carincotte, gerçek trafik video görüntüleri üzerinde araçların normal trafik akışından farklı olarak gerçekleştirmiş oldukları davranışların tespiti amacıyla çalışma yapmışlardır [10]. Sadece kavşaklardan alınan trafik video görüntülerinin üzerine bir sistem gerçekleştirmişlerdir. Video üzerinde araçların belirlenmesinin ve takip edilmesinin ardından izlemiş oldukları yörüngeler üzerinde parçacık tabanlı yörünge analizine dayalı olarak HMM ve hiyerarşik Dirichlet işlemlili Saklı Markov Modeli (HDP-HMM) yöntemlerinin birleşimi ile yapmış oldukları sınıflandırma işlemini temel alan bu çalışmada araçların gerçekleştirmiş oldukları yasak U dönüşleri ve ters yönde ilerlemeler tespit edilmiştir. Çalışmanın sonucunu değişik yöntemlerle kıyasladıklarında diğer çalışmalarda % 45’lerde olan aykırı davranış tespiti başarımının kendi uygulamalarında % 72 civarında olduğunu belirlemişlerdir. Şekil 1.2’de Jouneau ve Carincotte tarafından yapılan çalışmada yol modelinin öğrenilmesi ve aykırı davranış içerisinde olan araçların belirlenmesi gösterilmiştir.




Şekil 1.2 Parçacık tabanlı yörünge analizine dayalı aykırı davranış belirleme [10]
(a) Araçlara ait yörüngelerin elde edilmesi (b) Hareket modellerinin elde edilmesi
(c) Aykırı davranışlardaki araçların tespiti

Piciarelli, Micheloni ve Foresti’nin yapmış oldukları Destek Vektör Makinaları (Support Vektor Machines(SVMs)) yöntemine dayalı anormal yörünge belirleme çalışmasında SVM’nin kümeleme işlemi uygulanmamış ve uygulanmış veri kümeleri üzerindeki başarımını karşılaştırmışlardır [11]. Öncelikle yörüngelere ait veriler üzerinde SVM ile aykırı yörünge tespiti yapmışlardır. Daha sonra ise yörüngelere ait veriyi k-Ortalama Kümeleme (k-Means Clustering) yöntemi ile kümelemişlerdir. Ardından da SVM kullanarak aykırı yörüngeleri belirlemişlerdir. 30 – 100 arası değişen sayıda düzgün yörünge ve 20 şer adet aykırı yörünge içeren 20 farklı test verisi üzerinde yapmış

oldukları testlerde k- Ortalama Kümeleme yöntemi kullanarak yapılan kümeleme işleminin ardından uygulanan SVM ile aykırı yörünge belirleme işleminin daha başarılı sonuç verdiğini gözlemlemişlerdir.

Hanapiah, Al-Obaidi ve Chan, anormal yörüngeye sahip araçların tespiti üzerine yaptıkları çalışmada gerçek trafik kamera görüntüleri üzerinde çalışmışlardır [12]. Öğrenme işlemi sırasında GMM kullanarak görüntüye giren araçların belirlenmesi işleminin ardından, araçların takip işlemini olasılıksal görünüm manifoldu tabanlı izleme yöntemi kullanarak gerçekleştirmişlerdir. Daha sonra bölgesel regresyon analizi ve bulanık kural tabanlı bir sınıflandırma işlemi gerçekleştirilerek kamera görüntülerine test aşamasında giriş yapan araçların yörüngelerini normal, çok normal, şüpheli, çok şüpheli şeklinde sınıflandırmışlardır.

Sha, Zhao, Xu, Zhao, Cui, ve Zha, lazer tarayıcılar yardımıyla elde ettikleri araç yörüngeleri üzerinde öklid uzaklığına dayalı olarak kendilerinin geliştirmiş oldukları kümeleme yöntemi yardımıyla yörünge kümeleme işlemi yapmışlardır [13]. Ardından olasılıksal Bayes yöntemi kullanarak aykırı yörüngelerin tespit işlemini gerçekleştirmişlerdir. Şekil 1.3'de çalışmada lazer tarayıcılardan alınan yörüngelerin kümelenmesi ve daha sonra elde edilen yörüngelerin sınıflandırılarak normal ve anormal yörünge olarak değerlendirilmesi gösterilmiştir.



Şekil 1.3 Normal ve aykırı yörüngelerin tespiti [13]


(a) Yörüngelerin kümelenmesi (b) Normal yörünge tespiti (c) Anormal yörünge tespiti

Hu, Xiao, Fu, Xie, Tan ve Maybank, gerçek trafik kamera görüntüleri üzerinde gerçekleştirmiş oldukları çalışmada olağandışı davranışların belirlenmesi üzerine bir sistem önermişlerdir [14]. Araçların takip edilmesi sonucu elde edilen hareket yörüngeleri Bulanık k-Ortalama Kümeleme (Fuzzy k-Means Clustering) yöntemi

kullanılarak kümelenmiştir. Ardından olağandışı davranışların belirlenmesi amacıyla Bayes tabanlı sınıflandırma algoritması kullanarak sınıflandırma işlemini gerçekleştirmişlerdir. Çalışma sonucunda araçların gerçekleştirmiş oldukları U dönüşleri ve yanlış yöne girme olayları tespit edilmiştir.

Saunier, Sayed ve Lim yapmış oldukları çalışmada, gerçek trafik kamera görüntüleri üzerinde özellik tabanlı bir izleme yöntemi sonucunda elde ettikleri araç yörüngelerini öğrenme adımı aşamasında LCSS mesafe ölçme yöntemi ile kümelemişler ve araçların gidebilecekleri yol modellerini çıkarmışlardır [15]. Daha sonra ise bu yol modellerinin yardımıyla test aşamasında sisteme giren araçların diğer araçlarla olan çarpışma olasılıkları hesaplanarak video görüntülerindeki kaza riskinin bulunmasına yönelik bir çalışma gerçekleştirmişlerdir.

Piciarelli, Micheloni ve Foresti, araçların tipik ve aykırı davranışları belirlemek amacıyla bir çalışma gerçekleştirmişlerdir [16]. Çalışmalarında hem sentetik veri hem de gerçek trafik kamerası görüntüleri kullanmışlardır. Video üzerinde araçların belirlenmesini GMM yöntemini kullanarak, takip edilmesini Kalman ve CamShift izleme yöntemlerinin bir kombinasyonu ile gerçekleştirme aşamalarının ardından öğrenme adımı sırasında SVM ile yörüngelerin kümelenmesi işlemini yapmışlardır. Ardından da aykırı davranışların tespiti amacıyla destek vektör makinalarının özellik uzayındaki geometrik düşünceye dayalı olarak yeni bir yaklaşım önermişlerdir. Sentetik veri setleri üzerinde % 90'ın üzerinde doğrulukla aykırı davranışlarda bulunan araçların tespitini gerçekleştirebilirlerken, gerçek trafik kamerası görüntüsü üzerinde yapmış oldukları değerlendirmelerde 1430 adet araç yörüngesini 715 öğrenme ve 715 test yörüngesi olarak ayırdıktan sonra öğrenme yörüngeleri üzerinde yaptıkları kümeleme işleminin ardından, test yörüngelerinde gerçekten yanlış bir yerde yapılmış olan olağandışı 2 adet U dönüşünü doğru olarak tespit etmişlerdir. Şekil 1.4'de çalışmada tespit edilen normal ve anormal davranışlar gösterilmiştir.



Şekil 1.4 SVM ile aykırı davranış belirleme [16]
(a) Araçlara ait yörüngeler (b) Aykırı davranışlardaki araçların tespiti

Desheng ve Jia, gerçek zamanlı trafik videoları kullanarak olağandışı davranışlarda bulunan araçların tespiti işlemi için yeni bir sistem önermişlerdir [17]. Ortalama Kayma İzleme (Mean-Shift Tracking) yöntemi kullanarak araç yörüngelerini elde ettikten sonra, çalışmalarının öğrenme adımında yörüngeyi oluşturan araçların hızlarını, bu yörüngelerin yönlerini ve uzunluklarını kullanan Hausdorff mesafe ölçme yöntemine dayalı yeni bir kümeleme algoritması ile araç yörüngelerinin kümelenmesi işlemi gerçekleştirilmiştir. En Büyük Sonsal Olasılık (Maximum a posteriori (MAP)) adaptasyonu ile test adımında görüntüye giren araçların aykırı davranışta bulunup bulunmadığının tespiti yapılmıştır. Çalışmanın başarımını değerlendirme aşamasında, sonuçlarını anormal davranışların tespitini gerçekleştiren başka öğrenmeli metotlarla kıyaslamışlar. Onlarda %60 - 80 olan anormal davranışları doğru tespit etme oranının kendi sistemlerinde %90 civarında olduğu belirtilmiştir.

Saligrama, Konrad ve Jodoin, gerçek trafik kamerası görüntülerinde diğer video analizi çalışmalarından farklı olarak arka plan çıkarımı ve araç takip işlemlerini yapmadan sadece piksellerin istatistiksel modellenmesine dayalı olarak olağandışı araç hareketlerini tespit eden bir sistem önermişlerdir [18]. Çalışmalarında Markov zincir modelinden yararlanarak, görüntülerdeki pikseller için sabit ve hareketli durumların ve durumlar arası geçişe ait zaman aralıklarının çıkarılması ile olağan durumların öğrenilmesi adımı gerçekleştirilmiş, ardında da bu durumlara aykırı şekilde gerçekleşen

piksel hareketlerinin olağandışı davranışlar içerisindeki araçların sebep olduğu hareketler olduğu düşünülerek olağandışı durum tespiti yapılmıştır.

Swears, Hoogs ve Perera yapmış oldukları çalışmada takip ettikleri araçların hareket yörüngelerinden karayoluna ait hareket modellerinin çıkarılması amacıyla Hiyerarşik Toplamalı Saklı Markov Modeli (Hierarchical Agglomerative HMM Clustering) kullanmışlardır [19]. Daha sonra araçların olağandışı davranışlarını tespit etmek amacıyla elde edilen karayolu hareket modellerinin, test aşamasında görüntüye giren ve takibi sağlanan araçların kısmi yörüngeleriyle benzerliğine Saklı Modellerle İleri Yön Algoritması kullanılarak bakılmış ve benzerlik oranı belirli bir eşik seviyesinin altında olan yörüngeye sahip araçların davranışları olağandışı olarak tespit edilmiştir. Çalışmada durum sayısı da dahil olmak üzere HMM için gerekli tüm parametreler Beklenti Enbüyütme (Expectation Maximization (EM)) metodu kullanılarak belirlenmiştir.

1.2 Tezin Amacı

Karayolları trafik akışında olağandışı olayların tespiti trafik polisleri tarafından veya duyarlı vatandaşların bilgilendirmesiyle yapılabildiği gibi, günümüzde özellikle şehir merkezlerinde belirli noktalara yerleştirilen trafik kameralarına ait görüntülerin trafik izleme operatörleri tarafından izlenmesi ile de gerçekleştirilmektedir. Bu operatörler tarafından tüm trafik kamera görüntülerinin aynı anda izlenerek yorumlanması, insan faktörünün devrede olmasından dolayı hata olasılığı yüksek bir işlemdir. Bu tez çalışmasında, karayolu trafik akışında araçların olağandışı hareketlerinin tespitinin kamera görüntülerinden alınan veri değerlendirilerek otomatik olarak yapılması, insan faktörünün en az seviyede tespit ve yorumlama işleminde kullanılması amacıyla bir sistem tasarımı yapılmıştır. Tasarımı yapılan sistemin başarımı gerçek trafik görüntüleri kullanılarak değerlendirilmiştir.

1.3 Hipotez


Trafik kameralarından elde edilen görüntüler yardımıyla karayollarında normal trafik akışının belirli bir süre izlenerek değerlendirilmesi sonucu karayollarına ait hareket modelleri belirlenebilir. Daha sonra trafik kameralarında görüntüye girecek olan

araçların izlemiş oldukları yörüngelerin bu karayolu hareket modelleri ile olan benzerliğine bakılarak araçların yapmış oldukları olağandışı davranışlar tespit edilebilir. Ayrıca görüntüdeki araçların anlık hızlarında meydana gelen beklenmedik değişiklikler trafik akışının bozulmasına neden olan sürücü hareketi olarak belirlenebilir. Böylece elde edilen bilgiler doğrultusunda araçların olağandışı davranışlarının tespitinin yapılabilmesinin yanında bu olağandışı davranışlara neden olan araçların sürücüleri gerekli cezalandırma işlemine tabi tutulabilir. Eğer bu olağandışı davranışlar aynı görüntüde sürekli olarak meydana geliyorsa olağandışı durumun karayolunun karakteristiğinden meydana geldiği sonucuna varılarak karayolunun yapısının yeniden düzenlenmesi işlemi gerçekleştirilebilir. Olağandışı davranışların belirlenmesinin ardından, o anda karayolundaki diğer araçların durumları da dikkate alınarak yapılacak kaza tahmin işleminde, olağan dışı davranışlar kaza riskini arttırıcı birer etmen olarak kullanılabilir [5].

BÖLÜM 2

SİSTEM TASARIMI

Bu çalışma, trafik kamera görüntüleri kullanılarak karayolundaki normal trafik akışının öğrenilmesi ve normal trafik akışına ait bu bilgi kullanılarak olağandışı araç davranışlarının tespit edilmesi olarak iki kısımdan oluşmaktadır. Birinci kısımda karayolu normal trafik akışının sisteme öğretilmesi amacıyla normal trafik akışı sırasında trafik video görüntülerinde araçların belirlenmesinin ardından araçların takip edilmesi işlemi gerçekleştirilmiştir. Takip sonucu elde edilen araç yörüngelerine uygulanan bir kümeleme işlemi ile karayoluna ait hareket modelleri çıkarılmıştır. İkinci kısımda ise trafik video görüntülerinde belirlenerek takip edilen araçların kısmi hareket yörüngelerinin normal trafik akışında elde edilen karayolu hareket modelleri ile olan benzerliği bulunarak, araçların kısmi hareket yörüngelerinin hangi karayolu hareket modeline sınıflandırıldığı belirlenmiştir. Ardından kısmi hareket yörüngelerinin sınıflandırma işleminin yapıldığı karayolu hareket modelleri ile olan benzerlik oranı değerlendirilerek, araçların davranışlarında herhangi bir olağandışılık olup olmadığı tespit edilmiştir. Araçların yapmış olduğu olağandışı davranışların tespit edilmesi durumunda, bir uyarı mekanizması yardımıyla bu davranışların sistem tarafından kullanıcıya gösterilmesi sağlanmıştır. Çalışmaya ait sistemin tasarım diyagramı Şekil 2.1’de gösterilmiştir. Diyagramda belirtilen işlem adımları ileriki bölümlerde ayrıntılı şekilde anlatılmıştır.



Şekil 2.1 Sistem tasarım diyagramı

2.1 İlgili Trafik Görüntülerini İçeren Video Veri Tabanlarının Hazırlanması

Çalışmada iki farklı görüntü veri tabanındaki videolardan yararlanılarak başarımlı ölçümü yapılmıştır. Bunlardan ilki olan NGSIM [20] veri kümesi gerçek trafik görüntülerini içermektedir. Bu videolarda bulunan görüntüler normal trafik akışını içerdiği için bu video görüntüleri üzerinde “Karayolu Hareket Modellerinin Öğrenilmesi” işlemi gerçekleştirilmiştir. Bu görüntülerde araçların belirlenmesinin ardından takibi sağlanarak, araçlara ait hareket yörüngeleri belirlenmiştir ve bu yörüngeler kümlenerek karayoluna ait hareket modelleri bulunmuştur. Daha sonra ise görüntüye yeni giriş yapan araçların kısmi yörüngeleri ile elde edilen karayolu hareket modelleri arasındaki benzerliğe göre yeni giriş yapan araçların hangi karayolu hareket modeline dahil olduğu yapılan sınıflandırma işlemi sonucunda belirlenmiştir.

Diğer trafik video veri tabanı olan TRIMARC [21] ise araçların olağandışı davranışları ve kaza durumlarına ait görüntüler içermektedir. Bu kamera görüntüleri 8-10 saniyelik kısa süreli kayıtlardan oluşmaktadır. Bu nedenle karayolu hareket modellerinin elde edilmesi aşamasında kullanılan araç hareket yörüngeleri elle işaretlenmiştir ve bu yörüngeler üzerinde kümeleme işlemi yapılarak karayolu hareket modelleri elde edilmiştir. Daha sonra araçların kısmi hareket yörüngeleri ile karayolu hareket

modelleri arasındaki benzerlik oranı bulunarak bir sınıflandırma işlemi yapılmış ve benzerlik oranına göre araçların gerçekleştirmiş olduğu olağandışı davranışların tespit işlemi gerçekleştirilmiştir.

Tezde kullanılan video veri tabanları ile ilgili özellikler Çizelge 2.1’de belirtilmiştir [4].

Çizelge 2.1 Tezde kullanılan veri kümeleri ve açıklamaları [4]

Veri kümesi	Açıklama
NGSIM	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.
TRIMARC	TRIMARC organizasyonu tarafından sağlanan görüntülerde 75 farklı olağandışı trafik olayı, iki farklı açıdaki kamera sistemleri tarafından kaydedilmiştir. Mikrofon düzeneği ile olay yerindeki seslerinde alındığı görüntüler, olayların 4 saniye öncesini ve sonrasını gösterecek şekilde kayıt edilmiştir.

Kullanılan trafik görüntüsü veri tabanlarından örnek görüntüler Şekil 2.2’de verilmiştir. (a)’daki görüntü NGSIM, (b)’deki görüntü TRIMARC video veri tabanında bulunan videolardan alınmış birer görüntüdür.



