

**YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**KİSMİ ARAÇ YÖRÜNGELERİ KULLANIMI İLE
KAVŞAKLARDAKİ TRAFİK OLAYLARININ
GÖRÜNTÜ TABANLI ÇÖZÜMLENMESİ**

Bilgisayar Yük. Müh. Ömer AKÖZ

**FBE Bilgisayar Mühendisliği Anabilim Dalı Bilgisayar Mühendisliği Programında
Hazırlanan**

DOKTORA TEZİ

Tez Savunma Tarihi : 29 Aralık 2010

Tez Danışmanı : Yrd. Doç. Dr. M. Elif KARSLIGİL (YTÜ)

Jüri Üyeleri : Prof. Dr. Aytül ERÇİL (Sabancı Üniversitesi)

: Prof. Dr. A. Coşkun SÖNMEZ (YTÜ)

: Doç. Dr. Yücel YEMEZ (Koç Üniversitesi)

: Yrd. Doç. Dr. Müjdat ÇETİN (Sabancı Üniversitesi)

İSTANBUL, 2011

İÇİNDEKİLER

	Sayfa
SİMGE LİSTESİ	v
KISALTMA LİSTESİ	vii
ŞEKİL LİSTESİ	viii
ÇİZELGE LİSTESİ	xii
ÖNSÖZ	xiii
ÖZET	xiv
ABSTRACT	xv
1. GİRİŞ	1
1.1 Tezin amacı.....	2
1.2 Tezin önemi	2
1.3 Tezin katkıları.....	2
1.4 Tezin çıktıları.....	3
1.5 Tezin yapısı.....	3
2. ÖNCEKİ ÇALIŞMALAR	4
2.1 Trafik akışı öğrenme ve modelleme	4
2.2 Trafik olay belirleme ve kaza analizleri	9
3. SİSTEM TASARIMI.....	15
3.1 Veri kümeleri	16
4. ARAÇ BÖLÜTLEME ve TAKİBİ.....	17
4.1 Trafik videolarının önışlemlerden geçirilmesi.....	17
4.2 Arkaplan ve önplan modelleme	18
4.2.1 Nesne renk yoğunluğu histogramları	18
4.2.2 Ardışık çerçeve farklılığı	19
4.2.3 Arkaplan çerçeve farklılığı	19
4.2.4 Değişen ortalama arkaplan modelleme.....	19
4.2.5 Adaptif arkaplan modelleme.....	20
4.3 Önplandaki araç bölgelerinin bölütlenmesi	24
4.4 Araç temsil noktalarının belirlenmesi.....	25
4.5 Nesne takibi	27
4.5.1 Özellik noktalarının takibi	29
4.5.2 Araç hareket karakteristiklerinin belirlenmesi.....	33
4.6 Bölüm özeti.....	34
5. OLAĞAN ARAÇ YOL MODELLERİNİN ÖĞRENİLMESİ.....	35
5.1 Yörünge tanımı	35
5.2 Yörünge kümeleme.....	39
5.2.1 Genel yörünge kümeleme teknikleri.....	40
5.2.2 HMM ve Gauss karışımı ile yörünge kümeleme	42
5.2.3 Yörünge veri kümesinin oluşturulması.....	43
5.2.4 Markov Modelleri	44

5.2.4.1	Ayrık Markov süreci.....	45
5.2.4.2	Saklı Markov Model	46
5.2.4.3	Saklı Markov Modelin üç temel problemi.....	47
5.2.4.4	Sürekli Saklı Markov Modeller	51
5.2.4.5	Sürekli Saklı Markov Model ile olağan yol modellerinin belirlenmesi	52
5.3	Bölüm özeti.....	55
6.	OLAĞANDIŞI ARAÇ HAREKETLERİNİN BELİRLENMESİ	56
6.1	Kısmi araç hareketi gözlemleme	56
6.2	Maksimum Log-olabilirlik	57
6.3	Araç hareket analizi	58
6.3.1	Çevrimdışı hareket analizi	58
6.3.2	Çevrimiçi hareket analizi.....	59
6.4	Kısmi araç hareketi sınıflandırma	60
6.4.1	Sınıflandırma eşik değerlerinin belirlenmesi.....	61
6.4.2	Kavşak üzerindeki hareket değişimi durumları	61
6.4.2.1	Olağan araç hareketleri	61
6.4.2.2	Olağandışı araç hareketleri	64
6.4.2.3	Çarpışma olmayan olağandışı hareketler.....	67
6.4.2.4	Çarpışma olan olağandışı hareketler	69
6.5	Bölüm özeti	72
7.	TRAFİK OLAY ve ŞİDDET ANALİZİ.....	73
7.1	Kısmi gözlem uzunluğunun olay analizine etkisi	73
7.2	Değişim Katsayısı yöntemi ile değişim analizi	74
7.3	Çok Fazlı Doğrusal Regresyon Fonksiyonları ile değişim analizi	75
7.4	Bölüm Özeti.....	78
8.	OLAĞANDIŞI TRAFİK OLAYLARININ ÖĞRENİLMESİ ve SINIFLANDIRILMASI	80
8.1	Şiddet sınıflandırma eğitim modelinin oluşturulması	81
8.2	Destek Vektör Makineleri ile öğrenme ve sınıflandırma	81
8.3	k-En Yakın Komşuluk ile sınıflandırma.....	84
8.4	k-Çapraz Doğrulama ile model seçimi	85
8.5	Bölüm özeti.....	86
9.	UYGULAMA ve DENEYSEL SONUÇLAR	87
9.1	Doğal ortam görüntüleri ile yörünge kümeleme.....	87
9.1.1	Eğitim kümesinin hazırlanması	87
9.1.2	Yol modellerinin belirlenmesi	89
9.1.3	Yörünge sınıflandırma	90
9.2	Deney görüntüleri ile olay belirleme ve şiddet analizi	92
9.2.1	Eğitim kümesinin hazırlanması	93
9.2.2	Yol modellerinin belirlenmesi	94
9.2.3	Olay belirleme	95
9.2.3.1	Tek aracın yarattığı olağandışı durum	96
9.2.3.2	Bir aracın saptığı, diğer aracın ani duruş yaptığı olağandışı durumlar	97
9.2.3.3	İki aracın da yörüngelerinden saptığı olağandışı durumlar	98
9.2.4	Şiddet analizi	99

9.3	Doğal ortam görüntüleri ile olay belirleme ve şiddet analizi	101
9.3.1	Eğitim kümesinin hazırlanması	101
9.3.2	Yol modellerinin belirlenmesi	102
9.3.3	Olay belirleme	103
9.3.4	Şiddet analizi	107
9.4	Bölüm özeti.....	111
10.	DEĞERLENDİRMELER.....	112
10.1	Önceki çalışmalar ve farklılıklar	112
10.2	Çıkarımlar.....	117
10.3	Gelecek Çalışmalar.....	119
11.	SONUÇ.....	120
KAYNAKLAR		121
ÖZGEÇMİŞ		126

SİMGE LİSTESİ

A	Saklı Markov Model saklı durumlar arası geçiş olasılıkları matrisi
a_1	Çok Fazlı Doğrusal Regresyon regresyon sabiti
a_2	Çok Fazlı Doğrusal Regresyon regresyon sabiti
B	Saklı Markov Model Gauss emisyon olasılıkları matrisi
$b_j(o_t)$	t anında S_j durumunun o_t gözlemini üretme olasılığını
b_1	Çok Fazlı Doğrusal Regresyon regresyon katsayısı
b_2	Çok Fazlı Doğrusal Regresyon regresyon katsayısı
b	Bias, Sistematik Hata
c	Çok Fazlı Doğrusal Regresyon kırılma noktası
d_E	Öklid mesafesi
d_H	Hausssdorf mesafesi
f	Araç yörünge gözlem vektörü
f_i	i. hız ve konum vektörü
g	Başlangıç Optik Akış tahmini
H	SVM ayırıcı hiperdüzlemi
H_1	SVM hiperdüzlemi
H_2	SVM hiperdüzlemi
L	Optik Akış Piramit seviyesi
M	Gauss karışımı sayısı
m	Olağan yol modeli sayısı
N	Saklı durum sayısı
O	Kümülatif gözlem dizisi
o	Kısmi gözlem dizisi
P	Kısmi gözlem sayısı
q_t	Markov modelin t anında S_i durumunda olma olasılığı
S_i	Saklı Markov durumu
T	Her araca ait gözlemlenen özellik vektörleri dizisi
t	Zaman
Th	Çerçeve farkı eşik değeri
u_x	Optik akış tahmininin yapıldığı noktanın x değeri
u_y	Optik akış tahmininin yapıldığı noktanın y değeri
V_x	x ekseninde araç hızı
V_y	y ekseninde araç hızı
ω	Ağırlık
w	Kısmi gözlem pencere uzunluğu
y_i	Özellik noktasının y eksenindeki konumu
x_i	Özellik noktasının x eksenindeki konumu
Z	SVM yüksek boyutlu uzay
α	Güncel arkaplanın geçmiş çerçeveleri ne kadar hızlı unutacağını belirleyen parametre
μ	Ortalama
σ	Standart sapma
λ	Saklı Markov Model olağan yol modeli
Γ	Her yol modeli için normal akış eşik değeri
θ	Aracın anormal sapma açısı
η	Gauss karışım elementi
π	Saklı Markov Model başlangıç durum geçiş olasılıkları
Σ	Gauss karışımı Kovaryans matrisi

ε	Optik Akış hata fonksiyonu
α_i	İleri-Yön değişkeni
β_i	Geri-Yön değişkeni
$\gamma t(i)$	O gözlem dizisi için, sistemin t anında S_i saklı durumda olma olasılığı
$\zeta t(i,j)$	Birleşik olasılık parametresi
τ	Bekleme süresi eşik değeri
Φ	SVM çevirme fonksiyonu

KISALTMA LİSTESİ

AIRS	Auto Incident Recording System (Araç Olay Kayıt Sistemi)
CV	Coefficients of Variances (Değişim Katsayısı)
DCT	Discrete Cosine Transform
DP	Doğru Pozitif
DPO	Doğru Pozitif Oranı
DTW	Dynamic Time Warping (Dinamik Zaman Bükmesi)
DVM	Destek Vektör Makinaları
ELA	Emergency Lane Assist (Acil Şerit Asistanı)
EM	Expectation Maximization (Beklenti Maksimizasyonu)
FFT	Fast Fourier Transform
FPR	False Positive Rate
GMM	Gaussian Mixture Model (Gauss Karışım Modeli, GKM)
HMM	Hidden Markov Model
KLT	Kanade-Lucas-Tomasi Feature Tracker
KNN	K-Nearest Neighborhoods (k- En Yakın Komşuluk)
KTC	Kentucky Transportation Center, (Kentucky Ulaşım Merkezi)
LCSS	Longest Common Subsequence (En Uzun Ortak Altküme)
NGSIM	Next Generation Simulation Traffic Analysis Tool (Yeni Nesil Simülasyon)
NN	Neural Network (Sinir Ağı)
OpenCV	Open Source Computer Vision (Açık Kaynak Bilgisayar Görmesi)
PCA	Principal Component Analysis (Temel Bileşenler Analizi)
PDF	Probability Density Function (Olasılık Yoğunluk Fonksiyonu)
SMM	Saklı Markov Model
SOM	Self Organizing Map (Kendini Örgütleyen Eşleme yöntemi)
SVM	Support Vector Machines (Destek Vektör Makineleri)
TRIMARC	Traffic Response and Incident Management Assisting the River Cities
TUIK	Türkiye İstatistik Kurumu
WHO	World Health Organization (Dünya Sağlık Örgütü)
YP	Yanlış Pozitif
YPO	Yanlış Pozitif Oranı
3D	Üç Boyut

ŞEKİL LİSTESİ

Sayfa

Şekil 2.1a	Kavşak üzerindeki araç yörüngeleri (Saunier ve Sayed, 2007)	10
Şekil 2.1b	Temsilci aktivite yörüngeleri (Saunier ve Sayed, 2007).....	10
Şekil 2.2a	Deney ortamı kavşak modeli (Hu, 2003)	11
Şekil 2.2b	Model üzerinde örnek kaza anı (Hu, 2003)	11
Şekil 2.3	Aktif çevrit yöntemi ile kaza belirleme	12
Şekil 3.1	Trafik olay analizi işlem adımları	15
Şekil 4.1	Gauss ve Ortanca yumuşatma işlemi sonucunda elde edilen görüntü örnekleri	17
Şekil 4.1a	Orjinal görüntü.....	17
Şekil 4.1b	Ortanca filtreme sonrası oluşan görüntü	17
Şekil 4.1c	Gauss yumuşatma sonrası oluşan görüntü	17
Şekil 4.2	Çerçeve farkı arkaplan çıkarımı ile önplan nesnelerinin bölütlenmesi.....	23
Şekil 4.2a	Orjinal Çerçeve	23
Şekil 4.2b	Filtreme kullanmadan $\alpha = 0.05$ ile elde edilen arkaplan çerçevesi	23
Şekil 4.2c	$\alpha = 0.05$ ile elde edilen önplan çerçevesi	23
Şekil 4.2d	$\alpha = 0.8$ ile elde edilen arkaplan çerçevesi	23
Şekil 4.2e	$\alpha = 0.8$ ile elde edilen önplan çerçevesi	23
Şekil 4.2f	Gauss filtreleme uygulanarak $\alpha = 0.05$ ile elde edilen arkaplan çerçevesi	23
Şekil 4.2g	Gauss filtreleme uygulanarak $\alpha = 0.05$ ile elde edilen önplan çerçevesi.....	23
Şekil 4.2h	Gauss filtreleme uygulanarak $\alpha = 0.8$ ile elde edilen arkaplan çerçevesi	23
Şekil 4.2i	Gauss filtreleme uygulanarak $\alpha = 0.8$ ile elde edilen önplan çerçevesi	23
Şekil 4.3	Adaptif Gauss arkaplan çıkarımı yöntemi ile önplan nesnelerinin bölütlenmesi	24
Şekil 4.3a	Orjinal çerçeve	24
Şekil 4.3b	Gauss filtreleme kullanılarak elde edilen arkaplan çerçevesi	24
Şekil 4.3c	Gauss filtreleme kullanılarak elde edilen önplan çerçevesi.....	24
Şekil 4.3d	Gauss filtreleme uygulanmadan elde edilen arkaplan çerçevesi.....	24
Şekil 4.3e	Gauss filtreleme uygulanmadan elde edilen önplan nesnesi.....	24
Şekil 4.4a	Orjinal görüntü.....	25
Şekil 4.4b	Bağlı bileşen analizi sonucu önplan nesneleri	25
Şekil 4.4c	Bağlı bileşen analizi sonucu önplan nesnelerini çevreleyen çevritler.....	25
Şekil 4.5	Deney ve doğal sahneler üzerinde takip edilen araçların dış çevritlerinin belirlenmesi.....	25
Şekil 4.6	Farklı anlık trafik görüntüleri (Institut für Algorithmen und Kognitive Systeme).....	26
Şekil 4.7	Çevritleri belirlenmiş araç nesnesinin merkez noktasının belirlenmesi (Bradski ve Kaehler, 2008)	26
Şekil 4.8	Kavşak modeli üzerinde bulunan araçların merkez noktası özellikleri	27
Şekil 4.8a	Orjinal Çerçeve	27
Şekil 4.8b	Önplandaki bağlı bileşenler	27
Şekil 4.8c	Araçları çevreleyen dikdörtgenler ve merkez noktaları	27
Şekil 4.9	Piramitsel Optik Akış ile hareket vektörlerinin belirlenmesi (Bradski ve Kaehler, 2008).....	31
Şekil 4.10	Video görüntüsünün piramitsel olarak gösterilmesi, $I^0(a) \rightarrow I^1(b) \rightarrow I^2(c)$...	32
Şekil 4.11	Özellik noktaları kullanarak araç özelliklerinin takip edilmesi ve elde edilen hareket vektörleri	33
Şekil 4.12	Piramitsel Optik Akış ile hareket karakteristiklerinin çıkarımı	34
Şekil 5.1	Araç ve üzerindeki merkez noktası	36

Şekil 5.2	Görüntü üzerindeki araç merkez noktasının x-y koordinatlarındaki lokasyon değişimi grafiği.....	36
Şekil 5.3	Birim zamanda araçtaki hız değişimi.....	37
Şekil 5.4	Otoyol üzerinde araç ve araca ait merkez noktası	37
Şekil 5.5	Araçın merkez noktasının x-y koordinatlarındaki yer değişimi	38
Şekil 5.6	Otoyol üzerindeki araca ait hız değişimi - zaman grafiği	38
Şekil 5.7	Otoyol üzerinde iki araç ve farklı yönlerdeki hareketleri	38
Şekil 5.8	İki araç, farklı yönlerdeki hareketi ve koordinat düzleminde konum noktaları	39
Şekil 5.9	İki araç ve hız vektörleri grafiği.....	39
Şekil 5.10	Olağan yol modellerinin öğrenilmesi adımları	43
Şekil 5.11a	Kavşak akış modeli eğitim yörüngeleri	44
Şekil 5.11b	Eğitim yörüngelerinin kavşak modeli üzerindeki görüntüsü	44
Şekil 5.12	Birinci derece Markov model örneği, B başlangıç, Ç çıkış durumu.....	45
Şekil 5.13	3 durumdan oluşan Markov modeli örneği	46
Şekil 5.14	Saklı Markov Model Örneği	47
Şekil 5.15	HMM ve Gauss Karışımı yapısının örnek kavşak modeli üzerinde gösterimi	53
Şekil 5.16a	Öğrenme işleminde elde edilen olağan yol modellerinin kavşak üzerinde yansıtılması.	54
Şekil 5.16b	Kavşak giriş (G) – çıkış (Ç) noktaları.....	54
Şekil 6.1	Bağımsız ardışık kısmi hareket gözlem yöntemi	56
Şekil 6.2	Anlık araç hareketlerinin bağımsız kısmi gözlemler ile gösterilmesi.....	57
Şekil 6.3	Araç hareket davranışı tahmin etme (Morris ve Trivedi, 2008)	59
Şekil 6.4a	Olağan davranan bir aracın izlediği yörünge ve yol modelleri	62
Şekil 6.4b	Araç hareketine ait maksimum log-olabilirlik değişimleri.	62
Şekil 6.5	Olağan davranan aracın zaman içerisinde üzerinde bulunduğu yol modelleri	62
Şekil 6.6a	Araçın otoyol üzerinde olağan şerit değiştirmesi.....	63
Şekil 6.6b	Araç hareketine ait maksimum log-olabilirlik değişimleri	63
Şekil 6.7	Şekil 6.6(a)'da hareketi görülen aracın zaman içerisinde üzerinde bulunduğu yol modelleri	64
Şekil 6.8	Çok şeritli ve çok yönlü kavşak üzerinde çarpışma anı	64
Şekil 6.9	Çarpışma anında özellik vektörlerinin koordinat düzlemi üzerindeki değişimleri.....	65
Şekil 6.10	Çarpışma anında özellik vektörlerinin açı değişim grafiği	65
Şekil 6.11	Çok yönlü ve çok şeritli kavşak üzerinde kaza anı	65
Şekil 6.12	Çok yönlü ve çok şeritli kavşak üzerinde kaza anı ve sonrası araç davranışları.....	66
Şekil 6.13	Kaza anında araç hızları değişimi	66
Şekil 6.14	Ani duruş gözlemi için ardışık çerçeve örnekleri	68
Şekil 6.15	Uzun süre duraklayan araç için t ve $t+50$. andaki çerçeveler	68
Şekil 6.16	Bilinçli kural dışı dönüş örneği için ardışık çerçeve görüntüleri	69
Şekil 6.17	İki aracın çarpışması, siyah renkli aracın yolundan sapması, gri renkli aracın çarpma sonrasında sapma yaşamadan ani duruş yapması.....	69
Şekil 6.18	Kaza anı belirleme sahnesi, iki aracın çarpışması	70
Şekil 6.19	Şekil 6.18'de kazaya karışan V_1 ve V_2 aracına ait maksimum log-olabilirlik ve araçların üzerinde bulundukları anlık yol model değişimleri	70
Şekil 7.1	Farklı uzunluktaki kısmi gözlemler ile oluşturulan örnek kaza senaryosu için log-olabilirlik – zaman grafiği	73
Şekil 7.2	Her kısmi gözleme ait log-olabilirlik – zaman grafiği	75

Şekil 7.3	Çok fazlı doğrusal regresyon analizi ile bir aracın hareket değişiminin gözlemlenmesi.	76
Şekil 7.4	Kavşak üzerinde meydana gelen başka bir olağandışı sapma örneği.	77
Şekil 7.5	Farklı bir sapma örneğinde çok fazlı doğrusal regresyon analizi ile sapma yaşayan aracın hareket değişiminin gözlemlenmesi.	78
Şekil 8.1	Olağandışı olayların şiddet sınıflandırması işlemi.....	80
Şekil 8.2	İki boyutlu uzayda iki sınıflı SVM sınıflandırma.....	82
Şekil 8.3	Doğrusal olarak ayıramayan örneklerin yüksek boyutlu uzaya taşınması ve sınıflandırılması.....	83
Şekil 8.4	k=3 için k-En Yakın Komşuluk ile sınıflandırma.....	85
Şekil 9.1a	101 nolu otoban, gözlemlenen yol bölgeleri.....	88
Şekil 9.1b	101 nolu otoban şematik akışı.....	88
Şekil 9.1c	101 nolu otoban kavşak kuş bakışı görüntüsü	88
Şekil 9.2a	Kavşak başlangıç ve bitiş noktaları.....	88
Şekil 9.2b	Eğitim kümesini oluşturan yörüngeler.....	88
Şekil 9.3	Öğrenme işlemi sonucunda elde edilen olağan yol modelleri	89
Şekil 9.4	Yörünge sınıflandırma, kesinlik – iterasyon eğrisi	90
Şekil 9.5	Kavşak üzerinde normal davranan araç yörüngeleri ve kaza yapan diğer iki aracın yörüngeleri	91
Şekil 9.6a	Öğrenilen HMM orta noktaları, eğitim örnekleri ve kaza yapan araç örnek yörüngeleri	91
Şekil 9.6b	Kavşak giriş ve çıkış bölgeleri.....	91
Şekil 9.7	Deney ortamı kavşak modeli	93
Şekil 9.8a	Eğitim kümesini oluşturan olağan davranan araç yörüngeleri.....	93
Şekil 9.8b	Kavşak giriş çıkış noktaları.....	93
Şekil 9.9	Deney ortamında elde edilen olağan araç yol modelleri ve Gauss karışımı orta noktaları	94
Şekil 9.10	Deney kavşak modeli üzerinde olağandışı araç hareketleri.....	95
Şekil 9.10a	Tek bir aracın şeridinden sapması.....	95
Şekil 9.10b	Bir aracın şeridinden sapması, diğer aracın ani duruşu	95
Şekil 9.10c	İki aracın çarpışması	95
Şekil 9.11a	Tek aracın beklenen şeridinden sapması durumu için ardışık çerçeve görüntüleri.....	96
Şekil 9.11b	Takip sonucunda elde edilen araç yörüngesi	96
Şekil 9.12	Tek aracın şerit sapması durumu için olağandışılığın belirlenemediği örnekler	96
Şekil 9.13	Başarılı ve hatalı olay belirleme örnekleri	97
Şekil 9.13a	Çarpışma sonrası beyaz aracın sapması ve mavi aracın aniden durması.....	97
Şekil 9.13b	Çarpışma sonrası beyaz aracın durması, mavi aracın şeridinden sapması.....	97
Şekil 9.13c	Mavi aracın ani durması ve beyaz aracın şeridinden hafifçe sapması	97
Şekil 9.13d	Merkez noktasının takip sırasında araçla ilişkisinin kaybolması.....	97
Şekil 9.14a	Başarılı olay belirleme, (a) çarpışma sonrası beyaz ve mavi aracın şeritlerinden sapması.....	99
Şekil 9.14b	Başarılı olay belirleme, (b) çarpışma sonrası beyaz ve mavi aracın şeritlerinden sapması.....	99
Şekil 9.14c	Hatalı değerlendirmeler, (c) beyaz ve mavi aracın çarpışması ve şeritlerinden hafifçe sapmaları.....	99
Şekil 9.14d	Hatalı değerlendirmeler, (d) beyaz ve mavi aracın çarpışması ve şeritlerinden hafifçe sapmaları.....	99
Şekil 9.15a	Eğitim örneklerinin x-y düzleminde gösterilmesi.....	100

Şekil 9.15b	Gauss çekirdek fonksiyonu ile Destek Vektörleri sonucu elde edilen hiperdüzlemler	100
Şekil 9.16	Brook ve Jefferson caddesi (Louisville, 2001)	102
Şekil 9.17	Günümüzde Brook ve Jefferson caddeleri kesişimi görüntüsü.....	102
Şekil 9.18a	Kavşak üzerinde elde edilen tüm yörünge eğitim örnekleri	103
Şekil 9.18b	Öğrenim işlemi sonucunda elde edilen yol modelleri.....	103
Şekil 9.19	İki aracın karışmış olduğu çarpışma olayı örnekleri.....	103
Şekil 9.20	Araç çakışması sonucu oluşan takip hatası örneği, (a), (b) ve (c) araçların belirli zamanlardaki konumları, (d) araçların oluşturdukları yörüngeler.....	104
Şekil 9.21	Takip hatası sonucu olağandışı olarak belirlenen normal olaylar.....	105
Şekil 9.22	Olağandışı durumların olduğu fakat belirlenemediği olay örnekleri	106
Şekil 9.23	Bilinçli ve kural dışı dönüş örneği	107
Şekil 9.24	Olağandışı sahne üzerinde olağan davranan araç ve sahnenin sağ üst köşesinde kural dışı dönmeye çalışan araç.	107
Şekil 9.25	Doğal ortam görüntülerinde sınıflandırma işleminde kullanılan eğitim örnekleri	108
Şekil 9.26	Destek Vektör Makineleri ile sınıflandırma sonuçları.....	109
Şekil 9.27	Sınıflandırma sonucunda elde edilen yanlış pozitif örnekler.....	109
Şekil 9.27a	Sapma gerçekleşmeyen fakat ani duruşun olduğu olay	109
Şekil 9.27b	Hafif sapmanın ve çarpışmanın gerçekleştiği olay	109
Şekil 9.28	Şekil 9.27(a)'da yanlış sınıflandırılan kırmızı araca ait anlık çerçeveler ve hareketi boyunca oluşturduğu yörüngesi	110
Şekil 9.29	Şekil 9.27(b)'de yanlış sınıflandırılan gri renkli araca ait anlık çerçeveler ve hareketi boyunca oluşturduğu yörüngesi	110
Şekil 9.30	Sınıflandırma sonucunda elde edilen yanlış negatif örnekler	110
Şekil 9.30a	Sapma gerçekleşmeyen fakat ani duruşun olduğu olay	110
Şekil 9.30b	Hafif sapmanın ve çarpışmanın gerçekleştiği olay	110
Şekil 9.31	Şekil 9.30(a)'da yanlış sınıflandırılan gri araca ait anlık çerçeveler ve hareketi boyunca oluşturduğu yörüngeleri.....	111
Şekil 9.32	Şekil 9.30(b)'de yanlış sınıflandırılan sol üst köşeden gelen mavi renkli araca ait anlık çerçeveler ve hareketi boyunca oluşturdukları yörüngeleri.....	111

ÇİZELGE LİSTESİ

Sayfa

Çizelge 3.1	Tezde kullanılan veri kümeleri ve açıklamaları	16
Çizelge 9.1	Kaza yapan araç yörüngelerinin model üzerinde test edilmesi ve elde edilen log-olabilirlik değerleri	92
Çizelge 9.2	Olağan hareket eden araçlara ait test yörüngelerinin sınıflandırma sonuçları	92
Çizelge 9.3	λ_1 olağan yol modeli parametreleri, π başlangıç, A durum geçiş matrisi, B çıkış olasılıkları matrisi	94
Çizelge 9.4	Test senaryoları ile bir aracın saptığı, diğer aracın ani duruş yaptığı olağandışı durumları bulma başarısı	97
Çizelge 9.5	Test senaryoları ile iki aracın saptığı olağandışı durumları bulma başarısı	98
Çizelge 9.6	Test senaryoları ile olağandışı olayları bulma başarısı	99
Çizelge 9.7	Deney görüntüleri ile SVM ve k-NN sınıflandırma ile elde edilen sonuçlar	101
Çizelge 9.8	Gerçek trafik olay görüntüleri ile elde edilen olay belirleme sonuçları	104
Çizelge 9.9	Olay belirleme sonuçlarının test ve eğitim kümelerine dağılım miktarları	105
Çizelge 9.10	Test kümesinin olay tiplerine göre dağılımı	105
Çizelge 9.11	SVM ve k-NN ile elde edilen sınıflandırma sonuçları	108
Çizelge 10.1	Önceki çalışmalar ve önerilen çalışma ile farklılıkları	116

ÖNSÖZ

Günümüzde, trafik kazalarında hayatlarını kaybeden veya sakat kalan insanların sayısı gün geçtikçe artmaktadır. Yapılan istatistiksel çalışmalarda, kararlı adımlar ve projeler üretilmediği sürece bu oranların artmasından korkulmaktadır. Bu çalışmada, doğal ortam görüntüleri kullanılarak trafik kaza olaylarının analizleri yapılmış, kaza sebeplerinin araştırılması ve olayları en aza indirebilecek bir model geliştirilmesi hedeflenmiştir.

Bu tez çalışmasının yürütülmesinde konu seçiminden itibaren bana her konuda yol gösteren, lisans eğitimimden itibaren bana emeği geçen ve değerli bilgilerini ve tecrübelerini benimle paylaşan, bana farklı bakış açıları sunan ve her zaman beni sabırla dinleme zahmetini gösteren tez danışmanım Sayın Yrd. Doç. Dr. M. Elif Karslıgil'e sonsuz teşekkürlerimi sunarım.

Tez çalışmamın geliştirilmesine değerli fikirleri ve yorumlarıyla büyük katkılarda bulunan, tez izleme komitesi üyeleri Sayın Doç. Dr. Yücel Yemez ve Sayın Yrd. Doç. Dr. Müjdat Çetin'e teşekkürlerimi sunarım.

Tez çalışmasında kullandığım trafik video görüntülerini benimle paylaşan ve yardımlarını esirgemeyen TRIMARC Sistem Yöneticilerinden Bay Todd Hood'a, Cambridge Systematics'ten Bay Vassili Alexiadis ve Bayan Lin Zhang'a şükranlarımı borç bilirim.

Doktora eğitimim sürecindeki yardımları için Yıldız Teknik Üniversitesi, Bilgisayar Mühendisliği Bölümü ve Fen Bilimleri Enstitüsü çalışanlarına teşekkür ederim.

Tezi hazırlama sürecinde hiçbir zaman desteklerini esirgemeyen sevgili arkadaşım Samet Aksoy'a ve sevgili kardeşim Ebru Yıldırım'ya, sonuçlar ile ilgili uzman yorumları için Salih Dönmez'e teşekkür ederim.

Tezimin her aşamasındaki yardım ve desteğinden dolayı sevgili eşim Aslı Yıldırım Aköz'e ve gönülleri daima benimle olan, beni hayatım boyunca her şartta destekleyen sevgili aileme şükranlarımı sunarım. Sizler olmasaydınız bunu başaramazdım.

ÖZET

KISMİ ARAÇ YÖRÜNGELERİ KULLANIMI İLE KAVŞAKLARDAKİ TRAFİK OLAYLARININ GÖRÜNTÜ TABANLI ÇÖZÜMLENMESİ

Araç sürücüleri, trafikte bulundukları süre boyunca daha önceden belirlenmiş trafik kurallarına uygun hareket etmek zorundadırlar. Trafik kuralları ile sürücü davranışları kontrol altında tutulmaya çalışılsa da, kural dışı davranan sürücüler, yol güvenliğine aykırı davranan yayalar veya araçlardaki donanımsal arızalar kazalara sebep olabilmektedir.

Trafik takip ve gözlem araştırmalarının ana hedefi, izlenen sahne üzerindeki trafik hareketlerinin kurallara uygunluğunu değerlendirmektir. Günümüzde, trafik akışının kameralarla izlenmesi çok yaygın olmakla birlikte, olağandışı olayları gerçek zamanlı algılayan bilgisayar sistemlerinin kullanımı henüz çok yetersizdir. Kamera tarafından izlenen sahne üzerinde normal olmayan bir durum ile karşılaşıldığında olağandışı durumun belirlenmesi, gerekiyorsa acil müdahale edilmesinin sağlanması ve ileriye yönelik tedbirler alınması trafik kazalarının yol açtığı yaralanma ve ölümlerin azalması için önemli bir fayda sağlayacaktır.

Bu tez çalışmasında, doğal ortam trafik videosu görüntülerinde kavşaklardaki olağandışı trafik olaylarını yakalayan ve bu olayları şiddet karakteristiklerini değerlendirerek sınıflandıran özgün bir sistem tasarlanmış ve gerçekleştirilmiştir.

Olağandışı trafik olaylarını algılayabilmek için, önce araçların olağan durumlardaki hareket karakteristiklerinin öğrenilmesi gerekir. Bunun için, video görüntülerindeki olağan araç hareketlerine ait yörüngeler Sürekli Saklı Markov Model kümeleme yöntemi ile kümelenecek olağan yol modelleri öğrenilmiştir. Olağan yol modelleri, kavşak üzerinde gözlemlenen araç hareketlerinin göstermiş olduğu en tipik trafik akışını temsil etmektedir.

İkinci aşamada, kısmi araç yörüngeleri ve hareket karakteristikleri Maksimum Olabilirlik yöntemi ile gözlemlenerek olağandışı araç hareketleri yakalanmaya çalışılmıştır. Olağandışı davranan araçların öğrenilen yol modellerine olasılıksal olarak uzaklığı, araçların yapmış olduğu anormalliğin seviyesini ortaya çıkartır. Araçların gösterdiği anormallik, olağandışı sapma olarak nitelendirilir. Bu çalışmada, aracın normal hareket akışından sapma şiddeti Değişim Katsayısı ve Çok Fazlı Doğrusal Regresyon Fonksiyonları yöntemleri ile ölçülmüştür. Üçüncü aşamada, olağandışı davrandığı belirlenen araçların sapma şiddetlerinin tanımlanması ve sınıflandırılması işlemleri gerçekleştirilir. Bunun için, önce, kaza yapmış araçlara ait görüntülerden bir eğitim kümesi oluşturulmuştur. Kaza görüntülerinden elde edilen özellik vektörleri şiddetlerine göre düşük ve yüksek şiddetli olmak üzere 2 sınıfa yerleştirilerek sınıflandırma sisteminin eğitilmesi sağlanmıştır. Sınıflandırma için k-en yakın komşuluk ve Destek Vektör Makineleri yöntemleri kullanılmıştır. Sahne üzerinde izlenen araçların olağandışı davrandığı belirlendiğinde, sınıflandırma işleminden geçirilerek olayın şiddet derecesi belirlenmiştir.

Geliştirilen sistemin başarısını değerlendirmek için, deneysel ve doğal ortamdan elde edilen görüntüler ile yapılan olağandışı olay belirleme değerlendirmeleri sonucunda %83 ve %89 doğru belirleme başarısı elde edilmiştir. Olağandışı olayların şiddetlerine göre sınıflandırılması testleri ile deney görüntülerinde %83, doğal ortam görüntülerinde %75 doğru sınıflandırma başarısı elde edilmiştir. Elde edilen sonuçlar, olağandışı araç hareketlerinin olasılıksal olarak belirlenebileceğini ve olağandışı olayların bu olasılıklara bağlı olarak şiddet analizlerinin başarıyla yapılabileceğini göstermektedir.

Anahtar Kelimeler: Kaza Şiddet Analizi, Sapma Analizi, Kaza Sınıflandırma, Yörünge Kümeleme, Saklı Markov Modelleri, Araç Takibi.

ABSTRACT

VIDEO-BASED TRAFFIC EVENTS ANALYSIS AT INTERSECTIONS USING PARTIAL VEHICLE TRAJECTORIES

Vehicle drivers must follow the predefined traffic rules in the traffic scene. Traffic rules are defined to control driving behaviors of the drivers. However, drivers, pedestrians or mechanic failures of vehicles may cause dangerous situations in the traffic.

The main objective of the traffic monitoring and surveillance systems is basically to evaluate the behaviors of the drivers on the traffic movements. Today, it is very common to monitor the traffic flow by surveillance cameras, however, the use of computer systems that detect unusual events in real time is very insufficient. During surveillance period, when an abnormality event is encountered in the scene, it will be vital to determine the abnormality as it will provide a significant benefit to reduce traffic accidents and deaths caused by injury.

In this thesis, a novel real-time approach is designed to detect abnormality and evaluate the severity characteristics of real-world traffic events by classifying into two severity classes.

In order to detect abnormal traffic events, first, normal vehicle flow patterns in the traffic scene are learned to differentiate with usual and unusual motions. In order to that, the vehicle trajectories are used to extract common route models by clustering trajectories with Continuous Hidden Markov Model. The route models represent the common motion behaviors of vehicles which move most likely on these routes.

In the second part of the thesis, partial vehicle motion is observed by Maximum Likelihood method and compared with the learned route models in order to detect unusual vehicle motions. The magnitude of probabilistic distance of abnormal vehicle behavior to the route models indicates the severity of the abnormality. The abnormality of vehicle behaviors are named as vehicle deviation. In this work, the deviation magnitude is measured using Coefficient of Variances and Multiphase Linear Regression Functions techniques.

In the third part, the severity definition and classification is done for abnormal vehicle motions. In order to do that, accident training set is formed by extracting severity feature vectors from accident videos. Using these features, accident events are labeled as low and high severe events. In the classification part, k-Nearest Neighborhood and Support Vector Machines techniques are used. In the testing part, when abnormality is detected for new motion observation, it is evaluated and the severity class of the event is determined.

In order to evaluate the proposed system, the experimental and real traffic videos are used. The abnormality detection results indicate that the proposed system reaches up to 85% correct detection rate. The correct classification rate of severity of abnormal experimental events is 83 % and with the real world events, the success rate goes up to 75%. The results indicate that abnormal events can be detected and represented by likelihood probabilities, and depending on these probabilities, severity analysis of the events can be done successfully.

Keywords: Accident Severity Analysis, Dispersion Analysis, Accident Classification, Trajectory Clustering, Hidden Markov Models, Vehicle Tracking.

1. GİRİŞ

Araç trafiğini oluşturan sürücü ve yolcu emniyeti, kişilere ve kurumlara ait can ve mal güvenliği dünya üzerindeki en önemli meselelerden birisidir. Dünya Sağlık Örgütünün yapmış olduğu araştırmaya göre [1], her yıl 1 milyondan fazla insan trafik kazalarında hayatını kaybetmektedir. Kararlı önlemler alınmadığı takdirde önümüzdeki 20 yıl içerisinde bu sayının %65 artacağı öngörülmektedir. İsveç'te yapılan başka bir araştırmaya göre (Cano vd., 2009), yol kesişimlerinde ve kavşaklarında oluşan kazalar, bütün şiddetli kazaların %30'unu ve tüm ölümcül kazaların %20'sini oluşturmaktadır.

Avrupa'da şiddetli ve ölümcül kaza oranları %30-60 ve %16-36 olarak değişirken, Amerika'da yollardaki ölümlerin %21'i (Cano vd., 2009) kavşaklarda oluşan kazalardan dolayı meydana gelmektedir. Amerika'da yapılan başka bir araştırmada (Green ve Agent, 2001), Kentucky eyaletinde meydana gelen trafik kazalarının %35'inin kavşaklarda olduğu belirlenmiştir. Ülkemizde bu oranlar net olarak verilememekle birlikte, son 10 yılda oluşan kaza rakamlarına bakıldığında %100'e yakın bir artış gözlemlenmiş, trafik kazalarının, en çok caddelerde ve devlet kara yollarında olduğu belirlenmiştir [2]. Yol ve kavşak yapılarının düzensizliği, oluşan kazalarda sürücü hataları ve araç bozuklukları kadar önemli rol oynamaktadır.

Trafik görüntüleri kullanılarak trafikteki araçların belirlenmesi, takip edilmesi ve denetlenmesi konularında literatürde kapsamlı çalışmalar bulunmaktadır. Bu çalışmaların çoğundaki temel hedef, araç bulunması ve takip işlemlerinin iyileştirilmesi, çevre ve ışık faktörlerinin yaratmış olduğu zorlukların çözümü üzerinedir. Fakat, trafik görüntüleri kullanılarak trafik kazalarının belirlenmesi, kaza tahmininin yapılması, olay tiplerinin ve kaza şiddetlerinin incelenmesi üzerine kısıtlı sayıda çalışma mevcuttur.

