



T.C.
EGE ÜNİVERSİTESİ
Fen Bilimleri Enstitüsü



TRAFİK GÜVENLİĞİ DEĞERLENDİRMESİNDE KULLANILACAK YENİ BİR GÜVENLİK ÖLÇÜTÜ

Doktora Tezi

Pelin ÖNELÇİN

İnşaat Mühendisliği Anabilim Dalı

İzmir
2022

T.C.
EGE ÜNİVERSİTESİ
Fen Bilimleri Enstitüsü

TRAFİK GÜVENLİĞİ DEĞERLENDİRMESİNDE KULLANILACAK YENİ BİR GÜVENLİK ÖLÇÜTÜ

Pelin ÖNELÇİN

Tez Danışmanı: Doç. Dr. Yalçın ALVER

İnşaat Mühendisliği Anabilim Dalı
İnşaat Mühendisliği Doktora Programı

İZMİR
2022



EGE ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ**ETİK KURALLARA UYGUNLUK BEYANI**

EÜ Lisansüstü Eğitim ve Öğretim Yönetmeliğinin ilgili hükümleri uyarınca Doktora Tezi olarak sunduğum “Trafik Güvenliği Değerlendirmesinde Kullanılacak Yeni Bir Güvenlik Ölçütü” başlıklı bu tezin kendi çalışmam olduğunu, sunduğum tüm sonuç, doküman, bilgi ve belgeleri bizzat ve bu tez çalışması kapsamında elde ettiğimi, bu tez çalışmasıyla elde edilmeyen bütün bilgi ve yorumlara atıf yaptığımı ve bunları kaynaklar listesinde usulüne uygun olarak verdiğimi, tez çalışması ve yazımı sırasında patent ve telif haklarını ihlal edici bir davranışım olmadığını, bu tezin herhangi bir bölümünü bu üniversite veya diğer bir üniversitede başka bir tez çalışması içinde sunmadığımı, bu tezin planlanmasından yazımına kadar bütün safhalarda bilimsel etik kurallarına uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul edeceğimi beyan ederim.

03/03/2022

Pelin ÖNELÇİN



ÖZET**TRAFİK GÜVENLİĞİ DEĞERLENDİRMESİNDE KULLANILACAK
YENİ BİR GÜVENLİK ÖLÇÜTÜ**

ÖNELÇİN, Pelin

Doktora Tezi, İnşaat Mühendisliği Anabilim Dalı

Tez Danışmanı: Doç. Dr. Yalçın ALVER

Mart 2022, 152 sayfa

Güvenlik ölçütleri kazaların meydana gelmesini beklemeden trafik tesislerinin güvenliği hakkında bilgi sahibi olunmasını sağlamaktadır. Güvenlik ölçütleri ile ilgili çalışmalar çoğunlukla kavşaklarda ve arkadan çarpma tipi kazalar için gerçekleştirilmiştir. Trafik kaza istatistikleri incelendiğinde yandan çarpma tipi kazaların önemli bir paya sahip olduğu görülmektedir. Özellikle örülme bölgelerinde şerit değiştirmelerden kaynaklanan açılı/yandan çarpma tipi kazaların gerçekleşme olasılıkları yüksektir. Bu nedenle şerit değiştirme çatışmalarını dikkate alan güvenlik ölçütlerine ihtiyaç duyulmaktadır.

Bu tez çalışması kapsamında beş adet örülme bölgesinde şerit değiştirme çatışmaları incelenmiştir. İncelenen bölgenin trafik hacmi, taşıtların türüne göre hızları ve taşıt yörüngeleri derin öğrenme esaslı görüntü işleme yöntemiyle elde edilmiştir. Şerit değiştiren taşıtın çevresindeki taşıtlarla etkileşimleri göz önünde bulundurularak konum ve zaman esaslı olmak üzere iki yeni şerit değiştirme güvenlik ölçütü önerilmiştir. Bu iki ölçüt hata ağacı analizi kullanılarak şerit değiştirme risk indeksine dönüştürülmüştür.

Kazadan kaçınma süresi en sık kullanılan güvenlik ölçütlerinden bir tanesi olup bu tez çalışmasında şerit değiştiren taşıtlar için belirlenmiştir. Şerit değiştirme boyunca kaydedilen kazadan kaçınma sürelerinin en küçük değerleri seçilmiştir. Bir örülme bölgesinin kritik kazadan kaçınma süresi en sık görülen en küçük değer olarak kabul edilmiştir.

Kritik kazadan kaçınma süresi değeri benzetim programları ile çatışma sayılarının belirlenmesinde kullanılan bir değerdir. VISSIM benzetim programı taşıtların yörüngelerinin belirlenmesinde, SSAM programı ise yörünge dosyasının

işlenip çatışma sayılarının belirlenmesinde kullanılmıştır. Elde edilen çatışma sayılarının gerçek değerlerle uyumlu olması için iki aşamalı kalibrasyon yapılmıştır. Birinci kalibrasyon aşamasında VISSIM programındaki şerit değiştirme parametreleri ile Wiedemann 99 sürücü davranış modelinin parametreleri kullanılarak trafik hacim değerinin gerçek hacim değerine yakınlaştırılması amaçlanmıştır. Bu amaçla Plackett-Burman deney tasarımı ile genetik algorithmadan faydalanılmıştır. İkinci kalibrasyon aşamasında ise SSAM programındaki kazadan kaçınma süresi gözlenen değerlere göre uyarlanmıştır.

Anahtar sözcükler: Güvenlik ölçütleri, trafik güvenliği, şerit değiştirme çatışmaları, örölme bölgeleri, kritik kazadan kaçınma süresi, iki aşamalı kalibrasyon.



ABSTRACT**A NEW SURROGATE MEASURE TO BE USED IN TRAFFIC
SAFETY ASSESSMENT**

ÖNELÇİN, Pelin

Ph.D. in Civil Engineering

Supervisor: Assoc. Prof. Dr. Yalçın ALVER

March 2022, 152 pages

Surrogate safety measures provide information about the safety of traffic facilities without the need to wait for crashes to occur. Most of the studies related to surrogate safety measures were performed at intersections and mainly for rear-end crashes. Traffic accident statistics show that sideswipe accidents have a considerable percentage among all accidents. In particular, in weaving segments, sideswipe accidents arising from lane-change conflicts are highly probable to occur. Hence, surrogate safety measures that consider lane change conflicts are needed.

In this thesis, lane change conflicts at five weaving segments were analyzed. Traffic volume, vehicle speeds by type, and vehicle trajectories were extracted by deep learning-based image processing. Considering the interactions between the subject vehicle and the vehicles around, two new lane change surrogate safety measures that are time and position-based were recommended. These two measures were then used in fault tree analysis and converted to a lane change risk index.

Time to collision is one of the most frequently used surrogate safety measures, and this parameter was determined for lane-changing vehicles in this thesis. During lane change, the minimum of the recorded time to collision values was selected. The mode of the minimum time to collision values was assigned as the critical time to collision of the weaving segment.

The critical time to collision is used in identifying the conflict numbers in simulation programs. Vehicle trajectories were obtained from the VISSIM program, and then analyzed by SSAM, which gives the conflict numbers. A two-stage calibration procedure was applied to approximate the simulation conflict numbers to the actual field conflict numbers. In the first calibration stage, lane change

parameters and Wiedemann 99 driving behavior model parameters were calibrated to approximate the traffic volume from the simulation program to field observations. For this purpose, Plackett-Burman experiment design and genetic algorithms were used. In the second calibration stage, time to collision in SSAM was modified according to the observed field values.