Şekil 2.2 Çalışmada kullanılan trafik video veri tabanlarından örnek görüntüler

KARAYOLU HAREKET MODELLERİNİN ÖĞRENİLMESİ

Karayollarında normal trafik akışında araçlar, ana yollarda Karayolları Genel Müdürlüğü tarafından çizilen şeritlere uygun olarak hareket ederler. Bu şeritler karayolunda araçların belirli bir düzen içerisinde güvenle hareket edebilmeleri için çizilmektedir. Ana yollarda sürücüler bu şerit çizgileri içerisinde araçlarını hareket ettirmeye çalışarak trafik düzenini korumaya çalışırlar. Şeritlerin bilerek veya bilmeyerek çizilmediği bölgelerde ise trafiğin güvenli olarak ilerleyebilmesi için aynı yönde hareket eden her araç yaklaşık olarak aynı doğrultuda ilerlemektedir. Bir başka ifadeyle, şeritli ve şeritsiz karayollarında, araçların normal trafik akışında izlediği genel yörüngeler vardır ve sadece olağandışı trafik davranışları sergileyen araçlar bu genel yörüngelerin dışında hareket ederler. Sürücüler genellikle can ve mal güvenliğini riske etmeyerek araçlarını bu yörüngelere benzer yörüngeler oluşturacak şekilde hareket ettirmektedir. Şekil 3.1’de şeritli ve şeritsiz çeşitli karayolu ortamlarında araçların hareketleri gösterilmiştir [22][23][24][25]. Bu görüntülerde de görüldüğü gibi araçlar belirli bir düzen içerisinde belirli bir genel yörüngeye yakın olarak ilerlemektedir. İleriki bölümlerde, şeritli ve şeritsiz karayollarında araç hareketlerindeki düzeni sağlayan bu genel yörünge kavramı, karayolu hareket modeli (KHM) olarak ifade edilecektir.

Karayolu trafik görüntülerinde araçların gerçekleştirmiş olduğu olağandışı davranışların tespit işleminin yapılabilmesi için öncelikle, trafiğin normal akışının öğrenilmesi ve normal trafik akışına ait hareket modellerinin çıkarılması gerekmektedir. Karayolu hareket modellerinin öğrenilmesi sonucu trafiğin normal akışına dair bilginin elde edilmesinden sonra, olağandışı trafik davranışlarının tespit edilmesi çok daha kolay bir

şekilde gerçekleştirilebilir. Karayolu trafiğinin normal akışına ait trafik akış şekli ve yönü gibi bilgiler, bu bilgilerden farklı olarak davranış sergileyen araçların tespit edilmesi işleminde kullanılabilir. Normal trafik akışındaki şeritlerden çok uzak şekilde ilerleyen araçların, emniyet şeritlerinden hareketini sürdüren araçların, normal araç trafiğinin akış yönüne ters olarak hareket eden araçların davranışının olağandışı olarak tespit edilmesi gerekmektedir. Ayrıca karayolunda hareketini sürdüren araçların hızlarında meydana gelen ani hızlanma ve yavaşlama gibi beklenmedik değişimlerin trafik akışını bozan araç davranışı olarak tespit edilmesi gerekmektedir.




(a)



(b)



(c)




(d)

Şekil 3.1 Trafikte araçların belirli yörüngeler içerisinde hareketi

Bazı karayollarında günün değişik saatleri için değişik trafik akış yönleri uygulanabilmektedir. Bu çalışma trafik akış yönünün gün boyu aynı olduğu görüntü veri tabanları kullanılarak gerçekleştirilmiştir. Bu yüzden karayolları trafik akışı için günün değişik saatlerinde değişik hareket modellerinin çıkarılması işlemi gerçekleştirilmemiştir. Ayrıca gece çekimi yapılan karayolu trafik videolarında araçların belirlenmesi ve takip edilmesi işlemlerinin düşük başarımlı olması nedeniyle bu çalışmada sadece gündüz kayıt işlemi gerçekleştirilen trafik videoları kullanılmıştır.

Karayolu trafik hareket modellerinin belirlenmesi için öncelikle olağandışı araç davranışlarının bulunmadığı trafik görüntüleri kullanılarak, normal trafik akışındaki araçların yörüngelerinin belirlenmesi gerekir. Bunun için sırasıyla video görüntülerindeki araçların bulunması, takip edilmesi, hareket yörüngelerinin belirlenmesi ve elde edilen bu yörüngelerin kümelenmesi işlemlerinin gerçekleştirilmesi gerekmektedir. Şekil 3.2’de normal trafik akışı kullanılarak karayolu hareket modellerinin belirlenebilmesi için gerekli işlem adımları gösterilmektedir. İleriki bölümlerde bu işlem adımları ayrıntılı olarak anlatılmaktadır.



Şekil 3.2 Karayolu hareket modellerinin öğrenilmesi için gerekli işlem adımları

3.1 Trafik Görüntüsünde Araçların Belirlenmesi

Araçların hareket yörüngelerinin elde edilebilmesi için, trafik görüntülerinde araçların düzgün bir şekilde belirlenebilmesi ve takibinin yapılabilmesi önemlidir. Görüntülerde hareket eden nesnelerin dışında kalan hareketsiz kısımlar arka plan olarak adlandırılır. Arka planın doğru bir şekilde çıkarılması, trafik video görüntülerinde araçların doğru bir şekilde belirlenebilmesini sağlayacaktır. Arka planın karmaşıklığı, ortamın ışığı, hareket eden nesnelere ait gölgeler, hareket eden nesnelerin arka planla olan renk benzerliği gibi birçok etmen arka plan ayırmada önemli rol oynamaktadır. Dolayısıyla bu etmenler hareket eden nesnelerin belirlenerek takip edilmesine de etki etmektedir.

Arka plan çıkarımını daha düzgün olarak yapabilmek için görüntülere bazı ön işlemler uygulanmaktadır. Bu işlemler, görüntülerde arka plan – hareketli nesne ayırımında sonuçları olumsuz yönde etkileyen parazitleri temizlemek için yapılmaktadır. Bu işlemlerden aşağıda bahsedilmiştir.

3.1.1 Görüntülerdeki Parazitlerin Temizlenmesi


Karayolu trafik görüntülerinde arka plan çıkarımını olumsuz yönde etkileyen görüntülerin arındırılabilmesi amacıyla önce Ortanca Yumuşatma sonra Gauss filtreleri görüntülere uygulanmıştır. Böylece görüntülere ait arka plan tespiti daha doğru şekilde yapılabileceği için trafik görüntüsü üzerinde hareket halinde bulunan araçların belirlenmesi ve dolayısıyla takip edilerek yörüngelerinin edilmesi işlemleri daha iyi şekilde yapılabilecektir. Bu da sistemin performansı açısından olumlu katkı sağlayacaktır.

Ortanca yumuşatma filtresi, görüntülerde gürültüyü azaltmak için kullanılan yöntemlerden biridir. Uzaysal çözünürlüğü bozmadan kopuk (bağımsız) nokta ve çizgi gürültülerini temizlemek için kullanışlıdır. Bu yöntemde görüntüde seçilen pikselin değerini belirlemek için komşularının değerleri küçükten büyüğe sıralanır ve büyüklükçe ortadaki değer pikselin yeni değeri kabul edilir [26]. Yöntemde komşuluk sayısı genellikle tek sayı olarak seçilir. Komşuluk sayısının çift olarak girildiği durumlarda ise sıralama sonucu elde edilen dizide ortadaki iki piksel değerinin aritmetik ortalaması alınarak pikselin yeni değeri elde edilir. W görüntüyü, (m,n)

noktası yeni değeri bulunacak pikseli belirtmek üzere ortanca yumuşatma filtresinin matematiksel bağıntısı Eşitlik (3.1)'de verilmiştir.

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

Ortanca yumuşatma filtresinin çalışma mantığı Şekil 3.3'de gösterilmiştir. 200 değerine sahip pikselin 3x3'lük ortanca filtresi işlemi sonucunda yeni değerinin 110 olduğu görülmektedir. Ortanca yumuşatma filtresi uzaysal çözünürlüğü bozmadan bağımsız/kopuk renk değerlerine sahip piksellere ait gürültüleri temizlemek için kullanışlıdır.



Şekil 3.3 Ortanca yumuşatma filtresinin çalışma mantığı

Gauss Filtresi görüntülerde parazitlerin temizlenmesi için kullanılır. Parazit temizlenmesi sırasında görüntüyü bulanıklaştırır. Gauss Filtresi, Gauss dağılım fonksiyonu kullanarak, standart sapmanın genişliğine bağlı alçak geçiren bir filtredir. İki boyutlu Gauss filtresinin matematiksel bağıntısı Eşitlik (3.2)'de gösterilmiştir. Bu bağıntı bir $I(x,y)$ görüntüsündeki piksellere Eşitlik (3.3)'deki gibi konvolüsyon işlemi ile uygulanır. Gauss dağılımının varyansı (σ^2), eğrinin yayvanlığının ölçüsüdür ve filtrenin oluşturduğu bulanıklaşmanın derecesini etkiler.

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

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

Görüntüler gürültüden arındırıldıktan sonra araçların arka plandan ayrılarak ayrı birer nesne olarak belirlenmesi işlemi yapılmaktadır. Bunun için öncelikle arka plan belirlenerek ön plandaki hareket eden nesneler elde edilir. Daha sonra bağlı bileşenler

tekniki ile nesneler etiketlenir ve çevrit belirleme tekniği ile boyutu belirli bir eşik değerinden büyük nesneler araç olarak belirlenir. Bu adımların gerçekleştirilmesi için yapılan işlemler ileriki bölümlerde detaylı olarak anlatılmaktadır.

3.1.2 Trafik Görüntülerinde Arka Plan Çıkarımı

Hareketli görüntülerde zamanla değişmeyen kısımlar arka plan, hareket halindeki cisimler ise ön plan olarak adlandırılır. Video görüntülerinde arka planın belirlenmesinden sonra hareket halindeki nesnelerin algılanması, takip edilmesi ve sınıflandırılması çok daha basit şekilde yapılabilmektedir.

Fg ön planı, Bg arka planı, I ise mevcut resmi göstermek üzere i. görüntü için arka plan en basit şekliyle Eşitlik (3.4)'te görüldüğü gibi hesaplanır. Bu formülde de görüldüğü gibi ön plan mevcut resimde arka planda hareketsiz nesnelerin çıkarılmasıyla kalan alandır.

$$Fg_i = I_i - Bg_i \quad (3.4)$$

Arka plan çıkarımı üzerine çeşitli çalışmalar yapılmış, değişik yöntemler geliştirilmiştir. Arka plan çıkarımı yöntemlerinden bazıları şunlardır [27].

1. Basit Fark Tabanlı Arka Plan Çıkarımı
2. Gauss Ortalama Tabanlı Arka Plan Çıkarımı
3. Gauss Karışım Modeli Tabanlı Arka Plan Çıkarımı
4. Kernel Yoğunluk Tabanlı Arka Plan Çıkarımı
5. Ortalama Kayma Tabanlı Arka Plan Çıkarımı
6. Eigenbackgrounds

Tez çalışmasında ön planda hareket eden araçların belirlenmesi amacıyla arka planın çıkarımı için Gauss Karışım Modeli (Gaussian Mixture Model (GMM)) tabanlı Arka Plan Çıkarım yöntemi kullanılmıştır.

GMM istatistiğe dayalı bir öğretmensiz öğrenme algoritmasıdır. Model, aynı sınıfa ait verilerin normal dağılıma uygun bir şekilde sınıf merkezi etrafında dağıldığını öngörür. GMM algoritması ile oluşması istenen sınıf sayısı girdi olarak alınarak, verilerin en az varyansla toplandığı sınıf merkezleri ve bu merkezlere ait verilerin standart sapmalar bulunur.

Model matematiksel olarak şu temele dayanır:

$P(j)$ 'yi j . sınıfın dağılımdaki ağırlığı, diğer bir ifadeyle bu sınıftaki elemanların sayısının bütün eleman sayısına oranı olarak düşünürsek (3.5)'teki eşitlik elde edilir.

$$\sum_{j=1}^K P(j) = 1 \quad (3.5)$$

K uzayı ayrılması istenen bölge sayısıdır.

x elemanının j . sınıfa aidiyet olasılığına $P(x | j)$ denirse, bu olasılık Gauss dağılım bağıntısıyla Eşitlik (3.6)'daki gibi yazılabilir.

$$P(x|j) = \frac{1}{(2\pi)\sigma_j^2} e^{-\frac{(x-\mu_j)^2}{2\sigma_j^2}} \quad (3.6)$$

Burada x sınıflandırılacak veri, j aidiyetine bakılan sınıf numarası μ_j söz konusu sınıfın ortalaması ve σ_j^2 ise söz konusu sınıfın varyansını göstermektedir.

O halde sınıflamak istenilen bir x elemanının j sınıfına hangi oranda ait olabileceği Eşitlik (3.7)'deki gibi bulunabilir.

$$P(x) = P(x|j).P(j) \quad (3.7)$$

Bu durumda bütün x parçacıklarının söz konusu sınıflara ait olma ihtimali bütün x 'ler için Eşitlik (3.7)'deki ihtimallerin toplamıdır. Bu ihtimali en yüksek yapacak sınıf ortalamalarının ve varyanslarının ne olacağı bulunduğu sınıflama işlemi yapılmış olmaktadır. Bütün bu parametreleri bulma işlemi, literatürde Beklenti Enbüyütme (Expectation Maximization (EM)) olarak bilinen yöntemle hesaplanır. Algoritma başlarken her sınıfın ortalama değerleri, standart sapmaları ve ağırlıkları rastgele atanır ve her bir iterasyon için bu değerler güncellenir.

Staugger C. ve Grimson W.'nin arka plan çıkarımına yönelik olarak önermiş olduğu Gauss Karışım Modelinde her piksel için geçmiş bilgisi tutulur. Geçmiş zamandan şimdiye kadarki süre içerisinde piksellerin renk değerleri belirlenen sınıflara ayrılır. En büyük ağırlığa sahip sınıf arka plan sınıfı olarak belirlenir. Daha sonra ilgili pikselin ön plan sınıfına mı arka plan sınıfına mı ait olduğunu belirlemek amacıyla her yeni gelen renk değerine göre sınıflandırma yapılır. Bu yöntemde öğrenme katsayısı olarak kullanılan α , deneysel olarak belirlenmesi gereken tek parametredir. Yöntemde en iyi

sınıf parametrelerinin belirlenebilmesi için EM ve k-ortalama (k-means) algoritmalarının kullanılması önerilmektedir. EM'nin dezavantajı belirli sayıda geçmiş bilgiyi kullanarak çevrimdışı işlem yapmasıdır. Yeni piksel değeri elde edildiğinde yeniden sınıflandırma yapmayı gerektiren bu yöntemde her yeni gelen çerçeve için piksel sayısınca sınıflandırma yapılması yöntemin olumsuz yönüdür. Çevrimiçi parametre güncelleme yöntemlerinden biri olan k-ortalama ile sınıf parametreleri belirlendiğinde geçmiş bilgilere öğrenme katsayısı kadar etki edecek şekilde yeni piksel bilgileri güncellenir. Bu da her yeni gelen çerçeve için bir kez güncelleme yapılmasını sağlamaktadır.

Gauss Karışım Modeli Tabanlı Arka Plan Çıkarımı işlemi matematiksel olarak aşağıdaki şekilde özetlenebilir:

Belirlenen sınıf sayısı kadar sınıf ortalaması, sınıf varyansı ve sınıf ağırlıkları rasgele belirlenir. Sınıf sayısının belirlenmesi deneysel olarak yapılır. Genelde çalışmalarda sınıf sayısı 3 veya 5 olarak seçilmektedir.

$$\{w_i, \mu_i, \sigma_i\} = \{S_i(w, \mu, \sigma): 1 \leq i \leq K\} \quad (3.8)$$

w : Sınıf ağırlık değeri

μ : Sınıf ortalama değeri

σ : Sınıf varyansı

K : Sınıf sayısı

S : Sınıf Adı

İlgili resmin x, y koordinatındaki pikselin t anındaki değeri X_t , ilgili resim I ile ifade edilmek üzere bu ifade;

$$\{X_1, \dots, X_t\} = \{I(x, y, i): 1 \leq i \leq t\} \quad (3.9)$$

şeklinde yazılabilir. Gelen her yeni resim için yol maskesi içerisinde kalan bütün pikseller tek tek taranıp aidiyet fonksiyonu ile hangi sınıfa ait oldukları belirlenir. $S_{xy,t-1}^t$, resimdeki x, y koordinatlarında bulunan pikselin $t-1$ anında i . sınıfını ifade etmek üzere, yeni gelen piksel için sınıf belirleme işlemi (3.10)'da gösterildiği şekilde yapılır.

$$Sınıf = \operatorname{argmax}_{i=1..K} P(I_{xy}|S_{xy,t-1}^t) \quad (3.10)$$

Bu şekilde ilgili pikselin bütün sınıflardan hangisine ait olduğu belirlenir. Fakat en büyük aidiyet değerine bakıldığında, bu değer 2.5 standart sapmadan daha büyük olması durumunda bu sefer hiçbir sınıfa ait olmadığına hükmedilir ve yeni bir sınıf yaratılır. Bu işlem yapılırken sınıf sayısı (K) sabit olduğu için öncelikle ağırlığı düşük olan sınıf yok edilerek yeni sınıfın yaratılmasına dikkat edilir. Eğer yeni gelen değer bir sınıfa atılırsa, hemen o sınıfın değerleri Eşitlik (3.11)-(3.14)'de görüldüğü gibi güncellenir.

$$p = \alpha P(I_{xy,t}|Sınıf) \quad (3.11)$$

$$w_{i,t} = (1 - \alpha) \cdot w_{i,t-1} + \alpha(M_{i,t}) \quad (3.12)$$

$$\mu_{i,t} = (1 - p)\mu_{i,t-1} + pI_{xy,t} \quad (3.13)$$

$$\sigma_{i,t}^2 = (1 - p)\sigma_{i,t-1}^2 + p(I_{xy,t} - \mu_t)^T(I_{xy,t} - \mu_{i,t}) \quad (3.14)$$

p : Resmin incelenen pikselinin incelenen sınıfa ait olup olmadığının öğrenme katsayısıyla çarpılmış hali.

$M_{i,t}$: t anında incelenen piksel i. sınıfa aitse 1, değilse 0 olan bir sayı.

$w_{i,t}$: i. sınıfın t anındaki ağırlığı

$I_{xy,t}$: t anında resmin x ve y koordinatındaki piksel değeri.

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

$\sigma_{i,t}^2$: i. sınıfın t anındaki varyansı.

Eğer ağırlığı en az olan sınıf yok edilerek yerine aidiyeti 2.5 standart sapmadan daha büyük bir piksel değeri konulursa, yeni sınıfın varyansına diğer sınıfların içerisinde en az varyansa sahip sınıfın varyansı atanır.

$$S_{xy,y} = \operatorname{argmin}_{i=1..K} w_{xy,i} \quad (3.15)$$

$$\mu_{S_{xy,y}} = I_{xy} \quad (3.16)$$

$$\sigma_{S_{xy,y}}^2 = \min_{i=1..K} (\sigma_{xy,i}^2) \quad (3.17)$$

$$w_{i,y} = \begin{cases} 0.05 & i = S_{xy,y} \\ w_{i,y} - \frac{1}{K}(w_{S_{xy,y}} - 0.05) & i \neq S_{xy,y} \end{cases} \quad (3.18)$$


(3.18)'de görüldüğü gibi yeni oluşan sınıfına ağırlığına 0.05 değeri atanırken diğer sınıfların değeri de toplamaları 1 olacak şekilde güncellenir.