Bu tez çalışmasında, doğal ortamda alınan trafik video görüntülerinde trafik akışına uymayan olayları tespit eden ve olay bir kaza ise şiddetini belirleyen bir sistem tasarlanmış ve gerçekleştirilmiştir. Çalışma sonucunda elde edilen çıktılar ve çalışmanın gerçek hayatta uygulanması ile mevcut yol ve kavşak durumlarının iyileştirilmesi sayesinde ölüm ve yaralanmalarla sonuçlanan kazalarda azalma olması beklenmektedir.

1.1 Tezin amacı

Bu çalışmanın temel amacı, görüntü işleme ve örüntü tanıma yöntemleri ile video görüntülerinde trafik kazalarının algılanması ve kazanın şiddetinin belirlenmesi için yeni bir teknik önermektir. Tez çalışması, trafik görüntüleri içeren sayısal video görüntülerinde olağandışı olayların tanımlanması ve olayların şiddet karakteristiklerine göre kategorize edilmesi işlemlerini içermektedir.

1.2 Tezin önemi

Çoklu ortam teknolojilerinde yapılan en son çalışmalar, yüksek seviyeli görsel kavramları kullanarak insan algısına dayalı bilgi analizi, sorgulama ve arşivleme modellerini geliştirmeyi hedeflemektedir. Video görüntülerinde yer alan nesnelere ait düşük seviye özellik çıkarımları (kenar, renk, doku, şekil gibi) kullanarak sahne içerisinde nesnelerin yarattığı olaylar hakkında bilgi sahibi olunabilir. Örneğin, kırmızı renkli bir aracın kavşak üzerinden olağandışı şekilde hızla geçmesi örneği düşünüldüğünde, nesneye ait düşük seviye özelliği olan konum ve hız özelliklerini kullanarak hareketin olağandışılığı hakkında bilgi edinilebilir. Aracın hareketi hakkındaki bu tür bilgiler nesnelere ait yüksek seviye özellik olarak isimlendirilirler ve bu tür bilgiler insan algısına en yakın bilgilerdir.

Yüksek seviyeli ile düşük seviyeli görsel özellikleri eşleştirme yöntemlerinde henüz tamamlanmamış bilimsel açıklar mevcuttur ve son yıllarda düşük seviye nesne özellikleri kullanılarak insan algısına dayalı görsel bilgi çıkarımı çalışmaları hız kazanmıştır. Bu açıklar, semantik bilgi çıkarımı ile beraber olağandışı olay analizleri (trafik kazası, kalabalık arasından hızla koşan bir kişi, beklenmeyen bir paketin bulunması gibi) , görüntü arşivleme, bilgi dizinleme ve insan algısına yakın sorgulama mimarilerinde insan algısına yönelik eksiklikler olarak sıralanabilir. Bunların yanısıra, internet teknolojilerinde insan algısına dayalı bilgiye ulaşımında yüksek talepler, bu tezin gerçekleştirilmesinde ayrıca motivasyon kaynağı olmuştur.

1.3 Tezin katkısı

Bu tezde önerilen yaklaşım ile trafik görüntülerinde olağandışı davranan araç hareketlerinin belirlenerek olağandışılık şiddet büyüklüğünün istatistiksel yöntemler ile olasılıksal olarak gözlemlenebileceği ve trafik olaylarının bu gözlemlere dayanarak sınıflandırılabilceği kanıtlanmıştır.

1.4 Tezin çıktıları

Bu tezde önerilen çalışma, trafik video görüntülerindeki olağandışı olayları yakalayıp bu olayların şiddet, şekil gibi karakteristiklerinin belirlenmesi sayesinde, acil durumlarda trafik operatörlerine yardımcı olmada ve sonrasında yapılacak ilk yardım müdahalelerini hızlandırmada etkili rol oynayacaktır. Tez çalışması kullanılarak elde edilecek çıktılar üzerinde kaza analizlerinin yapılması, mevcut yol durumlarının iyileştirilmesinde ve ölümcül kazaların azaltılmasında faydalı olacaktır. Çalışma, trafik olay tiplerine göre genelleştirilerek, yaralanma, ölümcül kaza, maddi hasar gibi kaza sonuçlarının analiz edilmesi için veri madenciliği uygulamalarında kullanılabilir durumdadır.

1.5 Tezin yapısı

Tez kitabının 2. bölümü, literatürde yer alan tez konusu ile yakından ilgili önceki çalışmaların ve kullanılan yöntemlerin özetini içermektedir. Bölüm 3, bu tezde takip edilen sistem mimarisini; Bölüm 4, araç belirleme ve takip işlemlerini; Bölüm 5, olağan araç hareketleri kullanılarak yol modellerinin öğrenilmesi işlemlerini; Bölüm 6, olağandışı araç hareketlerinin belirlenmesini; Bölüm 7, trafik olay ve şiddet analizi adımlarını; Bölüm 8, olağandışı trafik olaylarının şiddetlerine göre sınıflandırılması işlemlerini; Bölüm 9, tez süresince elde edilen uygulama sonuçlarını ve elde edilen deney çıktılarını içermektedir. Önerilen yaklaşımın diğer çalışmalardan farkları, çıkarımlar ve gelecek çalışmalar Bölüm 10'da değerlendirilmiştir. Bölüm 11'de Sonuçlar belirtilmiştir. Son bölümde, Kaynaklar ve Özgeçmiş bulunmaktadır.

2. ÖNCEKİ ÇALIŞMALAR

Bu bölümde, literatürde yer alan tez çalışması ile yakından ilgili mevcut ve yönlendirici çalışmalar kullanılan yöntemlerle beraber özetlenmiştir. İncelenen çalışmalar kolay takip edilebilirliği açısından iki alt bölümde özetlenmiştir. Bu bölümler, kavşaklarda ve yollardaki trafik akışının modellenmesi ve trafik olay ve kaza analizleri çalışmalarıdır.

2.1 Trafik akışı öğrenme ve modelleme

Bu bölümde, trafik akışı ve araç hareketleri modelleme çalışmaları özetlenmiştir. Benzer hareket özellikleri gösteren araçların oluşturdukları yörüngelerin gruplandırılması, trafik akışının modellenmesi için ilk yapılması gereken işlemdir. Morris ve Trivedi (2008) tarafından yapılan çalışmada video takip uygulamaları için bu zamana kadar geliştirilen yörünge öğrenme ve kümeleme yöntemleri özetlenmiştir. Özetlenen bütün çalışmaların ortak özelliği nesnelerin şekil, renk, boy gibi ayırt edici özelliklerinin, pozisyon ve hız bilgilerinin akış örüntülerini öğrenmek için kullanılmış olmasıdır. Yörüngelerin benzerliklerinin karşılaştırılmasındaki problemlerden en belirgin farklı sürelerdeki yörüngelerin karşılaştırılmaya çalışılmasıdır. Örneğin, her araç farklı sürelerde görüntü üzerindeki ilgi alanında bulunabileceği için, trafik akışı zamana göre değiştiğinden ötürü yörünge süreleri farklılık gösterebilir. Bu nedenle, öğrenme işleminden önce normalizasyon veya süre küçültme gibi ön işlemler yapılması gereklidir. Normalizasyon, bütün yörüngelerin aynı uzunlukta ve sürede olmalarını sağlar. En basit üç tekniği, en uzun süreli yörünge baz alınarak diğerlerinin sonuna sıfır ekleme, tahmini yörünge uzatma ve tekrar örneklemedir (Morris ve Trivedi, 2008). Tahmini yörünge uzatmada, en son gözlemlenen vektör değerlerine bakılarak en uzun yörüngeye ulaşana kadar tahmini değerler eklenir. Tekrar örneklemede, doğrusal enterpolasyon ile bütün yörüngeler eşit süreli getirilir. Ancak, araç davranışları gözönüne alındığında bu iki işlemin çok uygun olmadığı görülmektedir. Dinamik trafik ortamlarında nesnelerin olası hareketleri daha önceki davranışlarına bakılarak tahmin edilebilir fakat yörüngelerinin sürelerinin uzatılması araçların davranışlarının yanlış yorumlanmasına sebep olacaktır. Bu nedenlerle, araç yörüngeleri için normalizasyon yöntemi uygun değildir.

Elde edilen nesne yörüngelerinin daha küçük ve kolay incelenebilir olması için boyut küçültme yöntemleri uygulanabilir. Bu yöntemlerden en basiti vektör nicemeleme yöntemidir. Yörüngeler sonlu alfabe kümesi ile temsil edilir. Yöntem, kayıplı boyut küçültme yaptığı için hareket halindeki nesnelerin hareketset karakteristیکlerinin kaybolmasına neden olmaktadır.

Polinom uyarlama yöntemi ile yörüngeler kendilerini en iyi temsil eden eğriler ile gösterilebilirler. Elde edilen eğriler ile yörüngelerin süreleri eşitlenerek kümeleme işlemine hazırlanırlar.

Dalgacık tekniği de yörüngelerin sürelerini küçültmede kullanılmaktadır. Bu teknik, yörüngeleri farklı seviyelerdeki ayrışmalarla temsil etmektedir. Bu yöntemle, yörüngeler yumuşatılarak şekli ve özellikler arasındaki ilişkileri korunmaktadır. Yumuşatma işleminin şiddeti uygun dalgacık seviyesinin seçilmesiyle ayarlanır. Literatürde, Haar ve Ayrık Fourier Dönüşümü en bilinen yöntemlerdir.

Başka bir süre küçültme yöntemi elde edilen yörüngelerin Saklı Markov Model (HMM) (Rabiner, 1989) işlemi ile istatistiksel olarak modellenmesidir. HMM, rastgele değişkenli farklı sürelerdeki zaman serileri için kümeleme işleminde başarılı bir yöntemdir. Bu özelliğiyle trafik uygulamaları için uygundur. Sahne üzerindeki araçların hareketleri boyunca sahip oldukları özellikler olasılık kuramında rastgele değişkenlere örnek olarak verilebilir. Bu özelliklere bağlı olarak araç hareketleri rastgele bir işlemdir denilebilir. Bir aracın anlık hareketinin Markov işlemine karşılık gelmesi, ardışık araç hareketlerinin Markov serisi olarak ifade edilebilmesini sağlar. Gauss Karışım Modeli (GKM, Gaussian Mixture Model) kullanılarak yörünge örnekleri arasında zamansal ilişki korunabilmektedir. Bu tezde HMM ve birden fazla Gauss karışımları kullanılarak araç yörüngeleri kümelemesi gerçekleştirilmiştir. HMM ve Gauss karışımları ile kümeleme işleminin adımları bir sonraki bölümde detaylı olarak anlatılmıştır. Diğer boyut azaltma yöntemlerine örnek olarak Temel Bileşen Analizi (Principal Component Analysis), Dalga Bandı (Spectral) ve Kernel yoğunluk metodları verilebilir.

Gerçek zamanlı yörünge öğrenilmesi çalışmasına Piciarelli ve Foresti'nin çalışması (2006) örnek olarak verilebilir. Çalışmanın amacı çevrimdışı önışlemlerden kaçınıp, tüm eğitim işlemlerinin gerçek zamanlı olarak yapılmasıdır. Yörüngeler, veriler gözlemlendikçe anlık olarak kümelenip farklı ağaç yapılarıyla temsil edilmekte, oluşturulan ağaçlar üzerinde araçların davranış analizleri yapılmakta ve olağandışı olayların tanımlanması sağlanmaktadır. Ancak, olağandışı davranışların belirlenmesi ileriki çalışmalar olarak nitelendirilmiştir.

Yörünge analizi ve olağandışı olayların belirlenmesi ile ilgili diğer bir çalışma da Piciarelli, Micheloni ve Foresti (2008)'in çalışmasıdır. Çalışmadaki yaklaşım iki sınıflı Destek Vektör Makineleri (Support Vector Machines - SVM) yöntemi ile kümelemeye dayanır. Kümeleme işlemine başlamadan önce elde edilen tüm yörüngeler normalizasyon yöntemiyle eşit süreli

hale getirilmiştir. Çalışmada pozisyon ve yön bilgileri kullanılmış, özellikler arasındaki zaman ilişkisi dahil edilmemiştir.

Fu, Hu ve Tan (2005) , yapmış oldukları çalışmada, olağandışı olayların belirlenebilmesi için benzerlik tabanlı izgesel (spectral) araç yörünge kümeleme yöntemini önermişlerdir. İki katmanlı hiyerarşik kümeleme yöntemi ile eşit boydaki araç yörüngelerini en iyi temsil eden örüntüler elde edilmiştir. Yörüngelerin birbirleriyle ikili ve konumsal özellikleri arasındaki mesafeleri baz alınarak benzerlik matrisi oluşturulmuş ve bu matrisin temsil ettiği en uygun yörünge bölmesini bularak kümeleme gerçekleştirilmiştir. Kümeleme işleminin ilk katmanında baskın yörüngelere sahip yollar kabataslak çıkarılmıştır. İkinci aşamada bu yollar üzerlerindeki şeritler ve bu şeritleri temsil eden örüntüler elde edilmiştir. Anormal durumların belirlenmesi için test yörüngesi ile elde edilen yörüngeler arasında Bayes karar teorisi kullanılarak test örneğinin hangi örüntüye yakın olduğu bulunmuştur. Anormal durumlar segment tabanlı olarak belirlenmeye çalışılmıştır. Test yörüngesi bütünüyle anormal olarak değil, sadece anormal olan yörünge segmenti işaretlenmiştir. Elde edilen sonuçlar bulanık k-ortalama kümeleme algoritması ile karşılaştırılmış ve önerilen kümeleme yönteminin bulanık k-ortalamaya oranla çok daha başarılı olduğu anlatılmıştır.

Aktivite yörünge modelleme çalışmalarından biri de Johnson ve Hogg (1996)'un yapmış olduğu olay tanımlamalar için nesne yörüngelerinin dağılımının öğrenilmesi çalışmasıdır. Çalışma, yayaların hareketlerinden elde edilen yörüngeler ile gerçekleştirilmiştir. Yörünge örüntüleri çift katmanlı Kendini Örgütleyen Eşleme yöntemi (Self Organizing Map - SOM Kohonen, 1997) yöntemi ile öğrenilmiştir. Eğitim öncesinde yörüngeler doğrusal olarak tekrar örneklenmiştir. Anormal yörüngelerin bulunması ve anlam çıkarımı ileriki çalışmaların konusu olarak ifade edilmiştir.

Öğretmensiz sinir ağları yöntemlerinden birisi olan SOM, Heikkonen ve Schnorr (1994) tarafından benzer yörüngelerin gruplandırılması için kullanılmıştır. Çalışmada, önplan nesnelerinin şekil ve hız özelliklerinin SOM ile öğrenilmesi sağlanmış, ağırlık vektörleri güncellenerek yörünge kümeleri belirlenmiştir.

Benzer çalışmalardan birisi de Wang ve Grimson'un (2006) yörünge analizi çalışmasıdır. Doğal ortam trafik sahnesi üzerinde olası bütün yörüngeler incelenerek yaya yolu, bisiklet veya araç yolu gibi semantik alanlar çıkartılır. Bu alanlar arka plan görüntüsünden ayırt edilerek ilgi alanları belirlenir. İlgi alanları üzerinde yörünge eşleştirme ve benzerlik hesaplama ile olağandışı olaylar bulunmaya çalışılır.

Atev ve Papanikolopoulos (2006), dalga bandı kümeleme işlemi ile trafik kavşağı üzerindeki yörünge kümelerini bulmaya çalışmışlardır. Önplan nesnelerin ayırt edilmesi için Gauss karışım modeli, araç takibi için Kalman filtresi kullanılmıştır.

Buzan, Sclaroff ve Kollios (2004), hiyerarşik kümeleme işlemi kullanarak yörünge analizi çalışması yapmışlardır. Çalışmada, hareket eden nesnelerin yörüngeleri üç boyutlu düzlemde genişletilmiş Kalman süzgeci (Welch ve Bishop, 2006) ile elde edilmiştir. En uzun ortak küme (LCSS) ile benzer hareket örüntü grupları belirlenmiş, hiyerarşik kümeleme ile hareket örüntüleri elde edilmiştir.

Trafik görüntülerinde gözlemlenecek ilgi alanları üzerindeki araç hareketlerinin modellere oturtulması, sahne üzerinde gerçekleşebilecek olayların ortaya çıkartılabilmesi için yardımcı olacaktır. Örneğin, üç şeritli bir otobanda, her şeride ait trafik akışının belirlenmesi, olağandışı şerit değişimlerinin yakalanmasında kullanılabilir. Başka bir örnek olarak kavşaklar üzerindeki olağan trafik akışı belirlendiğinde, kural dışı U dönüşleri yakalanabilir.

Gözlemlenen trafik hareketleri istatistiksel açıdan incelendiğinde, araç hareketlerinin zaman içerisinde yapmış oldukları hareketler rastgele işlem olarak tanımlanabilir ve stokastik model ile tarif edilebilirler (Saunier ve Sayed, 2006). İstatistiksel veri kümeleme işlemi için en güçlü modellerden biri HMM'dir. Bu modeldeki temel amaç, olasılık modelinin gözlemlenen veriler üzerinden tahmin edilmesi, gözlemlenen veriler üzerinde elde edilen küme bölümleri ile kavşak modelini oluşturan daha düşük boyutlu eğitim kümesini maksimum benzerlik ile temsil eden örüntülerin elde edilmesidir.

Bu modele dayalı Alon vd. (2003)'nin yapmış olduğu çalışmada, gözlemlenen yörüngeler Beklenti Maksimizasyonu (Expectation-Maximization, EM) tabanlı Gauss karışımı ile kümelendirilmiştir. Çalışmada ayrıca k-ortalama kümeleme algoritması ile karşılaştırma sonuçları verilmiş, bu sonuçlara göre, EM ve k-ortalama yöntemlerinin benzer başarı gösterdiği gözlemlenmiştir.

Saunier ve Sayed (2006), HMM ile araç yörüngelerini kümeleyerek otomatik trafik güvenlik analizi çalışması gerçekleştirmişlerdir. Çalışmada, k-ortalama ve HMM beraber kullanılmış, küme sayıları otomatik olarak bulunmuştur. K adet HMM karışımı ile araç yörüngeleri modellenmiştir. Yörünge kümeleri bulunduktan sonra verilen test örnekleriyle model üzerinde çakışma olasılıkları hesaplanmış ve trafik kazası olayı tahmin edilmeye çalışılmıştır.

Kato vd. (2002), çevreyolları üzerinde trafik durumlarını gözlemlemek ve gölge problemini çözmeye çalışan güçlü bir bölütleme yöntemi bulmak için HMM kullanmışlardır. Bu modelde, takip işlemi sırasında bilinmeyen HMM parametreleri EM algoritması yardımıyla öğrenilirken, segmentasyon aşamasında pikseller önplan, arkaplan ve gölge olarak sınıflandırılmışlardır.

Zou, Shi ve Wang (2009), HMM kullanarak ardışık görüntü tabanlı trafik olaylarını belirlemeye çalışmışlardır. Saklı Markov Modeli, trafik akışlarının sınıflandırılması için eğitim modeli olarak seçilmiştir. Batı-Doğu, Doğu-Batı, Güney-Kuzey, Kuzey-Güney normal trafik akışı olarak sınıflandırılırken, bu akışların dışında kalan olaylar kaza ya da olağandışı trafik olayları olarak nitelendirilmişlerdir.

Morris ve Trivedi (2008) dinamik ortamlardaki yörüngelerin öğrenilmesi ve sınıflandırma modelini oluşturan, model ile sahne üzerindeki nesnelerin hareket davranışlarını analiz eden bir çalışma gerçekleştirmişlerdir. Modelin ana unsuru, hareket eden nesnelerin takip işlemi ile elde edilmiş yörüngeleridir. Yörüngeler öğrenme işleminden önce normalizasyon ile eşit süreli hale getirilmişlerdir. Model, topografik harita olarak gösterilmiş, düğümler ilgi alanları olarak (nesnelerin sahneye giriş ve çıkış noktaları), düğümler arasındaki kenarlar da aktivite yolu olarak ifade edilmişlerdir. Üzerinde çalışılan kavşak için ilgi alan noktaları arasındaki kenar bilgileri öğrenilerek topografik sahne haritası tamamlanmıştır. İlgi alan noktaları GKM ile öğrenilmiş, yörüngeler bulanık k-ortalama ile kümelere ayrılmış veya başka bir deyişle kavşak modeli üzerindeki yollar ya da örüntüleri oluşturmuşlardır. Aynı çalışmada, bulanık k-ortalama algoritmasının düzlemsel bilgilerle araç davranış analizi için yeterli olmayacağı düşünülerek nesnelerin zaman ekseninde davranışlarını karakterize etmek için Gauss karışımı HMM'den yararlanıldığı anlatılmıştır. Her aktivite yolu ayrı Markov Modeline oturtulmuştur.

Bashir vd. (2005), HMM kullanarak nesne yörüngelerinin öğrenilmesi ve sınıflandırılması çalışmasını gerçekleştirmişlerdir. Model, kısa parçalara ayrıştırılan yörüngelerin PCA ile temsil edilmesine dayanır. Kısa parçalara ayrılan yörüngeler HMM için saklı durum olarak ifade edilir. Durum sayıları k-ortalama algoritması ile öğrenilir. Her sınıf için farklı Markov Modeli öğrenildikten sonra anormal test örnekleri sınıflandırılır. Kısa parçalara ayrılan test yörüngesinin PCA katsayı vektörleri her HMM'in gözlem sekanslarını oluşturur. Yörünge hangi modele en yakın benzerliği gösteriyorsa o modelin işaret ettiği sınıfa atanır.

2.2 Trafik olay belirleme ve kaza analizleri

Olağandışı trafik olaylarının belirlenmesi ve olay karakteristiklerinin çıkartılması bu tezin en önemli hedefidir. Bu bölümde, trafik video görüntüleri kullanılarak trafik kazalarının bulunması veya kaza tahmin edilmesi ile ilgili yapılan çalışmalar özetlenmiştir.

Yakın zamanda yapılan çalışmalardan Saligrama, Konrad ve Jodoin (2010)'in çalışmasında, nesne bölütleme ve hareketlerini takip etmeden, görüntü üzerindeki piksellerin istatistiksel olarak modellenmesine dayalı olağandışı olay belirleme önerilmiştir. Her piksel iki durumlu Markov zinciri modeline oturtulup, zaman içerisinde durağan veya meşgul sistem durumları ve durumlar arası zaman aralıkları gözlemlenerek olağan durumların öğrenilmesi ve bu durumlar dışında kalan piksel hareketlerinin olağandışı olarak belirlenmesi sağlanmıştır.

Saunier, Sayed ve Lim (2007)'in çalışmasında, doğal ortamdaki trafik video görüntüleri üzerinde araçlar arasındaki etkileşim olasılıkları hesaplanarak trafik kaza tahmini çalışması yapılmıştır. Sahne üzerindeki araçlar arka plandan ayrılarak takip edilmesi sağlanmış, gözlemlenen yörüngelerin olağan araç hareketleri ile öğrenilen kavşak modeli ile eşleştirilmesi yapılarak yörünge farklılıkları çıkarılmıştır. Araçların kısmi yörüngeleri kullanılarak t zaman sonra bulunabileceği noktalar tahmin edilerek farklı pozisyonlar için potansiyel çarpışma noktaları olasılıkları ile beraber ifade edilmiştir. Çalışma iki ana bölümden oluşmaktadır. Birinci bölümde (Beymer vd., 1997)'de önerilen özellik tabanlı araç takibi yöntemi ile araçların yörüngeleri elde edilmiştir. İkinci bölümde, elde edilen yörüngeler LCSS tekniği ile gruplandırılmış ve araçların aktivite örüntüleri elde edilmiştir. Aktivite örüntüleri kullanılarak araçların çarpışma olasılıkları hesaplanmıştır.

Saunier ve Sayed, (2006)'da önerilen özellik tabanlı takip yöntemini kavşaklardaki araçlar için genişleterek (Saunier ve Sayed, 2007)'de sunmuşlardır. Şekil 2.1'de çalışmada elde edilen yörünge analizi çıktıları görülmektedir. Çalışmada araçların ayırt edici noktalarının takibi, takip sonucunda elde edilen yörüngeleri ve bu yörüngelerin gruplandırılması gerçekleştirilmiştir.

Veeraraghavan, Masoud ve Papanikolopoulos (2003), video görüntülerinden kavşak görüntüleme, araç takibi, kaza belirleme veya tahmini uygulaması geliştirmişlerdir. Araç ve yayaların takibi için blob takibi ve Kalman süzgeci yöntemleri (Welch ve Bishop, 2006) kullanılmıştır. Blob takibi ile hareket eden bölgeler arkaplandan ayrılmış, daha sonra her hareketli bölge araç olarak kabul edilip Kalman süzgeci ile takibi yapılmıştır. Hareket bölütleme Adaptif Gauss Karışımı modeli yöntemi (Stauffer ve Grimson, 1999) ile

sağlanmıştır. Bu yöntemle, çerçeve üzerindeki pikseller yoğunluklarına göre birden fazla gauss dağılımı ile ilişkilendirilmişlerdir. Yeni gözlemlenen pikseller, yoğunluklarına ve eşleşen karışımlarına göre arkaplan veya önplan olarak etiketlenmiştir. Bu algoritma, özellikle karmaşık arkaplana sahip doğal ortamda alınmış trafik görüntülerinde başarılı olmaktadır. Çalışmanın ana hedefi, sahne üzerindeki nesnelerin birbirleri ve arkaplan ile aralarındaki çakışmanın bulunması ve giderilmesidir. Çalışmada gerçekleştirilen olay tanımlama modülü araçlar arasındaki muhtemel çarpışmaları yakalayacak şekilde tasarlanmıştır. Özellik vektörleri olarak araçların düzlem üzerindeki koordinatları, hızları ve şekilleri kullanılmıştır. İki aracın birbiriyle çarpışması, nesnelerin orta noktalarının ve çevreleyen kenarlarının birbirleriyle çarpışmaları ile temsil edilmiştir.




(a)

(b)

Şekil 2.1 (a) Kavşak üzerindeki araçların yörüngeleri ve (b) temsilci aktivite yörüngeleri (Saunier ve Sayed, 2007)

Hu vd. (2003), üç boyutlu araç takibi ile trafik kaza tahmini çalışması yapmışlardır. Bu çalışmada araçların üç boyutlu görüntüleri ile çakışma en aza indirilerek takip başarısı artırılmış, SOM kullanarak aktivite örüntüleri öğretilmiştir. Sahne üzerindeki her aracın hareket yörüngesi üç boyut (3D) model tabanlı araç takibi ile bulunmuştur. Üç boyut işlemleri hesaplama olarak maliyetli olmasına rağmen, nesneler arasındaki çakışmalar azaltılarak takip başarısı arttırılmaya çalışılmıştır. Yörüngeler bütün olarak sinir ağına (NN, Neural Network) giriş olarak verilmiştir. Giriş katmanındaki nöronlar tüm yörüngeleri temsil ederken, çıkış katmanındaki nöronlar aktivite örüntü sınıflarını temsil ederler ve aktivite kümeleri bulunmuş olur. Sahne üzerinde araçlar hareket ettikçe gözlemlenen kısmi yörüngeleri ile öğrenilmiş örüntüler arasında eşleştirme dereceleri yörünge noktaları arasındaki mesafeler baz alınarak araç çarpışma olasılığı hesaplanmaya çalışılmıştır. Çalışma sonuçları deney ortamında değerlendirilmiştir. Çalışmada kullanılan model ve örnek kaza anı görüntüsü Şekil 2.2’de gösterilmiştir.



Şekil 2.2 (a) Deney ortamı kavşak modeli ve (b) bu model üzerinde örnek kaza anı (Hu, 2003)

Hu vd. (2003) yapmış olduğu başka bir çalışmada araç takibi ve yörünge analizi yapılarak trafik kazalarının önceden tahmin edilmesi amaçlanmıştır. Araçların ayırt edici özellikleri belirlendikten sonra yapay sinir ağları kullanılarak olağan trafik örüntüleri öğrenilir. Trafik kaza tahmini için kaza olayına ait araçların yörüngeleri daha önceden öğrenilen yörünge kümeleri ile eşleştirilir ve benzerlikleri hesaplanır. Daha önce tanımlı herhangi bir kümeye ait olmayan yörünge, olağandışı bir durum olarak değerlendirilir ve kaza çarpışma olasılığı hesaplanır. Çalışmalar deney ortamında yapılmıştır.


Kavşaklarda olay belirleme ve analizi çalışmalarından biri de Kentucky Ulaşım Merkezi (Kentucky Transportation Center - KTC) tarafından (Green ve Agent, 2001) yapılmıştır. Önerilen ses tanıma modeli ile kavşak üzerinde oluşan olağandışı sesler belirlenerek trafik olayları kayıt edilmiştir. Çalışmanın amacı, kavşak üzerinde oluşan trafik olaylarını yakalamak ve daha sonrasında analiz işlemleri için kayıt etmektedir. Çalışmada, kavşak üzerinde meydana gelen ani ve olağandışı olaylar, araçların sebep oldukları sesler kullanılarak yakalanmıştır. Olağandışı seslere, korna, çarpışma esnasında çıkan metal sesleri, ani fren sesi, ani ve sert dönüşlerde patinaj sesleri, kavşağa yaklaşan ambulans ya da polis arabasının siren sesi gibi sesler örnek olarak verilebilir. Kazalar elle analiz edildikten sonra kavşakta yapılan düzeltmeler ile kazalarda %14 oranında azalma gözlemlenmiştir. 2001 yılında kurulan bu düzenek ile (AIRS – Auto Incident Recording System) ile elde edilen kaza ve olağandışı trafik görüntüleri, bu tezde önerilen yaklaşıma en yakın uyabilen veri kümesini içermektedir. Bu olağandışı trafik görüntü kümesi önerilen tezde kullanılmak üzere TRIMARC [3] organizasyonu tarafından sağlanmıştır.

Swears vd. (2008) otoban ve kavşak görüntülerinde hareket örüntülerinin öğrenilmesi ve olağandışı araç hareketlerinin yakalanması çalışmasını gerçekleştirmişlerdir. Çalışmalarında yörüngelerin gruplandırılması için hiyerarşik toplamalı Saklı Markov modeli kullanılmıştır. Önerilen çalışmada, gerçek görüntülerle çalışmalar yapılmış fakat başarı değerleri

belirtilmemiştir. Çalışmada, araçların üzerinde bulundukları şeritlerden hız ve pozisyon olarak olağandışı sapmaların yakalanabilmesi için kısmi araç yörüngelerinden yararlanılmıştır. Kısmi gözlemler kayan pencere tekniği ile oluşturulmuş, Saklı Modellerle İleri-Yön Algoritması (Rabiner 1989) kullanılarak test edilmiştir. Test işlemi sonucunda modellerin eşik seviyelerinden farklılıklarına göre sapma anları belirlenmiştir. Çalışmada, olağandışılık şiddet analizi ile ilgili bir öneri getirilmemiştir.

Tai vd. (2003), yaptıkları çalışmada, gerçek zamanlı otomatik trafik gözlem, araç takip ve kaza belirleme uygulamalarını geliştirmişlerdir. Araç takip yöntemi olarak Kalman süzgeci destekli aktif çevrit modeli (Kass vd., 1988) kullanılmıştır. Aktif çevrit modelinde başlangıç parametrelerinin belirlenebilmesi için kenar büyütme algoritması önerilmiştir. Kaza belirleme çalışmalarında laboratuvar simülasyon ortamında çalışılmış, önden ve yandan çarpma senaryoları üzerinde başarı sağlanmıştır. Çarpışma belirlemede aktif çevritlerin üstüste gelmesi kaza belirtisi olarak alınmıştır. Çalışmada, yoğun trafik ortamında çakışmaların sonuçları olumsuz etkilediği gözlemlenmiştir.

Aktif çevrit belirleme, önplandaki nesne dış kenarlarının belirlenmesi ve bu kenarları kullanarak takibin yapılmasını amaçlar. Ana fikir, nesnenin büyüklüğü ve konumuna göre sürekli güncellenerek nesnenin etrafında kapalı bir dış çevrit oluşturmak ve bu dış çevriti oluşturan noktalar üzerinden hedef takibi yapmaktır (Şekil 2.3).



Şekil 2.3 Aktif çevrit yöntemi ile kaza belirleme (Tai vd., 2003)

Kamijo vd. (2000), kavşaklar üzerindeki trafik takibi ve kazaların belirlenmesi araştırmasını yapmışlardır. Çalışmanın ana hedefi kavşak üzerinde nesneler arasındaki çakışmayı ve karmaşıklığı en aza indiren başarılı bir takip işlemi gerçekleştirmektir. Araç görüntülerinin birbirleriyle olan çakışmaları ve üst üste binmeleriyle ilgili HMM kullanılarak olay tanımlama yöntemi önerilmiştir. Önerilen sistem, her aracın davranış örüntülerini Saklı Markov zinciri olarak öğrenip, takip işlemi sonucunda elde edilen verileri kullanarak anlık olay zincirlerini tanımlamayı hedefler. Kavşak üzerindeki her araç çiftinin hareket vektörleri ve vektörler

arasındaki mesafe kullanılarak giriş gözlem serileri oluşturulmuştur. Çalışma, başarılı şekilde iki aracın zincirleme çarpışmasını, araç sıkışıklıklarını ve çarpışma olmadan riskli geçişleri sınıflandırabilmektedir. Çalışma süresince gerçek trafik görüntülerinden yararlanılmış ve trafik kazaları yakalanmaya çalışılmıştır. Fakat bir yıllık gözlem sonucunda üç adet kaza görüntüsü elde edilmiş, modelin başarısı için daha fazla kaza örneğine ihtiyaç duyulmuştur.

Ki ve Lee (2007) yapmış oldukları çalışmada, kavşak üzerinde oluşan araç çarpışmalarının belirlenmesini hedeflemişlerdir. Araçlar arka plandan ayrıldıktan sonra, hareketleri süresince kendilerine ait özellik vektörleri çıkartılmaktadır. Araçların arkaplandan ayrılması, ardışık çerçeve farklılığı yöntemi ile yapılmış, elde edilen hareket bölgeleri gruplandırılarak araç merkez noktaları takip edilmiştir. Araçların hızlarında ve ivmelerinde, bulundukları alan üzerinde ve pozisyonlarındaki ani değişiklikler kullanılarak kural tabanlı karar ağacı oluşturulmuştur. Özellikler için belirli eşik değerleri kullanılarak araçlar arasındaki çarpışmalar bulunmaya çalışılmıştır. Değerlendirme aşamasında kendi elde ettikleri görüntüler ve KTC tarafından elde edilen sonuçlar arasında karşılaştırma yapılmıştır. Testler sonucunda %60'lık başarı oranı elde edilmiştir. Bu yöntemin olumsuz yanı, kaza kararı verilmesinde eşik seviyelerine büyük ölçüde bağımlı kalınmış olmasıdır.

Atev vd. (2005), trafik kavşakları üzerinde trafik kazalarını oluşmadan önleyebilmek amacıyla görüntü işleme tabanlı gerçek zamanlı bir çarpışma tahmini çalışması yapmışlardır. Bu amaçla, doğal ortamda alınan görüntülerde kavşak üzerindeki araçların pozisyon bilgileri ve boyutları çıkartılmıştır. Çarpışma tahmin modülü bu bilgileri kullanarak araçların olası yörüngelerini tahmin etmeye çalışmakta ve kaza olasılıklarını hesaplamaktadır. Çalışma sonucunda elde edilen bilgilerin araç sınıflandırma ya da kaza şiddet kategorizasyonu amaçlı kullanılabileceği ve ileriki çalışmalarda değerlendirilebileceği ifade edilmiştir.

Shuming vd. (2002), parametrik olmayan regresyon yöntemi ile trafik sıkışıklığına çözüm getirmek amacıyla trafik olay belirleme yöntemini önermişlerdir. Bu yöntemle, herhangi bir modele oturtulamayan, dinamik ve belirsizlik taşıyan trafik akışı modele oturtulabilmiş ve olaylar yakalanabilmiştir. Amaç, daha önce elde edilen trafik görüntüleri kullanılarak benzer komşu noktaların bulunması ve bu noktaların bir sonraki akışta yerlerinin tahmin edilebilmesidir.

Görüntü işleme algoritmaları kullanan olağan dışı olay belirleme araştırmalarından birisi de Ikeda vd. (1999)'nin çalışmalarıdır. Önerilen yöntemde, arkaplan çıkarım metodu ile araç belirleme ve hareket takibi, hız ölçümü, nesne boyutlarının bulunması ve yörünge ölçümü

yapılarak, duran, yavaş giden veya yanlış şerit değişikliği yapan aracın yakalanması ya da yola düşmüş bir nesnenin bulunması sağlanmıştır.


Eidehall vd. (2007), ELA adı verilen (Emergency Lane Assist) acil durum şerit asistanı uygulamasını geliştirmişlerdir. Bu çalışma ile araçlar arasındaki çarpışmaların önlenmesi düşünülmüştür. Aracın şerit değiştirme anında görüş açısına göre aktif görme ile riskleri analiz edilerek yüksek riskli şerit değişikliklerinin önüne geçilmesi sağlanmıştır.

Bu çalışmada ana motivasyon kaynağı, trafik kaza videolarını oluşturan bileşenlerin, literatürde doğruluğu kanıtlanmış bölütleme ve takip sistemleri destekli ilişkisel analizlerinin yapılması, olay ve aksiyon tanımlarını oluşturan karar kurallarının tanımlanması ve olayların sonuçlarının farklı veri analizlerine sunulmasıdır. Bu tez, temel olarak, kavşaklardaki olağandışı olayların karakteristik özelliklerini çıkartarak istatistiksel tabanlı trafik kaza şiddet analizini hedefler. Yaklaşım, farklı sürelerdeki araç yörüngeleri ile kümeleme tekniklerini kullanarak olağan trafik akışının öğrenilmesi ve daha sonra kısmi araç yörüngeleri ve araç hareket karakteristiklerini gözlemleyerek kaza olaylarının çözümlenmesine dayanır. İlk olarak, kavşak üzerindeki araç yörüngelerinin elde edilebilmesi için görüntülerin ön işlemden geçirilmesi, araçların belirlenmesi ve zaman içerisinde takip edilmesi gerçekleştirilir. Her aracı temsil eden merkez noktaları Optik Akış yöntemi ile takip edilerek araç yörüngeleri çıkartılır. Elde edilen araç yörüngeleri ile ikinci aşamada Gauss karışımı destekli Sürekli HMM ile yörünge kümeleme işlemi gerçekleştirilir ve olağan yol modelleri bulunur. Öğrenilen yol modelleri ile kısmi araç hareketleri arasında maksimum olabilirlik yöntemi ile benzerlikler ve sapmalar gözlemlenerek olağan ve olağandışı davranışlar belirlenir. Bir sonraki aşamada, olağandışı trafik olaylarının şiddet özellikleri Değişim Katsayısı yöntemi ile elde edilir. Elde edilen olağan dışı değişim özellikleri ile trafik kazaları SVM ve k-NN sınıflandırma ile şiddetlerine göre iki farklı sınıfa ayrılır.

Son zamanlarda, video görüntülerinde olay analizi ve olağandışı durumların belirlenmesi büyük önem kazanmıştır (Regazzoni, Cavallaro, 2010). Yukarıda özetlenen çalışmalarda eksik görülen, trafik görüntülerinde olağandışı durumların olay analizlerinin yapılmamasıdır. Bu tezde elde edilen sonuçlar ile olağandışı araç hareketlerinin olasılıksal olarak gözlemlenebileceği ve olağandışı olayların bu olasılıklara bağlı olarak şiddet analizlerinin yapılabileceği ortaya çıkartılmıştır.