Keywords: Surrogate safety measures, traffic safety, lane change conflicts, weaving segments, critical time to collision, two-stage calibration.



ÖNSÖZ

Araştırma konusu olan güvenlik ölçütleri trafik kaza verisine ihtiyaç duyulmadan bir trafik tesisinin güvenliğinin belirlenmesinde kullanılmaktadır. Çatışmalara dayalı bir güvenlik analizinin araştırmacılar tarafından benimsenmesinin en önemli sebebi kaza verilerinin elde edilmesi ile ilgili yaşanan zorluklardır. Taşıt-taşıtların arkadan çarpma, yandan çarpma, kafa kafaya çarpışma gibi türlere ayrıldığı dikkate alındığında temsili güvenlik ölçütleri ile yapılan güvenlik değerlendirmesinde bu kazalara sebep olan çatışmalar incelenmektedir.

Sürücü ve yolcular için kazaya sebep olabilecek bir çatışma olasılığı gerçekleştiğinde taşıt içi uyarı sistemlerinin devreye girmesi olası bir kazayı engellemektedir. Bu nedenle kritik değerlerin seçimi güvenli ve güvensiz durumların ayırt edilmesinde önemli olmaktadır. Bu tez çalışmasında zorunlu şerit değiştirmelerin gerçekleştiği örülme bölgeleri incelenmiştir. Bu bağlamda şerit değiştirme çatışmaları için kritik kazadan kaçınma süresi belirlenmiştir. Ayrıca konum ve zaman esaslı iki yeni ölçüt ve bir risk indeksi önerilmiştir.

Benzetim programları birçok alanda olduğu gibi trafik ile ilgili çalışmalarda da sıklıkla tercih edilmektedir. Gözlemlenen bölgelerde meydana gelen çatışmalarla benzetim programından elde edilen çatışma sayılarının uyumlu olması için iki aşamalı bir kalibrasyon modeli uygulanmıştır.

Bu tez çalışmasında önerilen güvenlik ölçütlerinin trafik güvenliği alanında yapılacak çalışmalara katkı sağlamasını dilerim.

İZMİR

03/03/2022

Pelin ÖNELÇİN



İÇİNDEKİLER

	<u>Sayfa</u>
İÇ KAPAK	i
KABUL ONAY SAYFASI	iii
ETİK KURALLARA UYGUNLUK BEYANI.....	v
ÖZET	vii
ABSTRACT	ix
ÖNSÖZ	xi
ŞEKİLLER DİZİNİ	xix
TABLolar DİZİNİ.....	xxiii
1. GİRİŞ	1
2. TRAFİK GÜVENLİĞİ.....	4
2.1 Trafik Güvenliği Kavramının Gelişimi	4
2.2 Trafik Kazası Verileri.....	6
2.3 Trafik Kazası Verilerinin Güvenlik Değerlendirilmesinde Kullanımı.....	8
2.4 Trafik Çatışma Tekniği.....	8
3. TEMSİLİ GÜVENLİK ÖLÇÜTLERİ.....	17
3.1 Zaman Esaslı Temsili Güvenlik Ölçütleri	17
3.1.1 Kazadan kaçınma süresi	17

3.1.2 Eşik değeri altındaki toplam süre ve eşik değeri altında kalan toplam alan ölçütleri	19
3.1.3 Uyarlanmış minimum KKS	21
3.1.4 Değiştirilmiş KKS.....	23
3.1.5 Kaza indisi.....	25
3.1.6 Kaza indisi yoğunluğu	25
3.1.7 Genelleştirilmiş KKS	26
3.1.8 İhlal süresi	27
3.1.9 İhlal sonrası süre	28
3.1.10 Başlangıçta teşebbüs edilen ihlal sonrası süre	29
3.1.11 Boşluk süresi	29
3.1.12 Zaman avantajı.....	29
3.1.12 Zaman cinsinden aralık	30
3.2 Konum Esaslı Temsili Güvenlik Ölçütleri.....	31
3.2.1 Duruş mesafesi oranı.....	31
3.2.2 Emniyetsiz yoğunluk.....	31
3.3 İvme Esaslı Temsili Güvenlik Ölçütleri	32
3.3.1 Çarpışma olmaması için gereken yavaşlama ivmesi.....	32
3.3.2 Kaza potansiyel indisi	32
3.3.3 Yavaşlama esaslı temsili güvenlik ölçütü	33

3.4 Temsili Güvenlik Ölçütlerinin Kullanıldığı Çalışmalar	33
4. SAHA ÇALIŞMASI.....	40
4.1 Atakent Kavşağı	41
4.2 Girne Kavşağı.....	42
4.3 Gaziemir Kavşağı	43
4.4 Otogar Kavşağı.....	44
4.5 Örnekköy Kavşağı.....	45
5. GÖRÜNTÜ İŞLEME TEKNİĞİ	46
5.1 Nesne Tanıma Yöntemleri.....	46
5.1.1 Geleneksel nesne tanıma yöntemleri	47
5.1.2 Derin öğrenme yöntemleri ile nesne tanıma.....	50
5.2 Nesne Takibi.....	71
5.2.1 Nokta tabanlı takip yöntemleri	71
5.2.2 Çekirdek tabanlı takip yöntemleri	74
5.2.3 Silüet tabanlı takip yöntemleri.....	78
5.2.4 Tanımaya dayalı takip yöntemleri	79
6. KAZADAN KAÇINMA SÜRESİNİN TESPİT EDİLMESİ.....	82
6.1 Şerit Değiştiren Taşıtlar için Kazadan Kaçınma Süresinin Hesaplanması.....	82
6.2 Görüntü İşleme Tekniği ile Kazadan Kaçınma Süresinin Hesaplanması.....	85

6.2.1 Atakent kavşağı örülme bölgesi KKS değerleri.....	87
6.2.2 Girne kavşağı örülme bölgesi KKS değerleri	89
6.2.3 Gaziemir kavşağı örülme bölgesi KKS değerleri	90
6.2.4 Otogar kavşağı örülme bölgesi KKS değerleri	91
6.2.5 Örnekköy kavşağı örülme bölgesi KKS değerleri	92
7. ÇATIŞMA VERİLERİNİN KALİBRASYONU.....	94
7.1 Wiedemann Taşıt Takip Modelleri	94
7.2 VISSIM ile Örülme Bölgelerinin Benzetiminin Yapılması.....	98
7.2.1 Atakent kavşağı örülme bölgesi benzetimi	100
7.2.2 Girne kavşağı örülme bölgesi benzetimi.....	101
7.2.3 Gaziemir kavşağı örülme bölgesi benzetimi.....	102
7.2.4 Otogar kavşağı örülme bölgesi benzetimi.....	103
7.2.5 Örnekköy kavşağı örülme bölgesi benzetimi.....	105
7.3 VISSIM Programının Kalibrasyonu	106
7.3.1 Plackett-Burman deney tasarımı	110
7.3.2 Genetik algoritma ile en uygun değerlerin bulunması	113
7.3.3 SSAM programı ile çatışma verilerinin elde edilmesi	115
8. YENİ BİR GÜVENLİK ÖLÇÜTÜNÜN ÖNERİLMESİ.....	118
8.1 Şerit Değiştirme Güvenliği ile ilgili Çalışmalar	118