Hangi sınıfın arka plan olarak atanacağını belirlemek için, ağırlıklar büyükten küçüğe sıralanarak ağırlık toplamı belirli bir eşik seviyesini geçinceye kadar toplama işlemi yapılır. Eşik seviyesini geçtiği anda toplama etki eden ağırlıklara sahip tüm sınıflar arka plan sınıfı olarak alınır. B_{xy} ifadesi x,y koordinatındaki noktanın arka planına atılan sınıf numarasını göstermek üzere, arka plan sınıflarının belirlenmesi işlemi matematiksel olarak Eşitlik (3.19)'da gösterildiği şekilde ifade edilir.

$$i = 1 \dots K - 1 \text{ için } w_{xy,i+1} > w_{xy,i} \rightarrow B_{xy} = \arg\min_b \sum_{i=1}^b w_{xy,i} > T \quad (3.19)$$

Video görüntülerinde kıpırdayan yapraklar, dalgalanan deniz, hareket eden cisimlerin gölgeleri, ışıklandırma şartları, kamera kalibrasyonu gibi bir takım etmenler arka plan çıkarımının başarımında olumsuz etki yapmaktadır. Çalışmada da bazı trafik video görüntülerinde araç gölgelerinin arka plan çıkarımına olumsuz etki yaptığı, gölgelerin bulunduğu alanında hareket eden cisimler (araçlar) dahilinde ön plan olarak alındığı gözlemlenmiştir.

Çalışmada gerçekleştirilen Adaptif GMM tabanlı arka plan çıkarımı yöntemi ile elde edilen ön plan görüntüsü Şekil 3.4'te gösterilmiştir.



Şekil 3.4 Adaptif GMM ile elde edilen ön plan görüntüsü
(a) Orjinal görüntü (b) Ön plan görüntüsü

3.1.3 Arka Plan Çıkarımı Sonrası Araçların Belirlenmesi

Görüntülerde arka plan çıkarımı işlemi sonrasında görüntü üzerinde hareket eden bölgelerin (araçlar) tespitinin yapılmasının ardından araçların belirlenmesi ve etiketlenmesi işlemi için Bağlı Bileşen Analizi (Connected Component Analysis) ve Çevrit Belirleme (Chain Coding) yöntemleri uygulanır [28][29]. Öncelikle ön plan olarak belirlenen nesneler için bağlı bileşenler analizi yöntemi kullanılarak etiketleme işlemi yapılır. İçerdiği piksel sayısı olarak büyüklüğü belirli bir eşik seviyesinin altında olan bağlı bileşenler parazit olarak değerlendirilerek elenir. Daha sonra çevrit belirleme yöntemi kullanılarak her bağlı bileşeni oluşturan nesnenin etrafına kapalı birer çevrit oluşturulur.


Şekil 3.5’de soldaki resimler orijinal görüntüleri, sağdaki resimler ise bağlı bileşen analizi ve çevrit belirleme işlemleri sonrasında elde edilen görüntüleri göstermektedir.



Şekil 3.5 Bağlı bileşenler analizi ve çevrit belirleme işlemi ile araçların belirlenmesi


3.2 Araç Temsil Noktalarının Belirlenmesi

Araçların çevritleri belirlendikten sonra araçların takibinin yapılabilmesi için araçları tanımlayan özelliklere ihtiyaç duyulmaktadır. Bu amaçla araçlar için merkez noktası belirlenerek bu noktanın takibinin yapılması sağlanmıştır [4]. Araçlar için merkez noktanın belirlenmesi için öncelikle her bir araç için daha önce bulunan çevritleri kapsayan en küçük dikdörtgenler elde edilmiştir. Daha sonra bu en küçük dikdörtgenler için orta noktalar tespit edilerek, araçların yörüngelerinin belirlenmesi için gerekli olan takip işlemi sırasında merkez noktalar olarak kullanılmışlardır. Şekil 3.6'da araçlara ait çevritlerin belirlenmesinin ardından bu çevritleri kapsayan en küçük dikdörtgenlerin belirlenerek merkez noktalarının yani araç temsil noktalarının bulunma yöntemi gösterilmiştir.



Şekil 3.6 Araç merkez noktanın belirlenmesi [4]

Tez çalışmasında, trafik video görüntülerinde tespit edilen araçlar için çevrit belirleme işleminin ardından elde edilen en küçük dikdörtgen bölgeler ve bu dikdörtgenleri kullanarak bulunan merkez noktalar yani araç temsil noktaları Şekil 3.7'de gösterilmiştir.



Şekil 3.7 Araç temsil noktasının belirlenmesi

3.3 Görüntülerde Belirlenen Araçların Takibi

Nesne takibi, ardışık video görüntüleri içerisinde hareket eden nesnelerin algılanarak her birine eşsiz bir etiket verme ve bir sonraki görüntü üzerinde aynı etikete sahip nesneyi belirleme işlemi olarak ifade edilebilir. Yani ardışık video görüntülerinde bir görüntü üzerinde bulunan nesnelerin bir sonraki görüntüde koordinat düzlemindeki yerlerinin bulunması işlemidir. Kamera görüntülerinin otomatik olarak analiz edilerek yorumlanması ihtiyacının her geçen gün daha da artması nesne takip yöntemlerine olan ihtiyacı arttırmıştır. Kullanılan kamera görüntülerinde başarılı bir şekilde nesnelerin takip işlemlerinin yapıldığı çalışmalarda analiz ve yorumlama işlemleri daha başarılı bir şekilde yapılmaktadır.


Nesne takip yöntemleri, nesnelerin yeni görüntü üzerindeki konumunu bulma ve görüntüler boyunca nesnelerin arasındaki veri bağının belirlenmesi olmak üzere iki temel görevi üstlenir. Nesnelerin sabit hız ve ivmeye sahip olması, sayıları, büyüklükleri, görünüşleri veya sahip oldukları şekillerin önceden belirtilmesi nesne takip yöntemlerinin karmaşıklığını azaltır [30].

Nesne takibinde karşılaşılan temel zorluklar aşağıdaki gibi listelenebilir:

1. 3 boyutlu dünya verilerinin 2 boyutlu görüntü alanına yansıtılmasıyla meydana gelen bilgi kaybı
2. Görüntülerde meydana gelen gürültüler
3. Nesne hareketlerinin karmaşık oluşu
4. Nesnelerin ayırt edilebilir fiziksel bir yapıya sahip olmamaları
5. Nesne görünümünün bir kısmının veya tamamının engellenmesi
6. Karmaşık nesne şekilleri
7. Ortamdaki ışık miktarının değişimi
8. Gerçek zamanlı uygulama gereksinimleri

Nesne takibi için kullanılan yöntemler nokta tabanlı, çekirdek tabanlı ve silüet tabanlı yöntemler olmak üzere 3 ana grupta toplanabilir [31]. Şekil 3.8’de görüldüğü gibi nokta tabanlı nesne takibi deterministik ve istatistiksel yöntemler ile nokta tabanlı nesne

takibi olarak, çekirdek tabanlı nesne takibi tek boyutlu ve çok boyutlu çekirdek tabanlı nesne takibi olarak ve silüet tabanlı nesne takibi de sınır değerlendirme ve şekil eşleştirme yöntemleri ile silüet tabanlı nesne takibi olarak alt sınıflara ayrılmaktadır.



Şekil 3.8 Nesne takip yöntemleri [31]

Nokta tabanlı nesne takibi, takip edilen her nesnenin bir nokta ile ifade edilmesinin ardından bir önceki görüntüde belirlenmiş olan noktaların güncel görüntü üzerinde bulunması ve iki görüntü üzerindeki noktalar arasında güçlü veri ilişkisinin kurularak bir önceki görüntüdeki noktanın, güncel görüntüde hangi noktaya karşılık geldiğinin bulunması, yani noktanın güncel görüntüye ait koordinat düzlemindeki konumunun tam olarak tespiti edilmesidir.

Deterministik yöntemler kullanılarak yapılan nokta tabanlı nesne takibi işlemi, ardışık görüntüler arasında nesnelerin birbirlerine bağlanma maliyetini tanımlar. Yani bu yöntemlerde bir takım sınırlamalar kullanılarak noktanın güncel görüntü üzerindeki yerinin tespiti yapılmaya çalışılır. İki görüntü arasında nesnenin yer değiştirebileceği mesafenin belirli eşik seviyesi uzunluğundan küçük olacağının kabul edilmesi, nesnelerin hızlarının belirli bir değerin altında kabul edilmesi, bir nesne için üzerinde

bulunan iki nokta arasındaki uzaklığın iki görüntüde sabit olacağının kabulü (katılık) gibi bir takım önceden tanımlanmış kurallar çerçevesinde ardışık görüntüler arasında noktaların yeni yerlerinin tespit edildiği yöntemlerdir.

İstatistiksel yöntemler kullanılarak yapılan nokta tabanlı nesne takibi işlemi ise pozisyon, hız, ivme gibi nesne özelliklerini modellemek için durum uzay yaklaşımını kullanırlar. Videolar kullanılarak elde edilen ölçümlerin bir takım gürültüler nedeniyle ve cisimlerin şekillerinin ardışık görüntüler üzerinde farklılaşabileceği gerçeği nedeniyle istatistiksel yöntemlerle yapılan nesne takibi, deterministik yöntemlerle yapılan takibe göre daha iyi sonuçlar vermektedir.

Çekirdek tabanlı nesne takibi yönteminde ise, ilk görüntü üzerinde takip edilecek nesnenin basit bir geometrik şekil (genellikle dikdörtgen, kare veya daire) içerisine alınmasının ardından, şekil içerisinde kalan görüntü bilgisine ait olasılık yoğunluk dağılımı elde edilir. Daha sonra ardışık kamera görüntüleri boyunca bu dağılım takip edilerek nesnenin yeni görüntüdeki yeri tespit edilir.


Silüet tabanlı nesne takibi el, baş, omuz gibi belirli bir geometrik şekle sahip olmayan nesnelerin takibinin yapılabilmesi için kullanılan yöntemleri içerir. Bu tür nesneler için, görüntü üzerinde belirli bir geometrik şekle oturtularak olasılık yoğunluk dağılımları bulunamayacağı için, önceki görüntülerde tespit edilen nesne modellerinin güncel görüntülerde aranması işlemi gerçekleştirilir. Bu modeller nesnelerin renk histogramını, kenarlarını ve sınır şekillerini kullanırlar. Silüet tabanlı nesne takip edicileri “şekil karşılaştırmacılar” ve “sınır takip ediciler” olarak adlandırılan iki alt kategori altında incelemek mümkündür. Şekil karşılaştırmalı yaklaşım, güncel imge içerisinde nesne silüetini arar. Diğer taraftan sınır izlemeli yaklaşım ise, bazı enerji fonksiyonlarının minimizasyonunu veya durum uzay modellerini kullanarak nesnenin güncel imgedeki yeni yerini belirlemeye çalışır.

Çizelge 3.1’ de yukarıda bahsedilen nesne takip yöntemleri gösterilmiş ve her yöntem için yapılmış örnek bir çalışma hakkında bilgi verilmiştir [31].

Çizelge 3.1 Nesne takip yöntemleri ve ilgili çalışmalar


Yöntemler	İlgili Çalışmalar
Nokta Tabanlı	
• Deterministik	MGE izleyicisi (Salari ve Sethi 1990) GOA izleyicisi (Veenman 2001)
• İstatistiksel	Kalman Filtresi (Broida ve Chellapa 1986) Olasılıksal Veri İlişkilendirme Filtresi (Bar-Shalom and Foreman 1988)
Çekirdek Tabanlı	
• Tek Boyutlu	Ortalama Kayma Algoritması (Comaniciu 2003)
• Çok Boyutlu	SVM izleyicisi (Avidan 2001)
Yoğunluk Tabanlı	
• Sınır Takip Ediciler	Varyasyonel Metotlar (Bertalmio 2000)
• Şekil Karşılaştırmacılar	Hough dönüşümü (Sato ve Aggarwal 2004)

Tez çalışmasında nesne takip yöntemi olarak nokta tabanlı nesne takip yöntemlerinden biri olan optik akış kullanılmıştır [32]. Optik akış, 3 boyutlu sahnede gözlemci hareket ettiğinde, görüntüde meydana gelen hareket olarak tanımlanır. Optik akış, kamera görüntüsündeki hareketin yön ve hızını ifade eder. Gerçek dünyadaki 3 boyutlu hareketin, kamera görüntüsü üzerinde iki boyutlu düzlemde gösterimidir. Şekil 3.9’da gerçek dünyadaki nesnenin 3 boyutlu hareketi, görüntüde 2 boyutlu düzlemde optik akış vektörü olarak gösterilmiştir.



Şekil 3.9 Gerçek dünyada 3 boyutlu harekete ait optik akış vektörü

Genellikle optik akış hareket alanına karşılık gelir. Fakat bazı durumlarda bu denklik geçerli değildir. Örneğin dönen bir disk için hareket alanı ve optik akış birbirinden farklıdır. Şekil 3.10'da normal bir hareket sırasında optik akışın hareket yönüyle aynı olduğu, dönen bir disk içinse hareket ve optik akış yönlerinin farklı olduğu gösterilmektedir.



Şekil 3.10 Çeşitli hareket yönlerine göre optik akış yönleri
(a) Cisim (b) Cisim için hareket yönü (c) Cisim için optik akış yönü [33]

Videolarda optik akışın belirlenebilmesi için kullanılan en genel yaklaşım hareket vektörlerinin çıkarılması ve daha sonra bu vektörlerin yorumlanması adımlarından oluşur. Optik akış alanının bulunması ise hareket içeren piksellerin ve bu piksellerin yarattığı etkinin bulunmasıyla yapılır. Optik akış alanlarının tahmini, parlaklık kısıt denkleminin minimize edilmesi işlemine dayanır [34].

$$I_x(x, y) * u(x, y) + I_y(x, y) * v(x, y) + I_t(x, y) = 0 \quad (3.20)$$

$I_x(x,y)$, x eksenı boyunca g r nt  keskinliđinin, $I_y(x,y)$, y eksenı boyunca keskinliđin t revini belirtir. $I_t(x,y)$, ardışık  er evesler arasındaki keskinliđin zamana g re t revini, $u(x,y)$, yatay optik akış elementini, $v(x,y)$, dikey optik akış elementini g sterir.

Kanade-Lucas-Tomasi hareket takip algoritması en geliřmiř optik akış y ntemlerinden birisidir. Bu y ntemde ama , hareket eden nesneye ait  zniteliđin birinci  er evede bulunması, ardışık  er evesler  zerinde  zniteliđe ait yeni koordinatların piksellerin keskinlik farklarını minimize ederek tahmin edilmesidir. Sonu  akış vekt r  (3.21)'de belirtilen $\varepsilon(d)$ fonksiyonunu minimize eden d uzaklık vekt r d r.

$[u_x, u_y]^T$, I_1 g r nt s ndeki nokta

$[u_x + \delta_x, u_y + \delta_y]^T$, I_2 g r nt s nde ε deđerini minimize eden nokta

$$\varepsilon(d) = \varepsilon(\delta x, \delta y, \delta t) = \sum_{x=u_x-w_x}^{u_x+w_x} \sum_{y=u_y-w_y}^{u_y+w_y} (I_1(x, y, t) - I_2(x + \delta x, y + \delta y, t + \delta t)) \quad (3.21)$$

$I(x,y,t)$ keskinlik fonksiyonunu, (u_x, u_y) optik akış tahmininin yapıldığı noktayı, (w_x, w_y) , (u_x, u_y) noktasının etrafındaki pencere i indeki komřu pikselleri belirtir. Optik akış y ntemi ile her piksel i in bir hareket vekt r   kartılarak, bu hareket vekt rlerinin b y kl đ ne g re piksellerin hareket karakteristiđi elde edilir. Video g r nt lerinde hareket halinde bulunan bir nesne  zerindeki bir piksel i in optik akış vekt r , aynı cisim  zerindeki diđer cisimler i in elde edilen optik akış vekt rlerine benzer b y kl đe sahip olacaktır. Yani hareket eden nesneler i in, benzer hareket karakteristiđine sahip optik akış vekt r k mesi elde edilir ve bu benzer vekt rlerin belirlenmesi i in ortalama veya standart sapma y ntemleri kullanılır. B y k olasılıkla geri kalan vekt rler, g r lt den dolayı elde edilen vekt rler olup, d ř k hareket b y kl đ ne sahip vekt rlerdir ve belirli bir eřik b y kl đ n n altındaki hareket vekt rlerinin elenmesi sonucu ger ek hareket vekt rleri ve benzerlikleri hesaplanır.

Takip edilen  zniteliklerin ardışık  er evesler  zerindeki kısa mesafeli yer deđiřimleri temel optik akış algoritmasıyla rahat a belirlenebilirken, b y k yer deđiřimlerinde ise hareket takibi ihtiya ının karřılanması ile ilgili sıkıntılar yařanmaktadır. Ardışık  er evesler arasındaki b y k yer deđiřimlerinin belirlenebilmesi i in piramitsel optik akış y ntemi  nerilmiřtir. Kavřak  zerinde bulunan ara ların hızlı hareket etmesinden

dolayı ardışık çerçeveler arasında araçlara ait piksellerin hareket vektörleri büyük olacağından dolayı bu çalışmada piramitsel optik akış yöntemi kullanılmıştır.

Piramitsel Lucas-Kanade Optik Akış Yöntemi, ardışık görüntüler arasında piramitsel hiyerarşik yapının kullanılmasıyla akış vektörlerinin hesaplanması mantığına dayanır [4]. Şekil 3.11’de görüldüğü gibi I_{t-1} ve I_t görüntülerini içeren iki tane görüntü piramidi oluşturulur. Piramidin en üstünde bulunan düşük ölçekli görüntüler arasında akış vektörleri hesaplanır. Daha sonra hesaplanan akış vektörleri piramidin bir alt seviyesine ölçeklenir. İkinci seviyede, I_{t-1} referans ve I_t hedef görüntüleri arasındaki optik akış hesaplanırken, hedef görüntüsü üst seviyeden gelen vektör alanına göre değiştirilir ve yeni hesaplama yapılır. Bu şekilde piramidin en alt seviyesine inilerek son akış vektörleri elde edilir. Bu tez çalışmasında, araçların temsil noktasının takip edilmesi işleminde Intel OpenCV Görme Kütüphanesi tarafından sağlanan piramitsel optik akış yöntemi kullanılmaktadır. Yöntemin işlem adımları aşağıda belirtilmiştir.