3. SİSTEM TASARIMI

Tez çalışması üç ana bölümden oluşmaktadır. Birinci bölüm, olağan araç akışlarının belirlendiği ve kavşak üzerinde yol modellerinin belirlendiği bölümdür. Bu bölümde, trafik görüntülerinde ön işlemler, araçların bölütlenmesi, araç takibi ile belirlenen araç yörüngelerinin kümelenecek olağan trafik davranışının ve yol modellerinin elde edilmesi işlemleri yapılmaktadır. İkinci bölüm, araç hareketlerinin gözlemlenmesi ve öğrenilmiş yol modellerinden farklılıklarının değerlendirilmesi sonucunda oluşabilecek olağandışı olayların belirlenmesi işlemlerini içermektedir. Üçüncü bölümde, normal trafik akışına uymadığı belirlenen olayların şiddet sınıflandırılması yapılmaktadır. Olağandışı olaylar düşük ve yüksek şiddetli olmak üzere iki sınıfta incelenmiştir. Sistem, mevcut olağandışı olay örneklerine ait özellikler ile eğitilerek olay şiddet sınıflandırma modeli oluşturulmuştur. Daha sonra, farklı örneklerle kavşaklarda oluşan olağandışı olayların otomatik sınıflandırılması yapılarak sistemin başarısı değerlendirilmiştir. Bu tez çalışması, yörünge analizi, olay tanımlama ve şiddet kategorizasyonu bölümlerinde özgünlük taşımaktadır. Çalışma boyunca izlenen sistem tasarımı Şekil 3.1’de görülmektedir.



Şekil 3.1 Trafik olay analizi işlem adımları

İleriki bölümlerde, sistem tasarımında görülen adımlar detaylı olarak anlatılmaktadır. Seçilen yöntemler, kullanım örnekleri ile beraber diğer yöntemler ile karşılaştırılmalı olarak anlatılmıştır.

3.1 Veri kümeleri

Tez çalışmasında üç farklı veri kümesi kullanılmıştır. Birinci veri kümesi, kurulan deney kavşak modeli üzerinde oyuncak arabalar ile elde edilen görüntüleri içerir. Bu ortamda, mevcut doğal ortam trafik kazası görüntülerinde olmayan farklı senaryoların elde edilebilmesi amaçlanmıştır. İkinci veri kümesi, NGSIM [4] organizasyonu tarafından sağlanan doğal ortam trafik görüntülerinden oluşmaktadır. Bu veri kümesi, sadece olağan araç hareketlerini içermektedir. Bu sebeple, sadece yol modellerinin öğrenilmesi ve olağan araç hareketlerinin test edilmesi aşamasında kullanılmıştır. Üçüncü veri kümesi, TRIMARC organizasyonu tarafından sağlanmıştır. Bu küme, doğal ortamlardan elde edilen olağandışı araç davranışlarını içerir. Olay sınıflandırma ve tanıma aşamasında kullanılmıştır. Kullanılan görüntülerde kavşak veya yollar üzerinde hareket eden nesnelerin araç oldukları kabul edilmiştir. Yol üzerindeki bisiklet, insan, motosiklet vb. diğer hareketli nesneler çalışmanın kapsamına alınmamıştır. Çizelge 3.1’de kullanılan veri kümelerinin içerik ile ilgili açıklamaları verilmiştir.

Çizelge 3.1 Tezde kullanılan veri kümeleri ve açıklamaları


Veri kümesi	Açıklama
Deney Ortamı Kavşak Modeli	Deney ortamından elde edilen veri kümesi 115 adet farklı trafik olayını ve 200 adet normal araç hareketini içermektedir. Görüntüler 25 çerçeve/saniye olarak kayıt edilmiştir. Her video dosyası ortalama 6-7 saniye sürmektedir.
NGSIM (Next Generation Simulation)	Trafik görüntüleri NGSIM organizasyonu tarafından sağlanmıştır. Görüntüler, 2005 yılında California, Lankershim Bulvarının 5 farklı bölgesinden 5 farklı kamera ile kayıt edilmiştir. Görüntüler ile beraber her aracın yörünge bilgisi de sağlanmıştır.
AIRS (TRIMARC)	AIRS veri kümesi aynı kavşak üzerinde 75 farklı olağandışı trafik olayının görüntülerini içermektedir. Görüntüler TRIMARC organizasyonu tarafından sağlanmıştır. Olaylar farklı açılardan iki farklı kamera ile kaydedilmiş ve mikrofona düzeneği ile olay yerindeki sesler de alınmıştır. Görüntüler, trafik olaylarından 4 saniye öncesini ve sonrasını gösterecek şekilde kayıt edilmişlerdir.

4. ARAÇ BÖLÜTLEME ve TAKİBİ

Doğal ortamda hareket halinde bulunan nesneler ile ilgili çalışmaların büyük çoğunluğunda genel yaklaşım, odaklanılan nesnelerin karmaşık arkaplan üzerinden başarılı şekilde bölütlenmesi ve hareketlerinin takip edilerek anlamsal bilgi çıkarımı işlemleri ile değerlendirilmesidir. Araçlar, bulundukları doğal ortam itibariyle genel olarak karmaşık ve zaman içerisinde değişebilen arkaplan üzerinde yer alırlar. Ortam üzerindeki aydınlanmanın zaman içerisinde değişmesi, görüntü üzerindeki yansımalar, görüntüyü elde eden kameralarda meydana gelebilecek titreşimler, kar ya da yağmur gibi doğa olaylarının yarattığı karmaşıklık, sallanan ağaç dalları ve gölge oluşumu gibi olaylar bölütleme başarısını olumsuz yönde etkileyen ve araçların takip edilmesini zorlaştıran faktörlerdir.

4.1 Trafik videolarının önışlemlerden geçirilmesi

Video görüntülerinde gürültü giderme, arkaplan çıkarımı işlemine başlamadan veya gerekiyorsa sonrasında ihtiyaç duyulan adımdır. Bu işlem ile araçların bulunma ve takip doğruluğunun artırılması hedeflenmiştir. Bu çalışmada gürültü giderme için Ortanca ve Gauss yumuşatma filtrelerinden faydalanılmıştır. Şekil 4.1'de gürültü giderme işleminden geçirilen orjinal örnek anlık çerçeve görüntüsü (IBM Research Lab [5]) (Şekil 4.1(a)) ile Ortanca (Şekil 4.1(b)) ve Gauss (Şekil 4.1(c)) filtreleme sonucunda elde edilen görüntüler görülmektedir.



Şekil 4.1 Gauss ve Ortanca yumuşatma işlemi sonucunda elde edilen görüntü örnekleri, (a) orjinal görüntü, (b) Ortanca filtreme sonrası oluşan görüntü, (c) Gauss yumuşatma sonrası oluşan görüntü

Ortanca filtreme ile görüntü üzerinde bulunan aşırı büyük atlamaların yarattığı parazitlerin giderilmesi hedeflenmiştir (örneğin, aracın camlarından yansıyan yüksek ışık tesirleri). Gauss filtreleme ile görüntüde bulanıklık oluşmasına rağmen görüntü üzerindeki küçük detayların (örneğin, ağaç dallarının yarattığı küçük hareketler) yok edilmesi amaçlanmıştır.

4.2 Arkaplan ve önplan modelleme

Hareketli videolarda görüntü analizi iki temel unsur üzerinde yapılır. Bu unsurlar, görüntüyü oluşturan arkaplan ve önplan bileşenleridir. Önplan ve arkaplandaki nesnelerin birbirlerine göre durumları aşağıdaki gibi olabilir.

- Durağan sahnede tek bir nesne hareketi
- Durağan sahnede çoklu nesne hareketleri
- Arkaplandaki gürültüler, trafik lambaları, duraklar
- Hareketli sahnede tekli ve çoklu nesne hareketleri (aktif görme, robotik uygulamalar)

Önplan nesnelerinin bölütlenebilmesi için en kolay ortam durağan arkaplanların olduğu sahnelerdir. Değişimin olmadığı sahnelerde çerçeve farklılığı hesaplanarak hareketi oluşturan nesnelerin takibi yapılabilir. Durağan sahne üzerinde, ilgilenilen nesnelerin birbirlerinden bölütlenmesi gerekmektedir. Bölütleme işleminin başarısı, takip ve izleme sürecinin doğruluğunu etkilemektedir. Arkaplan sahnelerinin hareketli olduğu ortamlarda (örneğin, gökyüzü, bulut, gölgeler, rüzgardan sallanan ağaç dalları vb.) nesne bölütleme işlemi daha karmaşıktır. Arkaplan modeli, görüntü üzerinde oluşabilecek ani değişimlere (örneğin, kamera sallantısı, arkaplan geometrisinde bozulma, ani ya da kademeli ışık değişimleri vb) uyum sağlamalıdır. Sahne üzerinde ilgilenilen bölgeler hareket içeren bölgelerdir. Hareket içeren bölgeler başarılı şekilde bölütlendiği zaman, nesnelerin tanınması ve takip edilmesi için daha başarılı sonuçlar elde edilecektir. Önplan nesnelerinin arkaplandan ayrılması için kullanılan genel yöntemler; yoğunluk histogramlarının bulunması, ardışık çerçevelerin farkının alınması, anlık çerçevenin arkaplandan farkının alınması, ortalama ve adaptif arkaplan modeli çıkarımı yapılması şeklinde sıralanabilir.

4.2.1 Nesne renk yoğunluğu histogramları

Nesnelerin arkaplandan ayrılabilmesi için en temel yöntemlerden birisi gri seviyesi histogramlarının değerlendirilmesidir. Nesneler genel olarak bulundukları arkaplandan daha farklı renk yoğunluğuna sahiptirler. Bu tip görüntülerde, nesneler eşik seviyesi yöntemiyle arkaplandan kolayca ayrılabilir. Bu yöntemin başarısı seçilecek eşik değerine bağlı olduğu için, adaptif eşik değeri yöntemi ile farklı ışık yoğunluğundaki ortamlarda nesne ve arkaplan ayrımı yapılabilir. Fakat karmaşık doğal ortam görüntülerinde genel olarak arka ve önplanda ortak renkler olduğu ve resmin genelinde ikiden fazla farklı renk bölgesi bulunduğu için araçların renk histogramlarına eşik seviyesi uygulanarak bölütlenmesi uygun değildir.

4.2.2 Ardışık çerçeve farklılığı

Ardışık çerçevelerin farklarının değerlendirilmesi çok basit ve işlem karmaşıklığı düşük bir yaklaşım olmakla beraber gürültüye çok açık bir yöntemdir. Zaman içerisinde elde edilen ardışık çerçevelerin (4.1)'de görüldüğü gibi farkının alınarak hareketli bölgelerin bulunması hedeflenir.

$$|\text{çerçeve}(x, y)_i - \text{çerçeve}(x, y)_{i-1}| > Th \quad (4.1)$$

Birinci adım, ardışık çerçevelerin aynı piksel adreslerindeki gri seviyesi farklarının mutlak değerinin hesaplanmasıdır. Elde edilen sonuç belirli bir Th eşik seviyesi ile karşılaştırılır. Eşik seviyesinden büyük değerlere karşılık düşen pikseller hareket eden bölgeleri, diğer pikseller ise arkaplan bölgelerini oluştururlar. Sistem başarısının yüksek olması için eşik seviyesinin en iyi değerinin belirlenmesi gereklidir. Yöntemin en önemli dezavantajı rüzgarda sallanan yaprak gibi arkaplanda yer değiştirmeden küçük hareketler yapan nesnelerin de işaretleniyor olmasıdır. Bu nedenle özellikle karmaşık arkaplana sahip doğal ortamlarda kullanımı uygun değildir. Bundan başka basit bir ışık değişikliği bile hareket olarak algılanabilir.

4.2.3 Arkaplan çerçeve farklılığı

Bu yöntemin ardışık çerçeve farklılığından farkı, referans çerçevenin sabit olması ve (4.2)'de görüldüğü üzere anlık çerçevelerin referans çerçeveden çıkartılarak hareket eden bölgelerin bulunmasıdır. Arkaplanın durağan olduğu ve gürültü içermeyen görüntülerde başarılıdır. Doğal ortamlarda arkaplan karmaşıklığı artabileceğinden bu yöntem hedeflenen çıktıları karşılayamamaktadır.

$$|\text{çerçeve}_i - \text{çerçeve}_{ref}| > Th \quad (4.2)$$

Ardışık ve arkaplan çerçeve farklılıkları yöntemlerinde, arkaplan modelinin sürekli güncellenebilir olması, çok yavaş hareket eden nesnelerin arkaplan modeline dahil edilmemesi ve doğal ortamdan kaynaklanan gürültülere uyarlanabilmesi gerekmektedir.

4.2.4 Değişen ortalama arkaplan modelleme

Bu yöntemde, (4.3) eşitliği ile her piksel için arkaplan zaman içerisinde güncellenmektedir.

$$B_{i+1} = \alpha * F_i + (1 - \alpha) * B_i \quad (4.3)$$

Arkaplan görüntüsü B_{i+1} geçmiş ve şimdiki F_i piksel değerlerinin ağırlıklı ortalamasıdır. α , güncel arkaplanın geçmiş çerçeveleri ne kadar hızlı unutacağını belirleyen parametredir. α , 1 ise, arkaplan tamamen güncel çerçeveye bağımlıdır. α 'nın 0 olduğu durumlarda arkaplan başlangıçta verilen ilk arkaplan çerçevesi olarak sabit kalır. Bu değer 1'e yakın ise arkaplan güncel çerçeve ile çok sık güncellenecektir. Bu durumda arkaplan referans çerçevesi güncel çerçeveye çok yakın değerler içereceğinden, fark çerçevesi hedeflenen nesnelerin sadece kenar noktalarını gösterecektir. Öte yandan, α sıfıra yakın küçük değerler aldığı anda, arkaplan güncellemesi çok yavaş gerçekleşecektir. Bu durum, arkaplanda olmaması gereken hareketli bölgelerin arkaplan bölgesi olarak değerlendirilmesine yol açacaktır. Ayrıca, bu yöntem sahne aydınlanması, güneş batması gibi aşamalı çevre değişikliklerini yansıtmakta problemler yaşamaktadır. Bu tür dezavantajlar, daha iyi arkaplan modellerine ihtiyaç olduğunu göstermiştir.

4.2.5 Adaptif arkaplan modelleme

Bu modelleme yöntemi, doğal ortam görüntülerinde en başarılı sonuçları vermektedir. Model, gölge, yansıma gibi doğal ışık efektlerine ve görüntüler üzerinde bulunan gürültülere (yağmur, kar vb.) karşı oldukça başarılıdır. Bu yöntemlerden en önemlisi arkaplanın, birden fazla k Gauss Karışım Modeli ile belirlendiği yöntemdir (Stauffer ve Grimson, 1999). Bu çalışmada, trafik sahnesi üzerinde bulunan araçların arkaplandan bölütlenmesi amacıyla k Gauss Karışım Modeli kullanılmıştır.

Algoritmanın temel yaklaşımı, görüntü üzerindeki her pikselin birden çok Gauss karışımı ile parametrik olarak modellenmesidir. Her X_t pikselin gözlemlenebilme olasılığı k Gauss karışım dağılımı olarak (4.4) eşitliğiyle hesaplanır (Stauffer ve Grimson, 1999).

$$P(X_t) = \sum_{i=1}^K w_{i,t} \eta_{\mu_{i,t}, \Sigma_{i,t}}(X_t) \quad (4.4)$$

Bu eşitlikte k , Gauss dağılım sayısını, $w_{i,t}$ t anındaki i . Gauss karışımının ağırlığının tahminini gösterir. Her Gauss dağılımının ortalama değeri μ bir sonraki çerçevedeki piksel değerinin tahmini şeklinde düşünülebilir. $\mu_{i,t}$, t anında karışımındaki i . Gauss dağılımının ortalamasını, $\Sigma_{i,t}$, kovaryans matrisini ve η , Gauss Olasılık Yoğunluk Fonksiyonunu (Probability Density Function, PDF) göstermektedir. Dağılım fonksiyonu Eşitlik (4.5)'teki gibi hesaplanır.

$$\eta_{(\mu, \Sigma)}(X_t) = \frac{1}{\sqrt{2\pi}^d \sqrt{\det(\Sigma)}} e^{-\frac{1}{2}(X_t - \mu)^T \Sigma^{-1} (X_t - \mu)} \quad (4.5)$$

Her piksel için genelde 3 ile 5 arasında Gauss elementi kullanılır. Bu değerler, uygulamanın çalıştığı ortamın mevcut hafıza kapasitesine göre daha yüksek seçilebilir (Stauffer ve Grimson, 1999). Adaptif Arkaplan Modelleme işlem adımları aşağıda belirtilmiştir.

- Çerçeve üzerindeki her X_t piksel için :

- k -Ortalama ya da Beklenti-Maksimizasyonu (EM) algoritması ile X_t piksel değerine en iyi uyan k Gauss dağılımı ve ağırlığı bulunur.
- $|X_t - \mu_{i,t-1}| \leq D \cdot \sigma_{i,t-1}$ durumunda, dağılım eşleştirilmiş dağılım olarak atanır. D değeri küçük pozitif sapma eşik değerini gösterir (genel olarak 2.5 veya 3 seçilir). Eşleşen dağılımın parametreleri (4.6) eşitlikleri ile güncellenir.

$$\begin{aligned} w_{i,t} &= (1 - \alpha) \cdot w_{i,t-1} + \alpha \\ \mu_{i,t} &= (1 - \rho) \cdot \mu_{i,t-1} + \rho \cdot X_t \\ \Sigma_{i,t} &= (1 - \rho) \cdot \Sigma_{i,t-1} + \rho \cdot (X_t - \mu_{i,t})^2 \end{aligned} \quad (4.6)$$

α öğrenme oranını gösterir ve $[0,1]$ arasında değer alabilir. ρ , dağılım parametreleri öğrenme oranı (4.7) ile hesaplanır.

$$p \approx \frac{\alpha}{w_{i,t}} \quad (4.7)$$

- Eğer eşleşen bir dağılım bulunamadıysa, en küçük ağırlığa sahip dağılım, X_t değeri ortalamasıyla yeni bir dağılım ile yer değiştirir. Geride kalan dağılımlar aynı ortalama ve kovaryans ile işleme devam ederler. Bu dağılımların ağırlıkları (4.8) ile güncellenir.

$$w_{k,t} = (1 - \alpha) w_{k,t-1} \quad (4.8)$$

- X_t pikselinin önplan olup olmadığını belirleyebilmek için bütün dağılımlar $w_{i,t} / \sigma_{i,t}$ değerlerine göre sıralanırlar. Sıralama sonucu ön sıralardaki dağılımlar düşük varyansa ve yüksek olasılıklara sahip olduğundan Eşitlik (4.9)'u sağlayan dağılımlar arkaplan olarak atanırlar.

$$\sum_{k=i_1}^{i_M} w_{k,t} \geq \Gamma, \quad (4.9)$$

$i_1 \dots i_K$ Gauss dağılımları, M koşulu sağlayan dağılım sayısı, Γ ağırlık eşik değeri olarak kullanılır.

- Eğer X_t , arkaplan dağılımlarının D katı standart sapma aralığında ise önplan pikseli olarak atanır.

$$\text{Eğer } |D.\sigma_{i,t} - \mu_{i,t}| \leq X_t \leq |D.\sigma_{i,t} + \mu_{i,t}| \text{ ise } X_t \text{ önplan pikseli.} \quad (4.10)$$

Çalışmada, Ortalama Çerçeve Fark Alımı ve Adaptif Gauss Arkaplan Çıkarımı yöntemlerinin başarıları incelenmiştir. Çerçeve farkı, en basit arka ve ön plan ayırım yöntemidir. Arkaplanın sabit ve gürültünün olmadığı görüntülerde başarılı sonuçlar vermiştir. Başarı oranı α ve eşik değerine oldukça bağlıdır. Şekil 4.2’de çerçeve farkı yöntemi ile elde edilen arkaplan ve önplan görüntü örnekleri görülmektedir.

Şekil 4.2(a)’da orjinal çerçevesi görülen yol görüntüsünün arkaplan çıkarımı için iki farklı α değeri test edilmiştir. α değerinin 0’a yakın olması arkaplan çıkarımı başarısını artırırken (Şekil 4.2(b)), Şekil 4.2(c)’de görüldüğü üzere önplanda istenmeyen gürültülü nesneler önplan olarak atanır (örneğin, ağaç dallarının hareketi). α değeri 1’e yakın bir değer seçildiğinde (Şekil 3.3(d) ve $\alpha = 0.8$), arkaplan güncel çerçeve ile güncellendiği ve önplanda gürültüler ile beraber araç bütünlüğünün bozulduğu görülmüştür. Arkaplan görüntüsü üzerinde Gauss filtreleme uygulanarak farklı α değerleri ile önplan bölütleme işlemi tekrarlanmıştır (Şekil 3.3(f) ve (h)). Düşük α değeri ile (Şekil 3.3(f) ve (g)) arkaplan ve önplan üzerine aracın yaratmış olduğu hareket kalıntıları görülmektedir. Gauss filtreleme kullanılan ve α değeri yüksek seçilen durumlarda (Şekil 3.3(h) ve (i)) önplan nesnesinin bütünlüğünün bozulduğu görülmektedir.




(a)

(b) arkaplan $\alpha = 0.05$ (c) önplan, $\alpha = 0.05$ (d) arkaplan $\alpha = 0.8$ (e) önplan $\alpha = 0.8$ (f) arkaplan (gauss filtre) $\alpha=0.05$ (g) önplan $\alpha = 0.05$ (h) arkaplan (gauss filtre) $\alpha = 0.8$ (i) önplan $\alpha = 0.8$

Şekil 4.2 Çerçeve farkı arkaplan çıkarımı ile önplan nesnelerinin bölütlenmesi, (a) Orjinal çerçeve, (b) filtreleme kullanmadan $\alpha = 0.05$ ile elde edilen arkaplan çerçevesi ve (c) önplan çerçevesi, (d) $\alpha = 0.8$ ile elde edilen arkaplan çerçevesi ve (e) önplan çerçevesi, (f) Gauss filtreleme uygulanarak $\alpha = 0.05$ ile elde edilen arkaplan çerçevesi ve (g) önplan çerçevesi, (h) Gauss filtreleme uygulanarak $\alpha = 0.8$ ile elde edilen arkaplan çerçevesi ve (i)önplan çerçevesi

Doğal ortam görüntülerinde arkaplan çıkarımı için adaptif yöntemler tavsiye edilmektedir ve deneyler sonucunda diğer metodlara göre daha başarılı sonuçlar elde edilmiştir. Önplandaki nesnelerin bölütlenmesi için, arkaplan üzerinde olması muhtemel gürültüler (ağaç dallarının hareketi), ani kamera hareketleri, ışık ve hava durumuna uyum sağlayacak Adaptif Gauss tekniği arkaplan çıkarım yöntemi olarak seçilmiştir. Adaptif Gauss arkaplan yöntemi sonucunda elde edilen önplan ve arkaplan görüntüleri Şekil 4.3'te görülmektedir.




Şekil 4.3 Adaptif Gauss arkaplan çıkarımı yöntemi ile önplan nesnelerinin bölütlenmesi, (a) Orjinal çerçeve, (b) Gauss filtreme kullanılarak elde edilen arkaplan çerçevesi ve (c) önplan nesnesi, (d) Gauss filtreleme uygulanmadan elde edilen arkaplan çerçevesi ve (e) önplan nesnesi

Şekil 4.3(c)'de önplan nesnesi başarılı şekilde bölütlenirken, Şekil 4.3(e)'de önplan nesnesinin bütünlüğünün aracın önüne gelen ışık direği yüzünden hafifçe bozulduğu görülmektedir. Bu tür problemlerin en aza indirilebilmesi için bölütleme öncesi Gauss filtreleme kullanımı başarı oranını arttırmaktadır.

4.3 Önplandaki araç bölgelerinin bölütlenmesi

Video görüntülerinde takip edilecek araç adaylarının belirlenmesi ve etiketlenmesi trafik gözlem uygulamalarının en önemli adımlarından birisidir. Görüntü üzerinde hareket eden bölgeler belirlenip belli özellikleri çıkartıldıktan sonra araç adaylarının bulunması ve etiketlenmesi gerekmektedir. Bu amaçla, bağlı bileşenlerin bulunması ve çevrit belirleme yöntemlerinden faydalanılır [6]. Çevrit belirleme (Freeman, 1974), önplan olarak bölütlenmiş hareket eden nesnelerin çerçevelerinin belirlenmesini sağlar. Bunun için önce önplan olarak işaretlenen nesneler bağlı bileşenler yöntemi ile etiketlenir. Büyüklüğü belli bir eşik seviyesinin altında olan bağlı bileşenler parazit olarak değerlendirilerek elenir. Daha sonra her bağlı bileşenin etrafında kapalı bir dış çevrit oluşturulur. Şekil 4.4'te orjinal görüntüden bölütlenen hareket eden araç bölgeleri ve bu bölgelerin çevritleri görülmektedir.



Şekil 4.4 (a) Orjinal görüntü, (b) bağlı bileşen analizi sonucu önplan nesneleri ve (c) önplan nesnelerini çevreleyen çevritler



Şekil 4.5 Deney ve doğal sahneler üzerinde takip edilen araçların dış çevritlerinin belirlenmesi


Şekil 4.5'te deney ve doğal ortam üzerinde bulunan araçların hareket halindeyken belirlenen çevritleri görülmektedir. Kırmızı ile belirtilen noktalar, bir sonraki bölümde anlatılacak olan araçları temsil eden ve takip edilecek özellik noktalarıdır.

Arkaplandan bölütlenen araçlar üzerinde çeşitli işlemler yapılarak zaman ve düzlem üzerindeki hareketleri modellenenabilir. Önplanda ayırt edilen hareket bölgelerinin araçları temsil etmesi özellik vektörlerinin belirlenmesi ile gerçekleştirilir. Özellik vektörlerinin zaman içerisindeki yer değişimlerinin takibi araçların hareketlerini anlamayı sağlar.

4.4 Araç temsil noktalarının belirlenmesi


Doğal ortam görüntülerinde nesne takip işlemine başlamadan önce, nesneler hakkında fikir sahibi olunması gerekir. Takip edilecek nesnelerin tanımlayıcı ve ayırt edici özelliklerinin belirlenmesi görüntülerin anlamsal içeriklerinin yorumlanmasında önemli rol oynar.

Şekil 4.6'da farklı trafik görüntülerinden alınmış araç hareketleri görülmektedir. Bu tip trafik görüntülerinde odak noktası, hareket halindeki nesnelerin özellik çıkarımlarının yapılmasıdır.




Şekil 4.6 Farklı anlık trafik görüntüleri [7]

Bu tezde, hareket halindeki nesnelerin tanımlayıcı özelliklerinden biri olan Merkez noktası (Şekil 4.7) özelliği nesne takibinde kullanılmak üzere seçilmiştir. Örneğin, birbirleriyle etkileşime giren nesnelerin merkez noktalarının takibi olay belirleme aşamasında önemli rol oynamaktadır. Merkez noktası, nesnenin düzlem üzerindeki pozisyonu hakkında bilgi verir. Merkez noktasının bulunabilmesi için en genel yöntemlerden birisi, çevritleri belirlenmiş araçları dikdörtgen şablonuna oturtarak merkez noktalarının hesaplanmasıdır.



Şekil 4.7 Çevritleri belirlenmiş araç nesnesinin merkez noktasının belirlenmesi (Bradski ve Kaehler, 2008)

Şekil 4.8’de kavşak üzerinde bulunan araçların merkez noktası ve bağlı bileşenleri çevreleyen dikdörtgen şablonlar gösterilmiştir.



Şekil 4.8 Kavşak modeli üzerinde bulunan araçların merkez noktası özellikleri, (a) Orjinal çerçeve, (b) önplandaki bağlı bileşenler, (c) araçları çevreleyen dikdörtgenler ve merkez noktaları

4.5 Nesne takibi

Bu çalışmada, nesne takibi işlemi sahne üzerinde hareket halinde bulunan araçların hareket karakteristiklerini gösteren izlediği yörünge ve sahip olduğu hız bilgilerinin belirlenebilmesi amacıyla kullanılmaktadır. Takip işlemleri sonucunda, belirlenen olağan davranış gösteren araç yörüngeleri kullanılarak olağan trafik akış modellerinin öğrenilmesi amaçlanmıştır.

Genel olarak, nesne izleme ve takip işlemleri nesne belirleme adımlarından sonra gerçekleştirilir. Nesne izleme, video sekansları üzerinde bulunan nesnelerin zaman eksenini ve koordinat düzleminde hareketlerinin takip edilmesi ve modellenmesidir. Nesne izleme işlemleri beş ana grupta toplanır. Bu gruplar, model tabanlı, alan tabanlı, aktif-sınır tabanlı, yoğunluk tabanlı ve özellik nokta tabanlı izleme yöntemleridir.

Model tabanlı izleme algoritmaları takip edilecek nesneleri daha önceden belirlenmiş bir şablona oturtma işlemidir. Şablon eşleştirme yöntemi bu modele örnek olarak verilebilir. Bu yöntem, nesne şablonuna benzeyen bölgelerin her bir çerçeve içerisinde aranması tekniğine dayanır. Bu özelliğiyle, hesaplama açısından pahalı bir yöntemdir. Nesneler belirli geometrik şekiller ile temsil edilerek takip edilebilirler. İzlenen sahne ve nesne tiplerine göre düzenli nesneler dikdörtgen, elips, daire vb. şeklinde gösterilebilir. Örneğin, araçların izlendiği takip uygulamalarında araçlar dikdörtgen olarak modellenebilir, spor olayları takibi uygulamalarında oyunun oynandığı top nesnesi dairesel olarak temsil edilebilir. İnsan vücudu hareketinin takip edildiği uygulamalarda ise vücut organları elips şeklinde modellenebilirler (Yılmaz ve Javed, 2006). İnsan vücudu bütün olarak düşünüldüğünde ise düzensiz nesnelere örnek olarak verilebilir. Bu tür nesneler için şablon oturtulması zor olacağından silüet veya kenar çevritleri ile nesneler temsil edilebilir.

Nesne takibi uygulamalarında üç boyutlu model tabanlı takip yöntemleri önemli yer tutar. Bu yöntemlerin en önemli avantajları, takip başarısının dış çevre faktörlerinden daha az etkilenmesi, nesne çakışmalarını ortadan kaldırabilmesi ve hareketleri süresince şekilsel karakteristiklerinde değişim gösteren nesnelerin takiplerinin başarılı yapılabilmesi olarak sıralanabilir. Ayrıca, iki boyutlu görüntü koordinatları ve üç boyutlu dünya koordinatları arasında kamera kalibrasyon teknikleri ile eşleştirme yapılarak nesnelerin üç boyutlu pozları ortaya çıkartılabilir. Örneğin, trafik videolarında takibi yapılacak nesnelerin hareketleri boyunca düzlem üzerinde bulundukları lokasyonların ve durumlarının doğal ortam değerleriyle bulunması, nesne hareketlerinden anlamsal verilerin gerçeğe yakın olarak çıkartılmasına yardımcı olacaktır. Yukarıda bahsedilen avantajların yanısıra 3D model tabanlı takip yöntemlerinin dezavantajları da bulunmaktadır. Bu yöntemler, hesaplama olarak pahalı yöntemlerdir. Bu sebeple, gerçek zamanlı takip işlemlerinde tercih edilmesi, yüksek kapasiteli özel donanımların kullanılması ihtiyacını doğurur.

Alan tabanlı izleme algoritması, nesnelerin tanıma için önem arzeden özelliklerinin çıkartılması (renk, doku v.b.) ve bu özellikler ile destekli izleme çalışmasıdır. Doğal ortamda bulunan nesneler çeşitli şekillerde ve renklerde olabilirler. Nesneler üzerinde bulundukları ortam arkaplan görüntüsünden daha yoğun renk özelliği taşırlar. Hareket belirlemede her çerçevedeki renk histogram dağılımlarının belirlenmesi ve çerçeveler boyunca tekrarlanması sayesinde takip işlemi yapılabilir. Ancak, nesnelerin taşıdıkları renkler doğal ortamda meydana gelebilecek ışık değişimlerine karşı çok hassas tepki gösterebilirler. Ayrıca, benzer renkli nesneler ayrıştırma sorunu yaratacaklar ve çakışma durumlarında takip işlemlerinde başarısızlık yaşanacaktır. Bu sebeple, renk özelliği kullanarak nesne belirleme ve takibi yöntemleri özellikle trafik gözlem ve takip uygulamaları için eksik kalmaktadır.

Genel olarak, nesnelerin doku özellikleri ile takibi kendilerini çevreleyen düz yüzeylerin yoğunluk değişiminin ölçülmesi ile yapılır. Renk özelliği ile karşılaştırıldığında, nesnelerin doku özelliklerinin elde edilebilmesi için tanımlayıcı işlemler gereklidir. Law's doku ölçümleri ve dalgaboyları bu tür doku tanımlayıcılara örnek olarak verilebilir (Yılmaz ve Javed, 2006). Ayrıca, nesne doku özellikleri sahne üzerindeki ışıksal değişimlere renklere nispeten daha az hassasiyet gösterirler.

Aktif sınır tabanlı izleme yönteminde, hareketi takip edilecek nesnenin dış çerçevesini oluşturan aktif çevritlerin takibi yapılır (Kass vd., 1988).

Yoğunluk tabanlı takip yöntemi, nesne özelliklerinin yoğunluklarının bulunması ile gerçekleştirilir. Optik Akış ve Histogram tabanlı Ortalama-Kaydırma (Mean-Shift) yöntemi, yoğunluk tabanlı takip işlemlerine örnek olarak verilebilir. Yoğunluk algoritması (Condensation, Conditional Density Propagation) yöntemi de nesnelerin kenar çizgilerini belirleyerek takip işlemini gerçekleştirir (Isard ve Blake, 1998).

Özellik nokta tabanlı takip yaklaşımı, nesnelerin yerel özellikleri kullanılarak gerçekleştirilir. Örneğin, nesnenin belirtilen alanda merkez noktalarının, köşelerinin ya da vertislerinin çıkartılarak takibinin yapılması bu tür bir işlemdir. Özellik tabanlı takip algoritmalarında en bilinen yöntem Kalman süzgecidir (Welch ve Bishop, 2006).

4.5.1 Özellik noktalarının takibi

Bölütlenen nesneleri temsil eden tanımlayıcı noktaların belirlenmesinden sonraki adım, bu noktaların takibinin yapılması ve nesnelerin hareket yörüngelerinin bulunmasıdır. Nesnelerin takibinin yapılması, nesneye ait karakteristik özelliklerin görüntü üzerindeki lokasyonlarının ve hızlarının zaman içerisinde bulunmasıdır. Takip işleminde en bilinen yöntemlerden ikisi, özellik noktası takip yöntemlerinden Kalman Filtresi ve yoğunluk tabanlı takip yöntemlerinden Optik Akış Yöntemi'dir.

Kalman Filtresinde izleme işlemi, hareket eden nesnelere ait özellik vektörlerinin arka arkaya gelen görüntü sekanslarında bir sonraki pozisyonlarının tahmin edilmesi ve doğrulanması yöntemine dayanır. (Beymer vd., 1997), Kalman Filtresi ile özellik noktalarının takibi işlemini detaylı olarak özetlemiştir.

Bu çalışmada özellik noktası takip işlemi için Optik Akış yöntemi (Tomasi ve Kanade, 1991) seçilmiştir. Optik Akış algoritmalarının ortak özelliği, sadece hareket eden ayırt edici özelliklerinin aynı akış alanına sahip olduğu kabulünü yapmalarıdır. Takip edilen şeklin parlaklığının ardışık çerçeveler boyunca değişmeyeceği kabul edilir (brightness constancy). Görüntü üzerindeki gürültülerin yaratacağı akış alanları ardışık çerçeveler üzerinde küçük zaman farklılıklarında olacağından minimize edilir ve ileriki değerlendirmelere alınmaz (temporal persistence). Ayrıca, aynı yüzey üzerindeki hareket halindeki pikselin komşu pikselleri de aynı hareket özelliklerini gösterir (spatial coherence).

En genel yaklaşım iki adımdan oluşur. Hareket vektörlerinin çıkartılması ve bu vektörlerin yorumlanmasıdır. Optik akış alanı iki ayrı birimin bulunmasıyla oluşur. Bunlar, hareket içeren pikseller ve bu piksellerin yarattığı yer değişimleridir. Optik akış alanlarının tahmini,

parlaklık kısıt denkleminin minimize edilmesi işlemine dayanır [8].

$$I_x(x, y) * u(x, y) + I_y(x, y) * v(x, y) + I_t(x, y) = 0 \quad (4.11)$$

$I_x(x, y)$, x eksenini boyunca görüntü keskinliğinin, $I_y(x, y)$, y eksenini boyunca keskinliğin türevini belirtir.

$I_t(x, y)$, ardışık çerçeveler arasındaki keskinliğin zamana göre türevini belirtir.

$U(x, y)$, yatay optik akış elementi, $V(x, y)$, dikey optik akış elementini gösterir.

Kanade-Lucas-Tomasi (Lucas ve Kanade, 1981; Tomasi ve Kanade, 1991; Shi ve Tomasi, 1994) takip algoritması en gelişmiş optik akış yöntemlerinden birisidir. Yöntemin amacı, nesneye ait özneliğin birinci görüntüde yerinin bulunması, ardışık çerçeveler üzerinde bu yerin koordinatlarının tahmin edilerek korunmasıdır. Bu işlemi, ardışık çerçeveler üzerinde piksellerin keskinlik farklarını minimize ederek sağlar. Sonuç akış vektörü (4.12)'de belirtilen $\varepsilon(d)$ fonksiyonunu minimize eden d uzaklık vektördür.

$[u_x, u_y]^T$, I_1 görüntüsündeki nokta

$[u_x + \delta_x, u_y + \delta_y]^T$, I_2 görüntüsünde ε değerini minimize eden nokta

$$\varepsilon(d) = \varepsilon(\delta_x, \delta_y, \delta_t) = \sum_{x=u_x-w_x}^{u_x+w_x} \sum_{y=u_y-w_y}^{u_y+w_y} (I_1(x, y, t) - I_2(x + \delta_x, y + \delta_y, t + \delta_t)) \quad (4.12)$$


$I(x, y, t)$ keskinlik fonksiyonunu, (u_x, u_y) optik akış tahmininin yapıldığı noktayı, (w_x, w_y) , (u_x, u_y) noktasının etrafındaki pencere içindeki komşu pikselleri belirtir.

Optik akış alanı her pikselin hareket vektörünü çıkartır. Hareket vektörlerinin büyüklüğü ya da derecesi hareket eden pikselin hareket büyüklük karakteristiği hakkında bilgi verir. Eğer, hareket eden piksel bir nesne üzerindeyse, aynı nesneye ait diğer pikseller de benzer optik akış vektörlerine sahiptirler. Sonuç olarak, hareket eden nesne, benzer hareket karakteristiğine sahip optik akış vektör kümesi yaratır. Benzer vektörler, ortalama ya da standart sapma yöntemleriyle belirlenebilir. Geri kalan vektörler, büyük olasılıkla, gürültüden dolayı oluşan vektörlerdir ve düşük dereceye sahiptirler. Vektör derecelerini eşik işleminden geçirdikten sonra, seçilen vektörlerin boyları ve benzerlikleri hesaplanarak hareket kümeleri çıkartılır.

Temel optik akış algoritması takip edilen özelliklerin kısa mesafeli yer değişimlerini belirleyebilirken büyük yer değişimlerinde eksiklik göstermektedir (Suhr, 2009). Ardışık

çerçeveler arasındaki büyük yer değişimlerini belirleyebilmek için piramitsel optik akış yöntemi önerilmiştir. Bu yöntemle, kavşak üzerinde hareket eden araçların büyük miktarda yer değişimleri gözlenebileceğinden tezin ilerleyen aşamalarında bu algorithmadan faydalanılmıştır.

Piramitsel yöntem, temel olarak ardışık çerçeveler arasında piramitsel hiyerarşik yapı kullanarak akış vektörlerinin hesaplanması mantığına dayanır. Şekil 4.9’da 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 çalışmada, araçların özellik noktası takip işleminde Intel OpenCV Görme Kütüphanesi [9] tarafından sağlanan piramitsel optik akış yöntemi kullanılmaktadır. Yöntemin işlem adımları aşağıda belirtilmiştir (Bouguet, 2002).



Şekil 4.9 Piramitsel optik akış ile hareket vektörlerinin belirlenmesi (Bradski ve Kaehler, 2008)

- I_1 ve I_2 çerçevelerinin piramit gösteriminin oluşturulması:

$$\circ \left\{ I_1^L \right\}_{L=0, \dots, L_m} \quad (4.13)$$

$$\circ \left\{ I_2^L \right\}_{L=0, \dots, L_m}$$

- o 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 (Şekil 4.10) rekürsif olarak şu şekilde oluşturulur : $I^0 \rightarrow I^1 \rightarrow I^2 \rightarrow I^3 \rightarrow \dots \rightarrow I^{L_m}$. I^L , Eşitlik (4.14)’de görüldüğü gibi hesaplanır.