8.2 Yeni Güvenlik Ölçütleri	121
8.2.1 Konum esaslı risk indeksi.....	121
8.2.2 Zaman esaslı risk indeksi.....	122
8.2.3 Şerit deęiřtirme risk indeksi	123
8.3 Örölme Bölgelerinin Güvenlik Analizi	125
9. SONUÇLAR VE DEęERLENDİRMELER.....	130
KAYNAKLAR DİZİNİ.....	134
TEŞEKKÜR	151
ÖZGEÇMİŞ.....	152



ŞEKİLLER DİZİNİ

<u>Şekil</u>	<u>Sayfa</u>
Şekil 2.1 Trafik olaylarının görülme sıklığı ile çatışmaların kazaya yakınlık ilişkisi (Glauz and Migletz, 1980).	12
Şekil 2.2 Hydén'in güvenlik piramidi (Hydén, 1987).	13
Şekil 2.3 İsveç tekniğine göre şiddetli çatışma tanımı (Hydén, 1996).	13
Şekil 2.4 Hiyerarşi şekli örneği (Svensson, 1998).	14
Şekil 3.1 Teorik KKS eğrisi (Hayward, 1972).	18
Şekil 3.2 Taşıtların yörüngeleri ile KKS gösterimi (Minderhoud and Bovy, 2001).	19
Şekil 3.3 L uzunluğundaki bir yol kesiminde H periyodunda gözlenen taşıtların yörüngeleri (Minderhoud and Bovy, 2001).	19
Şekil 3.4 Örnek bir KKS profili (Minderhoud and Bovy, 2001).	20
Şekil 3.5 Çatışma-çarpışma durumunun aşamaları (Allen et al., 1978).	27
Şekil 3.6 İSS ölçütünün hesaplanmasına ait bir örnek (Archer, 2005).	28
Şekil 3.7 İSS'nin gecikmeye dayalı gösterimi (Laureshyn et al., 2010).	30
Şekil 3.8 Temsili güvenlik değerlendirmesinin kavramsal çerçevesi (Arun et al., 2021).	34
Şekil 3.9 İSDS ile insanın taşıtların sürme işleyişi (Dahl et al., 2018).	35
Şekil 4.1 Özel yaptırılan tripod ve pan tilt motor.	40
Şekil 4.2 Atakent kavşağı.	41

Şekil 4.3 a) Katılma ve b) ayrılma bölgesi, Atakent kavşağı.....	41
Şekil 4.4 Girne kavşağı.	42
Şekil 4.5 a) Katılma ve b) ayrılma bölgesi, Girne kavşağı.	42
Şekil 4.6 Gaziemir kavşağı.	43
Şekil 4.7 a) Katılma ve b) ayrılma bölgesi, Gaziemir kavşağı.	43
Şekil 4.8 Otogar kavşağı.	44
Şekil 4.9 a) Katılma ve b) ayrılma bölgesi, Otogar kavşağı.	44
Şekil 4.10 Örnekköy kavşağı.	45
Şekil 4.11 a) Katılma ve b) ayrılma bölgesi, Örnekköy kavşağı.	45
Şekil 5.1 Nesne tanıma alanındaki önemli gelişmeler (Sharma and Mir, 2020). ..	46
Şekil 5.2 Öznitelik dikdörtgenleri a) ikili, b) üçlü, (c) dörtlü (Viola and Jones, 2001).	48
Şekil 5.3 Basamak yapısının şematik gösterimi, D: Doğru, Y: Yanlış (Viola and Jones, 2001).	49
Şekil 5.4 YGH öznitelik piramidi (Felzenszwalb, 2008).....	50
Şekil 5.5 Biyolojik nöron yapısı (Buduma and Locascio, 2017).....	51
Şekil 5.6 Yapay sinir hücresi yapısı (Haykin, 2009).	52
Şekil 5.7 Yapay sinir ağı mimarisi (Wang, 2003).....	53
Şekil 5.8 Üç boyutlu ESA yapısı (Stanford, 2018).....	56
Şekil 5.9 ESA katmanlarında öznitelik çıkarımı (Albawi et al., 2017).	56

Şekil 5.10 ESA mimarisi (Di et al., 2018).....	57
Şekil 5.11 ESA mimarisi ve öznitelik haritası çıkarımı (Di et al., 2018).	57
Şekil 5.12 AlexNet mimarisi (Krizhevsky et al., 2012).	59
Şekil 5.13 ResNet artık blok (He et al., 2016).....	61
Şekil 5.14 MobileNet-V2 (Sandler et al., 2018).	63
Şekil 5.15 YOLO modeli (Redmon et al., 2016).....	66
Şekil 5.16 Nesne sınıflandırma türleri a) sınıflandırma b) tanıma c) anlamsal bölütleme d) örnek bölütleme (Wu et al., 2020).....	68
Şekil 5.17 R-CNN işleyişi (Girshick et al., 2014).	69
Şekil 5.18 Uzamsal piramit ortaklama katmanlı ağ yapısı (He et al., 2015).	70
Şekil 5.19 Ortalama-kaydırma yöntemi iterasyonları. (a) $t - 1$ anında tahmin edilen nesne konumu, (b) önceki nesne konumu kullanılarak t anındaki konum (c), (d), (e) ortalama kaydırma iterasyonları ile konum güncellenmesi, (f) t anındaki son nesne konumu.	75
Şekil 5.20 KLT izleyicisi ile takip edilen özellikler (Yılmaz et al., 2006).....	76
Şekil 5.21 Model tahmini ve kesin referans.	80
Şekil 5.22 Kesişim/birleşim oranı hesabında kullanılan sınırlayıcı kutular.	80
Şekil 6.1 Aynı açı ile gerçekleşen farklı kaza tipleri (Laureshyn et al., 2010).....	82
Şekil 6.2 Taşıtların nokta kabulü ile kesişim noktasının belirlenmesi (Jimenez et al., 2013).	83
Şekil 6.3 $\alpha < 90^\circ$ durumuna örnek (Jimenez et al., 2013).	84
Şekil 6.4 Şerit değiştirme durumuna bir örnek.	86

Şekil 6.5 Atakent kavşağı KKS değerlerinin dağılımı.....	89
Şekil 6.6 Girne kavşağı KKS değerlerinin dağılımı.	90
Şekil 6.7 Gaziemir kavşağı KKS değerlerinin dağılımı.....	91
Şekil 6.8 Otogar kavşağı KKS değerlerinin dağılımı.	92
Şekil 6.9 Örnekköy kavşağı KKS değerlerinin dağılımı.....	93
Şekil 7.1 Wiedemann 1974 taşıt takip modeli.	96
Şekil 7.2 Hacim değerlerinin karşılaştırılması.....	115
Şekil 7.3 İki aşamalı kalibrasyon akış şeması.....	117
Şekil 8.1 Şerit değiştiren taşıt ve çevresindeki taşıtlar (Park et al., 2018).....	118
Şekil 8.2 Hata ağacı yapısı.....	123
Şekil 8.3 Güvenlik ölçütü akış şeması.	124
Şekil 8.4 KERİ-Hız-Örülme uzunluğu ilişkisi.....	126
Şekil 8.5 KERİ-Hız-Hacim ilişkisi.	127
Şekil 8.6 DSRİ-Hız-Örülme uzunluğu ilişkisi.	127
Şekil 8.7 DSRİ-Hız-Hacim ilişkisi.....	128
Şekil 8.8 ŞDRİ-Hız-Örülme uzunluğu ilişkisi.	128
Şekil 8.9 ŞDRİ-Hız-Hacim ilişkisi.....	129