I_1 ve I_2 çerçevelerinin piramit gösteriminin oluşturulması:


- $\{I_1^L\}_{L=0,...,L_M}$ (3.22)
- $\{I_2^L\}_{L=0,...,L_M}$
- m piramit seviye sayısı, en çok seçilen m değeri, 2 veya 4

I^0 0. seviye ham görüntüsü, I^{L_m} L . seviye görüntüsü olmak üzere, piramitsel gösterim rekürsif olarak şu şekilde oluşturulur: $I^0 \rightarrow I^1 \rightarrow I^2 \rightarrow I^3 \rightarrow ... \rightarrow I^{L_m}$. I^L , Eşitlik (3.23)’de görüldüğü gibi hesaplanır.

$$I^L(x, y) = \frac{1}{4} I^{L-1}(2x, 2y) + \frac{1}{8} (I^{L-1}(2x - 1, 2y) + I^{L-1}(2x + 1, 2y) + I^{L-1}(2x, 2y - 1) + I^{L-1}(2x, 2y + 1)) + \frac{1}{16} (I^{L-1}(2x - 1, 2y - 1) + I^{L-1}(2x + 1, 2y + 1) + I^{L-1}(2x - 1, 2y + 1) + I^{L-1}(2x + 1, 2y - 1))$$

- $u^L = [u_x u_y]^L \rightarrow L = 0, ..., L_M, u^L, u(u^0)$ özellik noktasının piramit görüntülerinde karşılık gelen noktaları Eşitlik (3.24)’deki gibi hesaplanır.

$$u^L = \frac{u}{2^L}, u^L L. \text{ seviyedeki özellik noktası lokasyonu} \quad (3.24)$$



Şekil 3.11 Görüntünün t-1 ve t anındaki iki çerçevesi için Gauss Piramidi gösterimi [4]

Piramitsel algoritmanın özyinemeli olarak ilerlemesi aşağıdaki şekilde gerçekleşir.

- Uzaklık vektörü d^{L_m} , L_m seviyesinde hesaplanır.
- L_{m-1} seviyesindeki başlangıç L_m seviyesindeki d^{L_m} tahmini ile $d^{L_{m-1}}$ uzaklık vektörü hesaplanır.
- Bu işlem, 0. seviyeye kadar devam eder.
- L seviyesinde başlangıç optik akış tahmini : $g^L = [g_x^L g_y^L]^T$

L seviyesindeki gerçek optik akışın hesaplanabilmesi için, Eşitlik (3.25)'deki yeni görüntü eşleştirme hata fonksiyonu ε^L 'yi minimize eden artık piksel yer değişimi vektörünün hesaplanması gerekir.

$$d^L = [d_x^L d_y^L]^T \quad (3.25)$$

$$\varepsilon^L(d^L) = \varepsilon^L[d_x^L, d_y^L] = \sum_{x=u_x^L-w^x}^{u_x^L+w^x} \sum_{y=u_y^L-w^y}^{u_y^L+w^y} [I_1^L(x, y) - I_2^L(x + g_x^L + d_x^L, y + g_y^L + d_y^L)]$$

Bu adımda, d^L optik akışının hesaplanması için [35]'a danışılabilir. d^L optik akışının hesaplandığı kabul edilerek işleme (3.26) eşitliğindeki $L-1$ seviyesindeki tahmini optik akışın hesaplanması ile devam edilir.

$$g^{L-1} = 2(g^L + d^L) \quad (3.26)$$

$L-1$ seviyesindeki d^L optik akış vektörü hesaplanır. Bu vektör, $\epsilon^{L-1}(d-1)$ hata fonksiyonunu minimize eden akış vektörüdür. Bu işlem $L=0$ seviyesine kadar devam eder. Algoritmanın başlangıcında en derin seviyedeki g^{Lm} değeri Eşitlik (3.27)'deki gibi sıfır olarak atanır.

$$g^{Lm} = [0 \ 0]^T \quad (3.27)$$

Son adımda, final optik akış uzaklık vektörü (3.28)'deki gibi hesaplanır.

$$d = \sum_{L=0}^{Lm} 2^L d^L \quad (3.28)$$

3.4 Araçlara Ait Hareket Yörüngelerinin Elde Edilmesi

Piramitsel Lucas-Kanade Optik Akış Yöntemi kullanılarak araçların temsil noktalarının ardışık video görüntüleri üzerinde tespit edilmesi işlemi sonucunda araçların hareket yörüngelerinin belirlenmesi işlemi için her yeni görüntü üzerindeki araç temsil noktası birleştirilmiştir. Yani araçların hareket yörüngeleri, optik akış yöntemi sonucu yeni koordinatları bulunan araç temsil noktalarının geçmişe doğru birleştirilmesiyle elde edilmiştir.

Tez çalışmasında, araç temsil noktalarının Piramitsel Lucas-Kanade Optik Akış yöntemi ile takip edilmesi işlemi sonucunda elde edilen araç yörüngelerine ait bir örnek Şekil 3.12'de gösterilmektedir.



Şekil 3.12 Araç yörüngelerinin elde edilmesi

3.5 Karayolu Hareket Modellerinin Belirlenmesi

Araç yörüngelerinin elde edilmesi işleminin ardından, karayoluna ait hareket modellerinin belirlenmesi işlemi için elde edilen hareket yörüngelerinin kümelenmesi işlemi yapılmıştır. Kümeleme işlemi ile elde edilen hareket modelleri, görüntüye daha sonra girecek olan araçların yapabileceği olağan davranışlar hakkında bilgi vereceği için, olağandışı araç davranışların tespit edilmesi işleminde bu modeller kullanılacaktır.

Küme birbirine benzeyen nesnelerin oluşturduğu grup olarak tanımlanır ve kümeleme işleminin mantığı belirli bir benzerlik kriterine dayanarak aralarında güçlü ilişki bulunan nesnelerin aynı gruba dahil edilmesidir.

Kümeleme benzerlik ölçme teknikleri tanımlandıktan sonra kümelemede kullanılan öğretmensiz algoritmalar aşağıdaki şekilde gruplandırılmıştır [4].

- Yinelenen optimizasyon (K-ortalama, Bulanık C-Ortalama)
- Gerçek Zamanlı Adaptasyon (Benzerlik Eşik Aralığı)
- Hiyerarşik metotlar (Toplayıcı (agglomerative) ve Parçalayıcı (divisive))
- Yapay Sinir Ağları (Kendini Örgütleyen Eşleme (SOM))
- İstatistiksel Modeller (Saklı Markov Modeli (HMM) ve Baum Welch)

Bu tez çalışmasında [4]'deki yörünge öğrenme modeli kullanılarak Saklı Markov Modeli ve Gauss Karışımı yöntemleri ile yörünge kümeleme işlemleri gerçekleştirilmiştir. Saklı Markov Modeli ve Gauss Karışımı yöntemlerini anlatmadan önce bu bölümde Markov Süreci, Markov Özelliği ve sık kullanılan Markov Modelleri hakkında genel bilgi vermek faydalı olacaktır.

Verilen bir dizin kümesindeki n sayıda zaman noktasının herhangi bir $t_1 < t_2 < \dots < t_n$ için X_t 'nin $X_{t_1}, X_{t_2}, \dots, X_{t_n}$ 'in verilen değerlerine göre koşullu dağılımı yalnızca $X_{t_{n-1}}$ 'in değerine bağlı ise $\{X_t \in T\}$ süreci Markov Süreci olarak adlandırılır.

Buna göre herhangi gerçel $X_1, X_2, \dots, X_n$ sayıları için Eşitlik (3.28) sağlanır. Buna Markov Özelliği denir. Yani sürecin gelecek t_n zamanındaki durumu, geçmiş $t_1, t_2, \dots, t_{n-2}$ zamanlarındaki durumlarından bağımsız, sadece sürecin t_{n-1} zamanındaki durumuna bağlıdır.

$$P(X_{t_n} = X_n | X_{t_1} = X_1, \dots, X_{t_{n-1}} = X_{n-1}) = P(X_{t_n} = X_n | X_{t_{n-1}} = X_{n-1}) \quad (3.28)$$

Markov Modeli, Markov Özelliği taşıyan, yani mevcut durum verildiğinde, gelecek durumların geçmiş durumlardan bağımsız olarak belirlenebildiği stokastik modeldir. Markov Modelleri sistemin otonom veya kontrollü bir sistem olmasına göre ve sistemin durumlarının gözlemlenebilirlik seviyesine göre Çizelge 3.2 de gösterildiği gibi 4 grup altında incelenebilir.

Çizelge 3.2 Markov modelleri

	Sistem Durumları Tam Gözlemlenebilir	Sistem Durumları Kısmen Gözlemlenebilir
Otonom Sistem	Markov Zinciri	Saklı Markov Modeli
Kontrollü Sistem	Markov Karar Süreçleri	Kısmi gözlemlenebilir Markov Karar Süreçleri

3.5.1 Markov Zinciri

Markov Zincirleri, dinamik ve stokastik sistemlerin analizinde ve özellikle bir sistemin zaman boyunca içinde bulunabileceği farklı durumlar arasında yaptığı hareketlerin incelenmesinde yaygın olarak kullanılan modellerdir. Başka bir deyişle bir Markov zinciri, Markov sürecinin özel bir durumudur ve belirli stokastik sistemlerin uzun ve kısa dönemdeki davranışlarını modellemek için kullanılır [36].

Sistemin zaman içerisinde bulunabileceği tüm olası durumların listesi Markov Zincirlerinin en önemli elemanıdır. Markov zincirlerinde, bir sistemin sonlu sayıda olası durumu vardır. Sistemin belli bir t anında içinde bulunabileceği tüm durumlara ait olasılıklar, boyutlu bir vektör ile gösterilir. Bu vektöre, durum olasılık vektörü adı verilir [37].

Herhangi bir t anında i durumunun olasılığı P_i ise;

$$P(X_{t+1} = j \mid X_t = i) = P_{ij} \quad (3.29)$$

şeklindedir ve sistem $t+1$ anında j durumunda olacaktır. i den j ye harekete geçiş denilmektedir ve P_{ij} 'ler geçiş olasılıklarını ifade etmektedir. Geçiş olasılıkları matrisi halinde aşağıdaki şekilde gösterilir.

$$P = \begin{bmatrix} P_{11} & P_{12} & P_{13} & \dots & P_{1n} \\ \cdot & \cdot & \cdot & \dots & \cdot \\ \cdot & \cdot & \cdot & \dots & \cdot \\ \cdot & \cdot & \cdot & \dots & \cdot \\ \cdot & \cdot & \cdot & \dots & \cdot \\ P_{m1} & P_{m2} & P_{m3} & \dots & P_{mn} \end{bmatrix}$$

Herhangi bir j durumuna geçişte, tüm i'ler için geçiş olasılıkları toplamı Eşitlik (3.29)'da ifade edildiği şekilde 1'e eşit olacaktır. Ayrıca (3.30)'da belirtildiği şekilde tüm i ve j durumları için P_{ij} geçiş olasılığı değeri negatif bir değer olmayacaktır.

$$\sum_{i=1}^m P_{ij} = 1 \quad (3.29)$$

$$P_{ij} \geq 0 \quad (3.30)$$

t anında i durumunda olan sürecin t +1 anında j durumunda olması olasılığı P_{ij} ile gösterilmektedir. Sistemin m anında i durumunda iken n adım sonra j durumunda olması olasılığı ise P_{ij}^n ile gösterilir ve bu ifadeye adım geçiş olasılığı denir. Tüm

(n= 0,1,2,..) için n adım geçiş olasılığı Eşitlik (3.31)'de görüldüğü gibi ifade edilir.

$$P_{ij}^n = P(X_{n+m} = j | X_m = i) = P(X_n = j | X_0 = i) \quad (3.31)$$

Yukarıda verilen adım geçiş olasılıklarını hesaplamak için Chapman – Kolmogorov denklemi kullanılır.

Uzun dönem sonunda Markov zincirinde süreç denge durumuna veya durağan durum koşullarına ulaşır. Bu durumda sürecin geleceği ile ilgili etkili yorumlar yapılabilir.

3.5.2 Saklı Markov Modeli

Saklı Markov Modeli (HMM), Markov Zincirleri üzerine kurulu ve Markov Zincirlerine bazı özellikler eklenerek oluşturulmuş olan bir modeldir. Saklı Markov Modelinde, Markov Zincirlerinden farklı olarak başlangıç durum olasılıkları ve geçiş olasılıklarının yanında gözlem olasılıklarını da kullanılır. Saklı Markov Modelinde sistemin herhangi bir anda hangi durumda olduğu bilinmez, fakat sistemin bir durumda iken bu durumun tetiklediği gözlem ortaya çıkar ve bu gözlem bilinir [38].

Bir saklı markov modeli aşağıdaki şekilde tanımlanabilir:

1. N , saklı markov modelini oluşturan durumların sayısını ifade eder. Durumlar herhangi bir duruma herhangi başka bir durumdan ulaşılabilceği biçimde bağlantılıdır. t anındaki durum q_t ve durum kümesi $S = \{S_1, S_2, \dots, S_N\}$ olarak ifade edilir.

2. M , her bir durum için belirtilen ayırık gözlem sembollerinin sayısını ifade eder. Gözlem sembolleri modellenen sistemin fiziksel çıktısına karşılık gelir. Eğer gözlemler sürekli ise M sonsuzdur. Semboller $V = \{V_1, V_2, \dots, V_N\}$ şeklinde ifade edilir.

$$3. a_{ij} = P[q_{t+1} = S_j | q_t = S_i], \quad 1 \leq i, j \leq N \quad (3.32)$$

olmak üzere durum geçiş olasılıkları dağılımı $A = a_{ij}$ 'dir.

Herhangi bir durumun tek bir adımda herhangi başka bir duruma dönüşebileceği özel bir durum için, her i, j için $a_{ij} \geq 0$ olacaktır. Diğer Saklı Markov Modeli türleri için, bir ya da birden fazla (i, j) çifti için $a_{ij} = 0$ olacaktır. Geçiş olasılıkları standart olasılık kurallarını sağlamalıdır.

$$a_{ij} \geq 0, \quad 1 \leq i, j \leq N \quad (3.33)$$

ve

$$\sum_{j=1}^N a_{ij} = 1, \quad 1 \leq i \leq N \quad (3.34)$$

$$4. b_j(k) = P[V_k | q_t = S_i], \quad 1 \leq j \leq N, 1 \leq k \leq M \quad (3.35)$$

olmak üzere j durumundaki gözlem sembolü dağılımı $B = \{b_j(k)\}$ 'dir. $b_j(k)$ için aşağıdaki stokastik kısıtlamalar sağlanmalıdır [39].

$$b_j \geq 0, \quad 1 \leq j \leq N, 1 \leq k \leq M \quad (3.36)$$

ve

$$\sum_{k=1}^M b_j(k) = 1, \quad 1 \leq j \leq N \quad (3.37)$$

$$5. \pi_i = P[q_1 = S_i], \quad 1 \leq i \leq N \quad (3.38)$$

olmak üzere başlangıç durum dağılımı $\pi = \{\pi_i\}$ 'dir.

N, M, A, B, π 'nin uygun değerleri için Saklı Markov Modeli,

$$O = O_1, O_2, \dots, O_T \quad (3.39)$$

gibi bir gözlem dizisini verecek bir üreteç olarak kullanılabilir. Bunun için,

1- İlk durum dağılımı π ye bağlı olarak, $q_1 = S_i$ olacak biçimde bir başlangıç durumu seçilir.

2- $t=1$ olarak alınır.

3- S_i durumundaki sembol olasılığı dağılımına yani $b_i(k)$ 'ya göre $O_t = V_k$ olarak seçim yapılır.

4- S_i durumunun durum geçiş olasılığı dağılımına yani a_{ij} 'ye göre yeni bir $q_{t+1} = S_j$ durumuna geçilir.

5- $t=t+1$ olarak alınır; $t \leq T$ ise 5. adıma geri dönlür. Diğer durumlarda ise işlem sonlandırılır.

Yukarıdaki işlemler, hem bir gözlem üretici olarak ve hem de göz önünde bulundurulmuş bir gözlem dizisinin, uygun bir Saklı Markov Modeli tarafından nasıl üretildiğinin bir modeli olarak kullanılabilir.

Yukarıdaki değerlendirmelerden, Saklı Markov Modelinin özelliklerinin tam olarak belirlenebilmesi için, model parametreleri olan N ve M 'nin, gözlem sembollerinin ve üç olasılık ölçümünün A, B ve π 'nin belirtilmesinin gerekli olduğu görülür. Gösterimde kolaylık olması açısından, modeldeki parametreler kümesinin tamamını kısaca

$$\delta = (A, B, \pi) \quad (3.40)$$

biçiminde gösterilmektedir [39].

3.5.2.1 Saklı Markov Modelinin Üç Temel Problemi

Saklı Markov Modelini uygulama alanlarında kullanabilmek için literatürde "Saklı Markov Modelinin Üç Temel Problemi" olarak bilinen üç problemin çözülmesi gerekmektedir [40].

- **Problem 1/Değerlendirme Problemi:** Bu problem Saklı Markov Modelinde verilen $\delta = (A, B, \pi)$ parametreleri ve $O = O_1, O_2, \dots, O_T$ gözlem dizisi için, bu modele ait $P(O|\delta)$ gözlem dizisi olasılığının hesaplanmasına yöneliktir. Bu problemin çözümü, $P(O|\delta)$ gözlem dizisi olasılığının hesaplanması için İleri-Yön (Forward) veya Geri-Yön(Backward) Algoritmalarından yararlanır. Problem çözümünde iki algorithmada aynı sonucu vermektedir [40].

İleri-Yön Algoritması: α_t , ileri yön değişkeni olmak üzere aşağıdaki şekilde tanımlanır.

$$\alpha_t(i) = P(O_1, O_2, \dots, O_t, q_t = S_i | \delta) \quad (3.41)$$

Verilen δ modeli için $\alpha_t(i)$ ileri yön değişkeni, t anında S_i durumundaki sistemin $O_1, O_2, \dots, O_t$ kısmi gözlem dizisinin olasılığıdır. $\alpha_t(i)$ değişkeninin tümevarımsal çözümü aşağıda verilmiştir.