Şekil 4.10 Video görüntüsünün piramitsel olarak gösterilmesi, I^0 (a) $\rightarrow I^1$ (b) $\rightarrow I^2$ (c)

$$I^L(x, y) = \frac{1}{4} I^{L-1}(2x, 2y) + \frac{1}{8} [I^{L-1}(2x-1, 2y) + I^{L-1}(2x+1, 2y) + I^{L-1}(2x, 2y-1) + I^{L-1}(2x, 2y+1)] + \frac{1}{16} [I^{L-1}(2x-1, 2y-1) + I^{L-1}(2x+1, 2y+1) + I^{L-1}(2x-1, 2y+1) + I^{L-1}(2x+1, 2y-1)] \quad (4.14)$$

- $u^L = [u_x u_y]^L \rightarrow L = 0..L_m$, u^L , $u(u^0)$ özellik noktasının piramit görüntülerinde karşılık gelen noktaları Eşitlik (4.15)'deki gibi hesaplanır.

$$u^L = \frac{u}{2^L}, u^L L. \text{ seviyedeki özellik noktası lokasyonu} \quad (4.15)$$

Piramitsel algoritmanın özyineli olarak ilerlemesi aşağıdaki şekilde gerçekleşir (Suhr, 2009) :

- 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 (4.16)'deki yeni görüntü eşleştirme hata fonksiyonu ε^L 'yi minimize eden artık piksel yer değişimi vektörünün hesaplanması gerekir.

$$d^L = [d_x^L d_y^L]^T$$

$$\varepsilon^L(d^L) = \varepsilon^L(d_x^L, d_y^L) = \sum_{x=u_x^L-\omega_x}^{u_x^L+\omega_x} \sum_{y=u_y^L-\omega_y}^{u_y^L+\omega_y} [I_1^L(x, y) - I_2^L(x + g_x^L + d_x^L, y + g_y^L + d_y^L)]^2 \quad (4.16)$$

Bu adımda, d^L optik akışının hesaplanması için (Bouguet, 2002)'e danışılabilir. d^L optik akışının hesaplandığı kabul edilerek işleme (4.17) eşitliğindeki $L-1$ seviyesindeki tahmini optik akışın hesaplanması ile devam edilir.

$$g^{L-1} = 2(g^L + d^L) \quad (4.17)$$


$L-1$ seviyesindeki d^L optik akış vektörü hesaplanır. Bu vektör, $\varepsilon^{L-1}(d-1)$ hata fonksiyonunu minimize eden akış vektörüdür. Bu işlem $L=0$ seviyesine kadar devam eder. Algoritmanın başlangıcında en derin seviyedeki g^{Lm} değeri (4.18)'deki gibi sıfır olarak atanır.

$$g^{Lm} = [0 \ 0]^T \quad (4.18)$$

Son adımda, final optik akış uzaklık vektörü (4.19)'deki gibi hesaplanır.

$$d = \sum_{L=0}^{Lm} 2^L d^L \quad (4.19)$$


Şekil 4.11'de, tez çalışması boyunca Piramitsel Optik Akış yöntemi kullanarak elde edilen takip sonuçlarından bazı örnekler görülmektedir.



Şekil 4.11 Özellik noktaları kullanarak araç özelliklerinin takip edilmesi ve elde edilen hareket vektörleri

4.5.2 Araç hareket karakteristiklerinin belirlenmesi

Sahne üzerinde bulunan araçların merkez noktalarının Piramitsel Optik Akış yöntemi ile takip edilmesi sonucunda, merkez noktalarının sahne üzerindeki pozisyon bilgisi ve ardışık çerçeveler arasında birim zamandaki yer değişimleri belirlenir. Zaman içerisinde belirlenen pozisyon bilgileri araçların yörüngelerini oluşturur. Her bir araca ait yörünge bilgisi ve yer değişimleri araç sahnede olduğu sürece güncellenir. Bu adımda takip edilen işlem akış diyagramı Şekil 4.12'de gösterilmiştir.



Şekil 4.12 Piramitsel Optik Akış ile hareket karakteristiklerinin çıkarımı

4.6 Bölüm özeti

Bu bölümde, olağan trafik akış modelinin oluşturulması amacıyla uygulanan araç belirleme ve bölütleme işlemleri özetlenmiştir. İşlem adımları aşağıdaki şekilde sıralanır.

- İlk çerçeve ile arkaplan modeli oluşturulur.
- Araç aday bölgeleri belirlenir. Belirli bir büyüklükten küçük hareket bölgeleri elenir.
- Araç bölgelerini oluşturan pikseller etiketlenir ve bölgelerin çevritleri çizilir. Her bir araç için temsil edici merkez noktaları belirlenir.
- Temsil edici merkez noktaları takip işlemine sokulur.
- Yeni gözlemlenen çerçeve ile arkaplan modeli güncellenir.
- Yeni bir araç gözlemi yok ise merkez noktası takip işlemi aracın yarattığı yörünge ve hız bilgilerini kaydeder. Yeni bir araç gözlemlendiğinde b adımından tekrar devam edilir.

5. OLAĞAN ARAÇ YOL MODELLERİNİN ÖĞRENİLMESİ

Doğal trafik ortamları üzerinde bulunan araçlardan, trafik kuralları ile belirlenen hareket modellerine uymaları beklenmektedir. Örneğin, otoyol üzerinde giden bir aracın beklenen hareketi, kendi şeridini koruması ya da kurallar dahilinde şerit değiştirerek yoluna devam etmesidir. Trafik görüntülerinde, araçların yarattıkları olağandışı durumlar hareket kurallarına uymayan ve nadir karşılaşılan olaylardır. Belirli trafik kurallarına ve kalıplarına uymayan araç hareketlerinin yakalanabilmesi için olağan araç hareketlerinden ve trafik akış modellerinden yararlanılabilir. Hareket eden araçların izledikleri yol modeli o aracın hareket davranışını göstermektedir. Araç, beklenen modeli takip ederek hareket ediyorsa normal bir hareket gerçekleştiriyor demektir. Beklenen yol modelinden uzaklaşan bir araç, olağandışı bir davranış gösteriyor anlamına gelebilir. Olağandışı anların belirlenmesi, araçların karşılaştıkları olayları da işaret edebilir.

Olağan davranış gösteren araçların sahip olduğu özellikler kullanılarak normal araç hareketi ve yörüngesi elde edilmektedir. Bu tür yörüngelerin kümelenmesiyle olağan yol modelleri elde edilebilir. Yol modeli öğrenmesi, sahne üzerinde hareket eden araçların oluşturdukları yörüngelerin biraraya getirilmesi ve kümelenmesi işlemidir. Araçların hareketleri boyunca bulundukları lokasyonları ve taşıdıkları hız, şekil, renk gibi karakteristik özellikleri elde edilerek hareketleri ile ilgili genel tanımlar yapılabilir.

Sahne üzerinde yeni bir araç hareketi gözlemlendiğinde, yeni gözlem yörüngesi ile öğrenilen olağan yol modelleri arasındaki farklılıklar değerlendirilerek, aracın davranışının olağan olup olmadığına karar verilir.

Genellikle, yörünge öğrenme işlemlerinde araçların sahne boyunca sahip oldukları görüntü koordinat bilgileri (x,y) ve birim zamandaki yer değişimleri yani hızları (v_x, v_y) veya gerçek dünya koordinat bilgileri (x,y,z) ve gerçek hızları kullanılır.

5.1 Yörünge tanımı

Bir aracın yörüngesine ait uzaysal ve zamansal bilgiler aşağıdaki şekilde ifade edilebilir.

$T_k = \{f_1, f_2, f_3 \dots f_n\}$: her bir araca ait gözlemlenen özellik vektörleri dizisi

$f_i = \{x_i, y_i, v_{xi}, v_{yi}\}_t$: t anındaki özellik vektörü, pozisyon ve hız bilgileri.

x_i, y_i : aracın görüntü üzerindeki koordinat bilgisi.

v_{xi}, v_{yi} : birim zamanda aracın ardışık iki çerçeve arasındaki yer değişimi.

Birim zamandaki yer değişimleri V_i , optik akış ile bulunan hareket vektörünün piksel/çerçeve büyüklüğü olarak tanımlanır ve Eşitlik (5.1) ile hesaplanır.


$$\begin{aligned} V_{xi} &= (x_{i,t} - x_{i,t-1})^2 \\ V_{yi} &= (y_{i,t} - y_{i,t-1})^2 \\ V_i &= \sqrt{V_{xi} + V_{yi}} \end{aligned} \quad (5.1)$$

Yörünge öğrenme işlemlerinde genellikle pozisyon ve hız bilgileri kullanılmaktadır. Sahne üzerinde bulunan araçlar aynı yolu izleseler dahi hızlarındaki olası farklılıklardan dolayı yolu birbirlerinden farklı sürelerde katedeceklerdir. Bu sebeple, yörünge öğrenme işlemi için araç yörüngelerinin aynı sürelerde olmaları beklenemez.

Sahne üzerinde bulunan araçlara ait yörüngeler, araçları temsil eden merkez özellik noktalarının zaman içerisinde takip edilmesi ile elde edilir.




Şekil 5.1 Araç ve üzerindeki merkez noktası



Şekil 5.2 Görüntü üzerindeki araç merkez noktasının x-y koordinatlarındaki konum değişimi grafiği

Tek bir araç üzerindeki merkez noktası takibi ile ilgili örnek Şekil 5.1’de gösterilmektedir. Ardışık çerçeveler üzerinde aracın yol boyunca bulunduğu konum bilgisi x-y koordinat düzleminde Şekil 5.2’de gösterilmiştir. Şekil 5.2’deki konum değişimi incelendiğinde, araç belli bir süre sabit hızla giderken, görüntünün üst kısmına yaklaştığında yavaşladığı görülmektedir. Bu süre zarfında, aracın birim zamanda yaptığı yer değişiminin azaldığı ve gözlem noktalarının aynı bölgede toplandığı görülmektedir. Şekil 5.1’deki aracın yer değişimleri ölçülerek birim zamandaki araç hız değişimi Şekil 5.3’te gösterilmiştir. Birim zamandaki hız değişimi ile aracın düzlem üzerinde katettiği mesafe piksel/çerçeve biriminde hesaplanmaktadır.




Şekil 5.3 Birim zamanda araçtaki hız değişimi




Şekil 5.4 Otoyol üzerinde araç ve araca ait merkez noktası

Tek araç ve tek özellik görüntüsüne başka bir örnek Şekil 5.4’te görülmektedir. Şekil 5.5’teki konum grafiğinde görüldüğü gibi, Şekil 5.4’teki araç sağ yöne doğru düzgün bir yörünge ile yoluna devam etmektedir. Aracın bu zaman aralığında göstermiş olduğu hızlanma ve yavaşlama hareketleri Şekil 5.6’daki hız değişimi grafiğinde görülmektedir.



Şekil 5.5 Aracın merkez noktasının x-y koordinatlarındaki yer değişimi




Şekil 5.6 Otoyol üzerindeki araca ait hız değişimi - zaman grafiği




Şekil 5.7 Otoyol üzerinde iki araç ve farklı yönlerdeki hareketleri

Şekil 5.6'da görüldüğü gibi, belli bir süre aynı hızla hareketine devam eden araç, 6. çerçeveden itibaren hızlanmakta, tekrar belli bir süre sabit hızla gitmekte ve tekrar hızlanmaktadır.

Otoyol görüntüleri incelendiğinde çok yönlü ve çok şeritli yollardaki araç hareketlerine Şekil 5.7'deki görüntü örnek olarak verilebilir. Kuzeye doğru sağ taraftan giden araç ve güneye doğru sol taraftan giden araç ilgilenilen nesnelerdir. Kırmızı çizgiler, araçların anlık hareket vektör büyüklüklerini göstermektedir.



Şekil 5.8 İki araç, farklı yönlerdeki hareketi ve koordinat düzleminde konum noktaları



Şekil 5.9 İki araç ve hız vektörleri grafiği

Birden fazla aracın izlendiği durumlarda her aracın anlık yörüngesinin çıkartılması o araca ait hareket davranışını belirlemede yardımcı olur (Şekil 5.8). Zaman ekseninde her araç farklı hareket özelliği gösterebileceğinden izledikleri yörüngeleri de farklı olabilir. Şekil 5.9'daki V_0 ve V_1 araçlarına ait hız-zaman grafiğine bakıldığında araçların hızları hakkında genel bir yorum yapılabilir. V_1 aracı hızlanan bir davranış gösterirken, V_0 yavaşlayan bir davranış göstermektedir.

İki boyutlu görüntüde perspektif ve projeksiyon analizi yapıldığında kameradan uzaklaşan araçların katettiği yol mesafeleri hakkında bilgi sahibi olunamayacağından (yol koordinat bilgisi bilinmediği durumlarda) derinlik (z-ekseni) bilgisine ihtiyaç duyulmaktadır. Bu durumda iki boyutlu düzlemden 3D koordinat bilgisinin çıkartılması gerekmektedir. 3D koordinat çıkarımı tezde kapsam dışında tutulmuştur.

5.2 Yörünge kümeleme

Kümeleme işleminin temel amacı, sınıflar arasındaki farklılığın ve sınıf içi benzerliklerin maksimum tutulmasıdır. Sahne üzerindeki araçların takibinden elde edilen yörüngeleri araç davranışlarının ortaya çıkartılabilmesi ve analizleri için çok önemli rol oynar. Hareket modelleme için en önemli işlem, sahne üzerinde gözlemlenen araç yörüngelerinin birbirlerine

benzer olağan yol modellerine kümelenmesidir. Bu sayede, sahnedeki olağan hareket kalıplarına ulaşılabilir. Doğal ortamda bulunan araçların hareket davranışları gözönüne alındığında yörüngeler iki farklı sınıfta toplanmaktadır. Bu sınıflar, araçların ortak hareketlerini içeren normal yörüngeler ve olağandışı davranış gösteren araçların yörüngeleri, yani anormal yörüngelerdir. Anormal davranış gösteren araçlar gözönüne alındığında, yörüngelerinin normal yol sınıflarından maksimum seviyede ayrılması olağandışılığın yüksek seviyede anlaşılabilirliğini sağlar. Bu sebeple, yörüngeler arasındaki yakınlık mesafeleri gözlemlenerek ya da yörüngelerin istatistiksel seri özellikleri değerlendirilerek gruplandırmalar yapılır.

Kümeleme işlemlerinde dikkat edilecek adımlar, benzerlik ölçümlerinin doğru tanımlanması, kümelerin zaman içerisinde güncellenebilir olması ve kümeleme sonucunun doğrulanmasıdır.

5.2.1 Genel yörünge kümeleme yöntemleri

Mesafe benzerlik tabanlı kümeleme teknikleri yörüngelerin karşılaştırılabilmesi için mesafe benzerlik metrik tanımlarından yararlanırlar. En yaygın kullanılan mesafe ölçümü Öklid mesafesidir. Aynı n süresindeki T_i ve T_j yörüngeleri arasındaki d_E Öklid mesafesi Eşitlik 5.2’de görüldüğü gibi hesaplanır.

$$d_E(T_i, T_j) = \sqrt{\sum_{k=1}^n (T_{i,k} - T_{j,k})^2} \quad (5.2)$$

Süreleri farklı, m ve n boylu ($m > n$) T_m ve T_n yörüngeleri arasındaki benzerlik hesaplaması, d_E Öklid mesafesi formülü Eşitlik (5.3)’teki şekilde genişletilerek yapılabilir.

$$d_E(T_i, T_j) = \frac{1}{m} \left(\sum_{k=1}^n d_E(T_{i,k}, T_{j,k}) + \sum_{k=1}^{m-n} d_E(T_{i,n+k}, T_{j,n}) \right) \quad (5.3)$$

Bu tür mesafe ölçümleri, zaman farkı gözetmeksizin birbirleriyle aynı hizada olan yörünge noktaları arasındaki ölçümlerde başarılı olmaktadır. Ancak, nesne hareketlerinde zamansal değişim hesaba katıldığında, yörünge noktaları arasında uzaysal eşleşmenin yanısıra zamansal eşleştirme de yapılması gerekmektedir. Bu amaçla, özellikle ses tanıma işlemlerinde kullanılan Dinamik Zaman Bükmesi yöntemi (Dynamic Time Warping – Myers, 1981) zaman veya hız olarak farklı sürelerdeki sinyaller arasındaki benzerlik mesafelerinin hesaplanmasında önemli yer tutar. Dinamik programlama ile eşleştirilen iki yörünge noktası arasında en kısa mesafe sağlanarak optimum hizalama sağlanır. Örneğin, aynı yolu farklı

hızlarda yürüyen iki kişinin oluşturduğu yörüngelerin benzerlik hesaplanmasında DTW kullanılması uygundur.

Diğer bir yörünge karşılaştırma ve nokta hizalama tekniği dinamik programlama ile yapılan LCSS (Bergroth, 2000) analizidir. Bu işlem, iki farklı dizi arasındaki en uzun ortak gözlemin bulunması ve eşleştirilmesine dayanır. X ve Y , özellik noktaları x_i ve y_i olan iki farklı yörünge için özyineli LCS fonksiyonu aşağıdaki şekilde tanımlanır.

$$\begin{aligned} X &= (x_1, x_2, \dots, x_m) \\ Y &= (y_1, y_2, \dots, y_n) \end{aligned} \quad (5.4)$$

$$LCS(X_i, Y_j) = \begin{cases} 0 \rightarrow \text{if } (i = 0) \parallel (j = 0) \\ (LCS(X_{i-1}, Y_{j-1}), x_i) \rightarrow \text{if } (x_i = y_i) \\ \max(LCS(X_i, Y_{j-1}), LCS(X_{i-1}, Y_j)) \rightarrow \text{if } (x_i \neq y_j) \end{cases}$$

Farklı sürelerdeki yörünge dizileri arasındaki benzerlik mesafesi için kullanılan yöntemlerden birisi de Hausdorff mesafesi ölçümüdür (Morris ve Trivedi, 2008). Ölçüm, farklı sürelerdeki kümeleri hedef alır, fakat ölçüm öncesinde sıralama yapılması yörünge parçacıkları arasında yanlış benzeştirmelere sebep olmaktadır. Örneğin, farklı yönlerde yürüyüş yapan iki insanın yarattığı yörüngeler bu tür bir probleme örnek olarak verilebilir. T_i ve T_j yörüngeleri arasındaki d_H Hausdorff mesafesi aşağıdaki şekilde tanımlanır.

$$\begin{aligned} d_H(T_i, T_j) &= \max(d_H(T_i, T_j), d_H(T_j, T_i)) \\ d_H(T_i, T_j) &= \max(\min_{f_{i,k}} d_E(f_{i,k}, f_{j,l})) \rightarrow \forall k, l \end{aligned} \quad (5.5)$$

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

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

Yinelenen optimizasyon kümeleme tekniği bu teknikler arasında en basit ve yaygın kullanılan yöntemdir. K-ortalama veya bulanık C-ortalama teknikleri temel olarak Öklid mesafesi kullanarak kümeleme işlemini gerçekleştirirler. Olağan yol modelleri için küme sayısı başlangıçta tanımlanmalı ve yörünge süreleri eşit verilmelidir. Küme sayısını kümeleme işlemini maksimum başarıya ulaştıracak şekilde seçmek ve doğrulamak tavsiye edilir.

Gerçek Zamanlı Adaptasyon kümeleme tekniğinde daha önceden elde edilmiş yörünge eğitim kümesine ihtiyaç duyulmamaktadır. Her yeni yörünge gözlemlendiğinde, kümeleme işlemi yeni verilerle güncellenmektedir. Özellikle, gerçek zamanlı sahnelerde hareket eden nesnelerin yörüngelerinin kümelenmesinde uygundur. Kümeleme öncesinde toplam küme sayısının belirtilmesine ve yeterli eğitim örneklerinin toplanmasına ihtiyaç duyulmamaktadır.


Hiyerarşik kümeleme teknikleri toplayıcı ve parçalayıcı olarak iki gruba ayrılırlar. İki teknikte gözlemlenen yörüngeleri aşağıdan yukarıya ya da yukarıdan aşağıya ağaç yapısında modelleyerek yörüngeler arasında benzerlik ilişkisi kurmaya çalışırlar. Kümeleme işlemlerinin başarısı ağaç oluşturulurken alınacak bölme ya da birleştirme kararlarına bağlıdır.

Öğretmensiz yörünge kümeleme tekniklerinden bir tanesi de bir çeşit yapay sinir ağı tekniği olan SOM'dur. Kohonen tarafından tanımlanan SOM yöntemi ile yörüngeler biçimleri değişmeden kümelenebilirler. Sinir ağlarının her bir çıkış düğümü bir olağan yol modeline karşılık gelir. Ağlar, yeni gözlemler ile sürekli güncellenebilir durumdadır. Karmaşık trafik sahneleri ele alındığında, sinir ağları yüksek oranda gözlem örneklerine ihtiyaç duyar. Genel olarak öğrenme süresinin uzun sürmesi, nöron ağırlıklarının ve öğrenme parametrelerinin atanmasındaki zorluklar bu yöntemin dezavantajı olarak görülürler.

İstatistiksel seri kümeleme işlemlerinde, her yörünge serisinin dinamik özellikleri HMM veya Dinamik Bayes ağları ile modellenenebilir. İstatistiksel rastgele işlemlere örnek olan araç hareketleri stokastik modeller ile tanımlanabilirler. İstatistiksel seri kümeleme çalışmalarına referans olarak (Saunier ve Sayed, 2006) çalışmaları verilebilir. HMM ile zaman serileri kümelemede en önemli düşünce, elde edilen gözlem dizilerinin kümeleme sonucunda elde edilecek modellere olan $P(\text{Gözlem}|\text{Model})$ olasılıklarının hesaplanarak küme üyeliklerinin bulunmasıdır.

5.2.2 HMM ve Gauss karışımı ile yörünge kümeleme

Bu tezde, olağan araç hareketlerinin yarattığı yörüngeler ile HMM ve Gauss karışımı yöntemleri kullanarak kümeleme işlemi gerçekleştirilmiştir. Kümeleme işlemi sonucunda, olağan yol akış modelleri elde edilmiştir. Şekil 5.10'da olağan yol modellerinin öğrenilmesi için uygulanan işlem adımlarının blok diyagramı görülmektedir.



Şekil 5.10 Olağan yol modellerinin öğrenilmesi adımları

Olağan yol modellerinin öğrenilmesi için ilk işlem, daha önceki bölümlerde detaylı anlatılan olağan araç yörüngelerinin toplanarak eğitim kümesinin oluşturulmasıdır. Eğitim yörüngelerinin toplanmasından sonra, HMM parametrelerinin seçimi gerçekleştirilmiştir. HMM parametrelerinin belirlenmesinden sonra, Gauss karışımı destekli Sürekli HMM ile öğrenme işlemi yapılmaktadır. Öğrenme işlemi sonucunda, olağan yol modellerine ulaşılır.


5.2.3 Yörünge veri kümesinin oluşturulması

Araçların sahne boyunca sahip oldukları yörünge bilgileri (x,y) ve hareketlerine ait hız özelliği (v) olağan yörünge eğitim kümesini oluşturan özellik vektörleridir.

Toplanan araç yörüngeleri, iki boyutlu (x,y) ve üç boyutlu (x,y,v) gözlem noktalarını içerecek şekilde tekrar düzenlenirler. Yörüngelerin iki farklı gözlem tipiyle öğrenme işlemine hazırlanması, daha sonraki bölümde bahsedilen olağandışı araç hareketlerinin belirlenmesinde rol oynamaktadır. (x, y) uzaysal gözlemler ile öğrenme işlemi gerçekleştirildiğinde, araçların sadece yörüngelerinden pozisyonel sapmaları belirlenebilirken, (x,y,v) ile gerçekleştirilen olağan yol modelleri öğrenme işlemi sonucunda, araçların hızlarından dolayı oluşabilecek olağandışı durumlar da yakalanabilmektedir. Bu nedenle, öğrenme işlemi iki farklı veri yapısı ile ayrı ayrı gerçekleştirilmiştir.

Özellik vektör dizilerinin boylarının eşit ya da farklı olması öğrenme işlemini etkileyen faktörlerden birisidir. Boy eşitleme ve vektör nicemlemede oluşan bilgi kaybı ve zaman kavramı için ek işlemler (dynamic time warping) farklı sürelerdeki yörüngeler ile eğitimi etkili kılan faktörler olarak göze çarpar. Trafik üzerinde bulunan araçların doğal davranışları değerlendirildiği zaman, eğitim işleminin farklı sürelerdeki yörünge dizileriyle yapılması gerekliliğini ortaya koyar. Aynı mesafeyi bir araç benzer yörüngeyi izleyerek t_1 zamanında alırken, diğer bir araç t_2 zamanında farklı bir hızla alabilmektedir. Bu davranış biçimi, araç koordinat bilgileri yanında hız ve ivme gibi özellikleri de katarak çoklu boyutlu vektörlerle çalışmayı şart koşar. Bu şekilde, tüm yörüngeyi ve araç karakteristiklerini eğitim işlemine sokabilme ve veri kaybının olmaması sağlanır. Bu yöntem anlık araç davranışının ortaya çıkartılmasında önemli role sahiptir. Farklı sürelerdeki yörüngelerin getirdiği avantajlar göz önüne alındığında bu tip yörüngeler ile eğitim kümelerinin oluşturulmasına karar verilmiştir.

Şekil 5.11’de deney ortamı üzerinde örnek eğitim kümesini oluşturan hareket yörüngeleri ve yörüngelerin kavşak modeli üzerindeki yansıtılması görülmektedir. Her farklı renkteki yörünge farklı araç hareketlerini göstermektedir.



Şekil 5.11 (a) Kavşak akış modeli eğitim yörüngeleri ve (b) kavşak modeli üzerindeki görüntüsü

5.2.4 Markov Modelleri

Saklı Markov Model ile gözlem dizilerinin kümelenmesine geçmeden önce genel Markov modelinin ve çözüm algoritmalarının tanımlanması faydalıdır. Olasılık teoreminde, Markov modeli, Markov özelliğine sahip stokastik model olarak tanımlanır. Markov özelliğinde, stokastik sürecin gelecek durumlarının durumsal olasılık dağılımı sadece şuan ki duruma bağlıdır. Bu özelliğe sahip süreçler Markov süreci olarak isimlendirilirler.

En genel kullanılan Markov modeller, Markov Zinciri ve Saklı Markov Modelleridir. Sistem

durumları tam gözlemlenebilir olan Markov özelliğine sahip ayrık zaman süreçleri Markov Zinciri olarak tanımlanır. Sistem durumları kısmen gözlemlenebildiğinde, model, Saklı Markov Model olarak tanımlanır (Rabiner, 1989).


5.2.4.1 Ayrık Markov süreci

N durumlu ve ayrık zaman diliminde Markov süreci düşünüldüğünde, sistemin bir durumdan diğer bir duruma geçmesi olasılığı (5.6)'da görüldüğü gibi önceki durumların ne olduğuna bağlıdır.

$$P(q_t = S_j | q_{t-1} = S_i, q_{t-2} = S_k, \dots) \quad (5.6)$$

Eğer sistemde, $t+1$ anındaki durum sadece bir adım önceki t anındaki duruma bağlı ise, bu tip modeller birinci derece Markov modeli olarak isimlendirilir ve Eşitlik (5.7) ve Şekil 5.12'de olduğu gibi gösterilir.

$$P(q_{t+1} = S_j | q_t = S_i, q_{t-1} = S_k, \dots) = P(q_{t+1} = S_j | q_t = S_i) \quad (5.7)$$



Şekil 5.12 Birinci derece Markov model örneği, B başlangıç, Ç çıkış durumu


Sistemin başlangıç durum olasılıkları (5.8)'de gösterilen π_i ile ifade edilir.

$$\pi_i = P(q_t = S_i), \sum_{i=1}^N \pi_i = 1 \quad (5.8)$$

Durumlar arası geçiş olasılıkları $A = [a(i, j)]_{N \times N}$ matrisi ile gösterilir (5.9).

$$\begin{aligned} a_{ij} &= P(q_{t+1} = S_j | q_t = S_i) \\ a_{ij} &\geq 0, \sum_{j=1}^N a_{ij} = 1 \end{aligned} \quad (5.9)$$

Şekil 5.13'te 3 durumdan oluşan Markov modeli örneği görülmektedir.



Şekil 5.13 3 durumdan oluşan Markov Modeli örneği

Ayrık Markov modellerde, gözlem dizisi $O = o_1 o_2 \dots o_T$ ve durum dizisi $Q = q_1 q_2 \dots q_T$ olarak tanımlandığında, gözlem dizisinin gerçekleşme olasılığı Eşitlik (5.10) ile hesaplanır. Tüm gözlem dizisinin meydana gelme olasılığını bulabilmek için durum geçişleri olasılıkları çarpılarak birleşik gözlem olasılığı bulunur.

$$P(O = Q | A, \pi) = \pi_{q_1} a_{q_1 q_2} \dots a_{q_{T-1} q_T} \quad (5.10)$$


5.2.4.2 Saklı Markov Modeli

Saklı Markov Modeli, herhangi bir t anında sistemin hangi durumda olduğu bilinmiyor iken saklı durumun yarattığı gözlemi ortaya çıkartır.

Bir ayrık Saklı Markov model aşağıda belirtilen elemanlar ile tanımlanır.

- $S = \{S_1, S_2, S_3, \dots, S_N\}$ Saklı durumlar, N : Saklı durumların sayısı
- $A = \{a_{ij}\}$ durum geçiş olasılıkları matrisi, $a_{ij} = P\{q_{t+1} = S_j | q_t = S_i\}$ $1 \leq i, j \leq N$, q_t : t anındaki durum
- $B = [b(j, m)] = P(O_t = o_i | q_t = S_j)$ gözlem olasılıkları matrisi
- $O = \{o_1, o_2, o_3, \dots, o_M\}$ gözlemler, M gözlem sayısı
- $\pi = \{\pi_i\}$, Başlangıç durum dağılımları, $1 \leq i \leq N$

Şekil 5.14'te Saklı Markov Modeli diyagramı görülmektedir.



Şekil 5.14 Saklı Markov Model örneği

Sistem herhangi bir S_i durumundayken, O_j gözlemlerinin oluşma olasılığı $b_j(m)$ ile ifade edilir. Sistemin olabileceği durumlar $(S_1, S_2, \dots, S_N)$ ve oluşabilecek gözlemler $\{o_1, o_2, \dots, o_M\}$ olarak tanımlandığında, durumlar ve gözlemler arasındaki bağıntı $N \times M$ boyutundaki $B = [b(j, m)]$ emisyon matrisi ile gösterilir (5.11).

$$b_j(m) = P(O_t = o_i \mid q_t = S_j)$$

$$b_j(m) \geq 0$$

$$\sum_{m=1}^M b_j(m) = 1$$

(5.11)

5.2.4.3 Saklı Markov Modelin üç temel problemi

Saklı Markov model ile aşağıdaki üç temel probleme çözüm bulunur.

- Değerlendirme (Evaluation) : Verilen bir O gözlem dizisinin bilinen λ saklı modele olasılıksal yakınlığının bulunması , $P(O \mid \lambda)$
- Kodçözme (Decoding) : λ ve O verildiğinde, O gözlem dizisini oluşturma ihtimali en yüksek olan durum dizisi Q_t 'nin bulunması, $P(Q \mid O, \lambda)$
- Öğrenme (Training) : Eğitim gözlem örnekleri verildiğinde λ Saklı Markov Model parametrelerinin tahmin edilmesi

Bu üç temel problemten, Öğrenme ve Değerlendirme çözümleri bu çalışmada olağan trafik akışlarının öğrenilmesi ve olağandışı araç hareketlerinin belirlenmesi kısımlarında önemli rol oynamaktadır. Çözümlerin uygulanma biçimleri bu bölümün sonunda ve ilerleyen bölümlerde detaylı olarak anlatılmaktadır.

Değerlendirme

Gözlem değerleri $O = \{o_1, o_2, \dots, o_M\}$ 'nın λ modeli üzerinde karşılık gelen N^M tane farklı saklı durum dizisi $Q = \{q_1, q_2, \dots, q_M\}$ olabilir. O gözlem dizisinin elde edilme olasılığı Eşitlik (5.12) ile hesaplanır.

$$P(O | \lambda) = \sum_{i=1}^q P(O, Q_q | \lambda), \text{ } q \text{ olası saklı durum dizisi sayısı} \quad (5.12)$$

Eşitlik (5.12)'deki çözüm, çok fazla olası saklı durum dizisi olabileceği için işlem karmaşıklığı açısından uygun değildir. Bu nedenle $P(O | \lambda)$ hesaplaması için İleri-Yön (forward) ve Geri-Yön (backward) algoritması kullanılır [10].

İleri-Yön algoritması işlem adımları aşağıda gösterilmektedir.

- Başlangıç değerlerinin atanması

$$\alpha_1(i) = \pi_i b_i(o_1), i = 1..N \quad (5.13)$$

- Yineleme

$$\alpha_{t+1}(j) = \left[\sum_{i=1}^N \alpha_t(i) a_{ij} \right] b_j(o_{t+1}), j = 1..N \quad (5.14)$$

- Sonlandırma

$$P(O | \lambda) = \sum_{i=1}^N \alpha_T(i) \quad (5.15)$$

Eşitlik (5.14)'teki yineleme adımında, $\alpha_t(i)$ ilk t gözlemi ve sistemin S_i durumunda olmasını, a_{ij} , sistemin S_i durumundan S_j durumuna geçişini, $b_j(o_{t+1})$ ise $t+1$ anında o_{t+1} gözleminin elde edilmesi olasılığını ifade eder. Eşitlik (5.15)'teki Sonlandırma adımında, her t anı için tüm saklı durumların α ileri değerleri toplamı, gözlemin model tarafından üretilme olasılığını verir.

İleri-Yön algoritması, gözlem dizilerinin olasılıklarını hesaplamada en yaygın kullanılan algoritma olmasına rağmen, olasılık hesaplamalarında Geri-Yön algoritması'ndan da faydalanılmaktadır. Geri-Yön algoritmasında, $\beta_t(i)$ geri değişkeni, gözlem dizisinde geriye doğru ilerleyerek özyineli şekilde hesaplanır. $\beta_t(i)$ geri değişkeni Eşitlik (5.16)'da görüldüğü gibi t anında S_i durumunda olma ve $(o_{t+1} \dots O_T)$ kısmi gözlemini elde etme olasılığını gösterir.

$$\beta_t(i) = P(o_{t+1} \dots o_T \mid q_t = S_i, \lambda) \quad (5.16)$$

Geri-Yön algoritmasının işlem adımları Eşitlik 5.17-5.19'da gösterilmektedir.

- Başlangıç değerlerinin atanması

$$\beta_{t-1}(i) = \sum_{j=1}^N a_{ij} b_j(o_T), i = 1 \dots N \quad (5.17)$$

- Yineleme

$$\beta_t(i) = \sum_{j=1}^N a_{ij} b_j(o_{t+1}) \beta_{t+1}(j), i = 1 \dots N, t = T-1, T-2, \dots, 1 \quad (5.18)$$

- Sonlandırma

$$P(O \mid \lambda) = \sum_{i=1}^N \pi_i b_i(o_1) \beta_1(i) \quad (5.19)$$

Eşitlik (5.18)'deki yineleme adımında, a_{ij} , sistemin S_i durumundan N olası S_j durumuna geçişini, $b_j(o_{t+1})$, S_j durumunda iken o_{t+1} gözleminin elde edilmesi olasılığını ifade eder.

Sonuç olarak, İleri-Yön ve Geri-Yön algoritmaları O gözlem dizisi için aynı $P(O)=P(o_1 o_2 \dots o_T)$ birleşik olasılık sonucunu göstermelidir.

Kod Çözme (Decoding)

Saklı Markov modelin çözdüğü ikinci problem, gözlem dizisi $O = o_1 o_2 \dots o_T$ verildiğinde, bu gözlem dizisini oluşturma ihtimali en yüksek olan saklı durum dizisi $Q = q_1 q_2 \dots q_T$ 'yi bulmaktır. Bu işlem için iki farklı yaklaşım kullanılmaktadır. Birinci yaklaşım sonsal kodçözme (posterior decoding), saklı model tarafından gözlem açığa çıkarıldığı anda en olası saklı modelin seçilmesi ile gerçekleştirilir (Shokhirev, 2010).

Verilen O gözlem dizisi için, sistemin t anında S_i saklı durumda olma olasılığı Eşitlik (5.20)'deki $\gamma_t(i)$ ile gösterilir.

$$\gamma_t(i) = P(q_t = S_i \mid O, \lambda) \quad (5.20)$$

$$\gamma_t(i) = \frac{\alpha_t(i) \beta_t(i)}{P(O)}, i = 1 \dots N, t = 1 \dots T$$

Her t anında, olabilirlik olasılığı en yüksek olan S_t saklı modeli seçilerek durum dizisi oluşturulur (5.21).

$$S_t = q(t) = \arg \max \gamma_t(i) \quad (5.21)$$

Sonsal kodçözme yöntemi, her durumdan her duruma geçişin mümkün olduğu Saklı Markov Modellerinde (Ergodic HMM) başarılı çalışmaktadır (Shokhirev, 2010). Ancak, farklı yapıdaki bazı geçişlerin izin verilmediği modellerde kurallara aykırı sonuçlar üretmektedir. Bu nedenle, hesaplara durum geçiş olasılıklarını katan Viterbi algoritması (Rabiner, 1989) önerilmiştir.

Viterbi algoritması, verilen O gözlem dizisi için saklı durum gözlem olabilirliğini maksimize eden en iyi durum serisinin seçilmesini hedefler.

(5.22)'de verilen $\delta_t(i)$ değişkeni, t anına kadar olabilirliği maksimum olan durum dizisini ifade eder ve t anında S_t durumuna erişilir.

$$\delta_t(i) = \max\{P(q_1 q_2 \dots q_{t-1} q_t = S_i, o_1 \dots o_t \mid \lambda)\} \quad (5.22)$$

Viterbi algoritması işlem adımları aşağıda görülmektedir.

- Başlangıç değerlerinin atanması

$$\begin{aligned} \delta_1(i) &= \pi_i b_i(o_1), i = 1..N \\ \psi_1(i) &= 0 \end{aligned} \quad (5.23)$$

- Yineleme

$$\begin{aligned} \delta_t(j) &= \max_i [\delta_{t-1}(i) a_{ij}] b_j(o_t) \\ \psi_t(i) &= \arg \max_i [\delta_{t-1}(i) a_{ij}] \end{aligned} \quad (5.24)$$

- Sonlandırma

$$\begin{aligned} path^* &= \max_i [\delta_T(i)], i = 1..N \\ q_T^* &= \arg \max_i [\delta_T(i)] \end{aligned} \quad (5.25)$$

- Geriye gitme

$$q_t^* = \psi_{t+1}(q_{t+1}^*), t = T-1, T-2, \dots, 1 \quad (5.26)$$

Öğrenme (Training)

Öğrenme işlemi, gözlem dizileri kullanarak Saklı Markov Model parametrelerinin $\lambda=(A,B,\Pi)$ tahmin edilmesidir. $O = o_1o_2...o_T$ gözlem dizisi olmak üzere, t anında S_i ve $t+1$ anında S_j durumlarında olma olasılığı $\xi_t(i,j)$ birleşik olasılık parametresi olarak ifade edilir (5.27).

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

$$\xi_t(i, j) = \frac{\alpha_t(i)a_{ij}b_j(o_{t+1})\beta_{t+1}(j)}{\sum_{i=1}^N \sum_{j=1}^N \alpha_t(i)a_{ij}b_j(o_{t+1})\beta_{t+1}(j)} \quad (5.27)$$

Saklı Markov Modellerde Baum-Welch Beklenti Maksimizasyonu algoritması kullanılarak model parametreleri hesaplanır (Welch, 2003). Baum-Welch algoritması adımları aşağıda verilmiştir.

- Başlangıç $\lambda=(A,B,\Pi)$ modeli seçilerek, $\alpha_t(i)$, $\beta_t(i)$, $\xi_t(i,j)$ ve $\gamma_t(i)$ değişkenleri hesaplanır.
- Hesaplanan $\xi_t(i,j)$ ve $\gamma_t(i)$ değerleri ile $\lambda=(A,B,\Pi)$ model parametreleri Eşitlik (5.28) ile güncellenerek λ_{yeni} elde edilir .

$$\bar{\pi}_i = \gamma_1(i), i = 1..N$$

$$\bar{a}_{ij} = \frac{\sum_{t=1}^{T-1} \xi_t(i, j)}{\sum_{t=1}^{T-1} \gamma_t(i)}, i = 1..N, j = 1..N \quad (5.28)$$

$$\bar{b}_j(k) = \frac{\sum_{t=1}^T \gamma_t(j) \mid (o_t = o_k)}{\sum_{t=1}^T \gamma_t(j)}, j = 1..N, k = 1..M$$

- $\text{Log}[P(O \mid \lambda_{yeni})] > \text{Log} [P(O \mid \lambda)]$ olduğu sürece ilk adıma dönülür. Değilse, öğrenme işlemi tamamlanır.