TABLOLAR DİZİNİ

Tablo	Sayfa
Çizelge 2.1 Farklı görüşlere göre yol güvenliği gelişimi (Hakkert and Gitelman, 2014).	4
Çizelge 2.2 Trafik kaza istatistikleri (KGM, 2021).	6
Çizelge 2.3 2020 yılına ait oluş türlerine göre ölümlü ve yaralanmalı trafik kaza bilgileri (KGM, 2021).	7
Çizelge 2.4 Malmö çalışmasında kullanılan veri formu (Grayson et al., 1984). ...	11
Çizelge 3.1 Taşıtların takip koşulunda iki taşıtlar arasındaki olası senaryolar (Ozbay et al., 2008).	23
Çizelge 3.2 KKS hesaplaması için farklı durumların tanımlanması (Saffarzadeh et al., 2013).	26
Çizelge 3.3 Zaman cinsinden aralık ile KKS ilişkisi (Vogel, 2003).	31
Çizelge 5.1 Biyolojik ve yapay sinir hücresi elemanlarının karşılaştırılması (Öztürk ve Şahin, 2018).	52
Çizelge 5.2 Omurga yapılarının karşılaştırılması (Hoeser and Kuenzer, 2020). ...	64
Çizelge 5.3 Nesne takibi yöntemleri (Athanesious and Suresh, 2012).	71
Çizelge 6.1 $\alpha < 90^\circ$ durumunda kaza oluşum şekilleri (Jimenez et al., 2013).	84
Çizelge 6.2 Çatışma rotasındaki taşıtların örnek koordinat değerleri.	86
Çizelge 6.3 Atakent kavşağı kritik KKS değerleri.	88
Çizelge 6.4 Girne kavşağı kritik KKS değerleri.	89

Çizelge 6.5 Gaziemir kavşağı kritik KKS değerleri.	90
Çizelge 6.6 Otogar kavşağı kritik KKS değerleri.	91
Çizelge 6.7 Örnekköy kavşağı kritik KKS değerleri.	92
Çizelge 6.8 İncelenen örülme bölgelerinde elde edilen verilerin toplu gösterimi.	93
Çizelge 7.1 Birim otomobil tablosu (TS 6407, 2013).	100
Çizelge 7.2 Atakent kavşağı trafik kompozisyonu.	100
Çizelge 7.3 Atakent kavşağı trafiğın yönlere dağılımı.	100
Çizelge 7.4 Atakent kavşağı anayol hacmi hız dağılımı.	101
Çizelge 7.5 Atakent kavşağı katılma hacmi hız dağılımı.	101
Çizelge 7.6 Girne kavşağı trafik kompozisyonu.	101
Çizelge 7.7 Girne kavşağı trafiğın yönlere dağılımı.	102
Çizelge 7.8 Girne kavşağı anayol hacmi hız dağılımı.	102
Çizelge 7.9 Girne kavşağı katılma hacmi hız dağılımı.	102
Çizelge 7.10 Gaziemir kavşağı trafik kompozisyonu.	102
Çizelge 7.11 Gaziemir kavşağı trafiğın yönlere dağılımı.	103
Çizelge 7.12 Gaziemir kavşağı anayol hacmi hız dağılımı.	103
Çizelge 7.13 Gaziemir kavşağı katılma hacmi hız dağılımı.	103
Çizelge 7.14 Otogar kavşağı trafik kompozisyonu.	104
Çizelge 7.15 Otogar kavşağı trafiğın yönlere dağılımı.	104

Çizelge 7.16 Otogar kavşağı anayol hacmi hız dağılımı.	104
Çizelge 7.17 Otogar kavşağı katılma hacmi hız dağılımı.	104
Çizelge 7.18 Örnekköy kavşağı trafik kompozisyonu.	105
Çizelge 7.19 Örnekköy kavşağı trafiğin yönlere dağılımı.	105
Çizelge 7.20 Örnekköy kavşağı anayol hacmi hız dağılımı.	105
Çizelge 7.21 Örnekköy kavşağı katılma hacmi hız dağılımı.	106
Çizelge 7.22 VISSIM programının kalibre edildiği çalışmalar.	108
Çizelge 7.23 GEH istatistiği değerleri.	109
Çizelge 7.24 Plackett-Burman deney tasarımı örneği (Box et al., 2005).	110
Çizelge 7.25 Başlangıç model girdileri.	111
Çizelge 7.26 Atakent kavşağı örülme bölgesi ANOVA sonuçları.	112
Çizelge 7.27 Girne kavşağı örülme bölgesi ANOVA sonuçları.	112
Çizelge 7.28 Gaziemir kavşağı örülme bölgesi ANOVA sonuçları.	113
Çizelge 7.29 Genetik algoritma sonuçları.	114
Çizelge 7.30 Şerit değiştirme çatışmalarının karşılaştırılması.	116
Çizelge 8.1 Örülme bölgelerinde önerilen ölçütler ile elde edilen KERİ ve DSRİ değerleri.	125
Çizelge 8.2 Çatışma sayıları ve ŞDRİ sonuçları.	125



1. GİRİŞ

Güvenlik değerlendirmesi ile ilgili yapılan çalışmaların sayısı son elli yıllık süreçte artış göstermiştir. Kaza tutanaklarının analiz edildiği geleneksel yöntemler kazaların nadiren meydana gelmesi, tutanaklardaki eksiklikler, bazı durumlarda tutanak bile tutulmaması gibi sebeplerden dolayı yerini alternatif yöntemlere bırakmıştır. Temsili güvenlik ölçütlerinin kullanıldığı güvenlik değerlendirme yöntemi, trafik çatışmalarının analizine dayanan bir yöntemdir. 1940'lı yılların sonlarına doğru çatışmalarla ilgili ilk çalışmaların yapılmaya başlandığı görülse de günümüzde kullanılan tanımı ilk kez 1967 yılında Perkins and Harris tarafından yapılmıştır. Trafik çatışma tekniği üzerine düzenlenen çalıştaylarla birlikte 1970'lerin ikinci yarısından itibaren yapılan araştırmalar da artmaya başlamıştır. İncelenen çatışma türleri ve trafik tesisleri çeşitlilik gösterdikçe önerilen temsili güvenlik ölçütlerinin de sayısı artmıştır.

Bir kazanın meydana gelebilmesi için öncelikle o kaza türünde (arkadan çarpma, yandan çarpma, kafa kafaya çarpışma) bir çatışmanın ortaya çıkması gerekmektedir. Bu nedenle çatışmalar kazaların öncüsüdür ve nedensel olarak kazalarla ilişkilidir (Arun et al., 2020).