1) Başlangıç:

$$\alpha_1(i) = P(O_1, q_1 = S_i | \delta) = \pi_i b_i(O_1), \quad t = 1, \quad 1 \leq i \leq N \quad (3.42)$$

2) Yineleme:

$$\alpha_{t+1}(j) = \left[\sum_{i=1}^N \alpha_t(i) a_{ij} \right] b_j(O_{t+1}), \quad 1 \leq t \leq T-1, \quad 1 \leq j \leq N \quad (3.43)$$

3) Sonlandırma

$$P(O | \delta) = \sum_{i=1}^N P(O, q_t = S_i | \delta) = \sum_{i=1}^N \alpha_t(i) \quad (3.44)$$

Geri-Yön Algoritması: $\beta_t(i)$ geri yön değişkeni olmak üzere aşağıdaki şekilde tanımlanır.

$$\beta_t(i) = P(O_{t+1}, O_{t+2}, \dots, O_T, q_t = S_i | \delta) \quad (3.45)$$

Verilen δ modeli için $\beta_t(i)$ geri yön değişkeni, t anındaki S_i durumundaki sistemin, t+1 anından itibaren son ana kadar olan kısmi gözlem dizilerinin olasılığıdır. $\beta_t(i)$ değişkeninin tümevarımsal çözümü aşağıda verilmiştir.

1) Başlangıç:

$$\beta_T(i) = 1, \quad 1 \leq i \leq N \quad (3.46)$$

2) Yineleme:

$$\beta_t(i) = \sum_{j=1}^N a_{ij} b_j(O_{t+1}) \beta_{t+1}(j), \quad t = T-1, T-2, \dots, 1, \quad 1 \leq i \leq N \quad (3.47)$$

3) Sonlandırma

$$P(O | \delta) = \sum_{i=1}^N P(O, q_t = S_i | \delta) = \sum_{i=1}^N \beta_1(i) \pi_i b_i(O_1) \quad (3.48)$$

- Problem 2/Kodlama Problemi: Bu problem Saklı Markov Modelinde verilen $O_1, O_2, \dots, O_t$ gözlem dizisi için, bu gözlem dizisini oluşturma ihtimali en yüksek olan

$Q = \{q_1, q_2, \dots, q_t\}$ saklı durum dizisini bulma işleminin çözümlenmesidir. Bu problemin çözümünde viterbi algoritması kullanılır [40].

Viterbi Algoritması: Verilen $O_1, O_2, \dots, O_t$ gözlem dizisi oluşturma ihtimali en yüksek $Q = \{q_1, q_2, \dots, q_t\}$ saklı durum dizisini belirleyebilmek için;

$$\gamma_t(i) = \max_{q_1, q_2, \dots, q_{t-1}} P[q_1, q_2, \dots, q_t = S_i, O_1, O_2, \dots, O_t | \delta] \quad (3.49)$$

ifadesi tanımlanır. $\gamma_t(i)$, t anında S_i durumunda olan sürecin, t anına kadar olabilirlik derecesi en yüksek olan durum dizisini ifade eder. $\gamma_{t+1}(j)$ ise $\gamma_t(i)$ değişkenine tümevarım yöntemi uygulayarak elde edilir.

$$\gamma_{t+1}(j) = \left[\max_i \gamma_t(i) a_{ij} \right] b_j(O_{t+1}) \quad (3.50)$$

Gerçek durum dizisine erişmek için $\gamma_{t+1}(j)$ ifadesini maksimum yapan bağımsız değişkenin izlenmesi gerekir. Bu işlem $\varphi_t(j)$ dizisi ile yapılır.

t=1 anından başlayarak, yinelemeli olarak her t anı için en optimum yol bulunur. Viterbi algoritmasının işlem adımları aşağıdaki gibidir.

1)Başlangıç:

$$\gamma_1(i) = \pi_i b_i(O_1), \quad 1 \leq i \leq N \quad (3.51)$$

$$\varphi_1(i) = 0 \quad (3.52)$$

Yineleme:

$$\gamma_t(j) = \max_i \gamma_{t-1}(i) a_{ij} b_i(O_t), \quad 1 \leq i \leq N \quad (3.53)$$

$$\varphi_t(j) = \argmax_i \gamma_{t-1}(i) a_{ij} \quad (3.54)$$

2) Sonlandırma

$$path^* = \max_i \gamma_t(i), \quad 1 \leq i \leq N \quad (3.55)$$

$$q_T^* = \argmax_i \gamma_t(i) \quad (3.56)$$

3) Yol Durum Dizisi Geri İzleme

$$q_t^* = \varphi_{t+1}(q_{t+1}^*), \quad t = T-1, T-2, \dots, 1 \quad (3.57)$$

- Problem 3/Öğrenme Problemi:

Saklı Markov Modelinin temel problemlerinde çözümü en zor olan problem, verilen bir modele göre gözlem dizisinin olasılığını maksimize edecek şekilde model parametrelerinin belirlenmesi işlemidir [40].

Saklı Markov Modelinin parametrelerini tahmin etmek için genel olarak iteratif bir yöntem olan Baum-Welch Algoritması kullanılır.

Baum-Welch Algoritması: Saklı Markov Modelinin eğitimi olarak adlandırılan Baum-Welch Algoritması ileri-yön ve geri-yön algoritmasına ait değişkenler kullanılarak oluşturulur.

δ modeli ve herhangi bir gözlem dizisi için t anında S_i durumunda ve $t+1$ anında S_j durumunda olma olasılığı $\omega_t(i, j)$ değişkeni ile gösterilir.

$$\omega_t(i, j) = P(q_t = S_i, q_{t+1} = S_j | O, \delta) \quad (3.58)$$

$\omega_t(i, j)$ ileri yön ve geri yön değişkenler kullanılarak aşağıdaki şekilde ifade edilebilir.

$$\omega_t(i, j) = \frac{\alpha_t(i) a_{ij} b_j(O_{t+1}) \beta_{t+1}(j)}{P(O|\delta)} = \frac{\alpha_t(i) a_{ij} b_j(O_{t+1}) \beta_{t+1}(j)}{\sum_{i=1}^N \sum_{j=1}^N \alpha_t(i) a_{ij} b_j(O_{t+1}) \beta_{t+1}(j)} \quad (3.59)$$

Verilen bir gözlem dizisi ve model için t anında S_i durumunda bulunma olasılığı $\theta_t(i)$ ile gösterildiğinde $\theta_t(i)$ ve $\omega_t(i, j)$ arasında aşağıda verilmiş olan bağıntı yazılabilir.

$$\theta_t(i) = \sum_{j=1}^N \omega_t(i, j) \quad (3.60)$$

Saklı Markov Modeli parametrelerinin yeniden tahmini için yukarıda verilen bağıntılar yardımıyla elde edilen yeni parametreler $\bar{\delta} = (\bar{A}, \bar{B}, \bar{\pi})$ aşağıdaki gibi gösterilir.

$$\bar{\pi}_i = \theta_1(i) \quad (3.61)$$

$$\bar{a}_{ij} = \frac{\sum_{t=1}^{T-1} \omega_t(i, j)}{\sum_{t=1}^{T-1} \theta_t(i)} \quad (3.62)$$

$$\bar{b}_j(k) = \frac{\sum_{t=1}^{T-1} \omega_t(i, j) (O_t = V_k)}{\sum_{t=1}^{T-1} \omega_t(i, j)} \quad (3.63)$$

3.5.3 Markov Karar Süreçleri

Markov Karar Süreçleri, durum geçişlerinin mevcut duruma bağlı olduğu kesik zamanlı kontrollü stokastik bir süreçtir. Markov zincirlerinin uzantısı olarak kabul edilen Markov Karar Süreçleri, Markov Zincirlerinden farklı olarak durum geçişlerinde seçime izin verirken, takviyeli öğrenme (Reinforcement Learning) yönteminde olduğu gibi motivasyon verici ödülleri kullanır.

3.5.4 Kısmi Gözlemlenebilir Markov Karar Süreçleri

Markov Karar Süreçlerinden farklı olarak sistemdeki durum geçişlerinin bazılarının gözlemlenebildiği Kısmi Gözlemlenebilir Markov Karar Süreçleri, genellikle robotların navigasyon problemlerinin çözümünde kullanılmaktadır.

3.6 Saklı Markov Modeli ve Gauss Karışımı Yörünge Kümeleme

Araçların görüntülere girmesinden çıkış anına kadar kat ettikleri mesafe ve sahip oldukları hız bilgisi gibi dinamik karakteristik özelliklere sahip değişkenler sürekli değişkenler olarak ele alındığından dolayı tez çalışmasında Ayırık Saklı Markov Modelinin yerine Sürekli Saklı Markov Modelinin kullanılmasının daha uygun olacağı düşünülmüştür [4]. Sürekli Saklı Markov Modelinde, emisyon dağılımı ve gözlem olasılıklar Gauss Karışımı olarak ifade edilir. Görüntüye giren ve çıkan araçlara ait dinamik özellikler hiçbir vektör niceleme işlemine sokulmadan ve herhangi bir eşitleme işlemine ihtiyaç duyulmadan direk olarak Sürekli Saklı Markov Modelinin gözlem dizisi olarak ele alınabilirler. Yani karayolu hareket modellerinin belirlenebilmesi amacıyla yörünge kümeleme işlemi yapılırken, araçların görüntüde kalış sürelerinin ve nesne izleme işlemi sırasında araçların farklı sayıda takip noktalarının bulunmasından dolayı yörüngelere ait nokta sayılarının farklı olması Sürekli Saklı Markov Modelinde gözlem dizisini oluşturma işlemi sırasında herhangi bir ek işlem yapılmasına neden olmayacaktır. Bu değerlerin zamansal olarak araçların görüntüde kaldığı süre boyunca sürekliliği olduğu için Sürekli Saklı Markov Modelinin gözlem dizisi oluşturulurken direk olarak kullanılabileceklerdir.

Karayolu hareket modellerinin belirlenmesi amacıyla normal trafik akışı sırasında elde edilen araç yörüngelerine uygulanan Sürekli Saklı Markov Modeli ve Gauss Karışımı kümeleme yönteminin parametreleri aşağıda verilmiştir [4].

- K normal trafik akışı sırasında görüntüye girip çıkan araçların sayısını, k yörüngesi incelenen aracın numarasını ve n bu araçların takip elde edilmesi sonucu elde edilen takip noktası sayısına bağlı yörüngedeki nokta sayısını göstermek üzere araç yörüngesi:

$$\text{▪ } T_k: \{f_1, f_2, f_3, \dots f_n\},$$

- x_i, y_i takip işlemi sonucu elde edilen görüntü koordinat düzlemi üzerindeki araç pozisyonunu ve v_{xi}, v_{yi} araçlara ait görüntü üzerinde elde edilen hız değişkenlerini göstermek üzere t anında her bir araç için elde edilecek araç özellik vektörü:

$$\text{▪ } f_i : \{x_i, y_i, v_{xi}, v_{yi}\}_t,$$

- N saklı durumların sayısını göstermek üzere saklı durumlar:

$$\text{▪ } S : \{S_1, S_2, S_3, \dots S_N\};$$

- Her bir saklı durum için Gauss bileşeni sayısı:

$$\text{▪ } M,$$

- q_t : t anındaki durum, $a_{i,j} = P\{q_{t+1} = S_j \mid q_t = S_i\}$, $1 \leq i, j \leq N$ olmak üzere durum geçiş olasılıkları matrisi:

$$\text{▪ } A = \{a_{i,j}\},$$

- O_t , t anındaki gözlem, μ_j , S_j durumundaki ortalama ve Σ_j , S_j durumundaki kovaryans matrisini olmak üzere gözlem olasılıklarının dağılımı:

$$\text{▪ } B = \{O_t, \mu_j, \Sigma_j\},$$

- $1 \leq i \leq N$ olmak üzere başlangıç durum dağılımları:

$$\text{▪ } \Pi = \{\pi_i\},$$


- Beklenti Enbüyütme işlemi için iterasyon sayısı:

$$\text{▪ } Nr_iter,$$

- Beklenti Enbüyütme işlemi ile öğrenmenin tamamlanacağı yakınsama noktası:

- Stop,
- m karayolu hareket modeli sayısı olmak üzere öğrenilen Saklı Markov Model:
 - $\lambda_m = \{A_m, B_m, \Pi_m\}$ şeklinde tanımlanır.

Yukarıda verilen tanımlamalara göre Giriş – Çıkış noktaları arasındaki yol modelinin 3 farklı saklı durum (S_1, S_2, S_3) ve her duruma karşılık gelen 3 farklı $\eta(\mu_k, \Sigma_k)$ Gauss bileşeni ile temsil edildiği örnek kavşak modeli Şekil 3.13’de gösterilmiştir.



Şekil 3.13 HMM ve Gauss Karışımı yapısının örnek kavşak modeli üzerinde gösterimi [4]

Normal trafik akışı sırasında elde edilen araç hareket yörüngeleri kullanılarak Sürekli Saklı Markov Modeli ile karayolu hareket modellerinin elde edilmesi işleminde optimum parametrelerin kullanılabilmesi için Beklenti Enbüyütme Algoritmasından yararlanılmıştır. Bu algoritmanın adımları aşağıda açıklanmıştır [4].

- Yörüngesi elde edilen toplam araç sayısına (K) bağlı olarak her bir araç için eşit ilk değer olasılık değerleri atanır.

$$P(q_k) = \frac{1}{K} \quad (3.64)$$

- Her S_j saklı durumu için başlangıç Gauss modelleri $\eta(\mu_k, \Sigma_k)$ seçilir.
- Başlangıç $\delta = (A, B, \pi)$ modeli seçilerek, $\alpha_t(i)$, $\beta_t(i)$, $\theta_t(i)$ ve $\omega_t(i, j)$ değişkenleri hesaplanır.
- Algoritmanın beklenti adımında her O_t gözleminin $q_j = t$ saklı durumunda olma

olasılığı hesaplanır.

$$P(q_t = j | O_t, \delta_m) = \frac{P(q_t=j, \delta_m)P(O_t|q_t=j, \delta_m)}{P(O_t|\delta_m)} \quad (3.65)$$

- Algoritmanın enbüyütme adımında δ_m yol modeline ait S_j saklı durumdaki $\eta(\mu_k, \Sigma_k)$ Gauss modellerinin yeni ortalama μ_j ve kovaryans matrisleri Σ_j ve a_{ij} durum geçiş matrisi yeniden hesaplanır. Yeni değerler ile $\delta_{m,yeni}$ modeli elde edilir.

$$\bar{\mu}_j = \frac{\sum_{k=1}^n \sum_{t=1}^{T_k} \theta_t^k(j) o_t^k}{\sum_{k=1}^n \sum_{t=1}^{T_k} \theta_t^k(j)} \quad (3.66)$$

$$\bar{\Sigma}_j = \frac{\sum_{k=1}^n \theta_t^k(j) (o_t^k - \bar{\mu}_j)(o_t^k - \bar{\mu}_j)^T}{\sum_{k=1}^n \sum_{t=1}^{T_k} \theta_t^k(j)} \quad (3.67)$$

$$\bar{a}_{ij} = \frac{\sum_{k=1}^n \frac{1}{P_k} \sum_{t=1}^{T_k} \alpha_t^k(i) a_{ij} b(o_{t+1}^k) \beta_{t+1}^k(j)}{\sum_{k=1}^n \frac{1}{P_k} \sum_{t=1}^{T_k} \alpha_t^k(i) \beta_t^k(i)}, i = 1, 2, \dots, N, j = 1, 2, \dots, N \quad (3.68)$$

- $\text{Log}[P(O | \lambda_{m,yeni})] > \text{Log}[P(O | \lambda_m)]$ eşitliği sağlandığı sürece algoritmanın beklenti adımından sonraki işlemler tekrarlanır. Eşitliğin sağlanmadığı ilk durumda öğrenme tamamlanmış olur, bu nedenle bu noktaya gelindiğinde yapılan işlemler sonlandırılır.

Saklı Markov Modelini daha ayrıntılı incelemek için [41]'dan yararlanılabilir.

Tez çalışmasında Saklı Markov Yöntemi parametreleri olan saklı durum sayısı ve Gauss karışım sayısı denemeler sonucunda elde edilmiş ve her iki değişken içinde 3 değerinin kümeleme başarımında uygun sonuçlar verdiği gözlemlenmiştir. Bu değişkenlere verilecek daha yüksek değerler işlem karmaşıklığını arttırdığı için sistemin çalışma performansında olumsuz etki gösterecektir. Saklı durum sayısının ve Gauss karışım sayısının 3 olarak alındığı ve 3 saklı durum için elde edilen 3 Gauss bileşenin μ ortalama değerlerinin birleştirildiği durumlara ait karayolu hareket modelleri belirleme örnekleri Şekil 3.14'de gösterilmiştir. (a) ve (c) görüntülerinde araç takibi sonucu elde edilen hareket yörüngeleri, (b) ve (d) görüntülerinde Sürekli Saklı Markov Modeli ve Gauss Karışımı Kümeleme yöntemi ile elde edilen μ ortalama değerleri ve bu değerleri birleşimi sonucu ortaya çıkan karayolu hareket modelleri görülmektedir.



(a)



(b)



(c)



(d)


Şekil 3.14 Sürekli HMM ile karayolu hareket modellerinin elde edilmesi

ARAÇLARIN OLAĞANDIŞI DAVRANIŞLARININ TESPİT EDİLMESİ

Bu bölümde sistemin trafik görüntülerinde araçların gerçekleştirmiş olduğu olağandışı davranışların tespit edilmesi işlemi anlatılmaktadır. Önceki kısımda karayolu hareket modellerinin öğrenilmesi aşamasından sonra bu kısımda, görüntüye yeni giren araçların kısmi hareket yörüngelerinin, öğrenilmiş olan karayolu hareket modelleri ile benzerliğinin belirlenmesi işlemi yapılmaktadır. Kısmi hareket yörüngesi, karayolu hareket modelleri ile düşük benzerlik oranına sahip araçlar, sürücülerin ortalama olarak hareket ettiği karayolu hareket modeline aykırı biçimde ilerleme gerçekleştirdiği için olağandışı hareket içerisinde olarak değerlendirilir.