5.2.4.4 Sürekli Saklı Markov Modeller

Araçların hareket ettikleri düzlem üzerinde kat etmiş oldukları mesafe ve sahip oldukları dinamik karakteristik özellikler sürekli değişkenlere örnek olarak verilebilir. Bu özellikten yola çıkarak araçların göstermiş olduğu dinamik karakteristikleri ayrık modeller yerine sürekli Markov Modeli ile temsil etmek daha uygundur. Bu amaçla, HMM'deki emisyon dağılımları ya da gözlem olasılıkları Gauss karışımı olarak ifade edilir. Bu model ile araç özellik

vektörleri hiçbir vektör nicemleme işlemine sokulmadan ve süre eşitleme işlemine gerek duyulmadan Saklı Markov Modeline gözlem dizileri olarak girilir. Bu yöntem, önerilen tez çalışmasında sahne üzerindeki araç yörüngelerinin kümelenmesi ve olağan yol modellerinin belirlenmesi işlemlerinde kullanılmıştır.

Sürekli Saklı Markov Modellerde, modelin ürettiği gözlemlerin olasılık yoğunluk fonksiyonlarının (5.29)'da verilen Gauss tipi normal dağılıma uygun olduğu varsayılmıştır.

$$\eta(o, \mu, \Sigma) = \frac{1}{\sqrt{(2\pi)^{|\Sigma|}}} e^{-\frac{1}{2} \frac{(o-\mu)^2}{\Sigma}} \quad (5.29)$$


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

$b_j(o_t)$, t anında S_j durumunun o_t gözlemini üretme olasılığını verir.

5.2.4.5 Sürekli Saklı Markov ile olağan yol modellerinin belirlenmesi

Sahne üzerindeki olağan yol modellerinin belirlenebilmesi için kümeleme işlemlerinde kullanılan model parametreleri aşağıdaki şekilde tanımlanmıştır.

- $T_k: \{f_1, f_2, f_3, \dots, f_n\}$, k tane araç için n tane gözlem, n değişken yörünge boyu
- $f_i: \{x_i, y_i, vx_i, vy_i\}_t$, t anındaki özellik vektörü, x_i, y_i görüntü koordinatları üzerindeki araç pozisyonu, vx_i, vy_i hız değişkenleri (araçların birim zamanda yapmış oldukları yer değişimi miktarı)
- $S: \{S_1, S_2, S_3, \dots, S_N\}$ saklı durumlar, N : Saklı durumların sayısı
- M : Her bir saklı durum için Gauss bileşeni sayısı
- $A = \{a_{ij}\}$ Durum geçiş olasılıkları matrisi, $a_{ij} = P\{q_{t+1} = S_j \mid q_t = S_i\}$ $1 \leq i, j \leq N$, q_t : t anındaki durum
- $B = \{o_t, \mu_j, \Sigma_j\}$ Gözlem olasılıklarının dağılımı, o_t , t anındaki gözlem, μ_j ve Σ_j , S_j durumundaki ortalama ve kovaryans matrisi
- $\Pi = \{\pi_i\}$ Başlangıç durum dağılımları, $1 \leq i \leq N$
- Nr_iter : Beklenti Maksimizasyonu işlemi için iterasyon sayısı
- $Stop$: Beklenti Maksimizasyonu işlemi ile öğrenmenin tamamlanacağı yakınsama noktası
- $\lambda_m = \{A_m, B_m, \Pi_m\}$, öğrenilen Saklı Markov Model, m adet olağan yol modeli



Şekil 5.15 HMM ve Gauss Karışımı yapısının örnek kavşak modeli üzerinde gösterimi

Şekil 5.15'te HMM ve Gauss karışımı yapısının örnek kavşak modeli üzerinde gösterimi görülmektedir. Örnek kavşak modelinde, giriş-çıkış ile gösterilen yol modeli, 3 farklı saklı durum ve her duruma karşılık gelen 3 farklı $\eta(\mu_k, \Sigma_k)$ Gauss bileşeni ile temsil edilmiştir.

Kavşak üzerindeki her olağan yol modelinin öğrenilebilmesi için Beklenti Maksimizasyonu algoritmasından yararlanılmaktadır. Algoritma adımları aşağıda görüldüğü gibidir.

- Her S_j saklı durumu için k başlangıç Gauss modelleri $\eta(\mu_k, \Sigma_k)$ seçilir. $k = 1 \dots K$ eşit ilk olasılık değerleri $P(q_k) = 1 / K$ olarak atanır.
- Başlangıç $\lambda_m = (A, B, \Pi)$ modeli seçilerek, $\alpha_t(i)$, $\beta_t(i)$, $\xi_t(i, j)$ ve $\gamma_t(i)$ değişkenleri hesaplanır.
- Beklenti adımı: Her O_t gözleminin $q_j = t$ saklı durumunda olma olasılığı hesaplanır.

$$P(q_t = j | o_t, \lambda_m) = \frac{P(q_t = j | \lambda_m) \cdot p(o_t | q_t = j, \lambda_m)}{P(o_t | \lambda_m)} \quad (5.30)$$


- Maksimizasyon adımı: λ_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 güncellenir. Yeni değerler ile $\lambda_{m,yeni}$ modeli elde edilir.

$$\begin{aligned}
\bar{\mu}_j &= \frac{\sum_{k=1}^n \sum_{t=1}^{T_k} \gamma_t^k(j) \cdot o_t^k}{\sum_{k=1}^n \sum_{t=1}^{T_k} \gamma_t^k(j)} \\
\bar{\Sigma}_j &= \frac{\sum_{k=1}^n \sum_{t=1}^{T_k} \gamma_t^k(j) (o_t^k - \bar{\mu}_j)(o_t^k - \bar{\mu}_j)^T}{\sum_{k=1}^n \sum_{t=1}^{T_k} \gamma_t^k(j)} \\
\bar{a}_{ij} &= \frac{\sum_{k=1}^n \frac{1}{P_k} \sum_{t=1}^{T_{k-1}} \alpha_t^k(i) a_{ij} b(o_{t+1}^k) \beta_{t+1}^k(j)}{\sum_{k=1}^n \frac{1}{P_k} \sum_{t=1}^{T_{k-1}} \alpha_t^k(i) \beta_t^k(i)}, i = 1..N, j = 1..N
\end{aligned} \tag{5.31}$$


- e. $\text{Log}[P(O | \lambda_{m,yeni})] > \text{Log}[P(O | \lambda_m)]$ olduğu sürece c adımına dönülür. Değilse, öğrenme işlemi tamamlanır.

Saklı Markov modelleri ile ilgili daha detaylı bilgi için (Rabiner, 1989) incelenebilir.

Öğrenme işlemi sonucunda olağan trafik akışını ifade eden m adet λ_m yol modeli elde edilir. m yol modeli sayısı kavşak modeli üzerinde bulunan giriş-çıkış bölgelerinin sayısına göre elle belirlenmiştir.



(a)



(b)

Şekil 5.16 (a) Öğrenme işleminde elde edilen olağan yol modellerinin kavşak üzerinde yansıtılması ve (b) kavşak giriş (G) – çıkış (Ç) noktaları.

Her λ_m 'e ait Gauss bileşenlerinin μ ortalama değerlerinin koordinat düzleminde birleştirilmesiyle, olağan yol modelini oluşturan yörüngeler elde edilir. Şekil 5.16(a)'daki kavşak modelinde 4 adet yol modeli ve bu modellere ait yörüngeler görülmektedir. Yol modellerini gösteren olağan yörüngeler farklı renkler ile kavşak düzlemi üzerinde

gösterilmiştir. Her model için bir adet giriş ve çıkış noktası atanır. Yol modellerine ait giriş-çıkış noktaları Şekil 5.16(b)'de şekilde gösterilmiştir.

Bütün yol modelleri aynı saklı Markov parametreleri ile öğretilmiştir. Bu parametreler, saklı durum sayısı, Gauss karışım sayısı, iterasyon ve yakınsama sayılarıdır. Saklı durum sayısı kavşak üzerinde bulunan bölgelere göre gözlemle belirlenmiştir. Kavşaklarda genellikle giriş, orta ve çıkış bölgeleri bulunduğundan (Cano vd., 2009), her bölge için bir adet saklı durum trafik karakteristiğini yansıtmaya yeterli olmaktadır. Saklı durum ve Gauss karışım sayıları deneyler sırasında elde edilen başarılarla göre değerlendirilmiş ve testler sırasında üç olarak atanmıştır.

5.3 Bölüm özeti

Bu bölümde, Sürekli Saklı Markov Model kullanımı ile olağan araç yol modellerinin öğrenilmesi işlemleri anlatılmıştır. Öğrenme süresince yapılan işlemler sırası ile aşağıda belirtilmiştir.

- Araç takip işlemleri sonucunda olağan davranış gösteren araçlara ait yörüngeler ve anlık hız değerleri eğitim kümesi elde edilir.
- Araç yörüngeleri ve anlık hız değerleri eğitim kümesini kullanarak Baum-Welch Beklenti Maksimizasyonu algoritması yardımıyla olağan araç yol modelleri elde edilir.


6. OLAĞANDIŞI ARAÇ HAREKETLERİNİN BELİRLENMESİ

Sahne üzerinde olağan davranış gösteren araçların yörüngelerinden elde edilen olağan yol modelleri kullanılarak aynı sahne üzerinde gözlemlenecek yeni araçların zaman içerisindeki hareket davranışları analiz edilebilir. Araç hareketlerinin sınıflandırılması, kısmi araç hareket gözlem serilerinin Maksimum Log-olabilirlik değerlerinin her yol modeline olan benzerliğinin değerlendirilmesi ile yapılmıştır. Bu bölümde, sahne üzerindeki kısmi araç hareketlerinin gözlemlenerek Maksimum Log-olabilirlik yardımı ile olağan ve olağandışı davranan araçların belirlenmesi ve olağandışı hareketlerin sınıflandırılması anlatılmaktadır.

6.1 Kısmi araç hareketi gözlemlenme

Sahne üzerinde bulunan araçları temsil eden merkez noktalarının takibinden elde edilecek kısmi hareket özellikleri araçların anlık davranışlarını belirlemede kullanılmaktadır. Takip süresince her çerçeveden elde edilen araç pozisyon ve hız bilgileri ile örnekleme yapılmaktadır. Kısmi araç takibi ve hareket sınıflandırması, Şekil 6.1’de görülen bağımsız ardışık kısmi hareket gözlem yöntemi ile gerçekleştirilmiştir. Ardışık kısmi araç hareketleri $o_1, o_2, \dots, o_P$ birbirlerinden bağımsız olarak ele alınmış ve bu bağımsız gözlemler kullanılarak hareket sınıflandırması yapılmıştır.

w : Pencere boyutu



Şekil 6.1 Bağımsız ardışık kısmi hareket gözlem yöntemi

o_p = kısmi gözlem dizisi $\{f_i\}$, $1 < i \leq w$, w pencere boyu, $1 < p \leq P$, P toplam kısmi gözlem sayısı.

$f_i = \{x_i, y_i, v_{xi}, v_{yi}\}_t$: aracın t anındaki konumu ve $[t-1 \ t]$ süreleri arasında yaptığı yer değişimini göstermektedir.

Şekil 6.2’de kısmi gözlem yöntemlerinin doğal ortam görüntüsü üzerinde uygulanması görülmektedir. Bu çalışmada, mevcut veri kümelerindeki görüntü süreleri ve çerçeve sayıları dikkate alınarak pencere uzunluğu 3 olarak kabul edilmiştir.



Şekil 6.2 Anlık araç hareketlerinin bağımsız kısmi gözlemler ile gösterilmesi

Kısmi hareket değerlendirmede seçilen pencerenin boyu olağandışı davranışların oluşma anının yakalanmasında ve olay şiddetlerinin ortaya çıkartılmasında önemli rol oynamaktadır. Bu konuda detaylı bilgi Bölüm 7.1’de anlatılmaktadır.

6.2 Maksimum Log-olabilirlik

$O_i = \{o_1, o_2, o_3, .. o_P\}$, i . araç için gözlemlenen kısmi özellikler, P , i . araca ait toplam kısmi gözlem sayısı,

λ_j : olağan yol modelleri, $\{A_j, B_j, \Pi_j\}$, $1 \leq j \leq m$, m , yol modelleri sayısı olmak üzere;

Öğrenilen λ_m HMM’ye göre kısmi gözlem serilerinin birleşik olabilirlikleri (joint probability) Eşitlik (6.1)’de görüldüğü gibi hesaplanır.

o_i kısmi gözlemin olabilirlik değeri :

$$P(\lambda_j | o_p) = \prod_{i=1}^w \frac{P(f_i^p | \lambda_j)P(\lambda_j)}{\sum_{j=1}^m P(f_i^p | \lambda_j)P(\lambda_j)}, j = 1, 2, \dots, m, \quad p = 1, 2, \dots, P \quad (6.1)$$

Birleşik olabilirlik, gözlem serilerinin ardışık olasılık çarpımı olduğundan maksimize edilmesi zordur. İlerleyen aşamalarda bu değer yerine olasılık değerinin logaritmik karşılığı, başka bir ifadeyle, logaritmik olabilirliği (log-likelihood) kullanılmaktadır. Log-olabilirlik değeri kullanıldığında birleşik olasılık hesaplamasındaki ardışık çarpma işlemi Eşitlik (6.2)’deki gibi toplama işlemine dönüşür.

$$P(o_p | \lambda_j) = \prod_{i=1}^w p(f_i^p | \lambda_j) \Leftrightarrow \log p(o_i | \lambda_j) = \log \prod_{i=1}^w p(f_i^p | A_j, B_j(\mu, \Sigma), \pi_j) = \sum_{i=1}^w \log p(f_i^p | \lambda_j) \quad (6.2)$$

6.3 Araç hareket analizi

Hareket analiz araştırmalarının ve uygulamalarının ana hedefi olağandışı davranan araçların yakalanması veya olağandışılık riski oluşan durumların gerçekleşmeden önlenmesidir. Örneğin, trafik sahnesi ele alındığında, hep aynı yönde gidilmesi zorunlu olan bir yolda, aniden sağa dönüş yapan ya da yoldan çıkarak yörünge değişimi gözlemlenen araç olağandışı davranış gösteriyor denebilir. Yeni gözlemlenen araç hareketleri çevrimiçi ve çevrimdışı olarak iki farklı şekilde incelenmektedir.

6.3.1 Çevrimdışı hareket analizi

Bu tür analizlerde, sahne üzerinde değerlendirmesi yapılan araçların sahneden çıktıktan sonra veya sahne üzerinde uzun süre durması durumunda kümülatif olarak toplanan hareket gözlemlerinin tek seferlik değerlendirilmesi yapılmaktadır. Temel hedef sahnede bir olayın gerçekleşip gerçekleşmediğinin öğrenilmesidir. Çevrimdışı işlemlerde araçların yarattığı olay anlarının yakalanmasından daha çok, oluşan olayların sonradan değerlendirilmesi hedeflenir.

Sahne üzerinde bulunan her aracın kümülatif davranışı aşağıdaki şekilde değerlendirilir.


- $O_i = \{o_1, o_2, o_3, .. o_p\}$, i . araç için gözlemlenen tüm özellikler, $1 \leq i \leq nn$, nn , sahne üzerindeki toplam araç sayısı
- λ_j : yol modelleri, $\{A_j, B_j, \Pi_j\}$, $1 \leq j \leq m$, m , yol modelleri sayısı
- Γ_j : her yol modeli için normal davranış log-olabilirlik akış eşik değeri olmak üzere;

Eğer gözlemlenen araç hareketinin kümülatif eksi (-) log-olabilirlik değeri, $\log[P(\lambda_j | O_i)]$, her yol modeline ait eşik log-olabilirlik aralıklarından (Γ_m) küçük ise araç hareketi olağandışı hareket olarak tanımlanır. Her araca ait O_i kümülatif gözlemin olasılık değerinin λ_j yol modeline benzerliği (6.3)'teki eşitlik ile bulunur.

$$P(\lambda_j | O_i) = \frac{P(O_i | \lambda_j)P(\lambda_j)}{\sum_{j=1}^m P(O_i | \lambda_j)P(\lambda_j)}, j = 1, 2, \dots, m, i = 1, 2, \dots, nn \quad (6.3)$$

6.3.2 Çevrimiçi hareket analizi

Hareket halindeki araçların beklenen yol modellerinden farklı hareket etmeleri sonucunda hareketlerinin tümüyle olağandışı olarak sınıflandırılması çevrimiçi hareket analizi hedefleyen sistemler için eksik kalmaktadır. Çevrimiçi araç hareket analizi işlemlerinde temel hedef, araçların olağandışı davrandığı anın yakalanması ve anlık davranışlarının tanımlanmasıdır. Ayrıca, gözlemlenen hareketlerin t süre sonrası canlandırılarak araçların zaman içerisindeki davranışları tahmin edilebilir. Örneğin, Şekil 6.3'te görülen trafik sahnesi göz önüne getirildiğinde, kavşaktaki trafik ışıklarına yaklaşan bir araç sağa veya sola dönebilir, veya bulunduğu şeridi takip ederek yoluna devam edebilir. Çevrimiçi hareket analizi ile anlık olarak aracın dönüş yaptığı belirlenebilir veya araç kavşağa yaklaşmadan t süre sonraki hareketi olasılıksal yaklaşımla tahmin edilerek gelecekteki hareketi belirlenebilir (Morris ve Trivedi, 2008).



Şekil 6.3 Araç hareket davranışı tahmin etme (Morris ve Trivedi, 2008)

Kısmi gözlemler kullanılarak çevrimiçi hareket analizi aşağıdaki şekilde yapılır (Morris ve Trivedi, 2008).

$$\lambda^* = \arg \max_j P(\lambda_j | w_t F_{t+k}) \quad (6.4)$$

F_{t+k} , t anına kadar elde edilen gözlemler ve k adım sonraki tahmin edilen yörüngeleri, w_t pencere fonksiyonunu gösterir. λ^* , anlık olarak gözlemlenen araç hareketlerinin en yakın benzediği yol modelini göstermektedir.

Herhangi bir sahne üzerinde gözlemlenen araçların birbirleriyle olan veya olabilecek konumsal ve zamansal etkileşimlerinin bulunması olay belirleme ve tanımlama çalışmalarının

en önemli hedeflerinden birisi olmuştur. Yüksek seviye olay tanımlamaları, araçların bireysel ya da çoklu yapmış oldukları olağandışı davranışları kapsar. Trafik sahnesi örneği göz önüne getirildiğinde, araç hareketlerinin doğası gereği, tek bir araç olağandışı bir olay yaratabileceği gibi birden fazla aracın karıştığı olaylar da gözlemlenebilir. Sahne üzerinde olağandışılık yaratan araçların tamamının belirlenmesi olay tanımlama başarısını arttıracaktır. Ayrıca, hareket tahmini bölümünde de bahsedildiği gibi, zamansal ve pozisyonel olarak araçların gelecekteki olası davranışlarının tahmin edilebilmesi, olası araç etkileşimlerini veya çarpışmalarını engelleyebilir.

Bu çalışmada, her iki hareket analizi işlemi de kullanılmıştır. Çevrimdışı hareket analizi, bütün sahne ve üzerindeki araçların hareketleri incelendikten sonra olay analizi adımlarında kullanılmış, Çevrimiçi hareket analizinden, anlık olağandışı olay anlarının yakalanması ve karşılaşılan olay etkilerinin incelenmesi adımlarında faydalanılmıştır.

6.4 Kısmi araç hareketleri sınıflandırma

Araçların hareketleri boyunca gösterecekleri olağan ya da olağandışı davranışların belirlenmesi hareket sınıflandırmanın temel amacıdır. Hareketler olağan ve olağandışı olmak üzere iki gruba ayrılır. Olağan hareketler, araçların öğrenilen yol modellerine maksimum seviyede benzeyerek yarattıkları hareketlerdir. Sahneye giriş yapan araç, beklenen yörüngesini takip ederek sahneden çıkış yapar. Olağandışı anlık hareketler, araçların öğrenilen yol modellerine belli seviyedeki eşik değerinden daha düşük benzerlik gösterdiği durumlarda ortaya çıkar.

Bir aracın hareket durum sınıfını bulabilmek için maksimum koşullu olasılık hesaplamasından yararlanılır. Bir araca ait kısmi yörünge o_i gözleminin öğrenilmiş m adet λ_j yol modeline benzeme olasılığı $P(\lambda_j | o_i)$ Bayes teoremi kullanılarak aşağıdaki şekilde hesaplanır.

- o_i : kısmi gözlemlenen özellikler, $1 \leq i \leq P$
- λ_j : olağan yol modelleri, $\{A_j, B_j, \Pi_j\}$, $1 \leq j \leq m$,

$$P(\lambda_j | o_i) = \frac{P(o_i | \lambda_j)P(\lambda_j)}{\sum_{j=1}^m P(o_i | \lambda_j)P(\lambda_j)}, j = 1, 2, \dots, m \quad (6.5)$$

Kısmi gözlem o_i için $\log [P(\lambda_m | o_i)]$ log-olabilirliğini maksimum sağlayan yol modeli kısmi gözlemin ait olduğu yol modelini ifade eder. Kısmi gözlem ile elde edilen log-olabilirlik, herhangi bir yol modeli için önceden belirlenmiş eşik değerinin üzerindeyse, bu kısmi gözlem

olağandışı araç hareketi olarak ifade edilir. Olağandışı hareketin gözlemlendiği andan itibaren aracın anormal hareketi ve olası kaza olayı incelenir. Koşullu olasılıkların hesaplanması, HMM özelliklerinden birisi olan Değerlendirme işlemi için İleri-Yön ve Viterbi algoritmaları (Rabiner, 1989) ile gerçekleştirilmiştir.

Olağandışı araç aktivitelerin belirlenmesi gözlem uygulamalarının en önemli hedeflerinden birisidir. Doğal ortam üzerinde araçların olağandışı hareketleri nadir gerçekleşen olaylar olduğundan olağan yol modellerinden faydalanılarak olağandışı durumlar yakalanır. Olağandışı araç hareketleri eşik değerleri kullanılarak aşağıdaki özellikler ile belirlenir.

- Araçların şimdiki ve geçmiş hareketi boyunca gözlemlenen hareket özellikleri
- Araç gözlemlerinin her yol modeline olan maksimum benzerliği
- Her yol modeli için normal akış log-olabilirlik eşik değeri, Γ_m

Eğer gözlemlenen kısmi araç hareketi, $\log [P(\lambda_m | o_i)]$, (6.6)'da gösterildiği gibi her olağan yol modeline atanmış eşik değerlerinden küçük ise nesne hareketi olağandışı hareket olarak tanımlanır.

$$\log [P(\lambda_m | o_i)] < \Gamma_m \quad (6.6)$$

6.4.1 Sınıflandırma eşik değerlerinin belirlenmesi

Yol modellerine ait log-olabilirlik eşik değerleri (Γ_m), sahne hareket karakteristiklerine ve deney sonuçlarına göre seçilmektedir. Yol modelleri öğrenme aşamasında, olağan araç hareketleri kısmi gözlemler ile değerlendirilerek model eşik değerleri belirlenmektedir. Her modeli en iyi yansıtan eşik değerleri test aşamasında kullanılmaktadır.

6.4.2 Kavşak üzerindeki hareket değişimi durumları


Sahne üzerinde bulunan araçların anlık kısmi log-olabilirlik değerleri, araçların hareketleri boyunca öğrenilen yol modellerine olan yakınlıklarını ve olağandışı durumlarda sapma derecelerini belirlemede kullanılmaktadır.

6.4.2.1 Olağan araç hareketleri


Kavşak üzerinde bulunan araçlar farklı olağan durumlarda hareketlerine devam edebilirler. Bu bölümde, kavşak üzerinde sıklıkla gözlemlenen olağan hareket tipleri, log-olabilirlik değerleri ve araçların bulundukları yol modellerinin değişimi farklı görüntüler ile anlatılmıştır.

- Aracın yörüngesinden sapmadan yoluna devam etmesi

Olağan araç hareketlerinden en yaygını, araçların bulundukları yol modeli üzerinde sapma yaşamadan hareketlerine devam etmeleri ve sahneden uzaklaşmalarıdır. Bu şekilde olağan davranış gösteren bir aracın gidişatı Şekil 6.4(a)'da görülmektedir. Şekilde görüldüğü üzere, araç λ_1 yol modeline en yakın benzerlik göstererek hareketine devam etmektedir. Aracın seyahati süresince anlık kısmi log-olabilirlik değerlerinin, λ_1 yol modeli eşik değeri I_1 'den büyük olduğu görülmektedir (Şekil 6.4(b)). Diğer yol modelleri ile yakınlıkları değerlendirildiğinde, araç herhangi bir sapma gerçekleştirmeden sahneden çıkmaktadır.




(a)



(b)

Şekil 6.4 (a) Olağan davranan bir aracın izlediği yörünge ve yol modelleri ve (b) araç hareketine ait maksimum log-olabilirlik değişimleri.



Şekil 6.5 Olağan davranan aracın zaman içerisinde bulunduğu yol modelleri


Şekil 6.5'te görülen grafikte, aracın hareketi boyunca oturduğu modelin (1. max yol modeli) yanı sıra 2. ve 3. derece yakın olduğu diğer modeller farklı renklerle görülmektedir. Araç, kavşak üzerinde yol modellerinin kesişim noktalarına yaklaştığında, farklı yol modellerinden elde edilen kısmi log-olabilirlik değerlerinin (Şekil 6.4(b)) birbirlerine yaklaştığı görülmektedir. Özellik vektörleri olarak kullanılan konum ve hız bilgileri ele alındığında yakınlaşmaların oluşması beklenen bir davranıştır. Bu noktada önemli olan, aracın sahne üzerine giriş yaptığı başlangıç yol modeli ile üzerinde bulunduğu anlık yol modelini arasında değişimlerinin yakın olması ve eşik değerinin altında kalmasıdır.

- Aracın kural dahilinde başka bir yol modeline geçiş yapması ve yoluna devam etmesi

Sıklıkla rastlanan olağan araç hareketlerinden birisi de araçların öğrenilen yol modellerine uygun şerit değiştirerek yollarına devam etmesidir. Şekil 6.6(a)'da örneği ve Şekil 6.6(b)'de log-olabilirlik değerleri görülen araç hareketinde, 4 numaralı yol modelinden hareketine başlayan araç (Şekil 6.7), belli bir süre sonra 5 numaralı modele geçiş yapıyor ve o modelin log-olabilirlik eşik değerini (I_5 , -40) aşmayarak yoluna devam ediyor.




(a)



(b)

Şekil 6.6 Aracın otoyol üzerinde olağan şerit değiştirmesi (a) ve araç hareketine ait maksimum log-olabilirlik değişimleri (b)



Şekil 6.7 Şekil 6.6(a)'da hareketi görülen aracın zaman içerisinde üzerinde bulunduğu yol modelleri


6.4.2.2 Olağandışı araç hareketleri

Olağandışı durumları içeren görüntüler üzerinde incelemeler yapıldığında, araçlara ait düzenli akış halindeki özellik vektörlerinin olağandışılık anında normal olmayan ani değişimlere uğradığı görülmektedir. Olaya karışan araçların özellik vektörlerinin yörüngelerinde ve şiddetlerinde ani değişimler olaylarının yakalanmasında yardımcı olmaktadır.


Şekil 6.8'de çok şeritli ve çok yönlü kavşak üzerinde iki aracın çarpışma anı görülmektedir. Kırmızı ile belirtilen noktalar her araç için ayırt edici merkez noktalarıdır. Düz kırmızı çizgiler araçların $t-1$ ve t anındaki yer değişim büyüklüklerini göstermektedir. Şekil 6.9'da çarpışan iki aracı temsil eden merkez noktalarının koordinat düzlemi üzerinde değişimleri gösterilmiştir. Çarpışma anında her iki araca ait özellik vektörlerindeki yörünge sapmaları çarpışmanın şiddeti hakkında bilgi vermede önemli rol oynamaktadır. Şekil 6.10'da görüldüğü gibi, iki araç, 8. saniye civarında çarpışmaktadır. Aynı şekilde, çarpışma sonrası yönleri ve koordinat düzlemindeki açı değişimleri görülmektedir.



Şekil 6.8 Çok şeritli ve çok yönlü kavşak üzerinde çarpışma anı




Şekil 6.9 Çarpışma anında özellik vektörlerinin koordinat düzlemi üzerindeki değişimleri




Şekil 6.10 Çarpışma anında özellik vektörlerinin açı değişim grafiği



Şekil 6.11 Çok yönlü ve çok şeritli kavşak üzerinde kaza anı



Şekil 6.12 Çok yönlü ve çok şeritli kavşak üzerinde kaza anı ve sonrası araç davranışları



Şekil 6.13 Kaza anında araç hızları değişimi

Çok şeritli kavşak üzerinde kaza olayına başka bir örnek Şekil 6.11, 6.12 ve 6.13’de gösterilmiştir. Kavşak üzerinde iki araç çarpışır ve araçlar beraberce yörüngeleri değiştirerek güneye doğru yön değiştirirler, kaldırıma çarparak dururlar. Çarpışma anı ve sonrasında araç yörüngelerindeki değişim Şekil 6.11 ve 6.12’de gösterilmiştir. Kaza anında iki aracın birim zamandaki yer değişimleri de önemli derecede azalmıştır. (Şekil 6.13)

Trafik olaylarında, her kısmi anormallik, anormal araç hareketine veya araç çarpışmasına karşılık gelmeyebilir. Araçlar anlık anormal gidişattan sonra çok kısa bir sürede kendilerini toparlayabilir ve yoluna devam edebilirler. Bazı araçlar kaza anından hemen önce kaza yapmadan durumlarını düzeltebilirler. Kısmi anormallik bir araç için daha önceden belirlenmiş süre boyunca devam ediyorsa o araç anormal hareket yapıyor olarak nitelendirilir.

Kavşak sahnesi üzerinde birbirinden farklı anormallik tipleri olabilir. Bu bölümde, anormallik tipleri çarpışma olmayan ve olan olağandışı araç hareketleri şeklinde gruplandırılarak anlatılmıştır.

6.4.2.3 Çarpışma olmayan olağandışı hareketler

Kavşak üzerinde çarpışma yaşanmayan olağandışı hareketler genel olarak araçların çarpışmalardan hemen önce yaptıkları engelleyici hareketleri içerir. Örneğin, aracın ani fren yaparak durması bu tip olağandışı hareketlere örnek olarak verilebilir. Bir aracın kavşak üzerinde belirli bir süreden fazla durağan olması da çarpışma olmadan olağandışı bir hareket olabilir. Çarpışma olduktan sonra aracın durağan olması durumundan, çarpışma olan olağandışı hareketler bölümünde bahsedilmiştir. Sahne üzerinde hız aşımı da çarpışmanın yaşanmadığı olağandışı hareketlere örnek olarak verilebilir. Araç, öğrenilmiş yol modeline göre hızlı hareket ettiği zamanlarda hız aşımı gerçekleştiriyor olarak isimlendirilir. Bazı durumlarda, öğrenilen modeller dışında sürücüler bilinçli olarak olağandışı davranış gösteriyor olabilirler. Örneğin, kural dışı U dönüşü ya da ters yola giriş bu tip olaylara örnek gösterilebilir. Bu tip davranışlar da çarpışmanın yaşanmadığı olağandışı olaylardır. Bir sonraki alt bölümde, olağandışı hareketlerin anlık log-olabilirlik kullanımı ile belirlenmesi anlatılmıştır.

- Ani Araç Duruşu Belirleme

Araçlar, kavşak üzerinde olağandışı hareketlerden ve çarpışmalardan kaçınmak için ani duruş yapmak zorunda kalabilirler. Bu tip olağandışı araç davranışları kavşaklar üzerinde sıklıkla görülen olaylardır (Şekil 6.14). Bu çalışmada, araçların yol modellerinden sapmalarının yanı sıra ani duruşları da belirlenmektedir. Ani duruş belirleme için aşağıda belirtilen kurallar belirlenmiştir.

- t_1 ve t_2 anları arasında kısmi araç gözlemleri öğrenilen λ_m modellerine maksimum benzerlik sağlamasına ve beklenen yol modelleri üzerinde hareket etmesine rağmen araç yer değişimi önceden belirlenen ani duruş eşik seviyesinden fazla ve t_2 anındaki yer değişimi 0 ise araç yörüngesinden sapmadan ani duruş yapmış olarak işaretlenir.
- t_1 ve t_2 anları arasında araç beklenen yol modellerinden sapma gösterdikten sonra ani duruş yapmış olabilir. Bu gibi durumlarda, yol modellerinden sapma ve ani duruş hareketleri beraber belirlenmektedir.



Şekil 6.14 Ani duruş gözlemi için ardışık çerçeve örnekleri

- *Uzun Süreli Araç Duraklaması*

Başka tip bir olay, çok yavaş giden ya da uzun süre duraklayan bir aracın hareketidir. Bu olay tipinde, olması gerekenden fazla log-olabilirlik değerleri elde edilmektedir. Bekleme süresine bağlı eşik değeri τ , doğal ortam görüntüleri dikkate alınarak elle belirlenmiştir. Bu farklılık uzun süreli durma anormal durumu olarak isimlendirilir. Şekil 6.15'te kavşak üzerinde uzun süre duraklayan araç örneği görülmektedir.



Şekil 6.15 Uzun süre duraklayan araç için t ve $t+50$. andaki çerçeveler

- *Hız Aşımı*

Araç kavşak üzerinde çok hızlı gidiyorsa ve öğrenilen model yavaş akış özelliklerini içeriyorsa, araç hız aşımı gerçekleştiriyor demektir. Hız aşımı olan bölgelerde log-olabilirlik değerleri eşik seviyesinden yüksek olacaktır. Bu tip durumlar, araçlar için hız anormallliği olarak isimlendirilir. Bu olaylar, ani yön değişimi gözlemlenmediği durumlarda yol kurallarına göre olağan ya da olağandışı olarak sınıflandırılabilirler.

- *Öğrenilmemiş bir yol izleme, bilinçli sağa veya sola dönüş*

Kavşak üzerindeki araçlardan her koşulda kurallara uygun hareket etmeleri beklenir. Fakat, sürücülerin kurallara uymadığı durumlar da söz konusudur. Örneğin, aracın ters yola girmesi ya da kural dışı dönüş yapması öğrenilen yol modellerine aykırı araç hareketleridir. Bu çalışmada, bu türdeki olayların doğası gereği şiddet analizi işlemlerine gerek duyulmamıştır. Fakat, bu olayların bilinçsiz yapılan olağandışı durumlardan ayırt edilebilmesi için aşağıda belirtilen yöntem önerilmiştir.

- Öğrenilen yol modellerinden uzaklaşan aracın hızında düzenli değişim gözlemleniyorsa, bu aracın hareketi bilinçli kural dışı hareket olarak sınıflandırılır.
- Aracın yol modellerinden uzaklaşma sürecinde hızında ani değişimler gözlemleniyorsa, araç bilinçsiz olağandışı durum gerçekleştirmiştir. Bu tür durumlarda olay ve şiddet analizi işlemleri uygulanır.

Şekil 6.16’da bu tür olağandışı durumlara örnek araç hareketi görülmektedir. Yeşil renkli araç, kavşak orta bölümüne yaklaşarak kurallara aykırı şekilde sağa dönmektedir.



Şekil 6.16 Bilinçli kural dışı dönüş örneği için ardışık çerçeve görüntüleri

6.4.2.4 Çarpışma olan olağandışı hareketler

Bir önceki altbölümde bahsi geçen anormal olayları belirlemek sürücülerin güvenliği açısından önemlidir. Ancak, bu tezde önerilen model, anormal davranış gösteren ve kazaya karışan araçların karakteristik özelliklerini çıkartmayı hedeflediğinden, çarpışma belirleme işlemi için aşağıdaki ek koşullar kullanılmaktadır. Bu koşullar aşağıdaki şekilde sıralanabilir.

- Araçlardan birisinin çarpma sonrasında sapması, diğer aracın çarpma sonrasında sapma yaşamadan aniden durması

Eğer aynı t anında, yön değişimi, anormal log-olabilirlik gözlemlenmesi ve ani duraklama birden fazla araç için söz konusu ise, bu durum iki veya daha fazla aracın karışmış olduğu kaza anını işaret eder. Bu tip kazalarda, genelde, araçlardan biri çarpışma anından sonra durmak zorunda kalmıştır. İkinci araç, çarpmanın etkisiyle beklenen yol modelinden sapma göstermiştir. Şekil 6.17’de bu duruma uyan çarpışma anı örneği görülmektedir.



Çerçeve #87

Çerçeve #99

Çerçeve #165

Şekil 6.17 İki aracın çarpışması, siyah renkli aracın yolundan sapması, gri renkli aracın çarpma sonrasında sapma yaşamadan ani duruş yapması

- İki aracın çarpışma sonrasında sapması

Eğer birden fazla araçta ani yüksek log-olabilirlik ve yön değişikliği gözlemlenmiş ise, bu olay çarpışma içeren kazaya işaret eder. Bu tip olaylarda, genelde, iki araç çarpışır ve beklenen yol modellerinden sapma gösterirler.

Şekil 6.18'de iki aracın kavşak ortasında çarpışması kaza olayı görülmektedir. Şekil 6.18(d)'de görülen düz siyah çizgiler aracın çarpışma öncesinde beklenen yolunu, kırmızı ve mavi ile gösterilen noktalar aracın kaza öncesi ve sonrasında izlemiş olduğu yolu göstermektedir. V_1 aracının aldığı yol kırmızı renk ile V_2 aracının aldığı yol mavi renk ile gösterilmiştir. Beklenen yol modeli aracın başlangıçta takip ettiği yol modeline bakılarak elde edilir.




(a) Çerçeve #86

(b) Çerçeve #92

(c) Çerçeve #99

(d) Çerçeve #155

Şekil 6.18 Kaza anı belirleme sahnesi, iki aracın çarpışması.



Şekil 6.19 Şekil 6.18'de kazaya karışan V_1 ve V_2 aracına ait maksimum log-olabilirlik ve araçların üzerinde bulundukları anlık yol model değişimleri

Şekil 6.19, araçlara ait her kısmi gözlem için log-olabilirlik ve karşılık gelen yol modelini göstermektedir. Çarpışma anında, her aracın kısmi hareketi ile beklenen yol modelleri arasında benzersizlikler artmaya başlar.

λ_1 yol modeline maksimum benzerlik gösteren V_1 aracı 17. kısmi gözleme geldiğinde V_2 aracı ile çarpışmakta ve beklenen λ_1 yol modelinden uzaklaşmaktadır (Şekil 6.19(a) ve (c)). Aynı sahneye λ_8 yol modeline maksimum benzeyerek giriş yapan V_2 aracı da 13. kısmi gözlemde V_1 aracı ile çarpışarak beklenen λ_8 yol modelinden uzaklaşmaktadır (Şekil 6.19(b) ve (d)). Araçların çarpışma anından sonra kısmi log-olabilirlikleri model eşik değerlerinden yüksek gözlemlendiğinden olağandışı sapmalar şiddet sınıflandırma işleminde kullanılmak üzere kayıt edilirler.

Sonuç olarak, olay ve çarpışma belirleme, kısmi gözlemlerin, beklenen yol olasılıklarının belirlenme başarısına ve model eşik değerlerinin uygun seçilmesine bağlıdır. Önerilen olağandışı olay belirleme algoritmasının avantajları aşağıdaki şekilde sıralanabilir.