Temsili güvenlik ölçütleri konum, zaman ve ivme esaslı olmak üzere üç grupta incelenebilmektedir. Zaman esaslı bir ölçüt olan kazadan kaçınma süresi güvenlik ölçütlerinin kullanılmaya başlandığı zamandan bu yana en sık kullanılan ölçüt olmuş ve zaman içinde geleneksel bağıntısı değiştirilerek farklı ölçütlere de esas oluşturmuştur. Yapılan çalışmalarda kazadan kaçınma süresinin daha çok arkadan çarpma çatışmalarında kullanıldığı anlaşılrsa da farklı kaza oluşum türleri için de hesaplanmaktadır (Laureshyn et al., 2010; Jimenez et al., 2013). Yandan çarpma türü kazalar sık rastlanan kaza türlerinden biri olmakla birlikte ülkemizde ölümlü ve yaralanmalı kazalarda ilk sırada yer almaktadır. Buradan yola çıkarak, yandan çarpma türü kazalar için geliştirilecek uyarı sistemlerinde kullanılabilecek bir eşik değer belirlemek tez çalışmasının hedeflerinden birisidir.

Bu tez kapsamında örülme bölgelerinin güvenlik değerlendirmesinde kullanılabilecek zaman ve konum esaslı iki yeni ölçüt önerilmiştir. Bu amaçla şerit değiştiren taşıt ile şerit değiştirmenin başladığı mevcut şerit ve şerit değiştirmenin tamamlandığı hedef şerit üzerinde hareket eden taşıtlar arasındaki etkileşimler ikili olarak incelenmiştir. Zaman esaslı ölçütün oluşturulmasında kazadan kaçınma süresinden ve fren süresinden yararlanılmıştır. Şerit değiştirme çatışma rotasına sahip iki taşıtın olası kaza noktası belirlenip kazadan kaçınma süresi tespit edilmiş ve ardından kaçınma

manevrası olarak aniden frene basıldığı takdirde durma anına kadar geçen süre hesaplanmıştır. Bu iki değerden faydalanılarak duruş süresi risk indeksi önerilmiştir. Konum esaslı ölçütün oluşturulmasında ise duruş uzunluğu indeksi ile en küçük örülme uzunluğunun incelenen örülme bölgesi uzunluğuna oranından faydalanılmıştır. Örülme bölgesinin uzunluğunun da dikkate alındığı bu ölçüte konum esaslı risk ölçütü ismi verilmiştir. Bu iki ölçüt hata ağacı analizi ile bir araya getirilerek şerit değiştirme güvenli bir şekilde gerçekleşme olasılığı hesaplanmıştır.

Güvenlik değerlendirmesinde benzetim programlarından da yararlanılmaktadır. Bu tez çalışmasında çatışma verilerinin oluşturulmasında VISSIM ve SSAM programları kullanılmıştır. Sahadan toplanan veriler derin öğrenme esaslı nesne tanıma ve nesne takip yöntemleriyle işlenmiştir. Sahada yapılan ölçümler ile görüntü işleme ile elde edilen trafik verileri kullanılarak oluşturulan örülme bölgeleri VISSIM benzetim programı ile çalıştırılmıştır. Üç adet örülme bölgesinde trafik hacmi için GEH değerinin %5'in üstünde çıkması sebebiyle VISSIM programındaki şerit değiştirme parametreleri ile Wiedemann 99 sürücü davranış modelinin parametreleri kullanılarak bir kalibrasyon yapılmıştır. Benzetim yeni parametre değerleri ile gerçekleştirildikten sonra taşıt yürünge dosyaları elde edilmiş ve SSAM programında işlenerek çatışma sayıları belirlenmiştir. Elde edilen çatışma sayılarının gerçek değerlerle uyumlu olması için kalibrasyonun ikinci aşamasında sahada gözlenen kazadan kaçınma süreleri kullanılmıştır.

Tezin ikinci bölümünde trafik güvenliği kavramının geçmişten günümüze gelişimi ve trafik çatışma tekniği açıklanmıştır.

Üçüncü bölümde temsili güvenlik ölçütleri zaman, konum ve ivme esaslı olmak üzere üç başlık altında toplanarak detaylı olarak sunulmuştur. Ardından temsili güvenlik ölçütlerinin kullanıldığı çalışmalardan örneklere yer verilmiştir.

Dördüncü bölümde saha çalışmasının yapıldığı örülme bölgeleri tanıtılmıştır.

Beşinci bölümde görüntü işleme tekniği başlığı altında geleneksel yöntemlerden başlayarak derin öğrenme esaslı yöntemler dâhil olmak üzere nesne tanıma ve nesne takibi yöntemleri tanıtılmıştır.

Altıncı bölümde kazadan kaçınma süresinin tespit edilme yöntemi açıklanmıştır. Ardından her örülme bölgesi için kazadan kaçınma süreleri sunulmuştur.

Yedinci bölümde VISSIM ve SSAM programları aracılığıyla çatışma sayılarının elde edilmesi ve kalibrasyon yöntemlerine yer verilmiştir. Her örölme bölgesi için çatışma sayıları verilmiştir.

Sekizinci bölümde önerilen iki yeni güvenlik ölçütü ve risk indeksi açıklanmıştır. Ardından önerilen bağıntıların sonuçları sunulmuştur.

Dokuzuncu ve son bölümde ise önerilen güvenlik ölçütleri ve uygulama sonuçları tartışılmış, iki aşamalı kalibrasyon yöntemi değerlendirilmiş ve ileride gerçekleştirilebilecek çalışmalar için öneriler sunulmuştur.



2. TRAFİK GÜVENLİĞİ

Bu bölümde trafik güvenliği kavramının gelişimi anlatılmış, ülkemizde meydana gelen kazalara ait istatistiksel veriler sunulmuş, güvenlik değerlendirmesinde trafik kazası verilerinin yerinden bahsedilmiş ve son olarak güvenlik değerlendirmesinde alternatif yöntemlerin kullanımı açıklanmıştır.

2.1 Trafik Güvenliği Kavramının Gelişimi

Hakkert and Gitelman (2014) yaptıkları derlemede OECD (1997), Wegman et al. (2007) ve OECD (2008) kaynaklarına göre yol güvenliği gelişimini Çizelge 2.1'deki gibi ifade etmiştir. Görüldüğü gibi OECD (1997) raporu, yol güvenliği gelişimini ele alırken ilk önce taşıt kontrolü ile zaman içinde kazaların neden ve nasıl meydana geldiğine odaklanıldığını ve son yıllarda ulaşım sistemini bir bütün olarak ele alan disiplinler arası çalışmalara yönelimin söz konusu olduğunu belirtmiştir. Wegman et al. (2007) ve OECD (2008) ise yol güvenliği evrimini incelerken başlangıçta kaza sebebinin insan hatasına bağlandığını, sonraki yıllarda ise sistem yaklaşımının ön planda tutulduğunu belirtmişlerdir.

Çizelge 2.1 Farklı görüşlere göre yol güvenliği gelişimi (Hakkert and Gitelman, 2014).