Şekil 4.1’de karayolu hareket modelleri kullanılarak araçların gerçekleştirmiş olduğu olağandışı davranışların tespit edilmesi için gerekli işlem adımları gösterilmiştir. Buna göre öncelikle ön işlemler ve arka plan belirleme adımlarının ardından Piramitsel Lucas-Kanade Optik Akış Yöntemi ile ilgili trafik görüntüsünde araç takip edilirken aracın gerçekleştirmiş olduğu kısmi yörüngeler elde edilmeye başlanır. İlk kısmi yörüngenin elde edilmesinden itibaren, elde edilen her kısmi yörüngenin hangi karayolu hareket modeline ne kadar benzerlik gösterdiği bilgisine ulaşılır. Elde edilen benzerlik oranına göre kısmi hareket yörüngesinin karayolu hareket modelleri arasında sınıflandırması yapılır. Eğer sınıflandırma işlemi sırasında elde edilen benzerlik belirli bir eşik seviyesinin üzerinde ise aracın karayolu hareket modeline uygun şekilde hareket ettiği anlaşılır. Bu durumda ayrıca aracın anlık hızında meydana gelen değişimler incelenerek ani hızlanma ve yavaşlama gibi beklenmedik hız değişimi durumlarında aracın trafik akışını bozan davranışı tespit edilir. Karayolu hareket modeli ile kısmi yörüngenin

benzerliği belirli bir eşik seviyesinin altında olduğu durumlar için de aracın olağandışı davranış içerisinde olduğu tespit edilmiş olur. Bu durumda elde edilebilecek olağandışı trafik davranış durumları araçların karayolu hareket modeline ters yönde hareket etmeleri, araçların hiçbir karayolu hareket modeline uymayacak şekilde hareket etmeleri ve araçların komşuluğu bulunmayan hareket modelleri arasında geçiş yapma durumlarıdır.




Şekil 4.1 Olağandışı araç davranışlarının belirlenmesi için gerekli işlem adımları

4.1 Kısmi Hareket Yörüngesi Sınıflandırma

Kısmi hareket yörüngesi, araçların hareketi sırasında elde edilen yörüngelerin alt hareket parçasıdır. Diğer bir ifadeyle araçların hareket yörüngesini oluşturma aşamasında elde edilen son takip noktaları kısmi hareket yörüngesini oluşturur.

Araçların hangi karayolu hareket modeline benzer şekilde hareket edebildiğinin tespit edilebilmesi için, araçların kısmi hareket yörüngeleri karayolu hareket modelleri arasında sınıflandırılır. Kısmi hareket yörüngesinin sınıflandırılması ve buna bağlı olarak aracın ilerlediği karayolu hareket modelinin belirlenmesi için gerekli işlem adımları Şekil 4.2’de gösterilmiştir. Belirtilen işlem adımları ilerleyen bölümlerde detaylı bir şekilde açıklanmıştır.




Şekil 4.2 Kısmi Hareket Yörüngesi Sınıflandırma İşlem Adımları

4.1.1 Trafik Görüntüsünde Araçların Belirlenerek Takibinin Yapılması

Tez çalışmasının bu bölümünde gerçekleştirilen araç takip işlemi, birinci kısımda anlatılan Gauss ve Ortanca Yumuşatma Filtreleri uygulanarak görüntülerin gürültüden arındırılması, GMM tabanlı arka plan çıkarımının ardından araç temsil noktalarının belirlenmesi ve ardından Piramitsel Lucas-Kanade Optik Akış Yöntemi ile araçların takip edilmesi işlemlerini kapsamaktadır. Bu işlemler daha önce ayrıntılı şekilde anlatıldığı için bu bölümde tekrar anlatma gereği duyulmamıştır.

4.1.2 Takip Edilen Araçların Kısmi Hareket Yörüngelerinin Elde Edilmesi

Çalışmada deneysel sonuçların başarımı değerlendirilerek, araçların karayolu hareket modellerine sınıflandırma işlemi başlangıç zamanından önceki son 0.25 saniye boyunca elde edilen takip noktaları kısmi hareket yörüngesi olarak alınmıştır. Şekil 4.3'de 1 saniyede 28 çerçeve içeren bir video için her 0.25 saniyelik dilimde elde edilen 7'şer takip noktası ile oluşturulan 4 kısmi hareket yörüngesi gösterilmiştir.



Şekil 4.3 Bağımsız ardışık kısmi hareket yörüngeleri

4.1.3 Kısmi Yörüngelerin KHM'ler Arasında Sınıflandırılması

Araca ait kısmi hareket yörüngesinin hesaplanmaya başladığı ilk görüntüden itibaren aracın hangi karayolu hareket modelinin yapısına daha uygun şekilde hareket ettiğinin belirlenmesi işlemi yapılır. Bu işlem kısmi hareket yörüngesinin mevcut karayolu hareket modelleri arasında sınıflandırılmasıdır. Aracın kısmi hareket yörüngesinin karayolu hareket modelleri ile olan öklid uzaklığı ve kısmi hareket yörüngesinin karayolu hareket modelleri ile yaptığı açı bilgileri kullanılarak benzerlik değerleri elde edilir. Bu benzerlik değerleri arasında maksimum değere sahip karayolu hareket modeli, aracın kısmi hareket yörüngesinin sınıflandırıldığı karayolu hareket modeli olarak belirlenir. Kısmi hareket yörüngesinin sınıflandırma işleminin yapıldığı karayolu hareket modeli ile benzerliğinin belirli bir eşik seviyesinin üstünde hesaplanması durumunda araç, sınıflandırıldığı karayolu hareket modeline uygun şekilde hareket etmektedir.

Aracın kısmi hareket yörüngesinin karayolları hareket modellerine benzerliğinin bulunmasında kullanılan, kısmi hareket yörüngesi-karayolu hareket modeli arası uzaklık belirleme işleminin adımları aşağıdaki şekildedir:

- 1- Aracın kısmi hareket yörüngesinin notalarının aritmetik ortalamaları kullanılarak M merkez notası elde edilir.
- 2- Bütün karayolu hareket modelleri için M merkez noktasının en yakın olduğu iki Gauss karışım noktası μ_1 ve μ_2 değerleri bulunur.
- 3- Bütün karayolu hareket modelleri için elde edilen μ_1 ve μ_2 noktaları kullanılarak bu noktalardan geçen doğru elde edilir. Bu doğruyu elde etmek için

2 nokta arasından geçen doğru denklemi (4.1)'den yararlanılır. Eşitlik (4.2)'deki gibi bir denklem elde edilir.

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

$$a.C_x + b.C_y + c = 0 \quad (4.2)$$


- 4- M noktasının, bütün karayolu hareket modelleri için elde edilen doğrulara uzaklığını belirleyebilmek amacıyla noktanın doğruya dik uzaklığı hesaplanır.

$$d_n = \frac{|a.C_x + b.C_y + c|}{\sqrt{a^2 + b^2}} \quad (4.3)$$

- 5- Benzerlik oranları kısmi hareket yörüngesinin karayolu hareket modellerine olan öklid uzaklık değerleri ile ters orantılı olarak elde edilir.

$$b_1 = \frac{1}{d_n} \quad (4.4)$$

Şekil 4.4'de gösterilen KHM-C 'ye yakın olarak hareketini sürdüren kırmızı aracın siyah noktalarla belirtilen kısmi hareket yörüngesinin, beyaz noktalarla gösterilen Gauss karışım noktalarına sahip karayolu hareket modellerine olan uzaklığının belirlenebilmesi için $D = \{d_a, d_b, d_c, d_d\}$ değerleri hesaplanır ve benzerlik oranları bu uzaklık değerleri ile ters orantılı olarak alınır. $B = \left\{ \frac{1}{d_a}, \frac{1}{d_b}, \frac{1}{d_c}, \frac{1}{d_d} \right\}$



Şekil 4.4 Kısmi hareket yörüngesinin KHM'lere olan uzaklığının belirlenmesi
Aracın kısmi hareket yörüngesinin, karayolu hareket modelleri ile olan öklid uzaklığının bulunarak benzerliklerin belirlenmesi ve buna göre sınıflandırma yapılması, sadece


karayolunun paralel şeritlerden (paralel karayolu hareket modellerinden) oluştuğu durumlarda doğru sonuç verir. Şekil 4.5'te de görüldüğü gibi karayolu hareket modellerinin hepsinin birbirine paralel olmadığı durumlarda uzaklık bilgisi sınıflandırma için yeterli değildir. Burada kısmi hareket yörüngesinin sınıflandırılması gereken karayolu hareket modeli KHM-B olarak beklenirken, sadece dik uzaklık bilgisinin kullanıldığı durumlarda dik uzaklığın en küçük olduğu KHM-C modeline sınıflandırılma yapıldığı görülür. Bu durumu engellemek amacıyla aracın kısmi hareket yörüngesinin karayolu hareket modelleri ile yapmış olduğu açıdan yararlanılır. Aracın kısmi hareket yörüngesinin karayolu hareket modeline yakınlığının yanı sıra açısal olarak da benzemesi gerekmektedir. Yani Şekil 4.5'te görülen aracın kısmi hareket yörüngesi, dik olarak kesiştiği KHM-C modeline değil de, paralel olduğu KHM-B modeline sınıflandırılmalıdır. Aracın kısmi hareket yörüngesinin, karayolu hareket modelleri ile olan açısal benzerlikleri aşağıdaki şekilde hesaplanır.

- 1- Kısmi hareket yörüngesinin başlangıç noktası S ve bitiş noktası E olmak üzere kısmi hareket yörüngesinin eğimi m hesaplanır.

$$m_M = \frac{E_y - S_y}{E_x - S_x} \quad (4.6)$$

- 2- Bütün yol modelleri için kısmi hareket yörüngesi aritmetik merkez noktası M kullanılarak elde edilen en yakın Gauss Karışım noktalarının birleştirilmesiyle elde edilen doğruların eğimleri elde edilir. $m = \{m_a, m_b, m_c, m_d\}$
- 3- İki doğru arasındaki açı formülünden yararlanılarak 1. adımda bulunan kısmi hareket yörüngesi eğimi ve 2. adımda bulunan Gauss Karışım noktaları arası doğru eğimlerinin arasındaki açı belirlenir. $\theta = \{\theta_a, \theta_b, \theta_c, \theta_d\}$

$$\theta = \frac{|m_M - m_n|}{1 + m_M \cdot m_n} \quad (4.7)$$



Şekil 4.5 Kısımlı hareket yörüngesinin KHM'lerle olan açısının belirlenmesi

Kısımlı hareket yörüngesinin KHM'ler arasında sınıflandırma işleminin yapılmasında aracın kısımlı hareket yörüngesinin KHM'ler ile uzaklık benzerlikleri ve açısal benzerlikleri birlikte değerlendirilmelidir. Bunun için aracın kısımlı hareket yörüngesinin her KHM ile olan uzaklık benzerliği ve açısal benzerliği kullanılarak Eşitlik (4.8)'de bulunan genel benzerlik değeri R hesaplanır. Bu değerin en küçük çıktığı genel yol modeli sınıflandırmanın yapıldığı KHM olarak alınır. Diğer bir ifadeyle aracın bu KHM üzerinde hareket ettiği kabul edilir.


$$R = D * \theta \quad (4.8)$$

4.2 Yörüngeye Bağlı Olağandışı Araç Davranışlarının Belirlenmesi

Aracın hareketi sırasında elde edilen kısımlı hareket yörüngelerinin karayolu hareket modellerinden birine sınıflandırılmış olması, o aracın ilgili hareket modeline bire bir uygun doğrultuda hareket ettiği anlamı taşımaz. Aracın kısımlı hareket yörüngesi ile sınıflandırılmış olduğu sınıf arasındaki benzerlik oranı deneysel olarak elde edilen belirli bir eşik seviyesinin altında ise aracın karayolu hareket modelinin yapısından uzak bir davranış sergilediği belirlenir ve bu durum olağandışı araç davranışı olarak tespit edilir.

Şekil 4.6'da KHM-A'da hareketini sürdüren aracın, hiçbir karayolu hareket modeline uymayan davranışı gösterilmiştir. Burada aracın kısımlı hareket yörüngelerinin sınıflandırması tüm durumlarda KHM-A'ya yakın görünürken, aracın ilerleyen bölümlerde KHM-A'dan uzaklaştığı ve olağandışı hareket içerisinde olduğu


görülmektedir. Bu durumda aracın kısmi hareket yörüngesinin KHM-A'ya olan öklid uzaklığı ve KHM-A ile arasındaki açı arttığı için, aracın KHM-A ya olan genel benzerlik oranı düşer ve aracın olağandışı hareketi tespit edilir.



Şekil 4.6 Karayolu hareket modellerinin dışında hareket eden aracın tespiti


Araçların karayolu hareket modellerine ters yönde ilerleme durumları da araçların yapmış olduğu olağandışı hareketlerden birisidir. Ters şeride girme olarak bilinen bu durum günlük yaşantıda kazaların önemli sebeplerinden birisidir. Bu durumların olağandışı araç davranışı olarak yakalanabilmesi amacıyla aracın yapmış olduğu kısmi hareket yörüngesinin yönü ve sınıflandırılmış olduğu karayolu hareket modelinin yönü kullanılır. Karayolu hareket modelinin yönü, modeli oluşturan saklı durumların Gauss Karışım ortalamalarının takip edilmesiyle elde edilir. Her saklı durum kendisinden sonraki saklı duruma geçişe izin verdiği için ve saklı durumlarda bulunan Gauss Karışımları belirli bir sırası olduğu için, bu saklı durumların sırasından yani Gauss Karışımlarının sırasından farklı bir sırada hareket eden kısmi hareket yörüngesine sahip araç olağandışı davranış içerisinde olarak belirlenir. Şekil 4.7'de KHM-A'da hareket eden bir aracın, sırasıyla KHM-B, KHM-C ve KHM-D'ye geçişi gösterilmiştir. Aracın kısmi hareket yörüngesinin yönü, KHM-B ve KHM-C'nin yönü ile aynı olduğu için bu geçişler herhangi bir olağandışı durum içermemektedir. Ancak aracın KHM-D'ye geçişi ile

birlikte kısmi hareket yörüngesinin yönü ile KHM-D'nin yönü farklı olduğu için bu durum olağandışı araç davranışı olarak tespit edilecektir.



Şekil 4.7 Ters şeritte hareket eden aracın tespiti

Araçların olağandışı davranışı olarak ele alınan bir diğer durum ise araçların karayolu hareket modellerine uygun hareket ettiği fakat komşuluğu olmayan karayolu hareket modelleri arasında geçiş yaptığı durumlardır. En güzel örneğinin uygun olmayan yerlerde yapılan U dönüşleri olduğu bu durumlar, günlük yaşantıda meydana gelen trafik kazalarının önemli bir nedenidir. Şekil 4.8'de KHM-B'de hareket eden araç ani bir U dönüşü ile ters yöndeki şeride girmiştir. Burada aracın kendi şeridindeki ve ters yöndeki şeritteki hareketi trafik akışının bozulmasına neden olacak bir davranış değildir. Ancak bu U dönüşü sırasında kendi hareket yönü dışındaki bir şeride ani geçiş yaptığı için bu durum normal trafik akışını bozacak bir davranış olarak değerlendirilmektedir ve olağandışı araç davranışı olarak tespit edilmektedir.



Şekil 4.8 Komşuluğu olmayan KHM'ler arasında geçiş yapan aracın tespiti


4.3 Bağlı Hıza Bağlı Olağandışı Araç Davranışlarının Belirlenmesi

Karayollarında meydana gelen olağandışı davranışlardan bir diğeri de araçların ani hızlanma ve yavaşlama hareketleridir. Trafik videoları incelendiğinde, özellikle trafik kazalarının meydana gelmesi sırasında araçların hızlarında ani yavaşlamalar olduğu gözlemlenmiştir. TRIMARC video veri tabanında yapılan incelemelerde kaza yapan veya kaza yapmaya yaklaşan araçların yaklaşık %60'inde kaza öncesi ani yavaşlama hareketi görülmüştür. Bunun sebebi araç sürücülerinin kazayı engellemek için ani fren yapmalarıdır. Bu nedenle ani yavaşlama hareketi yapan araçların da sistem tarafından olağandışı davranış olarak tespit edilmiştir.

Hız, bir cismin birim zamanda aldığı yol olarak tanımlanır. Trafik videolarında, hareket eden araçların anlık hız bilgisinin gerçek değerinin belirlenmesi mümkün değildir. Bu nedenle video hareket analizinde anlık hızın gerçek değeri yerine bağlı hız kavramı kullanılır. Bağlı hız optik akış kullanılarak takip edilen araçların görüntü üzerinde ardışık çerçevelerde yer değiştirme miktarına bağlı olarak elde edilen değerdir. Yani ardışık çerçeveler üzerinde optik akış ile takibi sürdürülen aracın belirlenen bir süre sonunda koordinat düzlemindeki yeni yerinin belirlenmesi ile elde edilen yer değiştirme miktarının, süreye bağlı değeri bağlı hızı verir. Şekil 4.9'daki kırmızı aracın A notasından

B noktasına varması sırasında geçen süre t , A ve B noktalarının koordinat düzlemindeki yeri sırasıyla (x_A, y_A) , (x_B, y_B) olmak üzere aracın bağıl hızı Eşitlik (4.9)'da görüldüğü gibi hesaplanır.

$$V = \frac{\sqrt{(x_A - x_B)^2 + (y_A - y_B)^2}}{t} \quad (4.9)$$



Şekil 4.9 Araçlar için bağıl hız hesaplaması

Araçların bağıl hızlarının, belirlenen deneysel bir eşik değerinin üzerinde artan/azalan yönde değişmesi durumunda, araçların ani olarak hızlandığı/yavaşladığı anlaşılır. Bu durumlar, araçların karayolu üzerinde gerçekleştirmiş olduğu olağandışı araç hareketi olarak tespit edilir.

UYGULAMA VE DENEYSEL SONUÇLAR

Bu bölümde daha önceki bölümlerde bilgi verilen tasarıma göre gerçekleştirilen uygulama, bu uygulama ile gerçekleştirilen deneyler ve bu deneylerin sonuçları anlatılmıştır. Deneyler, doğal trafik ortamına ait trafik akışını ve olağandışı durumları içermektedir. İlk olarak trafik akışı öğrenme ve karayolu hareket modellerinin elde edilmesine ait deneyler açıklanmış, daha sonra araçların olağandışı davranışlarının tespit edilmesine yönelik yapılan deneyler anlatılmıştır.


5.1 Doğal Ortam Verileri İle Karayolu Hareket Modellerinin Belirlenmesi

Trafik videolarında araçların gerçekleştirmiş oldukları olağandışı davranışların tespit edilmesi işlemi için, karayolu hareket modellerinin iyi bir şekilde çıkartılmış olması gerekmektedir. Bunun için de öncelikle uygulanan yörünge kümeleme işleminin başarımının yüksek olması gerekmektedir. NGSIM projesi [U.S. Department of Transportation, Federal Highway Administration] tarafından sağlanan örnek video veri tabanı kullanılarak tez çalışmasında kullanılan Sürekli Saklı Markov Yöntemi'nin yörünge kümeleme işlemindeki başarımı değerlendirilmiştir.