- Kavşak üzerindeki her araç çifti için çarpışma olup olmadığının incelenmesine ihtiyaç yoktur. Bu durumda, sahne üzerinde n adet araç var ise $n \times (n-1)$ adet çarpışma sorgulamasına gerek vardır. Yüksek sayıdaki araçlar için bu özellik hesaplama karmaşıklığını arttıracaktır.
- Bu yöntem ile tek bir aracın yaratacağı aracın aşırı hızda olması veya nizami olmayan dönüşler gibi anormal hareketler yakalanabilmektedir.
- Kısmi gözlemler için her yol modeli ile karşılaştırma yapılmasına gerek yoktur. En yüksek olabilirlik gösteren yol modelleri seçilerek araçların hareketleri boyunca bu modellere yakınsaması incelenebilir. Bu yöntem, işlem sayısını önemli ölçüde azaltmaktadır. Diğer türlü, karmaşıklık Eşitlik (6.7)'deki gibi olur. Burada, n sahne üzerindeki toplam araç sayısı, p her bir araç için toplam kısmi gözlem sayısı, m yol model sayısı olarak belirtilmiştir.

$$\sum_i^n \sum_j^p (Ot_{ij})x(m) \quad (6.7)$$

6.5 Bölüm özeti

Bu bölümde, olağandışı araç hareketlerinin belirlenmesi amacıyla uygulanan işlemler özetlenmiştir.

1. Sahne üzerindeki her araç için kısmi gözlemler elde edilerek her kısmi gözlemin λ_m yol modeline karşılık gelen maksimum log-olabilirlik değerleri hesaplanır.
2. Her kısmi gözlem elde edildiğinde ani duruş kontrolü gerçekleştirilir.
3. Araç hareketleri boyunca elde edilen kısmi log-olabilirlik değerleri yol modellerine ait Γ_m eşik değerleri ile karşılaştırılır.
4. Kısmi log-olabilirlik değerleri eşik değerlerinden küçük ise olağandışı hareket durumu belirlenir. Bu durumda ani duruş davranışı kontrolü yapılır. Bu durumdaki araçlar durana kadar kısmi log-olabilirlik değerleri elde edilir. Olaya karışan her araç bir sonraki bölümde anlatılacak olan olay şiddet analizi bölümüne aktarılır.
5. Kısmi log-olabilirlik değerlerinin eşik değerlerinden büyük olduğu durumlarda ani duruş hareketi kontrolü yapılır. Ani duruş gözlemlendi ise araca ait bütün log-olabilirlik değerleri olay şiddet analizi bölümüne aktarılır.
6. Kısmi log-olabilirlik değerleri eşik değerlerinden büyük ve ani duruş gözlemlenmedi ise araç olağan akışındadır. Araç sahneden kaybolana kadar gözleme devam edilir. Bütünüyle olağan davranan araçlara ait log-olabilirlik değerleri kayda alınmaz.


7. TRAFİK OLAY ve ŞİDDET ANALİZİ

Bu bölümde, olağandışı davranan araçların takibinden elde edilen anlık log-olabilirlik değerleri ile olay şiddet analizi işlemleri anlatılmaktadır.

7.1 Kısmi gözlem süresinin olay analizine etkisi

Kaza anlarının belirlenebilmesi için yeterli derecede gözlem toplanması olay anının doğru zamanda yakalanabilmesi açısından önemlidir. Çoğu trafik kazası olayı hızlı gelişen olaylardır ve birkaç saniye içerisinde tamamlanır. Bu kadar kısa süre içerisinde elde edilecek kısmi gözlemler, kazanın gerçekte olma anını ve olay anından sonra araçların nasıl etkilendiklerini gösterecektir. Bu noktada, kısmi gözlemlerin süresi, anlık olay belirlemede ve olayın şiddetinin incelenmesinde önemli rol oynar.

Gözlemlenen araç özniteliklerini içeren kısmi örneklerin süresi kaza anındaki araç sapmalarının şiddet derecesini ortaya çıkarır. Kısmi gözlemlerin kısa boyda tutulması anlık sapma oranının daha düşük gözlemlenmesine ve kaza anının belirlenme süresini uzatmasına neden olur. Buna karşılık, daha uzun gözlemlenen kısmi örnekler ile sapma şiddeti ve kaza anı daha net gözlemlenebilir hale gelir. Kısmi gözlem süreleri, mevcut olağandışı kaza görüntüleri ile yapılan ön analizler sonucunda belirlenmiştir. Örneğin, saniyede 15 çerçeve içeren TRIMARC'a ait 8 saniyelik kaza görüntülerinde 120 çerçeve ile olay analizinin tamamlanması gerekir.



Şekil 7.1 Farklı sürelerdeki kısmi gözlemler ile oluşturulan örnek kaza senaryosu için log-olabilirlik – zaman grafiği

Şekil 7.1’de iki aracın karışmış olduğu kaza anının farklı kısmi gözlem süreleri ile yakalanması ve olay şiddetinin belirlenmesi farklı iki senaryo ile gösterilmiştir. Log-olabilirlik değerleri, öğrenilen örüntüler ile kısmi gözlemlerin zaman içerisinde eşleştirilmesi ile elde edilen sonuçları gösterir. Bu değerler, kısmi gözlemlerin olay anında normal akıştan ne derece sapma olacağını göstermektedir. X eksenini zaman, Y eksenini log-olabilirlik değerlerini gösterir. Y eksenini kolay okunabilirlik açısından ters sırada gösterilmiştir.

Şekil 7.1’de görüldüğü üzere, iki araç belli bir süre normal davranış ile hareketlerini devam ettirirken, aniden çarpışmakta ve hareket karakteristiklerinde ani değişimler meydana gelmektedir. Kısmi gözlem sonucunda elde edilen olabilirlik değerleri eşik değeri -50’nin altında seyrederken (bu model için örüntü eşik seviyesi), kaza sonrasında bu değer yüksek şiddette negatif yönde değişime uğramaktadır. Log-olabilirlik değerlerindeki ani değişim, araçların kaza anındaki olağandışı davranışlarını tanımlayıcı faktör olarak kullanılır. İki farklı durum karşılaştırıldığında, ilk senaryodaki sapma dikliğinin ikincisine göre daha şiddetli olduğu ve kaza anını daha iyi tanımladığı gözlemlenmektedir. Bu durumda, kısmi gözlem sürelerinin doğru seçimi sapma anı ve şiddetinin belirlenmesinde önemli rol oynamaktadır. Olağan araç davranışlarının öğrenilmesi aşamasında araçların takip ettikleri yörünge koordinatlarının yanı sıra hızları ve gidişat açıları da değerlendirildiğinden, kaza anını ve sonrasında etkileyen yer, hız ve yön gibi özniteliklerdeki değişimler yörünge sapmalarını ve kaza şiddetini doğrudan etkileyen faktörlerdir.

Sonraki bölümde, olağandışı trafik olayları şiddet analizi işlemleri anlatılmıştır. Şiddet analizinde kullanılacak olay özellikleri iki ayrı istatistik yöntemi ile incelenmiştir. Bu yöntemler, Değişim Katsayısı (Coefficients of Variances – CV) ve Çok Fazlı Doğrusal Regresyon Fonksiyonları (Multiphase Linear Regression Functions) yöntemleridir.

7.2 Değişim Katsayısı yöntemi ile olay analizi


Değişim Katsayısı yöntemi (Hendricks ve Robey, 1936; Abdi, 2010) ile gözlemlenen her kısmi örnek için, aracın sahip olduğu log-olabilirlik değerlerinin değişiminin istatistiksel olarak tanımlanması amaçlanmıştır. Bu yöntem, özellikle ortalamaları birbirlerinden çok farklılık gösteren farklı veri kümelerinin karşılaştırılmasında kullanılan istatistiksel yöntemlerdir. Bu özelliğiyle araçların ani değişimlerinin gözlemlenmesi probleminde kullanılmaya uygundur. Sahne üzerinde birden fazla aracın kazaya karışması düşünüldüğünde her bir araca ait değişim katsayısı, olay anında araçların ne derece etkilendiklerini ortaya

çıkartacaktır. Araçlarda oluşan toplam değişim ile birden fazla aracın karıştığı kaza olayının şiddeti tanımlanabilmektedir.

Değişim katsayısı, log-olabilirlik değer serisinden elde edilen standart sapmanın (σ) ortalamaya (μ) göre yüzdesel oranının bulunmasıyla elde edilir (7.1).

$$CV_i = \frac{\sigma_i}{\mu_i} \times 100 \quad (7.1)$$

σ_i , i . araca ait log-olabilirlik değerlerinin standart sapması, μ_i , i . araca ait log-olabilirlik değerlerinin ortalaması, CV_i , i . araca ait değişim katsayısı değerlerini gösterir.




Şekil 7.2 Her kısmi gözleme ait log-olabilirlik – zaman grafiği

Şekil 7.2’de olağandışı davranan bir aracın kısmi hareket gözlemlerinden elde edilen log-olabilirlik değerlerinin zamana göre değişimi görülmektedir. Log-olabilirlik değerlerinin ortalaması μ ve standart sapma aralıkları mavi renkli düz ve kesikli doğrular ile, olağan yol modeline ait eşik seviyesi kırmızı renkli doğru ile gösterilmiştir. Araç, olağandışı durum anına kadar yol modeli eşik seviyesinin altında hareket ederken, olay sonucunda sapma davranışı göstermiştir. Olay anında araçların sahip oldukları değişim katsayısı değerleri, bir sonraki bölümde anlatılan olay şiddeti sınıflandırma işlemlerinde kullanılmaktadır.

7.3 Çok Fazlı Doğrusal Regresyon Fonksiyonları ile değişim analizi

Bu bölümde, çok fazlı doğrusal regresyon analizi tekniği (Ryan, 2007), ani yörünge değişimlerini ve anormal olay sonucunda oluşan değişim dikliğini ölçmek için önerilmiştir. Bu tekniğin temel amacı, zaman serilerinde kritik değişim noktalarının bulunmasıdır. Yöntem, gözlemlenen değerleri çoklu bölmelere ayırarak, her bir bölmeye doğrusal

parametrize edilmiş polinomlar oturtmaktadır. Elde edilen kısmi gözlemler ile bir aracın çoklu doğrusal regresyon yöntemi ile hareket analizi Şekil 7.3'te görülmektedir.



Şekil 7.3 Çok fazlı doğrusal regresyon analizi ile bir aracın hareket değişiminin gözlemlenmesi

Mavi renkteki çizgiler, aracın gözlemlenen log-olabilirlik değerlerini, pembe renkli düz doğrular, çok fazlı doğrusal regresyon ile tahmin edilen fonksiyonları, kırılma noktası aracın normal durumdan anormal duruma geçiş anını gösterir. Aracın seyahati süresince olağan gidişatı “normal akış bölgesi” ile ifade edilir. Olağandışı durum sonrası araç “anormal akış bölgesi”ne geçiş yapmak zorunda kalır. θ değeri aracın anormal akış bölgesinde durana kadar ne kadar diklikle saptığını gösterir. Regresyon fonksiyonları aracın seyahati sürecinde bulunduğu her bölme için süreklilik özelliği göstermelidir. Bu özellikten yola çıkarak aşağıdaki eşitlikler yazılır (Ryan ve Porth, 2007).

$$Y_1 = a_1 + b_1 x(t) \quad x \leq c \quad (7.2)$$

$$Y_2 = a_2 + b_2 x(t) \quad x > c \quad (7.3)$$

- $x = c$ noktasında t anında sadece bir kırılma noktası bulunur. c olay anını temsil eder.
- Y_1 ve Y_2 , t anındaki tahmin edilen fonksiyon değerlerini gösterir. Y_1 normal akış bölgesindeki, Y_2 , anormal akış bölgesindeki regresyon fonksiyonlarını temsil ederler.
- b_1 ve b_2 , regresyon katsayılarını ifade eder, her bir doğrusal bölmenin eğimini gösterir.
- a_1 ve a_2 , regresyon sabitlerini ifade eder, her bir doğrusal bölme için y eksenindeki mesafeyi (intercept) gösterir.

Regresyon fonksiyonlarındaki sürekliliği koruyabilmek için Y_1 ve Y_2 denklemleri $x = c$ anında eşit olmalıdır.

$$a_1 + b_1c = a_2 + b_2c \quad (7.4)$$

$$a_2 = a_1 + c(b_1 - b_2) \quad (7.5)$$

$$y = a_1 + b_1x \quad x \leq c \quad (7.6)$$

$$y = \{a_1 + c(b_1 - b_2)\} + b_2x \quad x > c \quad (7.7)$$

Normal akış bölmesi, düz bir regresyon doğrusu ile temsil edilebilir. Kırılma noktasında, ani olağandışı olaydan sonra anormal akış bölmesi başlar. Araca ait bütün log-olabilirlik gözlemleri toplandıktan sonra, anormal akış bölmesini oluşturan regresyon doğrusunun dikliği aracın yarattığı olayın şiddeti hakkında bilgi verir. Şekil 7.3'te görüldüğü gibi, kırılma noktasına kadar olan bölmede araç olağan ve beklenen gidişatına devam etmektedir. Bu bölmeye ait regresyon doğrusunun eğimi sıfıra yakın değer gösterir. Araç, anormal akış bölgesine girdiğinde, regresyon doğrusunun dikliği sıfırdan çok yüksek bir değer alır. Bu değer, aracın gidişatında oluşan değişiminin şiddetini ortaya çıkartır. Olağandışı olaya birden fazla araç karıştığında, her bir araca ait anormal sapma, olayın bütün olarak şiddetini gösterir.



Çerçeve #95


Çerçeve #106

Çerçeve #139

Çerçeve #139

Şekil 7.4 Kavşak üzerinde meydana gelen başka bir olağandışı sapma örneği.

Şekil 7.4'te başka bir olağandışı olaya ait araç sapma örneği görülmektedir. Elips içine alınan araç, kendi şeridinde düz gitmesi beklenirken yanlış dönüş yapan başka bir araca çarpmamak için aniden şeridinden sapmaktadır.



Şekil 7.5 Farklı bir sapma örneğinde çok fazlı doğrusal regresyon analizi ile sapma yaşayan aracın hareket değişiminin gözlemlenmesi.

Şekil 7.5'te olaya karışan aracın regresyon analizi sonucunda elde edilen sapma değerleri gösterilmiştir. Araç, sapma öncesinde bulunduğu normal bölgede 2 derecelik bir değişim ile hareketine devam ederken, 10,4. anı sıralarında sapma göstermiş, 20,3 derecelik değişim ile beklenen yol modelinden uzaklaşmıştır.

Çok fazlı doğrusal regresyon ile elde edilen sapma diklik ya da değişim açısı θ büyüdükçe sapma derecesinde, dolayısı ile olay şiddetinde artış beklenmektedir. Bir sonraki bölümde anlatılan olağandışı olayların şiddet sınıflandırma işleminde, θ değişim açısı değişim katsayısı değişkeni ile beraber kullanılmaktadır.

7.4 Bölüm özeti


Bu bölümde, kısmi log-olabilirlik gözlemleri ile olağandışı davranan araçların yaratmış oldukları trafik olaylarının şiddet analizi işlemleri özetlenmiştir. Hareketleri boyunca kısmi log-olabilirlik değerleri elde edilen araçlar, değişim katsayısı ve çok fazlı regresyon analizi teknikleri ile şiddet analizi işlemlerinden geçirilmişler, elde edilen değişim katsayısı ve sapma açısı değerleri ile bir sonraki bölümde anlatılan olay sınıflandırma işlemine hazırlanmışlardır. Şiddet analizleri süresince yapılan işlemler, sırası ile aşağıda belirtilmiştir.

1. Olağandışı davranan araçlar bir önceki bölümde anlatılan yöntemler ile belirlenmiştir.
2. Olağandışı davranan araçların log-olabilirlik değerleri, olay anından hemen sonra araç sahne üzerinde durana kadar ya da sahneden kaybolana kadar kayıt edilir.

3. Değişim Katsayıları yöntemi kullanarak olağandışı davranan araçların değişim katsayısı değerleri hesaplanır.
4. Çok fazlı regresyon fonksiyonu yöntemi kullanarak olağandışı davranan araçların değişim dereceleri hesaplanır.
5. Elde edilen değişim katsayısı ve dereceleri olaya karışan her araç için bir sonraki bölümde anlatılan olay sınıflandırma bölümüne aktarılır.

8. OLAĞANDIŞI TRAFİK OLAYLARININ ÖĞRENİLMESİ ve SINIFLANDIRILMASI

Bu bölümde, olağandışı davranış gösteren araçların sapma karakteristikleri kullanılarak olayların şiddet kategorilerinin öğrenilmesi ve sınıflandırılması anlatılmıştır. Olay öğrenme ve sınıflandırma akışı Şekil 8.1’de özetlenmiştir. Birinci aşamada, veri kümelerindeki olağandışı araç hareketleri belirlenerek olay şiddet eğitim modeli oluşturulur. Eğitim modeli, olağandışı davranan araçlara ait değişim katsayısı, değişim dikliği ve olay anındaki hız değerleri özellikleri kullanılarak eğitilir. İkinci aşamada, eğitim modelinin başarısı k-en yakın komşuluk ve Destek Vektör Makineleri yöntemleri için k-katlı çapraz doğrulama (k-fold cross validation) tekniği kullanılarak değerlendirilir.



Şekil 8.1 Olağandışı olayların şiddet sınıflandırması işlemi

Şiddet sınıflandırmasına alınan olaylar, kavşaklarda çok sıklıkla karşılaşılan trafik olaylardır. Bu tür olaylar, düşük ve yüksek şiddetli olaylar olmak üzere iki sınıf altında incelenmiştir. Kavşak üzerinde görülebilecek trafik olayları şiddetlerine göre aşağıdaki şekilde sınıflandırılabilir:

- Düşük şiddetli olaylar
 - Çarpma riskine karşı araçların şeritlerinden sapmadan kontrollü yavaşlamaları
 - Çarpışma olmadan veya çarpışma sonucu şeritlerden zorunlu hafif şiddetli sapmalar
 - Kavşak güvenliğini tehlikeye atacak bilinçli ve kural dışı şerit değişiklikleri
- Yüksek şiddetli olaylar
 - Birden fazla aracın önden ya da yandan çarpışmaları

- Çarpma riskine karşı istem dışı şiddetli şerit değişimleri
- Çarpma riskine karşı yüksek hız değişimi oluşturan ani araç durmaları

Düşük şiddetli trafik olayları, araçların sahne üzerinde pozisyonlarında ve/veya hızlarında hafif şiddette değişimler gösterdiği olaylardır. Yüksek şiddetli olağandışı durumlarda, araçlar pozisyonel ve hızsal olarak ani değişimler göstermektedir. Olağan davranış gösteren araç hareketlerinde herhangi bir anormalite gözlemlenmediğinden sınıflandırma işlemine alınmamışlardır. Olay örnekleri, öğretmenli sınıflandırma yöntemlerinden olan Destek Vektör Makineleri ve k- En Yakın Komşuluk algoritmaları ile sınıflandırılmışlardır.

8.1 Şiddet sınıflandırma eğitim modelinin oluşturulması

Olayların şiddetlerine göre sınıflandırılması için mevcut veri kümelerindeki olağandışı araç hareketleri incelenerek eğitim modeli oluşturulmuştur. Eğitim modelinde kullanılan olağandışı araç şiddet özellikleri aşağıdaki şekilde belirlenmiştir.


- Aracın hareketi sonucunda elde edilen değişim katsayısı değeri (CV)
- Aracın olağandışılık değişim derecesi (sapma açısı θ)
- Aracın olay anındaki görüntü koordinatlarında V_i hızı (piksel/saniye)

Olağandışı araç hareketleri, sınıflandırma testleri öncesi düşük ve yüksek şiddetli olaylar olarak uzman görüş alınarak etiketlenmişlerdir.

8.2 Destek Vektör Makineleri (SVM) ile öğrenme ve sınıflandırma

Bu çalışmada, SVM, düşük ve yüksek şiddetli trafik olaylarının öğretmenli sınıflandırılması için kullanılmaktadır. SVM, 1992 yılında Vapnik tarafından doğrusal ve doğrusal olmayan sınıflandırma problemlerine çözüm olarak geliştirilmiştir (Vapnik ve Cortes, 1995). SVM, temelde öğretmenli bir öğrenme yöntemi olup, ikili sınıf problemlerinin çözümünde kullanılmaktadır.

Temel olarak yöntem, iki farklı sınıfı birbirinden ayıran en uygun hiperdüzlemi bulmayı amaçlar. Şekil 8.2’de görüldüğü gibi, SVM, sınıfların birbirlerine en yakın noktaları arasındaki karar sınırını (margin M) maksimize etmeye çalışır. Sınıflara ait en yakın noktalar destek vektörleri olarak isimlendirilir.



Şekil 8.2 İki boyutlu uzayda iki sınıflı SVM sınıflandırma

k uzunluğunda öğrenme kümesindeki d boyutlu veriler x_i eğitim örnekleri, y_i her örneğe karşılık gelen sınıf değeri $(-1, +1)$ olarak etiketlenir [11].

$$- \{x_i, y_i\}, i = 1, \dots, k, x_i \in R^d, y_i \in \{-1, +1\}$$

R^d uzayındaki bütün H hiperdüzlemler w vektörü ve b sabit değişkeni ile (8.1)'deki gibi ifade edilir.

$$w.x + b = 0 \quad (8.1)$$

Sınıfları birbirinden maksimum uzaklıkta ayırmayı sağlayan fonksiyon (8.2) ile ifade edilir.

$$f(x) = \text{sign}(w.x + b) \quad (8.2)$$

Bu hiperdüzlemin ayırdığı yarı uzaylar (8.3)'te görüldüğü gibi H_1 ve H_2 olarak iki farklı sınıfa temsil eder. En doğru sınıflandırmayı sağlayan H hiperdüzlemi, H_1 ve H_2 düzlemleri arasında bir örnek olmamasını ve aralarındaki sınır (margin) ya da uzaklığın maksimum olmasını garanti eder.

$$H_1 : y = w.x + b = +1$$

$$H_2 : y = w.x + b = -1$$


$$d(H_1 \rightarrow H) = \frac{|w.x + b|}{\|x\|} = \frac{1}{\|w\|} \quad (8.3)$$

$$H_1 = H_2 = \frac{2}{\|w\|}$$

H_1 ve H_2 hiperdüzlemleri arasındaki uzaklığın artırılması için $\|w\|$ değeri minimize edilmeye çalışılır. Bu işlemin yapılması için Lagrange çarpanlarından yararlanılır. Detaylı formülasyon bilgisi için [11] incelenebilir.

Olağandışı olay analizi işlemleri sırasında elde edilen olay özelliklerinin doğrusal hiperdüzlemler ile sınıflandırma başarısının yetersiz olduğu görülmüştür. Bu nedenle, Çekirdek Tabanlı Vektör Makineleri kullanılmıştır. Şekil 8.3'te görüldüğü gibi, doğrusal olarak ayırt edilemeyen sınıflarda çekirdek fonksiyonları kullanılarak veri kümesi yüksek boyutta yeni bir doğrusal veri kümesine dönüştürülür. Doğrusal olarak ayıramayan örneklerde veriler daha yüksek boyutlu başka bir uzaya taşınır ve sınıflandırma o uzayda yapılır. Bu işlem için (8.4)'te görülen ϕ çevirme fonksiyonu kullanılır. x , d boyutlu eğitim veri kümesini, z d^1 boyutlu çevrilmiş eğitim örneklerini gösterir.

$$z = \phi_d(x) \quad (8.4)$$



Şekil 8.3 Doğrusal olarak ayıramayan örneklerin yüksek boyutlu uzaya taşınması ve sınıflandırılması [11]

Boyut dönüşümü işlemi (8.5)'te görüldüğü gibi iç çarpımların yer değişimi ile gerçekleştirilir.

$$(x,y) \rightarrow \phi(x).\phi(y) \quad (8.5)$$

Çevirme fonksiyonu çekirdek tarafından (8.6)'daki şekilde yapılır..

$$K(x,y) = \phi(x).\phi(y) \quad (8.6)$$

Eğitim örneklerinin sınıflandırılabilmesi için uygun çekirdek fonksiyonu seçilir. Doğrusal olmayan yüksek boyutta sınıflandırmada çekirdek fonksiyonları önemli rol oynar. Çekirdek fonksiyonlarının doğru seçimi sınıflandırmanın başarısında etkilidir. Bu çalışmada yararlanılan çekirdek fonksiyonları (8.7)'de belirtilmiştir. Doğrusal çekirdek modeli testler sonucunda başarısız görüldüğü için kullanılmamıştır.

$$\begin{aligned} \text{Gauss(RBF)}: K(x_i, x_j) &= e^{-\frac{\|x_i - x_j\|^2}{2\sigma^2}}, 2\sigma^2 \rightarrow \text{\u00e7ekirdekgenisligi} \\ \text{Polinom}: K(x_i, x_j) &= (1 + x_i^T x_j)^p \end{aligned} \quad (8.7)$$

Quadratic

$$\text{\u00c7ok Katmanlı Alg\u0131lac\u0131y\u0131lar}: K(x_i, x_j) = \tanh(\beta_0 \cdot x_i^T x_j + \beta_1)$$

\u00c7ekirdek fonksiyonu se\u00e7iminden sonra \u00f6\u011frenme i\u015lemi (8.8)'deki $W(\alpha)$ de\u011ferinin maksimize edilmesi i\u015lemine dayan\u0131r (McCulloch, 2005).

$$\begin{aligned} W(\alpha) &= \sum_{i=1}^m \alpha_i - \sum_{i,j=1}^m \alpha_i \cdot \alpha_j \cdot y_i \cdot y_j \cdot K(x_i, x_j) \\ \sum_{i=1}^m \alpha_i \cdot y_i &= 0 \\ \alpha_i &\geq 0 \end{aligned} \quad (8.8)$$

$$b = -\frac{1}{2} \left[\max_{\{y_i = -1\}} \left(\sum_{j \in \mathcal{SV}} y_j \alpha_j K(x_i, x_j) \right) + \min_{\{y_i = +1\}} \left(\sum_{j \in \mathcal{SV}} y_j \alpha_j K(x_i, x_j) \right) \right]$$

E\u011fitim veri k\u00fcmesini iki s\u0131nfa en optimum ay\u0131ran hiperd\u00f6zlem bulunduktan sonra, test \u00f6rneklerinin hangi s\u0131nfa dahil oldu\u011fu (8.9)'da g\u00f6r\u00fclen karar fonksiyonu ile hesaplanır.


$$f(c) = \sum_i \alpha_i \cdot k(s_i, x) + b \quad (8.9)$$

S_i , α_i ve b , sırasıyla \u00f6\u011frenme i\u015lemi sonucunda elde edilen destek vekt\u00f6rlerini, a\u011f\u0131rlıkları ve sistematik hatayı g\u00f6sterir. k , \u00f6\u011frenme modelinde se\u00e7ilen \u00e7ekirdek fonksiyonunu i\u015aret eder. Sınıflandırma i\u015in a\u015fa\u011fıdaki kural ge\u00e7erlidir.

- E\u011fer $f(c) \geq 0$ ise, x pozitif \u00f6rnek
- E\u011fer $f(c) < 0$ ise, x negatif \u00f6rnek olarak sınıflandırılır.

8.3 k- En Yakın Kom\u015fuluk ile sınıflandırma

k-En Yakın Kom\u015fuluk (k-Nearest Neighborhood, k-NN) algoritması, \u00f6rnek tabanlı (instance based) bir sınıflandırma algoritmasıdır [12]. \u015ekil 8.4'te g\u00f6r\u00fcld\u00fc\u011fu gibi, bilinmeyen \u00f6rne\u011fin e\u011fitim k\u00fcmesindeki \u00f6rneklerden en \u00e7ok benzedi\u011fi k tanesi hesaplanır. \u00d6rne\u011fin sınıfı, k e\u011fitim \u00f6rne\u011finden \u00e7o\u011funlu\u011fu olu\u015fturan sınıf olarak belirlenir. \u015ekil 8.4'te $k=3$ i\u00e7in k-en yakın kom\u015fuluk sınıflandırması yapılırsa, bilinmeyen \u00f6rnek mavi sınıfa aittir.



Şekil 8.4 $k=3$ için k-En Yakın Komşuluk ile sınıflandırma

8.4 k-katlı Çapraz Doğrulama ile öğrenme modeli seçimi

Kullanılan öğrenme yöntemlerinin başarısının değerlendirilmesi ve en iyi sonucu veren öğrenme modelinin seçimi için Çapraz Doğrulama yöntemlerinden yararlanılır. Bu çalışmada, k-katlı çapraz doğrulama yönteminden faydalanılmıştır. Bu yöntem, eğitim modeli kurmak için veri sayısının yetersiz olduğu durumlarda sıklıkla kullanılmaktadır. Temel amaç, eğitim kümesindeki tüm verinin hem eğitim, hem de doğrulama için dönüşümlü olarak kullanılarak modelin öğrenme ve sınıflandırma başarısının ölçülmesidir.

K-katlı çapraz doğrulamada, doğrulama işlemi k defa yapılarak her adımda farklı bir $k-1$ kat eğitim için, geri kalan tek kat sınıflandırma için kullanılır. Modelin doğruluk oranı, k kere yapılan sınıflandırma başarı ölçümlerinin ortalaması olarak değerlendirilir. Bu yöntemin avantajı, eğitim kümesindeki tüm örneklerin hem eğitim hem de test için kullanılmasıdır [12].

Doğrulama işlemleri sonucunda en başarılı öğrenme modeli belirlenir. Elde edilen sonuçlar Bölüm 9’da detaylı olarak anlatılmıştır.

8.5 Bölüm özeti

Bu bölümde, daha önceki bölümlerde uygulanan olay belirleme ve şiddet karakteristiklerinin çıkarımı ile elde edilen olay özelliklerini kullanılarak şiddet sınıflandırıcıların modellenmesi ve olay örneklerinin test edilmesi gerçekleştirilmiştir. Sınıflandırıcıların modellenmesinde SVM ve k-NN öğrenme ve sınıflandırma yöntemleri kullanılmıştır. Sistemin başarısı k-katlı çapraz doğrulama yöntemi ile değerlendirilmiştir.

Olağandışı trafik olaylarının şiddet karakteristiklerine göre öğrenilmesi ve sınıflandırılması süresince yapılan işlemler sırası ile aşağıda belirtilmiştir.

1. Olağandışı davranan araçlar için bir önceki bölümde anlatılan yöntemler ile değişim katsayıları, değişim açıları ve olay anındaki hızları belirlenmiştir.
2. Elde edilen özellikler ile eğitim tablosu oluşturulmuştur. Eğitim tablosundaki örnekler uzman yardımı ile düşük ve yüksek şiddetli olaylar olarak etiketlenmiştir.
3. SVM ve k-NN yöntemi ile sınıflandırma modelleri oluşturulmuştur.
4. K-katlı çapraz doğrulama ile en uygun SVM ve k-NN sınıflandırma modelleri belirlenir. İki yöntemden hangisinin sınıflandırma başarısının daha yüksek olduğu belirlenir.

9. UYGULAMA VE DENEYSEL SONUÇLAR

Bu bölümde, önerilen yaklaşım ile gerçekleştirilen deneyler ve elde edilen sonuçlar anlatılmıştır. Testler iki ayrı görüntü veri kümesi ile yapılmıştır. Birinci tip görüntüler deney ortamından elde edilmiştir. İkinci tip görüntüler, doğal trafik ortamında meydana gelen kazaları ve diğer olağandışı durumları içeren görüntülerden oluşmaktadır. Bu bölümde, ilk olarak olağan trafik akışı öğrenme testleri ve yörünge kümeleme başarı ölçümlemesi yapılmıştır. İkinci aşamada, deney ortamından alınan görüntüler ile olay analizi ve şiddet sınıflandırma, son aşamada doğal ortam görüntüleri ile olay analizi ve şiddet sınıflandırması çalışmaları yapılmıştır.

9.1 Doğal ortam görüntüleri ile yörünge kümeleme

Gerçek trafik görüntülerinde yörünge kümeleme metodunun sağlayacağı başarı, trafik kazalarının analizi adımıyla önemli rol oynamaktadır. Bu nedenle, olağan trafik akışı öğrenme modelinin başarısını gözlemleyebilmek için, gerçek görüntülerden elde edilen yörüngeler kullanılmıştır. Bu amaçla, NGSIM projesi [U.S. Department of Transportation, Federal Highway Administration] tarafından sağlanan örnek yörünge veri tabanı kullanılarak Sürekli HMM ile yörünge öğrenme başarısı değerlendirilmiştir.

9.1.1 Eğitim kümesinin hazırlanması


NGSIM projesinde yapılan çalışmalardan biri, Kaliforniya eyaletindeki 101 numaralı otoban ve otobanı kesen kavşaklar üzerinde beş adet farklı kamera kullanılarak yoğun trafik zamanındaki araçların trafik karakteristiklerini çıkartmayı amaçlamıştır. 2005 yılında yapılan bu çalışma ile 30 dakikalık görüntü kaydı süresinde (08:15 – 08:30, Haziran 2005) yaklaşık 1200 tane araç başarıyla takip edilebilmiş, her aracın akış yönü, hızları, bulundukları şeritler ve şerit değişiklikleri, ön ve arkalarından gelen araçlar arasındaki mesafe analizleri gibi trafik özellikleri belirlenmiştir. Bu çalışmada, veri kümesi tarafından sağlanan mevcut bilgilerden, konum ve hız özelliklerinden yararlanılmıştır.

Figure 1. Study Area and Camera Coverage




(a)

Figure 4. Study Area Schematic with Various Identification Numbers




(b)




(c)

Şekil 9.1 (a) 101 nolu otoban, gözlemlenen yol bölgeleri, (b) şematik akış ve (c) kavşak kuş bakışı görüntüsü [NGSIM Data Analysis Report 08:30 – 08:45]



(a)



(b)


Şekil 9.2 (a) Kavşak başlangıç ve bitiş noktaları, (b) eğitim kümesini oluşturan yörüngeler

Şekil 9.1(a)'daki kamera kapsama alanları ve 9.1(b)'deki şematik bilgiler detaylı incelendiğinde, gözlemlenen iki numaralı alanın çalışmada incelenmesi hedeflenen kavşak modeline en benzer alan olduğu görülmektedir. Olağan araç akış öğrenme modeli, bu alan üzerinde elde edilen yörüngeler baz alınarak değerlendirilmiştir. Otoyol ve giriş-çıkışlar üzerindeki her başlangıç ve bitiş noktası 9.1(b)'de görülen sayılar kullanılarak elle etiketlenmiştir (Şekil 9.2(a)). İki numaralı gözlem alanı, Şekil 9.2(a)'da başlangıç ve bitiş noktalarını içerecek şekilde tekrar çizilmiştir. Şekil 9.2(b)'de kavşak üzerinde bulunan ve eğitim kümesini oluşturan araç yörünge örnekleri koordinat düzlemi üzerinde görülmektedir.

Olağan trafik akışı öğrenimi için eğitim modeli oluşturma aşamasında model parametrelerinin seçimi, gözlemlenen kavşaktaki trafik akış yoğunluğuna ve elde edilen yörüngelerin karakteristiklerine bakılarak değerlendirilir. Farklı sürelerdeki trafik yörüngelerinde model durum sayısını herhangi bir kurala oturtamamakla beraber, yörünge veri kümesindeki en hızlı aracın durumuna göre belirlenmesi araçların davranış karakteristiklerini modele yansıtmak açısından faydalıdır. Şekil 9.2(a)'da görüldüğü gibi, kavşak giriş, orta ve çıkış olarak 3 bölgeye ayrılmıştır. Her bölgeyi farklı Q_i saklı durumunun temsil etmesi düşünülmüştür. Bu nedenle, Q saklı durum sayısı 3 olarak alınmıştır. Her saklı durumun çıkış emisyon dağılımlarını gösteren Gauss karışımları sayısı deney sonuçlarına göre belirlenmiştir. Mevcut görüntüler ile yapılan değerlendirmelerde M karışım sayısının 3 olarak kullanılması yeterli görülmüştür.

9.1.2 Yol modellerinin belirlenmesi

Bölüm 5'te detaylı olarak anlatılan Sürekli HMM kümeleme yöntemi ile yörünge kümeleme ve olağan yol modellerinin belirlenmesi gerçekleştirilmiştir. Kümeleme işleminde, yörünge özellik vektörü olarak araçların görüntü düzlemi üzerinde hareketleri boyunca sahip oldukları koordinat bilgileri (x_i, y_i) kullanılmıştır. Kümeleme işlemi sonucunda elde edilen yol modelleri Şekil 9.3'te gösterilmiştir.



Şekil 9.3 Öğrenme işlemi sonucunda elde edilen olağan yol modelleri


Şekil 9.3'te görülen yol modellerinden bazıları öğrenme işlemi sonucunda sapmalar göstermektedir. Bu tür durumlar, birden fazla şerit olan yollarda akış modelinin tek bir yol modeli ile gösterilmeye çalışıldığı durumlarda ortaya çıkmaktadır. Her bir şerit için ayrı ayrı yol modelleri öğrenilerek bu problemin önüne geçilebilir. Bu adımda, Şekil 9.2(a)'da görüldüğü gibi her hareket yönü tek bir yol modeli ile temsil edilecek şekilde düşünülmüştür.

9.1.3 Yörünge Sınıflandırma

Araç hareketlerinin farklı saklı Markov modellerine olan benzerlikleri İleri-Yön algoritması ile Birleşik Log-olabilirliği hesaplanarak belirlenmiştir. Leave-One-Out çapraz doğrulama yöntemi ile eğitim kümesindeki tüm veriyi kullanarak modelin öğrenme ve sınıflandırma başarısının ölçülmesi hedeflenmiştir.


Testler sonucunda %96,6'lık doğru yakalama başarısı elde edilmiştir. Toplam 118 yörünge örneğinden 5 örnekte hata gözlemlenmiş ve yanlış negatif %3,4 olarak bulunmuştur. Hatalı yörünge örnekler incelendiğinde, yörüngelerin birden fazla yol modeline çok yakın benzediği ve elde edilen log-olabilirlik değerlerinin olması gereken modelden çok az farklılık gösterdiği anlaşılmıştır. Bu tür hataların giderilmesi için eğitimde kullanılan örnek yörünge sayılarının artırılması faydalı olacaktır.

Şekil 9.4'te sınıflandırma işlemi sonucunda elde edilen Kesinlik-iterasyon eğrisi görülmektedir.




Şekil 9.4 Yörünge sınıflandırma, kesinlik – iterasyon eğrisi

Şekil 9.5'te görülen kavşak görüntüsünde, olağan yol modellerini belirlemede kullanılan eğitim kümesini oluşturan tüm araç yörüngelerini ve bu modellere uymayan ve olağan dışı davranan iki aracın yörüngeleri görülmektedir. Olayın yaşandığı kavşağın olay anı öncesine ait görüntüsü çok kısa süreli olduğu için, eğitim kümesinde kullanılan yörüngeler el ile işaretlenmiştir.



Şekil 9.5 Kavşak üzerinde normal davranan araç yörüngeleri ve kaza yapan diğer iki aracın yörüngeleri



Şekil 9.6 (a) Öğrenilen HMM orta noktaları, eğitim örnekleri ve kaza yapan araç örnek yörüngeleri, (b) kavşak giriş ve çıkış bölgeleri

Şekil 9.6(a)'da örnek araç yörüngeleri, Sürekli HMM ile öğrenme sonucunda elde edilen küme noktaları ile beraber gösterilmiştir. Eğitim kümesine ait olağan araç yörüngeleri ile ($t11$, $t13$ vb.) öğrenilen olağan yol modellerinin orta noktalarına yakınlıkları gösterilmeye çalışılmıştır. Araç-1 ve Araç-2 yörüngeleri, kaza yapan iki araca ait yörüngeleri temsil etmekte ve olağan yol model orta noktalarından kaza sonrası sapmaları göstermektedir. Şekil 9.6(b)'de görüldüğü gibi kavşak 9 ayrı başlangıç ve bitiş noktası ile tanımlanmış, giriş ve çıkış alanlarının oluşturduğu yol modelleri farklı HMM'ler ile temsil edilmiştir. Kaza yapan araçların yörüngelerinin her Saklı Markov Modeline olan benzerliği hesaplandığında Çizelge 9.1'deki sonuçlar elde edilmiştir. Kırmızı ile işaretlenen hücreler yörüngelerin en çok benzediği modeli işaret etmekte, fakat log-olabilirlik değerleri eğitim sonucunda elde edilen birleşik log-olabilirlik eşik seviyesinden (-300) uzaklaşmaktadır.