Değerlendirme görüşü	Motorizasyonun ilk yılları	1950-1960'lar	1970-1980'ler	1990'lar	2000'ler
Yol güvenlik yönetimi (OECD, 2008)	-	Sürücü müdahalelerine odaklanma	Sistem genelindeki müdahalelere odaklanma	Hedeflenen sonuçlar ve liderlik ile sistem çapında müdahaleler	Güvenli sistem yaklaşımı
Yol güvenliği araştırma yaklaşımları (OECD, 1997)	Araç kontrolü; betimsel araştırma ("ne")	3E etrafında araştırma ("neden") Mühendislik, Eğitim, Kolluk kuvvetleri	Trafik sistemlerini yönetme ("nasıl"); matematiksel modeller; fayda maliyet analizleri	Ulaşım sisteminin yönetimi; çok boyutlu analiz	Disiplinler arası analiz; teori geliştirme
Esas kaza sebepleri (Wegman, et al., 2007)	Şans olgusu olarak kaza	Kazalar tek sebepli	Sistem yaklaşımına uyan kaza sebeplerinin birleştirilmesi	Zayıf yol kullanıcısı: daha fazla davranışsal etki	Mevcut stratejilerin daha etkin uygulanması; sistem yönetimi görüşü

Özellikle 1960'lı yıllara kadar kazaların sürücü hataları ve kural ihlallerinden kaynaklandığı görüşü hâkim olmuştur. Ancak 1966 yılında ABD'de Ulusal Karayolu Trafik Güvenliği İdaresi'nin (National Highway Traffic Safety Administration) kurulması ile birlikte güvenli taşıt tasarımının da kazaları azaltmada etkisi olduğu kabul edilmiştir. 1970'li yıllarda tercih edilmeye başlayan yöntem ise sistem yaklaşımı olmuştur. Bu yaklaşımla birlikte kaza oluşumunda tek bir sebebin yer almadığı; sürücü, taşıt ve yol kusurlarının birlikte incelenmesi gerektiği görüşü etkili olmuştur. Yaklaşımda

devlet güvenli yollar yapmaktan, sanayi güvenli taşıt üretmekten, sürücüler ise güvenli sürüş gerçekleştirmekten sorumludurlar (Hakkert and Gitelman, 2014).

Günümüzde çarpışma önleyici sistemlerin ve otomatik akıllı yol kontrol sistemlerinin gelişmesi ile birlikte trafik güvenliğinin artması beklenmektedir. Bu sistemlerin doğrudan sağladığı güvenlik yararları (ileri sürüş performansı ve kaza sonuçlarının hafifletilmesi, vb.) olduğu gibi dolaylı güvenlik yararları da (daha az çatışma sayısı, sürücü stres ve yorgunluğunda azalma, vb.) bulunmaktadır. Ancak sürücünün bu sistemlere koşulsuz güvenerek karşılaşacağı riskler de göz ardı edilmemelidir. Riskler de doğrudan ve dolaylı olarak ikiye ayrılmaktadır. Doğrudan güvenlik risklerine sürücü dikkatinin dağılması, azalan durum farkındalığı; dolaylı güvenlik risklerine ise sürüş becerisinin yitirilmesi örnek teşkil etmektedir (Minderhoud and Bovy, 2001).

Trafik güvenliğini iyileştirmek adına aktif ve pasif olmak üzere iki yaklaşımdan bahsedilmektedir. Pasif önlemler, emniyet kemeri kullanımı gibi uygulamalarla kaza sonucunu hafifletmeye yönelik önlemlerdir. Akıllı ulaşım sistemlerinin gelişimi ile birlikte sürücü hatasını azaltmaya yönelik olan aktif önlemler ön plana çıkmaktadır. İleri Sürücü Destek Sistemleri aktif önlemlere örnektir (Saffarzadeh et al., 2013).

OECD (1997) raporuna göre trafik güvenliği ile ilgili araştırmaların geliştirilmesinde bilimsel modellerin ve teorilerin kullanılması kritik öneme sahiptir. Bu raporda, dört ana model yaklaşımı önerilmektedir:

- Betimsel modeller: Trafik kaza verisi ve risk verisi olmak üzere iki temel veri kaynağına dayanmaktadır.
- Öngörücü/Analitik modeller: Bağımsız değişkenlerdeki değişimlerin bağımlı değişkeni nasıl etkilediği ve aralarında nasıl bir ilişki olduğunu belirlemek için kullanılmaktadır. Genellikle yapılan düzenlemelerin ve alternatif yol tasarımlarının etkilerinin incelenmesinde öncesi/sonrası çalışmasına alternatif olarak tercih edilmektedir.
- Risk modelleri: Bu modellerin temel amacı, bireysel yol kullanıcısı davranışını açıklayan ve tahmin eden risk faktörlerini tanımlamak ve çeşitli önlemlerin risk azaltma etkisine bağlı olarak güvenlik değerlendirmelerini yapmaktır.
- Kaza sonuç modelleri: Bu modelin esas amacı yol tasarımı, araç güvenliği ve acil durum hizmetleri gibi faktörleri belirleyerek kazaların sonuçlarını

hafifletmektir. Bu modeller aynı zamanda, hız kontrolü, alkol ve uyuşturucu kullanımı, emniyet kemeri kullanımı gibi konularda mevzuat uygulamalarını da içermektedir.

Son yıllarda benzetim modelleri güvenlik analizinde sıklıkla kullanılmaya başlanmıştır. Bu modellerden etkin fayda sağlayabilmek için mikro düzeyde detay elde edilebilmesi ve gerçek koşulların doğru bir şekilde yansıtılması gerekmektedir. Bu amaçla literatürde kalibrasyon ve validasyon yaklaşımları önerilmiştir. Özellikle incelenen bölgelerde alternatif güvenlik önlemlerinin uygulanması ve karşılaştırma imkânı sunması bu modellerin en büyük yararlarından bir tanesidir (Archer, 2005).

2.2 Trafik Kazası Verileri

Türkiye’de 2020 yılında toplam 983.808 kaza meydana gelmiştir. Çizelge 2.2’de 2010-2020 yılları arasında meydana gelen kazalar görülmektedir (KGM, 2021). 2015 yılından itibaren toplam ölü sayısında artış meydana geldiği görülmektedir. Bunun sebebi bu yıldan itibaren ölü sayısına trafik kazasında yaralanıp sağlık kuruluşlarına sevk edilenlerden kazanın sebep ve tesiriyle otuz gün içinde ölenlerin dâhil edilmesidir.

Çizelge 2.2 Trafik kaza istatistikleri (KGM, 2021).

Yıllar	Toplam Kaza Sayısı	Ölümlü, Yaralanmalı Kaza Sayısı	Maddi Hasarlı Kaza sayısı	Ölü Sayısı	Yaralı Sayısı
2010	1.105.201	116.804	988.397	4.045	211.496
2011	1.228.928	131.845	1.097.083	3.835	238.074
2012	1.296.634	153.552	1.143.082	3.750	268.079
2013	1.207.354	161.306	1.046.048	3.685	274.829
2014	1.199.010	168.512	1.030.498	3.524	285.059
2015	1.313.359	183.011	1.130.348	7.530	304.421
2016	1.182.491	185.128	997.363	7.300	300.812
2017	1.202.716	182.669	1.020.047	7.427	300.383
2018	1.229.364	186.532	1.042.832	6.675	307.701
2019	1.168.144	174.896	993.248	5.473	283.234
2020	983.808	150.275	833.533	4.866	226.266

Çizelge 2.3’te oluş türlerine göre trafik kaza bilgileri sunulmuştur (KGM, 2021). 2020 yılı verilerine göre en çok görülen kaza oluş türü %30,96’lık oranla yandan çarpma veya yandan çarpışmadır. Bu durum göstermektedir ki yandan çarpma kazalarının

oluşmadan önce önlenmesi kaza sayısında ciddi bir azalmaya neden olacaktır. Arkadan çarpma tipi kazalar da %11,07'lik oranla önemli bir paya sahiptir. Literatürde temsili güvenlik ölçütlerinin kullanıldığı ve arkadan çarpma tipi kazaların azaltılmasına yönelik çalışmalar mevcuttur. Ancak özellikle şerit değiştirmelerden kaynaklı açılı/yandan çarpma tipi kazalar için sınırlı sayıda çalışma bulunmaktadır. Bu tez kapsamında şerit değiştirmeler sonucunda meydana gelen arkadan çarpma ve açılı/yandan çarpma tipi kazaların engellenmesi için çarpışma önleyici akıllı ulaşım sistemlerinde kullanılacak yeni bir ölçütün geliştirilerek kaza sayılarında azalma sağlanması hedeflenmektedir.