5.1.1 Eğitim Kümesinin Hazırlanması

NGSIM kapsamında yapılan projelerden birisinde, Los Angeles'ta bulunan Lankershim Bulvarı'na yerleştirilen beş adet video kameradan alınan görüntüler yardımıyla trafik akışının yoğun olduğu saatlerde araçların trafik karakteristikleri çıkarılmaya çalışılmıştır. Bu amaçla 08:15 - 08:30 saatleri arasında elde edilen görüntüler kullanılarak araçlara

ait hız, hareket yönü, şerit, şerit değiştirme bilgisi gibi temel araç hareketi özellikleri elde edilmiştir. Bu video veri tabanında bulunan görüntülerin normal trafik akışına ait görüntüler olması nedeniyle olağandışı araç davranışı içermemektedir. Bu sebeple bu video veri tabanında bulunan görüntüler kullanılarak karayolu hareket modellerinin belirlenmesine yönelik deneyler yapılmış, olağandışı davranış belirlemesine yönelik deneyler için bu veri tabanındaki videolar kullanılmamıştır.



(a) Çerçeve #125



(b) Çerçeve #135




(c) Çerçeve #150



(d) Çerçeve #165



(e) Çerçeve #200




(f) Çerçeve #220

Şekil 5.1 Araçların takip edilmesi ve araç hareket yörüngesinin elde edilmesi


Sürekli Saklı Markov Yöntemi ile karayolu hareket modellerinin elde edilmesi işlemi için yapılan deneyde, 18 dakikalık videolarda 125. çerçevede görüntüye girişi gerçekleşen aracın Piramitsel Lucas-Kanade Optik Akış Yöntemi ile takip edilmesi ve 220. çerçevede takip işleminin tamamlanmasının ardından araç yörüngesinin belirlenmesi işlemine ait ekran görüntüleri Şekil 5.1 de gösterilmiştir. Aracın takibi sırasında elde edilen hareket yörüngesi mavi renkte, aracın görüntüden çıkışı ile birlikte takibinin tamamlanmasının ardından elde edilen hareket yörüngesi yeşil renkte gösterilmiştir.

Yapılan deneyde, normal trafik akışı sırasında bir şerit üzerinde hareket eden araçların Piramitsel Lucas-Kanade Optik Akış Yöntemi ile takip edilmesi işleminden sonra elde edilen araç hareket yörüngelerinin gerçek görüntü ve matlab üzerindeki gösterimi Şekil 5.2’de yer almaktadır.



Şekil 5.2 Bir şerit için elde edilen araç hareket yörüngelerinin gösterimi
(a) Gerçek görüntü üzerindeki gösterimi (b) Matlab gösterimi

Belirli bir şerit için elde edilen hareket yörüngelerinin Sürekli Saklı Markov Yöntemi ile kümelenmesinin ardından elde edilen HMM’in matlab üzerindeki görünümüne ve şeride ait karayolu hareket modelinin gerçek görüntü üzerindeki görünümüne Şekil 5.3’de yer verilmiştir. Gerçek görüntü üzerinde karayolu hareket modelinin başlangıç ve bitiş noktaları siyah renkle belirtilmiştir.



(a)




(b)

Şekil 5.3 Sürekli Saklı Markov Yöntemi ile KHM'nin elde edilmesi
(a) Matlab gösterimi (b) Gerçek görüntü üzerinde gösterimi


TRIMARC video veri tabanında bulunan videolar üzerinde olağandışı araç davranışlarının belirlenebilmesi için yapılan deneylerde eğitim kümesi hazırlama işlemi için mevcut videoların sürelerinin kısa olmasından dolayı normal trafik akışına ait araç yörüngeleri elde edilememiştir. Bu nedenle bu video veri tabanında yapılan deneylerde araç hareket yörüngeleri elle işaretlenmiştir. Şekil 5.4'te TRIMARC video veri tabanında elle işaretleme sonucu elde edilen araç yörüngeleri ve yörüngelerin Sürekli Saklı Markov Kümeleme Yöntemi ile kümelenmesi sonucu oluşan karayolu hareket modelleri gösterilmiştir. (a)'da el ile işaretlenen araç hareket yörüngelerinin görüntüsü, (b)'de bu yörüngelerin matlab üzerindeki görüntüsü, (c)'de yörüngelerin Sürekli HMM ile kümelenmesi sonucu elde edilen HMM'lere ait matlab görüntüsü, (d)'de ise oluşan karayolu hareket modellerinin gerçek çerçeve üzerine yerleştirilmiş görüntüsü mevcuttur.



(a)



(b)



(c)



(d)

Şekil 5.4 TRIMARC videoları için karayolu hareket modellerinin elde edilmesi

5.2 Kısmi Hareket Yörüngesinin Elde Edilmesi Ve Sınıflandırma

Araçların gerçekleştirmiş olduğu hareketlerin sınıflandırılması işleminde kullanılan kısmi hareket yörüngelerinin elde edilmesi Şekil 5.5'te gösterilmiştir. Şekil 5.5 (a),(b),(c),(d)'de aracın görüntü dışına çıkana kadar gerçekleştirmiş olduğu harekete dair çerçeveler, (e)'de ise bu hareket sırasında elde edilen kısmi hareket yörüngeleri farklı renklerde gösterilmiştir.



(a) Çerçeve #110




(b) Çerçeve #127



(c) Çerçeve #140




(d) Çerçeve #153



(e)


Şekil 5.5 Araç takibi ile elde edilen kısmi yörüngeler

Kısmi hareket yörüngelerinin sınıflandırılmasına ilişkin deneyde elde edilen bazı çerçeveler Şekil 5.6'da gösterilmiştir. Aracın yörüngesi mavi, kısmi hareket yörüngesi yeşil, karayolları hareket modelleri beyaz, aracın sınıflandırıldığı karayolu hareket modeli ise sarı renkle ifade edilmiştir. Bu sınıflandırma işlemleri sırasında hesaplanan kısmi hareket yörüngeleri ve karayolu hareket modelleri arasındaki uzaklık ve açı bilgileri de Çizelge 5.1 ve Çizelge 5.2'de gösterilmiştir.



(a) Çerçeve #102

(b) Çerçeve #112



(c) Çerçeve #120

(d) Çerçeve #130



(e) Çerçeve #138

(f) Çerçeve #148

Şekil 5.6 Kısmi hareket yörüngelerinin sınıflandırılması

Çizelge 5.1 Deney-1 için araç kısmi yörüngesi ve KHM'ler arası uzaklık bilgileri

	Çerçeve #102	Çerçeve #112	Çerçeve #120	Çerçeve #130	Çerçeve #138	Çerçeve #148
KHM-1	39,25	87,06	182,34	181,73	181,24	182,11
KHM-2	29,68	36,78	39,19	29,96	29,44	28,59
KHM-3	0,82	1,24	3,75	4,52	4,03	4,89
KHM-4	65,12	24,09	150,74	157,83	157,44	158,36
KHM-5	18	14,08	23,55	32,75	33,29	34,13
KHM-6	34,44	29,65	49,63	59,06	59,47	60,39
KHM-7	44,76	41,72	65,95	75,27	75,76	76,63
KHM-8	92,24	48,86	134,3	140,34	139,81	140,66

Çizelge 5.2 Deney-1 için araç kısmi yörüngesi ve KHM'ler arası açı bilgileri


	Çerçeve #102	Çerçeve #112	Çerçeve #120	Çerçeve #130	Çerçeve #138	Çerçeve #148
KHM-1	125,41	126,65	105,75	15,75	105,75	15,75
KHM-2	9,25	13,31	13,24	23,24	21,24	19,24
KHM-3	1,69	1,98	7,47	14,32	14,62	12,47
KHM-4	127,34	121,86	111,8	21,8	111,8	21,8
KHM-5	15,12	3,46	12,53	102,53	12,53	102,53
KHM-6	8,03	5,81	20,7	110,7	20,7	110,7
KHM-7	1,9	9,84	15,95	105,95	15,95	105,95
KHM-8	122,76	119,88	102,99	12,99	102,99	12,99

5.3 Yörüngeye Bağlı Olağandışı Araç Davranışlarının Belirlenmesi


Karayolu normal trafik akışında araç takip işlemi sonrasında elde edilen araç yörüngelerinin kümelenmesi ile oluşturulan KHM'ler, karayoluna yeni giren araçların davranışlarının izlenmesi ve olağandışı araç hareketlerinin belirlenmesi işleminde kullanılmıştır. Olağandışı araç davranışlarının belirlenmesi için yapılan deneylerde kullanılan maksimum uzaklık ve maksimum açı için gerekli eşik değerleri parametrik olarak alınmıştır.

5.3.1 Şerit Dışında Hareket Eden Araçların Belirlenmesi

Karayolu hareket modellerine uygun olarak hareketini sürdüren aracın ani olarak karayolu hareket modellerinden uzaklaşmasının tespit edilmesine yönelik olarak yapılan deneye ait çerçeveler Şekil 5.7’de gösterilmiştir. Aracın görüntüye girmesinden sonra kısmi yörünge benzerliğinin en fazla olduğu için sınıflandırıldığı karayolu hareket modeli sarı renk ile belirtilmiştir. Daha sonra son iki çerçevede ise aracın karayolu trafik modelinden uzaklaşması sonucu genel benzerlik oranı artmış, şerit dışında kalma durumu tespit edilmiş ve kendisine en benzer olduğu için sınıflandırıldığı karayolu hareket modelinin rengi kırmızıya dönüştürülmüştür.



(a)Çerçeve #150



(b)Çerçeve #200



(c)Çerçeve #245



(d)Çerçeve #265



(e)Çerçeve #271



(f)Çerçeve #290

Şekil 5.7 Belirli bir KHM’ye uygun hareket eden aracın şerit dışında kalma durumu

Çizelge 5.3 Deney-2 için araç kısmi yörüngesi ve KHM'ler arası uzaklık bilgileri

	Çerçeve #150	Çerçeve #200	Çerçeve #245	Çerçeve #265	Çerçeve #271	Çerçeve #300
KHM-1	58,81	15,96	17,6	64,14	76,42	84,43
KHM-2	59,91	57,2	25,35	92,17	136,29	174,17
KHM-3	94,1	46,34	45,71	138,4	183,88	223,27
KHM-4	34,01	30,1	2,65	119,15	162,93	200,88
KHM-5	86,08	42,67	9,55	41,44	49,69	62,26
KHM-6	11,8	7,33	26,87	140,62	181,98	217,02
KHM-7	3,97	8,4	42,91	155,83	198,32	237,17
KHM-8	14,31	19,39	54,69	168,15	211,98	249,55
KHM-9	1,72	3,43	2,19	20,38	32,93	59,88

Çizelge 5.4 Deney-2 için araç kısmi yörüngesi ve KHM'ler arası açı bilgileri

	Çerçeve #150	Çerçeve #200	Çerçeve #245	Çerçeve #265	Çerçeve #271	Çerçeve #300
KHM-1	104,86	98,69	43,39	14,04	14,5	2,57
KHM-2	11,31	25,48	80,79	107,35	109,96	121,89
KHM-3	88,6	34,75	20,56	101,31	103,91	115,84
KHM-4	22,01	28,35	83,66	110,22	109,71	121,64
KHM-5	105,26	97,13	41,82	15,46	9,66	7,27
KHM-6	8,13	33,59	88,9	115,91	118,51	130,44
KHM-7	13,67	35,31	86,99	117,18	106,27	118,21
KHM-8	18,43	38,51	93,81	108,43	111,04	122,97
KHM-9	3,34	8,75	4,15	6,84	15,83	10,9

Şekil 5.7'deki aracın kısmi hareket yörüngesinin mevcut 9 karayolu hareket yörüngelerine olan uzaklıkları piksel cinsinden Çizelge 5.3'de, kısmi yörüngelerin bu hareket modelleri ile olan açıları derece cinsinden Çizelge 5.4'de gösterilmiştir. Çizelge 5.3'de de görüldüğü gibi 9 numaralı karayolu hareket modeline en yakın olarak hareket eden araç, Çizelge 5.4'de yine aynı karayolu hareket modeli ile yakın açılarda kısmi hareket yörüngesine sahiptir. Aracın kısmi yörünge hareketinin karayolu hareket

modeline açılabilir olarak benzerliğinde herhangi bir sorun bulunmamaktadır fakat aracın kendisine en yakın karayolu hareket modelinden gittikçe uzaklaştığı görülmektedir.

Uygulamada emniyet şeridinden hareket ederek karayolunda olağandışı davranış sergileyen aracın tespit edilmesine yönelik yapılan deneye ait görüntüler Şekil 5.8’de gösterilmiştir. Aracın kısmi hareket yörüngelerinin karayolu hareket modelleri ile arasındaki uzaklık bilgileri Çizelge 5.5’te, açı bilgileri ise Çizelge 5.6’de gösterilmiştir. Bu deneyde, aracın karayolu hareket modellerine benzer doğrultulardaki açılarda hareketi söz konusu iken, genel benzerlik değeri uzaklık benzerliğinin çok fazla olması nedeniyle belirlenen eşik seviyesinin üzerinde olduğu için aracın yapmış olduğu hareket olağandışı olarak belirlenmiş ve kendisine en yakın hareket modeli kırmızı renkte ile ifade edilmiştir.



(a)Çerçeve #35



(b)Çerçeve #40



(c)Çerçeve #45



(d)Çerçeve #50

Şekil 5.8 Emniyet şeridinden hareket eden aracın belirlenme durumu

Çizelge 5.5 Deney-3 için araç kısmi yörüngesi ve KHM'ler arası uzaklık bilgileri

	Çerçeve #150	Çerçeve #200	Çerçeve #245	Çerçeve #265
KHM-1	32.35	31.63	35,39	37,04
KHM-2	65.24	64,41	68,45	69,26
KHM-3	99,72	99,02	102,98	103,12


Çizelge 5.6 Deney-3 için araç kısmi yörüngesi ve KHM'ler arası açı bilgileri

	Çerçeve #150	Çerçeve #200	Çerçeve #245	Çerçeve #265
KHM-1	2.52	2.27	3.52	2.87
KHM-2	1.86	2.42	3.46	3.54
KHM-3	3.21	3.24	3.89	3.82

5.3.2 Ters Şeritte Hareket Eden Aracın Belirlenmesi

Karayollarında meydana gelen ve tespit edilmesi gereken bir diğer olağandışı davranış ise araçların ters şeritte hareket etmeleridir. Karşı yönden gelen araçlar da düşünüldüğünde kaza meydana gelme riskini arttıran bu araç davranışında, araç kendisinin sınıflandırılmış olduğu karayolu hareket modeline ters yönde hareket eder.

Karayolu hareket modellerine ters yönde hareket eden araçların belirlenmesi için yapılan deneye ait çerçeveler Şekil 5.9'da gösterilmiştir. Aracın kısmi hareket yörüngesinin karayolu hareket modelleri ile arasındaki uzaklık bilgileri Çizelge 5.7'de, açı bilgileri ise Çizelge 5.8'de verilmiştir.



(a)Çerçeve #1410

(b) Çerçeve #1440




(c)Çerçeve #1482



(d)Çerçeve #1488



(e)Çerçeve #1524



(f)Çerçeve #1596

Şekil 5.9 Ters şeritte hareket eden aracın belirlenmesi

Çizelge 5.7 Deney-4 için araç kısmi yörüngesi ve KHM'ler arası uzaklık bilgileri

	Çerçeve #1410	Çerçeve #1440	Çerçeve #1482	Çerçeve #1488	Çerçeve #1524	Çerçeve #1596
KHM-1	30,78	34,54	33,65	23,94	12,25	3,34
KHM-2	82,08	43,39	22,61	19,81	27,23	32,35

Çizelge 5.8 Deney-4 için araç kısmi yörüngesi ve KHM'ler arası açı bilgileri


	Çerçeve #1410	Çerçeve #1440	Çerçeve #1482	Çerçeve #1488	Çerçeve #1524	Çerçeve #1596
KHM-1	6,12	8,24	7,67	9,34	24,53	13,56
KHM-2	16,23	24,43	11,34	13,49	40,34	28,67

Çizelge 5.7 ve Çizelge 5.8'de görüldüğü gibi aracın kısmi hareket yörüngelerinin karayolu hareket modelleri ile olan uzaklıkları ve açısal benzerlikleri uygun olmasına rağmen, en yakın uzaklıktaki karayolu hareket modeli olan KHM-2 nin hareket yönü ile

ters yönde hareket yapmış olduğu için Şekil 5.8’de 1482 ve 1488. çerçevelerde görülen uyarılar çıkarılmıştır.

5.3.3 Komşuluğu olmayan KHM’ler arasında geçiş yapan aracın tespiti

Şekil 5.10’da U dönüşü yaparak ters yönde yol alan araca ait çerçeveler gösterilmiştir. (a)’da araç KHM’nin eşik uzunluk ve açısına uygun olarak hareket ettiğinden ilgili KHM sarı ile işaretlenmiştir. (b) ve (c)’de KHM’ne aracın kısmi yörüngesinin açısal olarak benzerliği azaldığı için aracın olağandışı hareketi tespit edilmiştir. (d)’de ise araç ters yönde harekete başladığı için olağandışı hareket uyarısı çıkarılmıştır.



Şekil 5.10 U dönüşü yaparak ters yönde hareket eden aracın tespiti

5.4 Bağıl Hıza Bağlı Olağandışı Araç Davranışlarının Belirlenmesi

Karayollarında olağandışı araç davranışı olarak ele alınabilecek diğer bir durum olan araçların beklenmedik şekilde ani yavaşlama hareketini bulmaya yönelik olarak yapılan deneye ait görüntüler Şekil 5.11’de gösterilmiştir. Kaza öncesi araçların ani fren

yapması sonucu hızlarında meydana gelen beklenmedik ani değişimleri gösteren bu deneyde araçların hız bilgileri piksel/saniye cinsinden Çizelge 5.9'da gösterilmiştir. Çizelgede de görüldüğü gibi kaza öncesi araçların hızları normal şekilde artarken kaza yapacaklarını anladıktan sonra iki araç şoförünün de frene basması ve kaza ile birlikte araçların durması sonucu araçların bağıl hızları ani olarak azalmıştır.