Çizelge 9.1 Kaza yapan araç yörüngelerinin model üzerinde test edilmesi ve elde edilen log-olabilirlik değerleri

	HMM#1	HMM#2	HMM#3	HMM#4	HMM#5	HMM#6	HMM#7	HMM#8	HMM#9	
Araç 1	-2331,2	-Inf	-1806,6	-549,2	-1197,1	-2621,1	-4933,5	-Inf	-3022,4	olağandışı yörünge
Araç 2	-635,3	-511,3	-620	-1810	-2040,5	-1776,9	-1907,5	-6243,2	-Inf	olağandışı yörünge

Çizelge 9.2 Olağan hareket eden araçlara ait test yörüngelerinin sınıflandırma sonuçları

	HMM#1	HMM#2	HMM#3	HMM#4	HMM#5	HMM#6	HMM#7	HMM#8	HMM#9	
test1	-11987	-Inf	-4551	-1235	-2331	-5953	-11330	-Inf	-Inf	düşük hızlı
test2	-576,5706	-Inf	-824,6586	-63,6598	-125,2256	-399,8913	-530,3356	-Inf	-486,696	yüksek hızlı

Eğitim ve test veri kümesindeki araç yörüngeleri aynı sürelerde ele alındığında sadece log-olabilirlik değerlerine bakarak anormallik derecesi hakkında yorum yapılabilmesi mümkünken, gözlem sürelerinin farklı olduğu durumlar anormallik derecesi hakkında kesin yargıya varmamızı kısmen engellemektedir. Gerçek trafik görüntülerinde araçların sahnede kalma süreleri hızlarından dolayı farklılık gösterebilir. Anormal yörüngeye sahip araçların log-olabilirlik değerleri beklenildiği gibi yüksek olmasına karşın, yavaş giden ve yörüngesi normal olan bir aracın log-olabilirlik değeri de birleşik olasılık hesaplamalarından ötürü yüksek olabilmektedir (Çizelge 9.2 – test1 yörüngesi, -1235 değeri). Tam tersi olarak, çok hızlı giden bir aracın log-olabilirlik değeri de gözlem sayısı az olacağından çok düşük çıkabilmektedir (Çizelge 9.2 – test2 yörüngesi, -63 değeri).

Dolayısıyla, yörüngelerin sahne üzerinde bütün olarak değerlendirilmesi, sadece, araçların başlangıçtan bitişe kadar izlemiş olduğu yörüngelerin öğrenilen olağan yol modellerine yakınlıklarının elde edilmesini sağlar. Bu durumda, olay anı belirleme ve olay şiddeti hakkında fikir yürütülebilmesi için daha önceki bölümlerde bahsedilen kısmi araç yörünge gözlemlerine ihtiyaç duyulmaktadır. Bir sonraki bölümde, kısmi araç yörüngeleri kullanımı ile olay belirleme ve olay şiddet analizi deneyleri ve elde edilen sonuçlar anlatılmaktadır. Bu bölümünde Kevin Murphy'e ait HMM uygulamasından yararlanılmıştır [13].

9.2 Deney ortamı görüntüleri ile olay belirleme ve şiddet analizi

Bu bölümde, deney ortamı üzerinde elde edilen trafik görüntüleri ile olay belirleme ve şiddet analizi işlemleri gerçekleştirilmiştir.


9.2.1 Eğitim kümesinin hazırlanması

İlk olarak, Şekil 9.7’de gösterilen deney ortamı kurulmuştur. Bu ortam üzerinde araç yörünge eğitim kümesi oluşturularak olağan trafik akışının ve yol modellerinin öğrenilmesi gerçekleştirilmiştir.



Şekil 9.7 Deney ortamı kavşak modeli


Önerilen modelin başarısını ölçmek için deney ortamında 115 adet farklı trafik kaza senaryosu canlandırılmıştır. Kazalar uzaktan kumandalı oyuncak arabalar ile oluşturulmuştur. Her senaryo, saniyede 25 kare olacak şekilde kayıt edilmiştir. Her senaryo, ortalama 6-7 saniye sürmektedir. Şekil 9.8(a)’da eğitim kümesinde yer alan olağan araç yörüngeleri görüntü koordinat düzlemi üzerinde görülmektedir. Şekil 9.8(b)’de eğitim yörüngelerinin atandığı kavşak giriş ve çıkış bölgeleri görülmektedir.



Şekil 9.8 (a) Eğitim kümesini oluşturan olağan davranan araç yörüngeleri ve (b) kavşak giriş çıkış noktaları

9.2.2 Yol modellerinin belirlenmesi

Deney kavşak modeli üzerinde olağan trafik akışını temsil etmek için her yol modeli 50 farklı araç hareketi ile öğretilmiştir. Saklı Markov durum sayısı ve Gauss karışım sayısı üç olarak belirlenmiştir. Bu sayının seçilmesinin sebebi, daha önceki bölümlerde bahsedildiği gibi kavşak üzerinde bulunan üç farklı giriş – orta ve çıkış bölgelerinin bulunmasıdır. Kümeleme işlemi sonucunda Şekil 9.9’da görülen olağan yol modelleri ve modellere ait her Gauss karışımının ortalama (μ) vektörleri elde edilmiştir.



Şekil 9.9 Deney ortamında elde edilen olağan araç yol modelleri ve Gauss karışımı orta noktaları

Öğrenme işlemi sonucunda elde edilen model parametreleri değerleri λ_1 modeli için Çizelge 9.3’te görülmektedir.

Çizelge 9.3 λ_1 olağan yol modeli parametreleri, π başlangıç, A durum geçiş matrisi, B çıkış olasılıkları matrisi

π_i	A	S_1	S_2	S_3
0,34	S_1	0,9573	0,0426	0
0,33	S_2	1,53E-31	0,9552	0,0447
0,33	S_3	1,49E-274	1,63E-32	1

B	η_1	η_2	η_3	
S_1	0,308	0,31	0,38	
S_2	0,291	0,336	0,371	
S_3	0,322	0,269	0,407	

η_1	μ_1	μ_2	μ_3	Σ_1		Σ_2		Σ_3	
	228	135	88,0435	121,65	0	75,44	0	63,62	0
	66	141	177,8545	0	74,5	0	47,11	0	39,63
η_2	261	161	110,7749	119,17	0	108,3	0	74,9	0
	41	121	160,0192	0	68,8	0	69,98	0	47,1
η_3	294	194	70,2109	146,53	0	141,1	0	65,46	0
	16	94	192,4912	0	61,1	0	91,21	0	23,42


Çizelge 9.3'te A durum geçiş matrisi'nde görüldüğü üzere, araçlar hareketleri boyunca, çoğunlukla giriş (S_1), merkez (S_2) ve çıkış (S_3) durumlarında bulunmakta ve yüksek geçiş olasılıkları görülmekte, bölgeler arasında geçişlerde ise düşük olasılıklı geçişler yaşamaktadır. Araçlar sadece ardışık durumlar arasında geçiş yapmakta ve sonuç olarak birinci derece Markov modeline uymaktadırlar. Ayrıca, A matrisinde görüldüğü üzere, araçlar, S_3 durumuna geldiklerinde sadece o durumu temsil eden bölgede bulunacaklarından başka bir duruma geçiş ihtimalleri olmayacak ve olasılıkları 1 olacaktır. B matrisi, saklı durumların ürettikleri çıkış gözlemlerinin olasılıklarını η Gauss karışımları ile temsil etmektedir. Her Gauss karışımının μ orta noktaları, Şekil 9.9'da görülen ve olağan yol modellerini oluşturan orta noktalarıdır.

Bir sonraki alt bölümde, kısmi araç hareketi gözleme ile olağandışı araç hareketlerinin olağan yol modellerinden ayrılarak belirlenmesi ve bu olayların şiddet analizlerinin yapılması ile ilgili uygulama sonuçları anlatılmaktadır.

9.2.3 Olay belirleme

Bu bölümde, Bölüm 6'da detaylı anlatılan kısmi araç hareketi gözleme ile deney ortamından elde edilen olağandışı araç hareketlerinin belirlenmesi ve şiddet derecelerine göre sınıflandırılması sonuçları anlatılmaktadır.


Deney kavşak modeli üzerinde üç farklı olağandışılık durumu üzerinde çalışılmıştır. Birinci durum, sahne üzerinde tek bir aracın şeridinden sapmasını, ikinci durum, bir aracın saptığı, diğer aracın ani duruşunu ve üçüncü durum, iki aracın çarpışmasını ve sapma göstermelerini içermektedir. Şekil 9.10, üç farklı olağandışı araç durumu için örnek sahneleri göstermektedir.




Şekil 9.10 Deney kavşak modeli üzerinde olağandışı araç hareketleri, (a) tek bir aracın şeridinden sapması, (b) bir aracın şeridinden sapması, diğer aracın ani duruşu, (c) iki aracın çarpışması

9.2.3.1 Tek aracın yarattığı olağandışı durum

Bu tür olağandışı durumlar, tek aracın devam etmesi beklenilen şeridinden ani sapması şeklinde oluşan durumlardır. Şekil 9.11(a)'da bir saniye arayla ardışık çerçeveleri görülen araç hareketinde, 1 numaralı yol modelinden hareketine başlayan araç kavşak merkezini geçtikten sonra kendi yol modelinden sapmaktadır. Aracın hareket halindeyken oluşturduğu yörünge Şekil 9.11(b)'de görülmektedir.




(a)



(b)

Şekil 9.11 (a) Tek aracın beklenilen şeridinden sapması durumu için ardışık çerçeve görüntüleri ve (b) takip sonucunda elde edilen araç yörüngesi



Şekil 9.12 Tek aracın şerit sapması durumu için olağandışılığın belirlenemediği örnekler

20 adet tek araca ait olağandışı hareket görüntüsü kullanarak tek aracın şeritten sapmasının belirlenmesi durumu test edilmiştir. Yapılan testler sonucunda %86'lık doğru yakalama başarısı elde edilmiştir. Şekil 9.12'de görülen 3 tane görüntüde hata tespit edilmiştir. Bu görüntülerden ilk ikisinde çok küçük sapmalar olduğundan, son görüntüde ise olay arabanın görüntüden çıkmasından önceki son birkaç çerçevede olduğundan olay anları yakalanamamıştır.

9.2.3.2 Bir aracın saptığı, diğer aracın ani duruş yaptığı olağandışı durumlar

Doğal ortam görüntülerinde yapılan incelemelerde birden fazla aracın kavşak üzerinde çarpışmaları çok sıklıkla görülen olağandışı durumdur. Çarpışma anındaki durumlardan biri, bir aracın şeridinden sapmadan ani duruş yapması, diğer aracın çarpışma şiddeti ile şeridinden uzaklaşması durumudur. Ani durma durumları, çarpışma riskinin hemen öncesinde veya kaza anında araçların çarpışmasının etkisiyle oluşmaktadır.


Bu tipteki olay örneklerini test etmek amacıyla kavşak üzerinde iki aracın dahil olduğu 36 farklı olay görüntüsü oluşturulmuştur. Olay görüntülerinde 66 farklı araç hareketi ile olağandışı olayların bulunması test edilmiştir. Yapılan testler sonucunda 66 farklı araç hareketinden 55 tanesinde olağandışı durum başarıyla yakalanabilmiş, 11 tane hareket anormalliği yakalanamamıştır. 24 tane olayda iki aracın olağandışı davranışı, 10 tane olayda tek bir aracın olağandışı davranışı yakalanmıştır. 2 tane olayda olağandışı davranışlar yakalanamamıştır. Elde edilen başarı değerleri Çizelge 9.4'te görülmektedir. Testler olağandışı olayların olduğu görüntüler ile gerçekleştirilmiştir. Olağan durumlar ile beraber yapılan testler birsonraki altbölümdeki Çizelge 9.6'da belirtilmiştir.

Çizelge 9.4 Test senaryoları ile bir aracın saptığı, diğer aracın ani duruş yaptığı olağandışı durumları bulma başarısı


Doğru Referans		
Tahmin edilen	Olay	Olay değil
Olay	55 (DP)	0 (YP)
Olay değil	11 (YN)	1 (DN)
DPO		0,83
YPO		0



(a)



(b)



(c)



(d)

Şekil 9.13 Başarılı ve hatalı olay belirleme örnekleri, (a) çarpışma sonrası beyaz aracın sapması ve mavi aracın aniden durması, (b) çarpışma sonrası beyaz aracın durması, mavi aracın şeridinden sapması, (c) mavi aracın ani durması ve beyaz aracın şeridinden hafifçe sapması, (d) merkez noktasının takip sırasında araçla ilişkisinin kaybolması

Şekil 9.13'te dört farklı durum için olay örnekleri görülmektedir. Şekil 9.13(a) ve (b)'de başarılı yakalanabilen sapma ve ani durma olayları, Şekil 9.13(c)'de yakalanamayan şeritten sapma olay örneği görülmektedir. Şekil 9.13(c) örneğinde, beyaz araç, mavi araca çarpıp beklenen yörüngesine yakın bir şekilde yoluna devam etmektedir. Kısmi gözlemlenen log-olabilirlik değerleri eşik seviyesinden yüksek oluşmadığı için aracın hareketi olağandışı olarak değerlendirilememiştir. Şekil 9.13(d)'de, mavi renkli araca ait merkez noktası, kavşak ortasına geldiğinde araçla ilişkisini kaybetmiş ve araç hareketine devam etmesine rağmen nokta takibi kesintiye uğramıştır. Bu problem, optik akış takibi sırasında kamera gürültüsünden dolayı oluşan takip hatası olarak değerlendirilmiştir. Diğer hatalı örnekler, hafif sapmaların olduğu fakat kısmi log-olabilirliklerin yol modeli eşik seviyesinin altında kaldığı örneklerdir.

9.2.3.3 İki aracın da yörüngelerinden saptığı olağandışı durumlar


Kavşaklar üzerinde çok sık rastlanan diğer bir olağandışı durum örneği de iki aracın çarpıştıktan sonra şeritlerinden sapmalarıdır. Bu tipteki olağandışı araç hareketlerini test etmek amacıyla kavşak üzerinde iki aracın dahil olduğu 23 farklı olay görüntüsünden yararlanılmıştır.

Yapılan testler sonucunda 46 farklı araç hareketinden 34 tanesinde olağandışı şerit sapması başarıyla yakalanabilmiş, 6 tane hareket anormalitesi yakalanamamıştır. 12 tane olayda iki aracın olağandışı davranışı, 10 tane olayda tek bir aracın olağandışı davranışı yakalanmıştır. 1 tane olayda takip hatası sonucu olağandışı davranışlar yakalanamamıştır. Elde edilen başarı değerleri Çizelge 9.5'te görülmektedir.

Çizelge 9.5 Test senaryoları ile iki aracın saptığı olağandışı durumları bulma başarısı

Doğru Referans		
Tahmin edilen	Olay	Olay değil
Olay	34 (DP)	0 (YP)
Olay değil	6 (YN)	0 (DN)
DPO		0,85
YPO		0

Şekil 9.14'te dört farklı durum için olay örnekleri görülmektedir. Şekil 9.14(a) ve (b)'de başarılı yakalanabilen sapma olayları, Şekil 9.14(c) ve (d)'de yakalanamayan şeritten sapma olay örneği görülmektedir. Çizelge 9.5'te yanlış negatif olarak belirtilen bu tür hatalı örnekler, hafif sapmaların olduğu fakat kısmi eksi log-olabilirliklerin yol modeli eşik seviyesinin altında kaldığı örneklerdir.



Şekil 9.14 Başarılı (a ve b) ve hatalı (c ve d) değerlendirmeler, (a ve b) çarpışma sonrası beyaz ve mavi aracın şeritlerinden sapması, (c) ve (d) beyaz ve mavi aracın çarpışması ve şeritlerinden hafifçe sapmaları

Çizelge 9.6, yukarıda bahsedilen tüm olağandışı örnekler ve eğitim kümesinde yeralan olağan araç hareketleri ile elde edilen değerlendirme sonuçlarını içeren hata matrisini (confusion matrix) göstermektedir. Testler sırasında, test edilen eğitim örneği, eğitim işlemi dışında tutularak yol modelleri tekrar eğitilmiş ve sınıflandırma işlemi gerçekleştirilmiştir. Olağan araç hareketi içeren eğitim örneklerinin tümü başarı şekilde doğru negatif olarak belirlenmişlerdir.

Çizelge 9.6 Test senaryoları ile olağandışı olayları bulma başarısı


Tahmin edilen	Doğru Referans	
	Olay	Olay değil
Olay	89 (DP)	0 (YP)
Olay değil	18 (YN)	120 (DN)
DPO		0,83
YPO		0

Doğru Pozitif değerleri (DP), örnek sahnelerde meydana gelen anormal durumların doğru bulunma sayısını gösterir. Yanlış Pozitifler, sahne üzerinde olağandışı araç hareketi yokken, modelin olağandışı olarak tahmin ettiği değerlerdir. Değerlendirme başarısı 10 katlı çapraz doğrulama yöntemi ile hesaplanmıştır.

9.2.4 Şiddet analizi

Olağandışı araç hareketleri yakalandıktan sonra şiddet derecelerine göre sınıflandırma işlemi gerçekleştirilmiştir. Şiddet sınıflandırma işleminde, olağandışı davranan araçların takip edilmesiyle elde edilen değişim katsayısı özellikleri (CV), olay anı ve sonrasında meydana gelen değişimin ölçülmesi ile elde edilen sapma derecesi θ ve olay anında aracın sahip olduğu hız özelliği kullanılır.

Sınıflandırma testleri sırasında kullanılan özellik vektör değerleri incelendiğinde, değişim katsayıları (CV) ve sapma derecesi (θ) değerleri arasında yüksek derecede pozitif yönde korelasyon gözlemlenmiştir. Bu nedenle, şiddet sınıflandırmada olay anındaki hız vektörleri ile beraber sadece değişim katsayısı değerleri kullanılmıştır. Sınıflandırma işleminde kullanılan özellik vektörleri Şekil 9.15(a)'da gösterilmiştir.



Şekil 9.15 (a) Eğitim örneklerinin x-y düzleminde gösterilmesi, (b) Gauss çekirdek fonksiyonu ile Destek Vektörleri sonucu elde edilen hiperdüzlemler

Elde edilen olay özellik vektörleri için kaza şiddeti sınıflandırma işlemi SVM ve k-NN sınıflandırıcıları ile yapılmıştır. En uygun sınıflandırma modelinin seçimi için 10-katlı çapraz doğrulama yöntemi kullanılmıştır. Sınıflar doğrusal ayrılabilir olmadığı için SVM yönteminde farklı doğrusal olmayan çekirdek fonksiyonları denenmiştir. Elde edilen sonuçlara göre Gauss, Polinomsal ve Karesel (Quadratic) çekirdekleri yakın başarı oranları göstermişlerdir. Şekil 9.15(b)'de Gauss çekirdek fonksiyonu ile her iterasyonda elde edilen hiperdüzlemler görülmektedir.

k-NN sınıflandırma yönteminde k değeri ve uzaklık fonksiyonu sınıflandırmanın başarısını etkileyen faktörlerdir. $k=1$ seçiminde hatalı sınıflandırmayla karşılaşılacağından, hata oranını minimize etmek için k değeri 3 ve 5 olarak kullanılmıştır. Bu sayede, örnekler ve komşuları arasındaki etkileşim yüksek tutulmaya çalışılmıştır. k-NN yönteminin başarısı $k=1,3$ ve 5 değerleri için değerlendirildiğinde $k=3$ değeri için en başarılı sonuçların elde edildiği görülmüştür. Eğitimde kullanılan örnek sayıları artırıldığı takdirde k değerinin arttırılmasının sınıflandırma başarısını olumlu yönde etkilemesi beklenmektedir. Örnekler arasındaki uzaklıklar hesaplanırken Öklid mesafesi formülü kullanılmıştır. Deneysel olaylar ile ilgili yapılan değerlendirme sonuçları Çizelge 9.7'de görülmektedir. Deneyler sonucunda

k-NN $k=3$ ve Gauss çekirdekli SVM yöntemleri ile aynı başarı değerleri elde edilmiştir. Sınıflandırıcıların 2 tane örneği yanlış negatif olarak sınıflandırdığı görülmüştür. Bu örnekler incelendiğinde, örneklerin düşük ve yüksek şiddet sınıflarını optimum ayıran hiperdüzlemlere çok yakın oldukları görülmektedir (Şekil 9.15(b)).

Çizelge 9.7 Deney görüntüleri ile SVM ve k-NN sınıflandırma ile elde edilen sonuçlar

		SVM (Gaussian, ölçekleme faktörü, sigma = 1)	KNN (k=3), Öklid	KNN (k=5), Öklid	
		Doğru Referans		Doğru Referans	
		Yüksek	Düşük	Yüksek	Düşük
Tahmin	Yüksek	10 (DP)	0 (YP)	8 (DP)	0 (YP)
edilen	Düşük	2 (YN)	41 (DN)	4 (YN)	41 (DN)
		DPO	0,83	0,66	
		YPO	0	0	

9.3 Doğal ortam görüntüleri ile olay belirleme ve şiddet analizi

Bu bölümde, doğal ortam görüntüleri kullanarak olay belirleme ve şiddet analizi test sonuçları anlatılmaktadır.

9.3.1 Eğitim kümesinin hazırlanması

TRIMARC organizasyonu tarafından 2010 Mayıs ayı başında, çalışmamızda önerilen modeli değerlendirmek üzere 2001 yılında kayıt edilen 75 adet olağandışı trafik olayı görüntüsü temin edilmiştir. Görüntüler Şekil 9.16'da görülen kavşak üzerinde, mpeg formatında, olağandışı olaylardan 4 saniye öncesi ve sonrasını içerecek şekilde kayıt edilmiştir. Görüntüler incelendiğinde, anormal olayların genel olarak iki aracın çarpışması veya tam çarpışma öncesi araçların ani fren yapmaları şeklinde olduğu gözlemlenmiştir.

Bu görüntülerde önerilen modele uymayan ortak özellik, kavşak üzerinde kaza anına ait kısa süreli kayıtlar yapıldığı için olağan trafik akışı ile ilgili örnek veri kümesinin olmayışıdır. Aynı kavşak üzerinde olağan trafik akışı görüntüleri elde etmek için organizasyonla temasa geçilmiş, fakat kaza kayıtlarının yapıldığı tarihteki düzeneğin kaldırıldığı, yine de çalışmamız için farklı açılardan görüntü temin edilebileceği bilgisi alınmıştır. Şekil 9.17'de kavşağın günümüzdeki görüntüsü görülmektedir. Bu görüntülerden olağan trafik akışı elde edilebilir, fakat kaza olaylarının kayıt edildiği kamera üzerindeki görüş açısı ile farklı olacağından iki tip görüntüler için koordinat eşleştirme çalışması yapılması ihtiyacı doğmaktadır.



Şekil 9.16 Brook ve Jefferson caddesi (Louisville, 2001)




Şekil 9.17 Günümüzde Brook ve Jefferson caddeleri kesişimi görüntüsü

Gerçek ortam görüntüleri detaylı izlendikten sonra yapılan değerlendirmelerde, kaza kayıtlarındaki anormal davranmayan ve kazaya karışmayan araçların hareketlerinden olağan durumları öğrenebilmek için eğitim kümesi oluşturulabileceği düşünülmüştür. Bu amaçla, görüntüler üzerindeki tüm araçların yörüngeleri ve hızları elde edilmiştir. Araç belirleme ve takip işleminde oluşabilecek gürültüler ve araç çakışmalarından etkilenmemek amacıyla, görüntüler üzerinde araçlar el ile işaretlenmiş ve takipleri gerçekleştirilmiştir. Toplam 400 adet normal hareket eden araç hareketi incelenmiştir.

9.3.2 Yol modellerinin belirlenmesi

Olağan davranan araçlardan elde edilen yörüngeler ile eğitim işlemi sonucunda elde edilen yol model örüntüleri Şekil 9.18(a) ve (b)'de görülmektedir. Düz siyah oklar, hareket yönlerini işaret etmektedir.



Şekil 9.18 (a) Kavşak üzerinde elde edilen tüm yörünge eğitim örnekleri, (b) öğrenim işlemi sonucunda elde edilen yol modelleri.

Şekil 9.18(a)'da eğitim kümesini oluşturan olağan araç yörünge örnekleri ve hareket yönleri görülmektedir. Şekil 9.18(b)'de gözüken olağan yol modelleri incelendiğinde kavşağın sağ köşesindeki sola dönme yolu, eğitim örneklerinin yeterli sayıda olmamasından ötürü beklenildiği gibi öğretilmemiştir.

9.3.3 Olay belirleme

75 adet olay sahnesi incelendiğinde, 40 sahnede araç çarpışmaları, tehlikeli araç geçişleri, yanlış şerit değiştirmeler veya olağandışı araç duruşları bulunmaktadır. Bu tür olaylara örnekler Şekil 9.19'da gösterilmiştir.



Şekil 9.19 İki aracın karışmış olduğu çarpışma olayı örnekleri

Diğer 35 sahnedeki trafik olayları, farklı bir kamera açısı ile çekildiğinden ya da sahne üzerinde olağandışı durum gözlemlenmediğinden değerlendirmeye alınamamıştır. Bu tür örnekler, genelde kaza ile ilgili olmayan fakat kavşak üzerinde duyulan olağandışı seslerin kayıt edildiği görüntüleri içermektedir (Örneğin, polis sireni, kamyonun şerit değiştirirken çıkardığı gürültü gibi)

Test kümesinde yeralan toplam 40 sahnede, araçlar anormal davranış göstermişlerdir. Bu sahnelerin 12'sinde araçlar çarpışmışlar, diğer 21 sahnede bir veya birden fazla araç beklenilen aksine bilinçli ve kural dışı yanlış şerit değiştirmişler, 3 sahnede olay olmadan hemen önce araçlar durmayı başaramamışlardır. Bir sahnede çarpışma oluşmuş fakat belirlenememiştir. Diğer bir sahnede iki araç anormal hareketler yapmış, fakat sadece bir araçta anormallik yakalanabilmiştir. Her örnek test, geri kalan örnekler eğitim kümesi olarak kullanılmış ve bütün örnekler test edilecek şekilde işlem tekrar edilmiştir. İki sahnede takip hatası gözlemlenmiştir. Şekil 9.20'de takip hatası örneği görülmektedir.



(a) Çerçeve #69

(b) Çerçeve #89

(c) Çerçeve #96

(d) Araç yörüngeleri

Şekil 9.20 Araç çakışması sonucu oluşan takip hatası örneği, (a), (b) ve (c) araçların belirli zamanlardaki konumları, (d) araçların oluşturdukları yörüngeler

Şekil 9.20(a)'da çarpışma öncesinde beklenilen yol modeline uygun hareket eden otomobil, beyaz renkli kamyonun bilinçli ve kural dışı dönüşü sonucunda kaza yapmakta ve kamera görüş açısından kaybolmaktadır. Çarpışma anı ve sonrasında araçların elde edilen yörüngeleri Şekil 9.20(d)'de görülmektedir. Kaza yapan otomobil'e ait takip noktası çakışmadan sonra kamyon'a ait nokta olarak değerlendirilip takibine hatalı olarak devam edilmiştir. Bu tür problemler, birden fazla kamera ile elde edilecek ve üç boyut tabanlı modellenecek araç yörüngelerinin takip edilmesiyle giderilebilir.

Çizelge 9.8, testler sonucunda elde edilen olay belirleme değerlerini ve başarı oranlarını göstermektedir.

Çizelge 9.8 Gerçek trafik olay görüntüleri ile elde edilen olay belirleme sonuçları

Doğru Referans

Tahmin edilen	Olay	Olay değil
Olay	43 (DP)	12 (YP)
Olay değil	5 (YN)	99 (DN)
DPO		0,89
YPO		0,1

Elde edilen sonuçların eğitim ve test kümelerine göre dağılımları Çizelge 9.9’da, test kümesinin olaylara göre dağılımı Çizelge 9.10’da görülmektedir.


Çizelge 9.9 Olay belirleme sonuçlarının test ve eğitim kümelerine dağılım miktarları

	DP	YP	YN	DN
Eğitim kümesi	0	12	0	85
Test kümesi	43	0	5	14
Toplam	43	12	5	99

Çizelge 9.10 Test kümesinin olay tiplerine göre dağılımı

	DN	YN	DP
Bilinçli şerit değişimi	0	0	24
Olağan Araç davranışı	14	0	0
Olağandışı Araç davranışı	0	5	0
Belirlenen olağandışılık	0	0	19

12 adet eğitim kümesi örneğinde gerçekte olağandışı durum olmadığı halde olağandışı durum olduğu belirlenmiştir. Bu örneklerde genel olarak, araçların çakışması sonucu oluşan takip hatası nedeniyle hareketleri olağandışı olarak belirlenmiştir (Şekil 9.21).




Şekil 9.21 Takip hatası sonucu olağandışı olarak belirlenen normal olaylar

Şekil 9.21(c) ve (f)’de görülen örneklerde, iki farklı araca ait araç merkez noktaları, araçlar çakışma yaşayana kadar başarılı şekilde takip edilirken, çakışma sonrası merkez noktaları, kameraya yakın taraftaki araca hatalı olarak ilişkilendirilip ikinci bir noktaymış gibi takip

edilmeye devam ediyor. Bu durumlarda takip edilen nokta, olağandışı sapma göstermemiş olsa bile (Şekil 9.21(f)), ait olduğu araçla ilişkisi kesildiği için hatalı olay olarak değerlendirilmiştir.

Test kümesinde yer alan ve Çizelge 9.10’da yanlış negatif olarak görülen 5 adet araç hareketi, gerçekte olağandışı hareketken, yakalanamamış ve olağan hareket olarak değerlendirilmiştir. Bu tür araç hareketlerine örnekler Şekil 9.22’de görülmektedir.



Şekil 9.22 Olağandışı durumların olduğu fakat belirlenemediği olay örnekleri

Şekil 9.22(a),(b) ve (c)’de görülen olağandışı durum, sistem tarafından şerit sapması veya ani duruş gözlemlenemediğinden belirlenememiştir. Kırmızı renkli kamyonet, beyaz renkli kamyonet’in çarpması sonucu beklenilen şeridinden sapma göstermiş, fakat oluşan sapma log-olabilirlik eşik değerini aşmadığından olağandışı olarak değerlendirilmemiştir. Şekil 9.22(d), (e) ve (f)’de ise orta şeritten gelen mavi renkli araç ani duruş gerçekleştirmiş fakat belirlenememiştir. Her iki olay da sahnenin uzak köşesinde olduğundan araçların zaman içerisinde kat ettikleri mesafe ani duruş hesaplaması için yetersiz kalmaktadır. Bu tür durumlarda, gerçek yol boyutlarının bilinmesi ile sistem başarısının artacağı düşünülmektedir.

Çizelge 9.10’da yer alan 24 adet araç hareketi bilinçli ve kural dışı araç hareketi olarak sınıflandırılmıştır.



Çerçeve #38 (a)

Çerçeve #63 (b)

Çerçeve #99 (c)

Şekil 9.23 Bilinçli ve kural dışı dönüş örneği

Şekil 9.23(a), (b) ve (c)'de görülen olay örneğinde, kırmızı renkli araç beklenen yol modeli dışına çıkıp bilinçli ve kural dışı dönüş yaparak yoluna devam etmektedir. Bu tür davranışların, bilinçsiz araç sapmalarından ayrılabilmesi, aracın kural dışı dönüşü süresince sahip olduğu hızın değişiminin gözlemlenmesi ile sağlanır. Bilinçli ve kural dışı araç örnekleri incelendiğinde, bu tür harekette bulunan araçların hızları düşük değişimler gösterirken, ani sapmalarda araç hızlarında yüksek değişim oranları gözlenmektedir. Bu şekilde olan hareketler, sürücülerin bilinçli olarak yarattığı olağandışı hareketlerdir ve şiddet sınıflandırmaya alınmamışlardır.


Çizelge 9.10'da yer alan 14 adet araç hareketi, kavşak üzerinde olağandışı durumu yaratan araçlar dışında kalan ve olağan şekilde hareket eden araçları gösterir. Şekil 9.24'te bu gruba dahil olan araç hareketi örneği görülmektedir.



Şekil 9.24 Olağandışı sahne üzerinde olağan davranan araç ve sahnenin sağ üst köşesinde kural dışı dönmeye çalışan araç

9.3.4 Şiddet analizi

Olağandışı araç hareketleri yakalandıktan sonra şiddet derecelerine göre sınıflandırma işlemi gerçekleştirilmiştir. Sınıflandırma işleminde kullanılan özellik vektörleri Şekil 9.25'te görülmektedir.




Şekil 9.25 Doğal ortam görüntülerinde sınıflandırma işleminde kullanılan eğitim örnekleri

Olay belirleme sonucunda elde edilen olay özellik vektörleri ile SVM ve k-NN sınıflandırıcı başarı değerleri 10-katlı çapraz doğrulama tekniği ile elde edilmiştir. SVM yönteminde farklı çekirdek fonksiyonları denenmiştir. Testlerde, Gauss, Polinomsal ve Karesel çekirdek fonksiyonları kullanılmıştır. Sınıflandırma sonuçları Çizelge 9.11’de gösterilen başarı değerleri ile gösterilmiştir. k-NN yönteminde $k=3$ ve $k=5$ ile, SVM yönteminde Polinomsal çekirdek ile en başarılı sınıflandırma sonuçları elde edilmiştir. Sonuçlar değerlendirildiğinde, daha fazla olay örneği ile sınıflandırma yapılarak düşük ve yüksek şiddet sınıflarının daha belirgin şekilde ayrıştırılacağı düşünülmektedir.

Çizelge 9.11 SVM ve k-NN ile elde edilen sınıflandırma sonuçları

		SVM (Gauss ölçüm faktörü, sigma=1)		SVM (Polinomsal)		SVM (Karesel)		KNN (k=3, k=5)	
		Doğru Referans Yüksek	Düşük	Doğru Referans Yüksek	Düşük	Doğru Referans Yüksek	Düşük	Doğru Referans Yüksek	Düşük
Tahmin edilen	Yüksek	5 (DP)	2 (YP)	6 (DP)	2 (YP)	5 (DP)	3 (YP)	6 (DP)	2 (YP)
	Düşük	3 (YN)	8 (DN)	2 (YN)	8 (DN)	3 (YN)	7 (DN)	2 (YN)	8 (DN)
DPO		0,625		0,75		0,625		0,75	
YPO		0,2		0,2		0,3		0,2	

Şekil 9.26’da farklı çekirdek fonksiyonları kullanarak elde edilen SVM sınıflandırma sonuçları x-y koordinat düzleminde gösterilmiştir. X eksenini her araca ait değişim katsayısı değerini, y eksenini olay anındaki aracın hızını göstermektedir.




Şekil 9.26 Destek Vektör Makineleri ile sınıflandırma sonuçları

Koordinat düzlemleri üzerinde her doğrulama adımında elde edilen hiperdüzlemler ve son adımdaki sınıflandırma sonuçları görülmektedir. “+” ile işaretlenen örnekler her adımda sınıflandırılan düşük şiddetli olay örneklerini, “*” ile gösterilen örnekler her adımda sınıflandırılan yüksek şiddetli olay örneklerini göstermektedir. “o” ile işaretlenen örnekler her adımda bulunan destek vektörleridir. Çalışmanın bu aşamasında, Matlab uygulamasının SVM modülünden [14] faydalanılmıştır.

Çizelge 9.11’deki sonuçlar değerlendirildiğinde, k-NN yöntemi için $k=3$ değeri ile Polinomsal SVM yöntemleri ile en başarılı sonuçlar elde edilmiştir. Her iki yöntem için de sınıflandırma sonucunda oluşan hatalı örnekler değerlendirildiğinde, iki örnek düşük şiddetli sınıfa aitken yüksek şiddet, diğer iki örnek de yüksek şiddet sınıfına aitken düşük şiddet sınıfına atanmıştır.

Gerçekte düşük şiddetli sınıfa ait olup yüksek şiddet sınıfına atanan örnekler Şekil 9.27, 9.28 ve 9.29’da görülmektedir.



Şekil 9.27 Sınıflandırma sonucunda elde edilen yanlış pozitif örnekler, (a) Sapma gerçekleşmeyen fakat ani duruşun olduğu olay, (b) hafif sapmanın ve çarpışmanın gerçekleştiği olay



(a) Çerçeve #91

(b) Çerçeve #103

(c) Çerçeve #132

Şekil 9.28 Şekil 9.27(a)'da yanlış sınıflandırılan kırmızı araca ait anlık çerçeveler ve hareketi boyunca oluşturduğu yörüngesi




(a) Çerçeve #70

(b) Çerçeve #92

(c) Çerçeve #131

Şekil 9.29 Şekil 9.27(b)'de yanlış sınıflandırılan gri renkli araca ait anlık çerçeveler ve hareketi boyunca oluşturduğu yörüngesi

Gerçekte yüksek şiddet sınıfına dahil olup düşük şiddet sınıfına atanan örnekler Şekil 9.30, 9.31 ve 9.32'de görülmektedir.



Şekil 9.30 Sınıflandırma sonucunda elde edilen yanlış negatif örnekler, (a) Sapma gerçekleşmeyen fakat ani duruşun olduğu olay, (b) hafif sapmanın ve çarpışmanın gerçekleştiği olay



(a) Çerçeve #78

(b) Çerçeve #92

(c) Çerçeve #165

Şekil 9.31 Şekil 9.30(a)'da yanlış sınıflandırılan gri araca ait anlık çerçeveler ve hareketi boyunca oluşturduğu yörüngeleri (siyah renkli araç kural dışı ve bilinçli şerit değiştirdiğinden şiddet sınıflandırılmasına alınmadı)



(a) Çerçeve #60

(b) Çerçeve #78

(c) Çerçeve #119

Şekil 9.32 Şekil 9.30(b)'de yanlış sınıflandırılan sol üst köşeden gelen mavi renkli araca ait anlık çerçeveler ve hareketi boyunca oluşturdukları yörüngeleri, (diğer mavi renkli araç kural dışı ve bilinçli şerit değiştirdiğinden şiddet sınıflandırılmasına alınmadı)

9.4 Bölüm özeti

Bu bölümde, deneysel ve doğal ortamdan elde edilen trafik görüntüleri ile olağan yol modellerinin belirlenmesi, olağandışı araç hareketlerinin bulunması ve olağandışı davranan araçlar için şiddet analizi uygulamaları ve deney sonuçları anlatılmıştır.

Olağan yol modellerinin belirlenmesi başarısı, doğal ortam trafik görüntülerinden elde edilen NGSIM veri kümesi ile gerçekleştirilmiştir. Olağandışı durumların belirlenmesinde ve şiddet analizi işlemlerinde deney ve TRIMARC veri kümeleri kullanılmıştır. SVM ve k-NN sınıflandırma yöntemleri kullanarak olağandışı araçların şiddet karakteristikleri çıkartılmıştır. Şiddet sınıflandırma başarısı 10-katlı çapraz doğrulama tekniği ile ölçülmüş, yörünge öğrenme ve sınıflandırma testlerinde Leave-one-out çapraz doğrulama tekniği kullanılmıştır.

10. DEĞERLENDİRME

Bu çalışmada, video görüntü işleme ve örüntü tanıma teknikleri kullanılarak kavşaklarda meydana gelen trafik kazalarının tanınması ve şiddet derecelerine göre sınıflandırılmasını yapan bir sistem tasarlanmış ve gerçekleştirilmiştir. Bu çalışmanın en önemli özgülüğü, trafik görüntülerinde kaza anının anlaşılması ve kazanın karakteristik özelliklerinin incelenerek olayın şiddet derecesinin belirlenmesidir. Bu bölümde, daha önce Bölüm 2’de literatür değerlendirmesinde özetlenen ve bu tezde önerilen sisteme en yakın çalışmalar ile detaylı karşılaştırmalar yapılmış, farklılıklar, tez sonucunda elde edilen çıkarımlar ve gelecek çalışmalar anlatılmıştır.

10.1 Önceki çalışmalar ve farklılıklar

Önceki çalışmalar ile ilk karşılaştırma, KTC (Green ve Agent, 2001) tarafından önerilen çalışma ile yapılmıştır. Önerilen model, kavşak üzerinde oluşan olağandışı seslere göre değerlendirme yaparak olayları kaydetmiştir. Çalışmanın en büyük farklılığı, sadece ses bilgisinin değerlendirilmiş olmasıdır. Sistemin başarısı polis raporları ile ölçülmüş, küçük şiddetli olaylar polis raporlarına yansımadığından dolayı sadece polis raporlarında olan kazalar kriter alınarak başarı değerlendirmesi yapılmıştır. Yapılan çalışmada %56 oranında olay belirleme başarısı elde edilmiştir. Bu değer, testler sonucunda başarıyla belirlenen kaza sayısının polis raporlarına yansıyan toplam kaza örneklerine oranıyla bulunmuştur. Polis raporlarına yansımayan olaylar, küçük şiddetli ve polis müdahalesine gerek olmayan durumlar olarak ifade edilmiştir. Tüm olayların polis raporları ile karşılaştırıldığı durumda, yüksek derecede yanlış alarm üretildiği görülmüş ve doğru belirleme oranı %1’lere kadar düşmüştür. Çalışmamızda, bu çalışmada elde edilen olay görüntüleri kullanılmıştır. Önerdiğimiz sistemde çarpışma ve yakın tehlikeli geçişlerdeki olağandışı araç hareketlerine odaklanıldığından başarı değerlendirmesi bu türdeki görüntüler ile yapılan testler sonucunda elde edilmiştir. Bu tezde %89 olay belirleme başarısı ve %75 olay sınıflandırma başarısına ulaşılmıştır. TRIMARC tarafından sağlanan görüntüler ile KTU tarafından elde edilen sonuçlar arasında eşleştirme sağlanamadığından başarı değerlerinin birebir karşılaştırması yapılamamıştır.