Çizelge 2.3 2020 yılına ait oluş türlerine göre ölümlü ve yaralanmalı trafik kaza bilgileri (KGM, 2021).

Kaza Oluş Türü	Toplam	
	Kaza Sayısı	%
Yandan Çarpma veya Yandan Çarpışma	46.502	30,96
Yayaya Çarpma	21.821	14,52
Yoldan Çıkma	22.161	14,75
Devrilme, Savrulma, Takla	17.191	11,44
Arkadan Çarpma	16.633	11,07
Karşılıklı Çarpışma	9.324	6,20
Engel/Cisim ile Çarpışma	8.481	5,64
Duran Araca Çarpma	2.047	1,36
Yan Yana Çarpışma	2.047	1,36
Araçtan Düşen İnsan	1.233	0,82
Hayvana Çarpma	854	0,57
Zincirleme Çarpışma	368	0,24
Çoklu Çarpışma	362	0,24
Araçtan Düşen Cisim	65	0,04
TOPLAM	150.275	100

Türkiye’de 2019 verilerine göre 1000 kişiye düşen taşıt sahipliği oranı 150’dir (Eurostat, 2021). Bu değer AB üyesi ülkelerin yaklaşık üçte biridir. Ancak kaza sayısına bakıldığında ülkemiz üst sıralarda yer almaktadır. Bu durum, ülkemizde kaza sayılarının azaltılmasına yönelik çalışmaların artırılması gerektiğini göstermektedir. Özellikle planlama aşamasında benzetim modellerinden yararlanılarak güvenlik analizlerinin yapılması ortaya çıkabilecek sorunların tespitinde yararlı olacaktır.

2.3 Trafik Kazası Verilerinin Güvenlik Değerlendirilmesinde Kullanımı

Hauer (1982) çalışmasında sistem güvenliğini gerçekleşmesi beklenen kaza sayısı olarak tanımlamaktadır ve sistem güvenliğinin kaza raporlarından elde edildiğini belirtmektedir. Güvenlik düzeyinin belirlenmesinde kaza verilerinin istatistiksel değerlendirmesi en yaygın kullanılan yaklaşımdır (Chin and Quek, 1997).

Bu yaklaşımda bir bölgenin güvenlik değerlendirmesinin yapılabilmesi için öncelikle o bölgede kaza meydana gelmesi gerekmektedir (Archer, 2005). Ancak kazaların nadiren görülmesi sebebiyle bir bölgenin kaza potansiyelini tahmin etmek zorlaşmaktadır. İstatistiksel analizlerin yapılması için gerekli olan kaza sayısı çok uzun süre içinde gözlenebilmektedir (Hauer, 1982; Grayson et al., 1984; Saffarzadeh et al., 2013), ayrıca bir bölgenin güvensiz olarak nitelendirilmesi için çok sayıda kaza meydana gelmesini beklemek etik açıdan tartışmalıdır (Chin and Quek, 1997). Bazı durumlarda ise kaza verisi mevcut değildir (Svensson, 1998) ya da maddi hasarlı kazalara ilişkin tutanak tutulmamaktadır (Lighburn, 1984). Özellikle kısa vadeli güvenlik değerlendirmelerinde kaza verilerinin kullanımı elverişsiz olmaktadır (Archer, 2005). Bir diğer zorluk ise kaza tutanaklarının detaylı bilgi içermemesi ve bir örnek hazırlanmamasıdır. Bahsedilen kısıtlar, kaza verilerinin yerine farklı ölçütlerin kullanılması gerekliliğini ortaya çıkarmıştır (Grayson et al., 1984; Chin and Quek, 1997).

2.4 Trafik Çatışma Tekniği

Trafik çatışması kavramından ilk kez Klebelsberg (1964) tarafından bahsedilmiş ve tehlikeli trafik etkileşimleri olarak tanımlanmıştır (Arun et al., 2021). Ancak bugün bilinen anlamıyla Trafik Çatışma Tekniği (TÇT) kavramı, ilk kez Perkins and Harris (1967) tarafından General Motors Araştırma Laboratuvarı'nda ortaya atılmıştır. Böylece, ilk kez kaza verisi yerine farklı ölçütlerin kullanılması gündeme gelmiştir. Araştırmacılar, olası kaza durumlarına trafik çatışması adını vermişlerdir. Bu teknik, sürücüler tarafından uygulanan kaçınma manevralarını esas almaktadır. Kaçınma manevraları; fren ışıklarının yanması, sürücünün şerit değiştirmesi gibi gözlenebilir durumlarla ilişkilendirilmiştir (Grayson et al., 1984).

Lighburn (1984), trafik çatışmaları ile ilgili ilk çalışmaların Greenshields et al. (1947) ve Homberger (1951) tarafından kavşaklarda yapıldığını belirtmiştir. Bu çalışmalarda sürücülerin sağdan yaklaşan taşıtlara ne oranda yol verdiği tespit edilmiştir.

Perkins and Harris (1967) çalışmalarında beş tip çatışmadan bahsetmiştir. Bunlar; sola dönüş çatışmaları, örülme çatışmaları, kesişme çatışmaları, kırmızı ışık ihlalleri ve arkadan çarpmaya sebep olabilecek çatışmalardır.

İlk Uluslararası Trafik Çatışma Çalıştayı 1977 yılında Oslo'da düzenlenmiştir. Bu çalıştayın amacı farklı ülkelerde kullanılan çatışma tekniklerinin değerlendirilmesi ve TÇT'nin geliştirilmesidir. Çalıştay sonucunda çatışma için aşağıdaki tanım üzerinde fikir birliğine varılmıştır (Amundsen and Hydén, 1977):

“Bir trafik çatışması, iki veya daha fazla yol kullanıcısının, konumda ve zamanda, doğrultularını değiştirmedikleri takdirde çarpışma riski doğacak şekilde birbirlerine yaklaştığı gözlemlenebilir bir durumdur.”

Hauer (1982), sistem güvenliği değerlendirmelerinde geleneksel olarak kaza raporlarının kullanıldığını ancak kazaların nadiren meydana gelmesi sebebiyle “ramak kala” durumların veya “çatışma” sayılarının tercih edildiğini belirtmiştir. Ramak kala kazalar, bir kazanın gerçekleşme olasılığının olduğu ancak yol kullanıcılarından birinin kaçınma manevrasında bulunmasından dolayı çarpışmanın gerçekleşmediği trafik olayları olarak tanımlanmıştır (Forbes, 1957; Lightburn, 1984). Hauer (1982), sistem güvenliğini çatışma sayısı ve maruziyet açısından değerlendirmiştir ve sistem güvenliğinin belirlenmesi gereken durumları aşağıdaki gibi özetlemiştir:

- Herhangi bir güvenlik önleminin etkisinin araştırılması.
- Kurallardan uzaklaşan ve düzeltilmesi gereken sistemlerin (sürücü, taşıt, yol kesimleri, vb.) belirlenmeye çalışılması.
- Geleceğe ve geçmişe dönük standartların, programların, kuralların ve politikaların değerlendirilmesi.
- Diğer bazı durumlar.