(a) Çerçeve #144



(b) Çerçeve #168



(a) Çerçeve #180



(b) Çerçeve #216

Şekil 5.11 Kaza sırasında araçların hızında meydana gelen ani değişimin tespiti

Çizelge 5.9 Kaza sırasında araçlara ait hız değişim bilgisi

	1. Saniye	2. Saniye	3. Saniye	4. Saniye	5. Saniye	6. Saniye	7. Saniye	8. Saniye	9. Saniye	10. Saniye	11. Saniye
Araç-1	0.72	0.95	1.22	1.66	2.42	3.66	2.54	1.65	1.54	1.42	0.22
Araç-2	0.51	0.58	0.93	0.95	1.46	1.92	2.63	3.08	3.75	0.58	0.14

5.5 Deney Sonuçlarının Değerlendirilmesi

TRIMARC video veri tabanında bulunan 75 adet videodan 30 tanesi bir veya birden fazla olağandışı hareket içermektedir. Ayrıca bilinçli olarak elle yanlış yönde çizilerek üretilen araç hareket yörüngelerinin kümelenmesi sonucu elde edilen karayolu hareket modelleri sayesinde test işlemi sırasında oluşan olağandışı hareket sayısı arttırılmıştır. TRIMARC veri tabanında bulunan videolar karayolu hareket modeli dışında hareket

eden araçların (şerit dışına çıkma durumu) tespiti, karayolu hareket modeline ters yönde hareket eden araçların (ters şeritte ilerleme durumu) tespiti ve bağlı hızlarında beklenmedik değişimler meydana gelen araçların tespiti için kullanılmıştır. Komşuluğu olmayan karayolu hareket modelleri arasında geçiş yapan araçların (yanlış yerde yapılan U-dönüşü durumu) tespiti için yapılan deneyde ise 2 tane yanlış U-dönüşü içeren 1 video kullanılmıştır. Çizelge 5.10'da yapılan deneylerde araçların yapmış oldukları olağandışı davranışlarının türüne göre başarı oranları gösterilmiştir.

Çizelge 5.10 Türe göre olağandışı davranış belirleme deney sonuçları

<u>Anomali Çesidi</u>	Doğru Pozitif	Yanlış Negatif	Yanlış Pozitif
Şerit Dışına Çıkma	24	5	4
Ters Şeritte Hareket	10	0	0
Yanlış Yerde Yapılan U-dönüşü	1	1	0
Bağlı Hızda Ani Değişim	12	4	3

Şerit dışında hareket etme durumunun tespit edilmesi için yapılan deneylerde, şerit dışında hareket eden 29 araçtan 24'ü için olağandışı davranış alarmı üretilmiştir. 5 araç için araç takibinin tamamlanamaması, araç takibi sırasında merkez noktanın KHM'ye yakınsayacak şekilde yer değiştirmesi ve aracın KHM'den uzaklaşmasına rağmen aracın kısmi hareket yörüngesinin KHM ile yaptığı açının çok düşük olması gibi nedenlerle olağandışı davranış alarmı üretilmemiştir. 4 araç için ise araç KHM'ye yakın olarak gitmesine rağmen kısmi hareket yörüngesi ile karayolu hareket modeli arasındaki açının fazla olması nedeniyle olağandışı olay olmadığı durumlarda olağandışı araç davranış alarmı üretilmiştir.

Araçların ters şeritte hareketinin tespiti için elle ters yönde üretilen KHM'ler kullanılarak yapılan deneylerde, ters yönde takip edilen 10 araç için başarıyla aracın ters şeritte hareket ettiğine dair olağandışı araç davranış alarmı üretilmiştir.

Yanlış yerde yapılan U-dönüşünün tespiti için yapılan deneylerde, 1 deneyde yanlış yerde U-dönüşü yapan araç tespit edilirken, diğer bir deney sırasında aracın takibi tamamlanamadığı için olağandışı davranış tespit edilememiştir.


Bağıl hızda meydana gelen ani değişimlere dayalı olağandışı davranışın tespiti için yapılan deneylerde ise, kaza öncesi ani yavaşlamanın bulunduğu 12 araç doğru olarak tespit edilmiştir. Gerçekte olağandışı hareket olarak yavaşlamanın bulunduğu 4 durum tespit edilememiş, 3 durum için ise herhangi bir olağandışı hareket olmamasına rağmen araçlardaki normal yavaşlama hareketi olağandışı durum olarak tespit edilmiştir.

Deneylerde elde edilen olağandışı araç davranış belirlene başarımları Çizelge 5.11’de gösterilmiştir.

Çizelge 5.11 Olağandışı davranış belirlene deney sonuçları

Tahmin Edilen	Doğru Referans	
	Olay	Olay Değil
Olay	47	7
Olay Değil	10	56
Doğruluk (Accuracy)	%85	
Hassasiyet (Precision)	%87	

Videolarda bulunan 39 olayın 32 tanesi doğru olarak tespit edilmiş, diğer 7 olay tespit edilememiştir. Araçların takip işleminde meydana gelen çeşitli problemler nedeniyle bazı durumlarda sınıflandırma ve buna bağlı olağandışı hareket belirlene işlemleri başarısız olmuştur. Şekil 5.12’de aracın takibi sırasında meydana gelen bir problemin olağandışı hareket belirlenmeye etkisi gösterilmiştir. Görüldüğü gibi önce belirli bir KHM’ne doğru yaklaşan aracın hareketi daha sonra U dönüşü olarak fark edilmektedir fakat araç takibindeki problem nedeniyle araç görüntüde kaybedilmektedir.



Şekil 5.12 Araç takip probleminin olağandışı hareketin belirlenmesine etkisi

Trafik yoğunluğunun yüksek ve/veya kamera görüş açısının düşük olduğu durumlar da araç belirleme ve takip işlemlerinde problemlere neden olduğu için olağandışı araç davranışlarının belirlenmesine olumsuz yönde etki etmektedir. Bu gibi durumlarda ortamda bulunan kamera sayısının arttırılması, kamera görüntü kalitesinin yükseltilmesi gibi çeşitli önlemler alınabilir.

SONUÇ VE ÖNERİLER

Trafik akışını bozan araç sürücüsü, yaya, yol yapısı gibi etmenler trafik polisi gibi olay yerinde bulunan gözlemcilere ihtiyaç duyulmadan uzaktan elde edilen trafik görüntüleri yardımıyla belirlenebilmektedir. Uzaktan elde edilen kamera görüntülerinin incelenerek yorumlanması işlemi için birçok sistemde yine insanların kamera görüntülerini sürekli olarak izlemesi ve yorumlaması gerekmektedir. Bu inceleme ve yorumlama işleminin otomatik olarak yapılmasını sağlayan sistemlerin geliştirmesi üzerinde çalışmalar devam etmektedir. Bu çalışmada, trafik videoları kullanılarak araçların normal trafik akışından farklı olarak yapmış oldukları olağandışı davranışların tespit edilmesini sağlamak üzere bir sistemin tasarımı ve gerçekleştirilmesi yapılmıştır.

Araçların olağandışı davranışlarının tespit edilebilmesi amacıyla öncelikli olarak karayolunda normal trafik akışı sırasında takip edilen araçların hareket yörüngeleri elde edilmiştir. Ardından hareket yörüngeleri Sürekli Saklı Markov Modeli kümeleme yöntemi ile kümelenmiş ve elde edilen her bir HMM araçların normal trafik akışına uygun davranış sergilediği karayolu hareket modeli olarak alınmıştır.

Çalışmanın ikinci kısmında ise görüntüye yeni giren araçların takibi sonucunda elde edilen kısmi hareket yörüngelerinin, elde edilen karayolu hareket modellerine mesafe ve açı olarak benzerlikleri ölçülerek, kısmi hareket yörüngeleri için sınıflandırma işlemi yapılmıştır. Araçların kısmi hareket yörüngelerinin sınıflandırıldığı karayolu hareket modeli ile olan benzerlik oranının belirli bir eşik seviyesinin altında olması, araçların kısmi yörüngelerinin doğrultusunun karayolu hareket modelleri doğrultusu ile ters

yönde olması ve araçların ilişkisi olmayan karayolu hareket modelleri arasında geçiş yapıyor olması durumları olağandışı durumlar olarak değerlendirilmiştir. Ayrıca araçların hızlarında beklenmedik şekilde meydana gelen ani değişimler de, araçların gerçekleştirmiş olduğu olağandışı davranış olarak belirlenmiştir.

Bu çalışmada önerilen sistem, trafik operatörleri tarafından izlenilen mevcut trafik kameraları altyapısını kullanılabileceği için kolaylıkla gerçekleştirilebilir. Normal trafik akışı sırasında elde edilen görüntüler kullanılarak karayolu hareket modelleri öğrenildikten sonra, araçların gerçekleştirmiş oldukları olağandışı davranışların tespiti ile trafik operatörlerinin ilgili kamera görüntüsüne odaklanması sağlanacaktır. Belirli bölgelerde sürekli olarak tespit edilebilecek olağandışı araç davranışları sayesinde o bölgelerdeki yol yapısının bozukluğunun sebep olduğu anlaşılabilir ve yetkililerce o bölgedeki yol yapısının değiştirilmesini sağlanabilecektir. Ayrıca olağandışı davranışların belirlenmesinin ardından, o anda karayolundaki diğer araçların durumları da dikkate alınarak hesaplanmak istenecek kaza tahmin işleminde de, olağandışı davranışlar kaza riskini arttırıcı birer etmen olarak ele alınabilecektir [5].

KAYNAKLAR

-
- [1] Karayolları Genel Müdürlüğü, 2010 Trafik Ulaşım Bilgileri, <http://www.kgm.gov.tr/SiteCollectionDocuments/KGMdocuments/Istatistikler/TrafikveUlasimBilgileri/10TrafikUlasimBilgileri%20.pdf>, 11 Ağustos 2012.
- [2] Emniyet Genel Müdürlüğü, 2010-2011 Yılları Türkiye Geneline Ait Trafik İstatistikleri, <http://www.egm.gov.tr/detay.aspx?id=46&tur=haberler>, 12 Ağustos 2012.
- [3] Karayolları Trafik ve Yol Güvenliği Araştırma Derneği, Karayolu İstatistikleri, <http://www.trafik.org.tr/karayolu-istatistikleri.html>, 12 Ağustos 2012.
- [4] Aköz, Ö., (2010). Kısmi Araç Yörüngeleri Kullanımı İle Kavşaklarda Trafik Olaylarının Görüntü Tabanlı Çözümlemesi, Doktora Tezi, YTÜ Fen Bilimleri Enstitüsü, İstanbul.
- [5] Er, U., (2012). Video Görüntülerinden Trafik Kazası Riskini Gerçek Zamanlı Belirleyen Bir Sistem Tasarımı, Yüksek Lisans Tezi, YTÜ Fen Bilimleri Enstitüsü, İstanbul.
- [6] Morris, B. T. ve Trivedi, M. M., (2008). "Learning, Modeling and Classification of Vehicle Track Patterns from Live Video," IEEE Trans. Intell. Transport. Syst., 9(3):425-437.
- [7] Buzan, D., Sclaroff S. ve Kollios G., (2004). "Extraction and Clustering of Motion Trajectories in Video", Proceedings of the 17th International Conference On Pattern Recognition, 2:521-524.
- [8] Heikkonen, J., Koikkalainen P. ve Schnor, (1994). "Learning Motion Trajectories via Self-Organization", Pattern Recognition, Computer Vision & Image Processing, 2:554-556.
- [9] Atev, S., Miller, G. ve Papanikolopoulos, N., (2010). "Clustering of Vehicle Trajectories", IEEE Trans. Intelligent Transportation Systems, 11(3):647-657.

- [10] Jouneau, E. ve Carincotte, C., (2011). "Particle-Based Tracking Model For Automatic Anomaly Detection", International Conference on Image Processing, 11-14 Eylül 2011, Brüksel.
- [11] Piciareli, C., Micheloni, C. ve Foresti, G. L., (2008). "Trajectory-Based Anomalous Event Detection", IEEE Transactions on Circuits and Systems for Video Technology, 18(11):1544-1554.
- [12] Hanapih, F., Al-Obaidi, A. A. ve Chan, C. S., (2010). "Anomaly Detection over Spatiotemporal Object Using Adaptive Piecewise Model", PRICAI, 421-432.
- [13] Sha, J., Zhao, Y., Xu, W., Zhao, H., Cui, J. ve Zha, H., (2011). "Trajectory Analysis of Moving Objects at Intersection Based on Laser-Data", IEEE Int. Conf. on Intelligent Transportation Systems (ITSC), 5-7 Ekim 2011, Washington.
- [14] Hu, W., Xiao, X., Fu, Z., Xie, D., Tan, T. ve Maybank S., (2006). "A system for learning statistical motion patterns", IEEE Transactions on Pattern Analysis and Machine Intelligence, 28(9):1450-1464.
- [15] Saunier, N., Sayed, T. ve Lim, C., (2007). "Probabilistic Collision Prediction for Vision-Based Automated Road Safety Analysis", IEEE Intelligent Transportation Systems Conference, 30 Eylül – 3 Ekim 2011, Pekin.
- [16] Piciarelli, C., Micheloni, C. ve Foresti, G., (2008). "Trajectory-Based Anomalous Event Detection", IEEE Transactions on Circuits and Systems for Video Technology, 18(11):1544-1554.
- [17] Desheng, W. ve Jia, W., (2009). "A New Method of Vehicle Activity Perception from Live Video", Computer Network and Multimedia Technology, 18-20 Ocak 2009, Vuhan.
- [18] Saligrama, V., Konrad, J. ve Jodoin, P., (2010). "Video anomaly identification, A statistical approach", IEEE Signal Processing Magazine, 27(5):18-33.
- [19] E. Swears, Hoogs, A. ve Perera, A.G.A., (2008). "Learning Motion Patterns in Surveillance Video using HMM Clustering", Proceedings of IEEE Visual Motion Computing (Motion) Workshop, 8-9 Ocak 2008, Kolorado.
- [20] NGSIM, Next Generation Simulation Community, <http://ops.fhwa.dot.gov/trafficanalysistools/ngsim.htm>, 10 Ağustos 2011.
- [21] TRIMARC, Traffic Response and Incident Management Assisting the River Cities, <http://www.trimarc.org>, 10 Ağustos 2011.
- [22] Beyaz Gazete, "Motorlu Kara Taşıtı Sayısı 16 Milyon 394 Bin 741'e Ulaştı", <http://www.beyazgazete.com/haber/2012/6/14/motorlu-kara-tasiti-sayisi-16-milyon-394-bin-741-e-ulasti-1253482.html>, 5 Ağustos 2012.

- [23] Haber 34, "Kadıköy Ve Çağlayan'da Yollar Kapanacak", <http://www.haber34.com/kadikoy-ve-caglayanda-yollar-kapanacak-17477-haberi.html>, 5 Ağustos 2012.
- [24] Bursa Büyükşehir Belediyesi Fotoğraf Arşivi, Demirtaş Kavşağı, <http://fotograf.bursa.com.tr/demirtas-kavsagi>, 5 Ağustos 2012.
- [25] M.B.B. Trafik Mühendisliği, Hemzemin Kavşak Maketi, <http://www.mbbtrafik.com/trafik-malzemeleri/trafik-egitim-maketleri/hemzemin-kavsak/resimler.html>, 5 Ağustos 2012.
- [26] Nixon, M.S. ve Aguado, A.S., (2002). Feature Extraction and Image Processing, 1. Baskı, Newnes, Londra.
- [27] Piccardi, M., (2004). "Background subtraction techniques: a review", 2004 Systems, Man and Cybernetics Conference, 10-13 Ekim 2004, Lahey.
- [28] Dillencourt, M. B., Samet, H. ve Tamminen, M., (2012). "A General Approach to Connected-Component Labelling for Arbitrary Image Representations", J. ACM 39(2): 253-280.
- [29] Freeman, H., (1974). "Computer processing of line-drawing images", ACM Computing Surveys, 6(1): 57-97.
- [30] Talu, M.F., (2010). "Nesne Takip Yöntemlerinin Sınıflandırılması", İstanbul Ticaret Üniversitesi, Fen Bilimleri Dergisi, 9(18):45-63.
- [31] Yılmaz, A., Javed O. ve Shah M., (2006). "Object tracking: A survey", ACM Comput. Surveys, 38(4).
- [32] Tomasi, C., ve Kanade, T., (1991). "Detection and Tracking of Point Features", Carnegie Mellon University Technical Report CMU-CS-91-132.
- [33] Sonka, M., (1997). Image Analysis and Understanding, <http://css.engineering.uiowa.edu/~dip/LECTURE/Motion2.html>, 19 Mart 2012.
- [34] Birchfield, S., "Derivation of Kanade-Lucas-Tomasi Tracking", 20 Ocak 1997.
- [35] Bouguet, J., (2002). "Pyramidal Implementation of the Lucas Kanade Feature Tracker, Description of the algorithm", Intel Corporation, Microprocessor Research Labs.
- [36] Wu, H.H. ve Shieh, J., (2006). "Using a Markov Chain Model in Quality Function Deployment to Analyse Customer Requirements", Int J. Adv. Manuf. Technology, 30: 141–146.

- [37] Ertuğrul, İ., Aytaç, E., (2007). "Kalite Fonksiyon Göçeriminde Markov Zincirleri: Otomotiv Sektörü", İşletme Fakültesi Dergisi, 8(2):181-200.
- [38] Öz, E., (2009). "İstanbul Menkul Kıymetler Borsası Üzerine Saklı Markov Modeli İle Bir Tahminleme", Ekonomik Yaklaşım, 20(72):59-85.
- [39] Warakagoda, N., (1996). Definition Of Hidden Markov Model, <http://jedlik.phy.bme.hu/gerjanos/HMM/node4.html>, 20 Mayıs 2012.
- [40] Semerci, Z., (2006). Saklı Markov Modellerinde Üç Temel Problemin İncelenmesi, Yüksek Lisans Tezi, Hacettepe Üniversitesi Fen Bilimleri Enstitüsü, Ankara.
- [41] Rabiner, L., (1989). "A Tutorial on Hidden Markov Models and Selected Applications in Speech Recognition", Proceedings of the IEEE, 77(2): 257-286.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Süleyman YÜKSEL
Doğum Tarihi ve Yeri : 11.09.1986 Zonguldak
Yabancı Dili : İngilizce
E-posta : suleymanyuksel@outlook.com

ÖĞRENİM DURUMU

Derece	Alan	Okul/Üniversite	Mezuniyet Yılı
Lisans	Bilgisayar Mühendisliği	Yıldız Teknik Üniversitesi	2009
Lise	-	Mehmet Çelikel Lisesi	2004

İŞ TECRÜBESİ

Yıl	Firma/Kurum	Görevi
2009 - 2012	NETAŞ	Yazılım Tasarım Mühendisi
2009	INTERTECH	Yazılım Mühendisi

YAYINLARI

Bildiri

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