Ki ve Li (2007), kavşak üzerinde oluşan kazaların belirlenmesi için çalışmıştır. Kendi oluşturdukları gerçek görüntü toplayan sistem ile görüntüler elde edilmiştir. İki haftalık izleme sürecinde gerçekte 10 adet kaza gerçekleşirken, kurdukları sistem ile 6 adet kazanın başarılı olarak yakalandığı ifade edilmiştir. Testler sonucunda %60’lık başarı oranı elde edilmiştir. Çalışmada, KTU tarafından elde edilen sonuçlar ile karşılaştırma yapılmıştır.

Makalede, KTU tarafından elde edilen kaza görüntülerinin kullanılıp kullanılmadığına dair bir bilgi bulunamamıştır. Trafik kazası belirleme aşamasında, araçlara ait ivme, konum, yön ve kapladığı alan özelliklerinden yararlanılmış, her özellik için ayrı eşik değerleri kullanarak olağandışı durumlar belirlenmeye çalışılmıştır. Önerilen yöntemin olumsuz yanı, kaza kararı verilmesinde yüksek ölçüde eşik değerlerine bağımlı kalınmış olmasıdır.

Swears vd., (2008) otoban ve kavşak görüntülerinde hareket örüntülerinin öğrenilmesi ve olağandışı davranan araçların üzerinde bulundukları şeritlerden hız ve pozisyonel olarak sapmalarını incelemiştir. Çalışmalarında hiyerarşik toplamalı Saklı Markov Modeli kullanılmıştır. Bu çalışmada önerilen model ile benzerliği, yeni gelen gözlemleri yol modelleri ile eşleştirirken kısmi gözlemler ve log-olabilirlik değerlerinin kullanılmış olmasıdır. Doğal ortamdan elde edilen görüntülerle çalışmalar yapılmış fakat kaza belirleme ve olay analizi ile ilgili herhangi bir değerlendirme yapılmamıştır.

Başka bir kaza belirleme çalışması Zou vd. (2009, 2010) tarafından gerçekleştirilmiştir. Kavşak üzerinde araçların trafik akış yönleri kullanılarak trafik durumunun belirlenmesi amaçlanmıştır. Önerilen yöntemde, kavşak üzerindeki trafik, başlangıç ve bitiş hareket yönlerine göre 5 farklı sınıfa ayrılmıştır. Bu sınıflar batı-doğu, doğu-batı, güney-kuzey, kuzey-güney ve kaza durumlarıdır. Her sınıf 100 adet çerçeve farklı görüntüsü kullanılarak eğitilmiş, 500 adet çerçeve ile sınıflandırma testleri HMM ve SVM sınıflandırma yöntemleri kullanılarak gerçekleştirilmiştir. Sınıflandırmada kullanılmak üzere özellik çıkarımı için FFT ve DCT kullanılmıştır. Kendi kurdukları kavşak izleme sistemi ile doğal ortamdan elde edilen 500 adet hareket çerçevesi ile testler sonucunda FFT özellik çıkarımı ile %84, DCT ve FFT'nin beraber kullanımı ile %97'lik olay belirleme başarıları ifade edilmiştir. Olay belirleme başarıları kısıtlı kaza görüntüsü ile elde edilmiş ve yöntemin genelleştirilmesi için kaza örneklerinin arttırılmasının planlandığı ifade edilmiştir. Ayrıca, özellik çıkarımı ardışık çerçeve farkına bağımlı olduğundan karmaşık arkaplanın olduğu kavşak görüntülerinde başarı olumsuz etkilenebilecektir.

Hu vd. (2006) tarafından istatistiksel hareket örüntülerinin öğrenilmesi çalışması gerçekleştirilmiştir. Çalışmalarında, başarılı araç belirleme ve takibi, kaza tahmini ve araç davranış anlama üzerine yöntemler sunulmuştur. Gerçek hayattan elde edilen görüntülerle %97'lik araç takibi başarı oranı elde edilmiştir. Olağandışı durumların belirlenebilmesi ve tahmin edilebilmesi için deney ortamı kullanılmıştır. Değerlendirme testlerinde anormallik yakalama ve kaza tahmini için başarı oranları belirtilmemiştir.

Kamijo vd. (2000) önerdikleri çalışmada %93-96 arası araç belirleme ve takip başarısı elde etmişlerdir. Değerlendirme testlerinde gerçek hayattan elde edilen görüntüler kullanılmıştır. Kendi düzenekleri ile bir yıllık uzun süreli gözlem sonucunda sadece 3 adet kaza görüntüsü elde edilmiştir. Çalışmalarında, HMM tabanlı olay ve kaza belirleme yöntemi önerilmiştir. Sahne üzerinde hareket eden her araç çifti için ardışık hareket vektörü farkı bulunmuş, bu özellik araç çiftleri arasındaki mesafeler ile beraber kullanılarak HMM giriş gözlemleri oluşturulmuştur. Arkadan çarpma, arkadan çarpma öncesi durma ve yakın geçiş trafik olaylarına ait 3 farklı Saklı Markov Modeli öğretilmiş, gerçek görüntülerin yetersiz kaldığı durumlarda elle oluşturdukları olay gözlem serileri kullanılmıştır. Olay belirleme için soldan sağa Markov zinciri yapısı kullanılarak yeni gözlem örneklerinin bu sınıflara benzerlikleri hesaplanmaya çalışılmıştır. Trafik kazalarının nadir gerçekleşen olaylar olduğu düşünüldüğünde, her olağandışı trafik durumunun öğretilmesi önerilen modelin uygulanabilirliği için zorlayıcı faktördür. Ayrıca, çok fazla sayıda aracın bulunduğu karmaşık kavşak görüntülerinde, her araç çifti için hareket vektör farklarının çıkarımı, gözlem örneklerinin maksimum olabilirliklerinin ve olayların belirlenebilmesi için ek yük getirecektir.

Yukarıda bahsedilen çalışmalar genel olarak değerlendirildiğinde, hedeflenen ortak amacın olağandışı trafik olaylarının belirlenmesi ve olayların arkadan veya yandan çarpmalar gibi etiketlenmesi olduğu görülmektedir. Günümüzde, video görüntülerinde olağandışı durumların belirlenmesinin yanı sıra, olayların anlamsal içeriklerinin çıkartılması büyük önem kazanmıştır. Bölüm 2’de özetleri verilen ve burada detaylı karşılaştırılan çalışmalarda eksik görülen ve bu tezle hedeflenen, trafik görüntülerinde olağandışı durumların belirlenerek olay analizlerinin yapılmasıdır.

Hemen hemen bütün kavşaklar doğal olarak karmaşık görüntülere sahiptirler. Bu sebeple, önerdiğimiz yöntemin sonuçları başarılı arkaplan çıkarımı, araç bölütleme ve takip işlemlerine dayalıdır. Arkaplan çıkarımı ve önplanda yer alan araçların bölütlenmesinde Adaptif Gauss Arkaplan modelleme ve Bağlı Bileşenler yöntemleri kullanılmıştır. Araç hareketlerinin belirlenmesi, Piramitsel Optik Akış yöntemi kullanarak temsili araç merkez noktası takibi ile gerçekleştirilmiştir. Elde edilen araç yörüngeleri ile Gauss Karışım Modeli destekli Sürekli HMM ile yörünge kümeleme işlemi gerçekleştirilmiş ve olağan yol modelleri bulunmuştur. Sürekli HMM’in araçların zamansal-uzaysal hareketlerini yansıtmada başarılı olduğu çalışmamızda da görülmüştür. Öğrenilen olağan yol modelleri ile kısmi araç hareketleri arasında Maksimum Olabilirlik yöntemi ile benzerlikler ve sapmalar gözlemlenerek olağan ve

olağandışı davranışlar belirlenmiştir. Bir sonraki aşamada, olağandışı trafik olaylarının şiddet özellikleri Değişim Katsayısı ve Çok Fazlı Doğrusal Regresyon Fonksiyonu yöntemi ile elde edilmiştir. Değişim özellikleri kullanılarak SVM ve k-NN sınıflandırma yöntemleri ile olağandışı olduğuna karar verilen olayların şiddet sınıflandırması yapılmıştır. Sınıflandırma aşamasında en uygun modellerin belirlenmesi ve sınıflandırma başarısının ölçülebilmesi için olay belirleme aşamasında Leave-One-Out Çapraz Doğrulama, kazaları şiddetlerine göre sınıflandırma aşamasında 10-katlı Çapraz Doğrulama yöntemleri kullanılmıştır.

Deney ve doğal ortamlarından elde edilen görüntüler ile yapılan olağandışı olay belirleme değerlendirmeleri sonucunda %83 ve %89 doğru belirleme başarısı elde edilmiştir. Olağandışı olayların şiddet tiplerine göre sınıflandırılması testleri ile deney görüntülerinde %83, doğal ortam görüntülerinde %75 doğru sınıflandırma başarısı elde edilmiştir. Elde edilen sonuçlar, olağandışı araç hareketlerinin olasılıksal olarak belirlenebileceğini ve olağandışı olayların bu olasılıklara bağlı olarak şiddet analizlerinin başarıyla yapılabileceğini ortaya çıkartmıştır.

Olağan yol modellerinin öğrenilmesi aşamasında, çalışmamız Swears ve ekibinin yapmış olduğu çalışmayla benzerlik göstermektedir, fakat bahsedilen çalışmada kaza analizine yönelik herhangi bir işlem yapılmamıştır.

KTU tarafından önerilen ses tanıma tabanlı olay belirleme yöntemlerinin genel özelliği, olayların çıkarmış olduğu ayırt edici seslerin tanınmasıyla olağandışı durumları belirlemeye çalışmaktadır. Farklı trafik görüntüleri incelendiğinde, araçların bulundukları ortamdaki ses gürültüleri (korna sesleri, yol gürültüleri gibi) ve araçların hareket halinde neden oldukları sesler (ani fren, sert kalkış, patinaj gibi) çok çeşitlilik göstermektedir ve gruplandırılması zordur. Doğal trafik ortamlarında, ses tanıma tabanlı olay belirleme yöntemleri genel olarak görüntü tanıma tabanlı olay belirleme yöntemlerine destek olarak düşünülmelidir. KTU tarafından elde edilen sonuçlar incelendiğinde olay belirlemede kabul edilebilir bir başarı elde edilmişken, yanlış alarmların oranı hayli fazla ve kabul edilemez miktardadır.

Zou ve ekibi tarafından yapılan çalışma incelendiğinde, çalışmada araç davranışlarını bireysel olarak incelemek yerine kavşak üzerindeki trafik akışının gidişat yönüne göre trafik durumu farklı sınıflarla etiketlenmiştir. Özellik çıkarımı için ardışık çerçeveler arasındaki fark görüntüleri kullanılmış ve genel hareket akışları sınıflandırma işleminde değerlendirilmiştir. Karmaşık arkaplan görüntülerinde, önerilen modelin arkaplan ve kamera gürültülerinden etkileneceği düşünülmektedir. Olay analizlerinin temel amacı, sahnede gerçekleşen olayın ne olduğunun ortaya çıkarılmasının yanı sıra olaya karışan nesnelerin davranışlarını incelemek

ve olayın temel nedenini ortaya çıkarmaktadır. Çalışmamızda, her aracın davranışı incelendiğinden olayların nedenleri hakkında fikir sahibi olunabilmektedir.

İncelenen diğer çalışmalara (Ki, Hu ve Kamijo) göre, olağandışı durumların belirlenmesi aşamasında, çalışmamız bazı avantajlar içermektedir. Önerdiğimiz model ile kavşak üzerindeki her araç çifti için çarpışma olup olmadığının incelenmesine ihtiyaç yoktur. Öteki türlü, sahne üzerinde her çerçevede n adet araç var ise $n \times (n-1)$ adet çarpışma sorgulamasına gerek duyulmaktadır. Yüksek sayıda araçların olduğu kavşak ortamlarında, bu durum hesaplama karmaşıklığını arttıracaktır. Ayrıca, önerdiğimiz yöntem ile araçların reel hızlarına ihtiyaç duyulmadan araçların aşırı hızda olması gibi öğrenilen modellere uymayan anormal hareketler yakalanabilmektedir.

Önerilen tez çalışmasının diğer çalışmalar ile olan farklılıkları ve benzerlikleri Çizelge 10.1’de özetlenmiştir.

Çizelge 10.1 Önceki çalışmalar ve önerilen çalışma ile farklılıkları

Çalışma	Yörünge öğrenimi	Olay Belirleme	Olay Analizi	Olay Tahmini	İçerik Analizi
Önerilen çalışma	Sürekli HMM	Kısmi gözlemler ile Maksimum Olabilirlik ve kural tabanlı karar ağacı	Olay ve tiplerinin belirlenmesi	-	Değişim katsayısı ile kaza şiddet analizi
AIRS, Green ve Agent	-	Olağandışı seslerin belirlenmesi	-	-	-
Ki vd.	-	Kural tabanlı karar ağacı	-	-	-
Swears vd.	Sürekli HMM	Kısmi gözlemler ile Maksimum Olabilirlik kullanarak konumsal ve hızsal anormallik	-	-	-
Zou vd.	HMM	HMM/SVM	Kaza durumu Belirleme	-	-
Hu vd.	SOM	Maksimum Olabilirlik	-	Çakışma tahmini	-
Kamijo vd.	HMM	HMM ile olay sınıflandırma	HMM ile olay tanıma	-	-
Piciarelli vd.	Clustering tree-like structure	Olasılıksal tabanlı	Konumsal ve hızsal anormallik	-	-
Fu vd.	Spektral kümeleme	Maksimum olabilirlik	-	-	-
Saunier vd.	Sürekli HMM	-	-	Çakışma tahmini	-
Tai vd.	-	Aktif Çevrit takibi	Çevritlerin çakışması	-	-
Atev vd.	-	-	-	Çakışma tahmini	-

10.2 Çıkarımlar

Bu çalışmada mevcut çalışmalardan farklı olarak, araç hareketlerinin öğrenilen yol modellerine olasılıksal benzerliğini ölçerek olağandışı olayların varlığını anlayan ve bu olasılıkları değerlendirerek olayların şiddet derecelerini belirleyen bir sistem geliştirilmiştir. Tez çalışması ile elde edilen sonuçlar değerlendirildiğinde kullanılan yöntemler ve birbirleri ile olan etkileşimleri ile ilgili aşağıda belirtilen çeşitli çıkarımlar yapılmıştır.

Kavşaklardaki trafik görüntülerinin çok karmaşık yapıda olması önplandaki araçların başarılı bölütlenmesi için en önemli zorlaştırıcı faktördür. Araç takibi sırasında araç çakışmalarını en aza indirebilmek için başarılı bölütleme çözümlerine ihtiyaç bulunmaktadır. Bu adımda elde edilecek başarı diğer işlemlerde elde edilecek başarı oranlarını tümüyle etkilemektedir.

Araç takibi ile ilgili olarak araçları temsil edecek özellik vektörlerinin doğru seçilmesi gerekir. Seçilecek özellikler ile araçlar arasında olan ilişkilendirmenin hareketleri boyunca korunması gerekeceğinden gürültü durumlarında ilişkilendirmedeki hatalar ileriki aşamalarda başarı oranlarını etkilemektedir. Örneğin, takip edilen araçlara ait kenar çevritlerinin izlenmesi yapıldığında araçların birbirlerine yaklaştıklarında üst üste binmesi probleminin çözülmesi gerekmektedir. Aynı şekilde, özellik tabanlı takip sistemlerinde araçları temsil eden noktasal özellikler kullanıldığında bu noktaların araçlar için özel olduğu hareket süresince korunmalıdır. Birden fazla özellik noktası düşünüldüğünde, özelliklerin her araç için gruplandırılarak temsilci özellik noktasının seçimi ile kısmi olarak çakışma probleminin çözüm sağlanabilir. Bununla beraber, temsil edici özellik noktalarının sahne üzerinde gürültü durumunda araçlarla olan ilişkilerinin de korunması gerekmektedir. Örneğin, kamera ile araç arasına bir direk ya da ağaç nesnesi geldiğinde, bu durumda takip edilen özellik noktası ile araç arasındaki ilişki kaybolabilmektedir. Bu ilişkinin araç görünür hale geldiği anda tekrar sağlanması gerekebilir.

Araçların takibi sonucunda konumsal ve hızsal bilgilerinin başarılı şekilde elde edilebilmesi için trafik sahnesini gözlemleyen kameraların yol veya kavşak geometrik yapısı gözönüne alınarak doğru noktalara yerleştirilmesi gerekir. Görüntü koordinatlarında çalışıldığında, kamera görüntüsünde oluşan perspektif etkisi mümkün olduğunca azaltılmalıdır. Örneğin, herhangi bir kavşağı gözlemleyebilmek için kuşbakışına yakın görüntü sağlayan kamera kullanımı, araçların daha başarılı bölütlenmesine ve doğru takip sonuçlarının elde edilmesine yardımcı olacaktır.

Önerilen tezde kullanılan Saklı Markov Model ile olağan araç hareketlerinin belirlenmesi, bu çalışmanın yol geometrisinden bağımsız olarak her türlü trafik ortamına uyum göstermesini sağlamaktadır. Saklı Markov Model’de saklı durum sayısının yol veya kavşak geometrisine göre belirlenmesi başarıyı etkileyen faktörlerden birisidir. Ayrıca, Saklı Markov Model’deki Gauss karışım sayısının mevcut eğitim örneklerinin sayısına göre belirlenmesi doğru olacaktır. Düşük sayıda örnek olduğu durumlarda karışım sayısının düşük tutulması yol modellerinin daha düzgün temsil edilmesini sağlar. Öteki türlü, ortak yol örüntülerinde karışım sayısının çokluğuna bağlı olarak zigzag şeklinde düzensiz örüntülerle karşılaşılmaktadır. Sürekli veri kaynağının olduğu durumlarda karışım sayısının her saklı durum başına arttırılması tahmin edilen araç hareketlerinin saklı model tarafından daha başarılı açığa çıkartılmasını sağlamaktadır.

Olağan yol modellerinin öğrenilmesi ile ilgili diğer bir çıkarım; yol modellerinin tek bir örüntü ile temsil edilmesi yerine aracın üzerinde hareket ettiği şeridi tümüyle kapsayacak bir yol modeli ile temsil edilmesi daha başarılı kümeleme sonuçlarının üretilmesine yardımcı olacaktır. Bu şekilde şerit kenarlarına yakın hareket eden araçların doğru yol modelinde bulunması sağlanmış olacaktır.

Olağan yol modelleri öğrenimi sırasında gözlemlenen olağandışı araç hareketleri sıklıkla belli bir örüntüye oturuyorsa (örneğin, sürekli aynı yöne kural dışı hareket eden araçlar), bu gibi durumların öğrenilebilmesi düzenli seyir gösteren olağandışı olayların belirlenmesini sağlamaktadır. Bu şekilde, olağandışı olaylar öğrenilebilir hale gelmekte ve diğer odaklanılan olağandışı olayların daha efektif olarak ayrıştırılabilmesi sağlanabilmektedir.

Olağandışı araç hareketlerini belirleme işlemlerinde kullanılan kısmi gözlem segmentlerinin uzunluğu, olayların yakalanma anını ve şiddetlerinin büyüklüklerini belirlemede önemli rol oynamaktadır. Kısmi gözlem sürelerinin seçiminde araçların sahne üzerinde ortalama kalma süreleri gözönüne alınarak deneysel olarak karar verilmektedir. Yavaş akan bir trafik görüntüsünde kısmi gözlem süresinin uzun tutulması işlem karmaşıklığını azaltırken, hızlı akan bir trafikte az sayıda kısmi gözlem elde edilebileceğinden, kısmi gözlem süresinin kısa tutulması olayların tam zamanında yakalanması açısından faydalı olacaktır. Ayrıca, olağandışı durumları belirlemede kullanılan yol modellerine ait eşik değerlerinin eğitim kümesi baz alınarak sabit olarak genel belirlenmesi yerine adaptif olarak yerel, değişken ve öğrenilebilir yapıda olması sistemin değişken trafik durumlarına uyumlu olmasını sağlayacaktır.

10.3 Gelecek alışmalar

Tez alışması sonucunda daha fazla olağandışı olay örneği toplayarak şiddet sınıflarının genişletilmesi planlanmaktadır. Ayrıca, dünya koordinatlarında ve reel araç hızları ile şiddet sınıflandırma işlemi ve çoklu görüş ile kameralardan alınan görüntüler üzerinde alışmaların gerçekleştirilmesi düşünülmektedir. Bu alışmalar ile araç takibinde karşılaşılan mevcut kısıtların giderilebileceği önerilmektedir. Bu tez ile elde edilen sonuçlar, literatürde son zamanlarda aktif olarak incelenmeye başlanan arpışma tahmini alışmalarına da yardımcı olacaktır. Bununla beraber, uygulanan yöntemlerin gerçek zamanlı olarak yürütülebilmesi için yol modellerinin ve model eşik değerlerinin çevrim içi öğrenilmesi ve en yakın anı temsil edecek şekilde sürekli güncel tutulması sağlanacaktır. Araç hareketlerinin gözlemlenerek sürücü davranış modellerinin belirlenmesi ve farklı veri analizlerine bilgi sunulması diğer bir alışma konusu olarak önerilebilir.

11. SONUÇ

Bu çalışmada, doğal ortam trafik videosu görüntülerinde kavşaklardaki olağandışı trafik olaylarını yakalayan ve bu olayları şiddet karakteristiklerini değerlendirerek sınıflandıran gerçek zamanlı özgün bir sistem tasarlanmış ve gerçekleştirilmiştir.

Olağandışı trafik olaylarını algılayabilmek için olağan araç hareketlerine ait yörüngeler Sürekli Saklı Markov Model kümeleme yöntemi ile kümelenecek olağan yol modelleri öğrenilmiştir. İkinci aşamada, kısmi araç yörüngeleri ve hareket karakteristikleri Maksimum Olabilirlik yöntemi ile değerlendirilerek olağandışı araç hareketleri yakalanmıştır. Son aşamada, olağandışı davranışları belirlenen araçların sapma şiddetlerinin tanımlanması ve sınıflandırılması işlemleri gerçekleştirilmiştir. Sistemin olağandışı olayları sınıflandırabilmesi için, k-en yakın komşuluk ve Destek Vektör Makineleleri yöntemleri kullanılmıştır. Kaza yapmış araçlara ait görüntülerden bir eğitim kümesi oluşturulmuş, kaza görüntülerinden elde edilen özellik vektörleri şiddetlerine göre düşük ve yüksek şiddetli olmak üzere 2 sınıfa yerleştirilerek sınıflandırma sistemi eğitilmiştir.

Doğal ortamdan elde edilen görüntüler ile yapılan olağandışı olay belirleme değerlendirmeleri sonucunda %89 doğru belirleme başarısı elde edilmiştir. Olağandışı olayların şiddetlerine göre sınıflandırılması testlerinde %75 doğru sınıflandırma başarısı elde edilmiştir. Elde edilen sonuçlar, olağandışı araç hareketlerinin olasılıksal olarak belirlenebileceğini ve olağandışı olayların bu olasılıklara bağlı olarak şiddet analizlerinin başarıyla yapılabileceğini göstermektedir.

Önerilen sistemin, gerçek hayatta kullanılmak üzere, acil durumlarda olay anının kısa sürede belirlenmesinde trafik operatörlerine yardımcı olacağı ve sonrasında yapılacak ilk yardım müdahalelerini hızlandıracağı, trafik olaylarını derecelerine göre sınıflandırarak acil yardım işlemlerinin daha verimli hale getireceği, uzun vadede kaza analizleri yapılarak mevcut yol durumlarının iyileştirilmesinde ve ölümcül kazaların azaltılmasında faydalı olacağı görülmektedir. Yöntem, kaza sonucu tiplerine göre genelleştirilerek (örneğin, yaralanma, ölümcül kaza, maddi hasar) kaza sonuçlarını analiz etmede veri madenciliği uygulamaları ve polis raporları ile eşleştirilerek beraber kullanılabilecektir.

KAYNAKLAR

- Abdi, H., (2010), "Coefficient of Variation". Encyclopedia of Research Design, CA.
- Alon, J., Sclaroff, S., Kollios, G. ve Pavlovic, V., (2003), "Discovering Clusters in Motion Time-Series Data", Proc. IEEE CVPR, 1: 375-381, 18-20 June 2003, Wisconsin.
- Atanasov, D., (2010), "Two-phase Linear Regression Model", Matlab Toolbox, New Bulgarian University.
- Atev, S., Arumugam, H., Masoud, O., Janardan, R. ve Papanikolopoulos, P., (2005), "A Vision-Based Approach to Collision Prediction at Traffic Intersections", IEEE Transactions on Intelligent Transportation Systems, 6(4): 416-423, Dec. 2005.
- Atev, S., Masoud, O. ve Papanikolopoulos, P., (2006), "Learning Traffic Patterns at Intersections by Spectral Clustering of Motion", IEEE/RSJ Int. Conference of Intelligent Robots and Systems, 4851-4856, 9-15 Oct. 2006, Beijing.
- Bashir, F., Qu, W., Khokhar, A. ve Schonfeld, D., (2005), "HMM-based Motion Recognition System using Segmented PCA", IEEE Int. Conference on Image Processing, III-1288-91, 11-14 Sept. 2005, Genoa, Italy.
- Bergroth, L., Hakonen, H. ve T. Raita, (2000), "A Survey of Longest Common Subsequence Algorithms", 7th Int. Symposium on String Processing and Information Retrieval, 39-48, A Coruna, Spain.
- Beymer, D., McLauchlan, P., Coifman, B. ve Malik, J., (1997) "A Real-time Computer Vision System for Measuring Traffic Parameters", IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 495-501, 17-19 June 1997, San Juan, Puerto Rico.
- Beymer, D., McLauchlan, P., Coifman, B. ve Malik, J., (1998), "A Real-Time Computer Vision System for Vehicle Tracking and Traffic Surveillance", Transportation Research Part C, Emerging Technologies, 6(4): 271-288, August 1998.
- Bouguet, J., (2002), "Pyramidal Implementation of the Lucas Kanade Feature Tracker, Description of the algorithm", Intel Corporation, Microprocessor Research Labs.
- Bradski, G. ve Kaehler, A., (2008), Learning OpenCV, Computer Vision with the OpenCV Library, O'Reilly, CA.
- 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, 23-26 Aug. 2004, Cambridge.
- Cano J., Kovaceva, J., Lindman, M. ve Brannstrom, M., (2009), "Automatic Incident Detection and Classification at Intersections", Volvo Car Corporation, 09-0245, Sweden.
- Canny, J., (1986), "A Computational Approach To Edge Detection", IEEE Trans. on Pattern Analysis and Machine Intelligence, 8(6):679-698.
- Cheung, S. ve Kamath, C., (2004), "Robust Techniques for Background Subtraction in Urban Traffic Video", Visual Communications and Image Processing, 5308: 881-892.

- Cortes, C. ve Vapnik, V., (1995), "Support-vector Networks", *Machine Learning*, 20(3): 273-297.
- Eidehall, A., Pohl, J., Gustafsson, F. ve Ekmark, J., (2007), "Toward Autonomous Collision Avoidance by Steering", *IEEE Transactions on Intelligent Transportation Systems*, 8(1): 84-94, March 2007.
- Freeman, H., (1974), "Computer processing of line-drawing images", *ACM Computing Surveys*, 6(1): 57-97, March 1974.
- Fu, Z., Hu, W. ve Tan, T., (2005), "Similarity based Vehicle Trajectory Clustering and Anomaly Detection", *IEEE International Conference on Image Processing*, 2: II-602-5, 11-14 Sept. 2005, Genoa, Italy.
- Green, E., Agent, K. ve Pigman, J., (2005), "Evaluation of Auto Incident Recording System", Kentucky Transportation Center, University of Kentucky, Kentucky, 2005.
- Gunn, S., (1998), "Support Vector Machines for Classification and Regression", Technical Report, Image Speech and Intelligent Systems Research, University of Southampton.
- Harris, C., ve Stephens, M.J., (1988), "A combined corner and edge detector", In *Proceedings of The Fourth Alvey Vision Conference*, 147-152, 1988.
- Heikkonen, J., Koikkalainen, P. ve Schnorr, C., (1994), "Learning Motion Trajectories via Self-Organization", *Pattern Recognition, Computer Vision & Image Processing*, 2: 554-556, 9-13 Oct. 1994, Israel.
- Hendricks, W. ve Robey, K., (1936), "The sampling distribution of the coefficient of variation", *Annals of Mathematical Statistics*, 7(3): 129-132, 1936.
- Hu, W., Xiao, X., Xie, D. ve Tan, T., (2003), "Traffic Accident Prediction Using Vehicle Tracking and Trajectory Analysis", *Proceedings of the IEEE Intelligent Transportation Systems*, (1): 220-225, 12-15 Oct. 2003, Shanghai.
- Hu, W., Xiao, X., Xie, D., Tan, T. ve Maybank, S., (2004), "Traffic Accident Prediction Using 3-D Model-Based Vehicle Tracking", *IEEE Transactions on Vehicular Technology*, 53(3): 677-694, May 2004.
- 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, Sept. 2006.
- Ikedda H., Matsuo, T., Kaneko, Y. ve Tsuji, K., (2009), "Abnormal Incident Detection System Employing Image Processing Technology", *Proceedings of IEEE International Conference on Intelligent Transportation Systems*, 748-752, 5-8 Oct. 1999, Tokyo, Japan.
- Isard, M. ve Blake, A., (1998), "Conditional Density Propagation for Visual Tracking", *International Journal of Computer Vision*, 29(1): 5-28, Aug. 1998.
- Johnson, N. ve Hogg, D., (1996), "Learning the distribution of object trajectories for event recognition", *Image and Vision Computing*, 14(8): 609-615, Aug. 1996, United Kingdom.
- Kamijo, S., Matsushita, Y., Ikeuchi, K. ve Sakuchi, M., (2000), "Traffic Monitoring and Accident Detection at Intersections", *IEEE Transactions on Intelligent Transportation Systems*, 1(2): 108-118, Jun. 2000, Tokyo, Japan.

- Kass, M., Witkin, A. ve Terzopoulos, D., (1988), "Snakes: Active Contour Models", *International Journal of Computer Vision*, 1(4): 321-331, 1988.
- Kato, J., Joga, S., Rittscher, J. ve Blake, A., (2002), "An HMM-Based Segmentation Method for Traffic Monitoring Movies", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 24(9): 1291-1296, Sep. 2002.
- Ki, Y. ve Lee, D. (2007), "A Traffic Accident Recording and Reporting Model at Intersections", *IEEE Transactions on Intelligent Transportation Systems*, 8(2): 188-194, Jun. 2007.
- Kohonen, T., (1997), *Self-organizing maps*, Springer-Verlag, New York.
- Liao, T., (2005), "Clustering of Time Series Data", *Pattern Recognition*, 38(11):1857-1874, Nov. 2005.
- Lin, C., Tai, J. ve Song, K., (2003), "Traffic Monitoring Based on Real-Time Image Tracking", *Proceedings of the IEEE International Conference on Robotics and Automation*, 2: 2091-2096, 14-19 Sept. 2003, Taiwan.
- Lucas, B. ve Kanade, T., (1981), "An Iterative Image Registration Technique with an Application to Stereo Vision", *International Joint Conference on Artificial Intelligence*, 2: 674-679, 1981.
- McCulloch, D., (2005), "An Investigation into Novelty Detection", Master Thesis, Departments of Engineering Mathematics, University of Bristol.
- Moon, T., (1996), "The Expectation-Maximization Algorithm in Signal Processing", *IEEE Signal Processing Magazine*, 13(6): 47-60, 1996.
- Morris, B. ve Trivedi, M., (2008), "A Survey of Vision-Based Trajectory Learning and Analysis for Surveillance", *IEEE Transactions on Circuits and Systems for Video Technology*, 18(8): 1114-1127, Aug. 2008.
- Morris, B. ve Trivedi, M., (2008), "Learning and Classification of Trajectories in Dynamic Scenes: A General Framework for Live Video Analysis", *IEEE 5th International Conference on Advanced Video and Signal Based Surveillance*, 154-161, 1-3 Sept. 2008, Santa Fe, NM.
- Morris, B. ve Trivedi, M., (2008), "Learning, Modeling, and Classification of Vehicle Track Patterns from Live Video", *IEEE Transactions on Intelligent Transportation Systems*, 9(3): 425 – 437, Sept. 2008, Tokyo, Japan.
- Myers, C.S. ve Rabiner, R., (1981), "A comparative study of several dynamic time-warping algorithms for connected word recognition", *The Bell System Technical Journal*, 60(7): 1389-1409, Sept. 1981.
- Piciarelli, C. ve Foresti, G. L., (2006), "Online Trajectory Clustering for Anomalous Events Detection", *Pattern Recognition Letters*, 27(15): 1835-1842, Nov. 2006.
- Piciarelli, 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, Nov. 2008.
- Rabiner, L., (1989), "A Tutorial on Hidden Markov Models and Selected Applications in Speech Recognition", *Proceedings of the IEEE*, 77(2): 257-286, Feb. 1989.

- Ryan, S. ve Porth, L., (2007), "A Tutorial on the Piecewise Regression Approach Applied to Bedload Transport Data", General Technical Report RMRS-GTR-189, May 2007.
- Saligrama, V., Konrad, J. ve Jodoin, P., (2010), "Video anomaly identification, A statistical approach", IEEE Signal Processing Magazine, 27(5): 18-33, Sept. 2010.
- Saunier, N. ve Sayed, T., (2006), "Clustering Vehicle Trajectories with Hidden Markov Models, Application to Automated Traffic Safety Analysis", IEEE International Joint Conference on Neural Networks, 4132-4138, 16-21 Jul. 2006, Vancouver.
- Saunier, N. ve Sayed, T., (2006), "A feature-based tracking algorithm for vehicles in intersections", The 3rd Canadian Conference on Computer and Robot Vision, 59-59, 7-9 Jun. 2006, Canada.
- Saunier, N., Sayed, T. ve Lim, C., (2007), "Probabilistic Collision Prediction for Vision-Based Automated Road Safety Analysis", IEEE Intelligent Transportation Systems Conference, 872-878, 30 Sept. – 3 Oct. 2007, Seattle, USA.
- Shi, J. ve Tomasi, C., (1994), "Good features to track", IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 593-600, 21-23 Jun. 1994, Seattle, USA.
- Shuming, T., Xiaoyan, G. ve Feiyue, W., (2002), "Traffic Incident Detection Algorithm based on Non-parameter Regression", IEEE 5th International Conference on Intelligent Transportation Systems, 714-719, 2002, Singapore.
- Stauffer, C. ve Grimson, W.E.L., (1999), "Adaptive Background Mixture Models for Real-time Tracking", IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2: 246-252, 23-25 Jun. 1999, Fort Collins, USA.
- Suhr, J., (2009), "Kanade-Lucas-Tomasi Feature Tracker", Computer Vision Lab., Yonsei University.
- Swears, E., 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, 1-8, 8-9 Jan. 2008, Colorado, USA.
- Tomasi, C. ve Kanade, T., (1991), "Detection and Tracking of Point Features", International Journal of Computer Vision, 1991.
- Veeraraghavan, H., Masoud, O. ve Papanikolopoulos, N., (2003), "Computer Vision Algorithms for Intersection Monitoring", IEEE Transactions on Intelligent Transportation Systems, 4(2): 78-89, Jun. 2003.
- Wang, X., Tieu. K. ve Grimson, E., (2006), "Learning Semantic Scene Models by Trajectory Analysis", Proceedings of European Conference on Computer Vision, 110-123, 2006.
- Welch, L., (2003), "Hidden Markov Models and the Baum-Welch Algorithm", IEEE Information Theory Society Newsletter, (53):4, Dec. 2003.
- Welch, G., ve Bishop, G., (2006), "An Introduction to the Kalman Filter", TR 95-041, Jul. 2006, North Carolina, USA.
- Yilmaz, A. ve Javed, O., (2006), "Object Tracking: A Survey", ACM Computing Surveys, 38(4), Dec. 2006.

Yokoyoma, M. ve Poggio, T., (2005), “A Contour-Based Moving Object Detection and Tracking”, 2nd Joint IEEE International Workshop on Visual Surveillance and Performance Evaluation of Tracking and Surveillance, 271-276, 15-16 Oct. 2005, Beijing, China.

Young, I., Gerbrands, J. ve van Vliet, L., (1995), Fundamentals of Image Processing, the Delft University of Technology, The Netherlands.

Zou, Y., Shi, G., Shi, H. ve Wang, Y., (2009), “Image Sequences Based Traffic Incident Detection for Signaled Intersections Using HMM”, 9th International Conference on Hybrid Intelligent Systems, 1: 257-261, 12-14 Aug. 2009, China.

Zou, Y., Shi, G., Shi, H. ve Zhao, H., (2010), “Traffic incident classification at intersections based on image sequences by HMM/SVM classifiers”, Multimedia Tools and Applications, 2010.

İnternet Kaynakları

- [1] WHO, World Health Organization, Road Traffic Injuries, <http://www.who.int>
- [2] TUIK, (2009), Türkiye İstatistik Kurumu, Türkiye Karayolu Trafik Kazaları, <http://www.tuik.gov.tr>
- [3] TRIMARC, (2001), Traffic Response and Incident Management Assisting the River Cities, <http://www.trimarc.org>
- [4] NGSIM, Next Generation Simulation Community, <http://ops.fhwa.dot.gov/trafficanalysisistools/ngsim.htm>
- [5] <http://www.research.ibm.com/peoplevision/performanceevaluation.html>
- [6] Fisher, R., Perkins, S., Walker, A., ve Wolfart, E., (2003). “Connected Component Labeling”, <http://homepages.inf.ed.ac.uk/rbf/HIPR2/label.htm>
- [7] Image Sequence Server, (1997), Institute of Algorithm and Cognitive Systems, University of Karlsruhe, http://i21www.ira.uka.de/image_sequences/
- [8] Birchfield, S., (1997), “Derivation of Kanade-Lucas-Tomasi Tracking”, <http://www.ces.clemson.edu/~stb/klt/birchfield-klt-derivation.pdf>
- [9] OpenCV, (2001), <http://opencv.willowgarage.com/wiki/>
- [10] Shokhirev, N., (2010) “Hidden Markov Models”, <http://www.shokhirev.com/nikolai/abc/alg/hmm/hmm.html>
- [11] Boswell, D., (2002) “Introduction to Support Vector Machines”, <http://dustwell.com/PastWork/IntroToSVM.pdf>
- [12] Osuna, G., (2002), “Introduction to pattern analysis”, Texas A&M University, http://courses.cs.tamu.edu/rgutier/ceg499_s02/
- [13] Murphy, K., (1998), HMM Tool, <http://www.cs.ubc.ca/~murphyk/Software/HMM/hmm.html>
- [14] MATLAB, SVM Tool, <http://www.mathworks.ch/help/toolbox/bioinfo/ref/svmtrain.html>

ÖZGEÇMİŞ

Doğum tarihi	27.01.1979	
Doğum yeri	Amasya	
Lise	1992-1996	Orhan Cemal Fersoy Lisesi
Lisans	1996-2001	Yıldız Teknik Üniversitesi Elektrik-Elektronik Fak. Bilgisayar Mühendisliği Bölümü
Yüksek Lisans	2001-2004	Boğaziçi Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı, Bilgisayar Mühendisliği Programı
Doktora	2004-2010	Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı, Bilgisayar Mühendisliği Programı

Çalıştığı Kurumlar

2001-2004	HSBC Bank A.Ş., Türkiye
2004-2007	TURKCELL İletişim Hizmetleri A.Ş., Türkiye
2007-2008	VODAFONE İletişim Hizmetleri A.Ş., Türkiye
2008-2009	Credit Europe Bank N.V., Hollanda
2009-Devam ediyor	OCLC – Online Computer Library Center, Hollanda