Kaza sayıları yerine çatışma sayılarının tercih edilmesinin altında yatan iki sebep bulunmaktadır. İlki, daha kısa sürede istatistiksel açıdan güvenilir sonuçların elde edilmesidir. İkincisi ise, çok sayıda ramak kala kaza ve çatışmaların gözlemlendiği bölgelerde kaza sayısının da çok olmasını beklemenin mantığa uygun gelmesidir. Çatışma sayısını belirlemedeki amaç sistem güvenliğini tahmin etmek, maruziyet ölçümündeki amaç ise sistemi nitelendiren riski tahmin etmektir.

Sistem güvenliği (S), bir çatışmanın kazaya dönüşme olasılığı (P) ile sistemde meydana gelen çatışma sayısının (N) çarpımıdır. Bu tanımın kabul ettiği iki koşul; a) kaza sayısı ile çatışma sayısının orantılı olması ve b) güvenlik karşılaştırmasına tabi tutulan sistemlerin tümünde bir kazanın bir çatışmadan kaynaklanma olasılığının eşit olmasıdır. Çatışmayı, maruziyetten ikinci koşul ayırmaktadır (Hauer, 1982).

Cooper (1977), çatışma sonuçlarının bir bölgeden diğerine transfer edilebilmesi için kaza-çatışma oranının yerel faktörlerden bağımsız olması gerektiğini belirtmiştir. Cooper'a (1977) göre, çatışma kavramının karşılaması gereken üç özellik bulunmaktadır. Bunlar; a) kaza sayısının çatışma sayısına orantılı olması için her kazadan önce bir çatışma gerçekleşmesi, b) makul bir maliyetle çatışmaları temsil eden bir örnekleme büyüklüğü elde edilmesi, c) akım, davranış ve çevre koşullarının yerel özelliklerinin çatışma sayılarına yansımaları ancak kaza-çatışma oranının yerel etkilerden bağımsız olmasıdır.

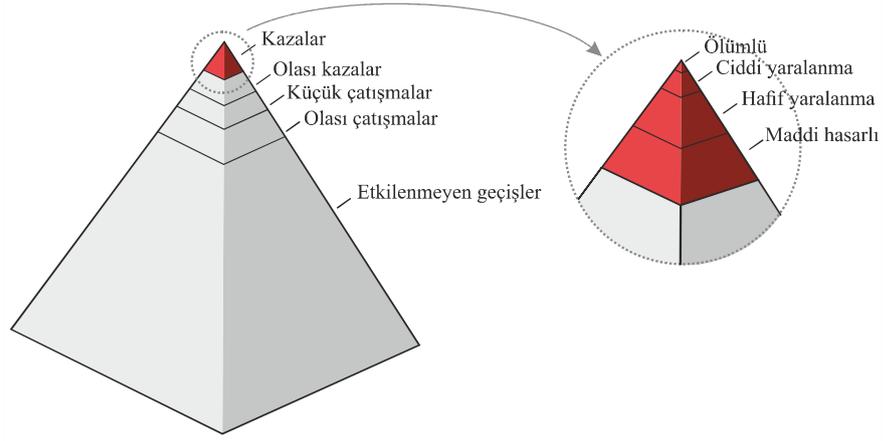
1979 yılında Trafik Çatışma Teknikleri Uluslararası Komitesi (International Committee on Traffic Conflicts Techniques - ICTCT) kurulmuştur. 1986 yılına gelindiğinde ise ismi Trafik Güvenliğine İlişkin Teori ve Kavramlar Üzerine Uluslararası İşbirliği (International Cooperation on Theories and Concepts on Traffic Safety) olarak değiştirilmiştir (Hydén, 1996). ICTCT, 1983 yılında Malmö, İsveç'te sekiz ülkeden gelen katılımcılarla bir kalibrasyon çalışması gerçekleştirmiştir. Çalışma kapsamında, üç farklı kavşakta gerçekleştirilen bir saha çalışması yürütülmüştür. Gözlemcilerden Çizelge 2.4'te gösterilen formu doldurmaları istenmiştir.

Bu formda, çatışmanın gerçekleştiği zaman, hangi yol kullanıcılarının çatışmaya dâhil olduğu, çatışmanın taslak çizimi, çatışmanın şiddeti gibi bilgiler yer almaktadır. Şiddet sınıflandırılmasıyla ilgili yaklaşımlar farklı olsa da elde edilen sonuçların kıyaslanabilir olduğu kanısına varılmıştır. Çalışma sonucunda elde edilen bir başka sonuç ise bir çatışmanın şiddetinin belirlenmesinde; zaman ve konumdaki yakınlık, taşıt hızları, yol kullanıcı türü ve manevra tipinin önemli kabul edilmesidir (Grayson et al., 1984).

Çizelge 2.4 Malmö çalışmasında kullanılan veri formu (Grayson et al., 1984).

ICTCT – Çatışma Veri Föyü										ID-Kod
Kavşak:					Tarih:.....					
Takım:	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
	A	CAN	D	DK	F	GB	NL	S	SF	USA
Gözlemci:										
Dâhil olan yol kullanıcıları:										
1) —	O	= Otomobil	<div style="border: 1px solid black; padding: 5px;"> Çatışmanın gerçekleşme zamanı </div> <div style="border: 1px solid black; padding: 5px; margin-top: 5px;"> Otomobiller için rengini, markasını Y/B/M/Ms için sürücünün yaş ve cinsiyetini not </div>						
2) —	T	= Taksi							
3) —	Y	= Yaya							
4) —	B	= Bisiklet							
		M	= Moped							
		Ms	= Motosiklet							
		TT	= Toplu Taşıma							
		K	= Kamyon							
		D	= Diğer							
Çatışma eskizi:										
Ek veri/Yorumlar:										

Literatürde çatışmalar ile kazaları ilişkilendiren farklı gösterimler yer almaktadır. Bunlardan bir tanesi Glauz and Migletz (1980) tarafından önerilen dağılım fonksiyonudur. Şekil 2.1’de gösterilen fonksiyonda belirli bir sınır değer ötesi çatışma olarak nitelendirilmektedir. Çatışmalar da kendi içinde ciddi ve orta seviyeli çatışmalar olarak ayrılmaktadır. Ölçüm değerinin sıfır veya daha düşük olduğu durumlar ise kazalara karşılık gelmektedir.



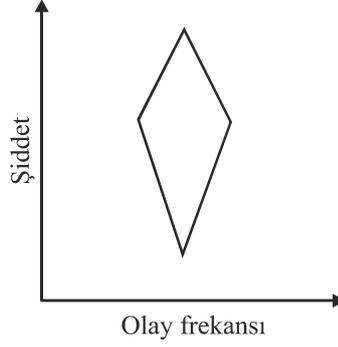
Şekil 2.2 Hydén'in güvenlik piramidi (Hydén, 1987).

Hydén (1996) daha sonra ciddi çatışma tanımının sadece KKaS'ye bağlı olması yerine hıza da bağlı olması gerektiğini öne sürmüştür ve çalışmalar sonucunda Şekil 2.3'te gösterilen şiddetli çatışma tanımının kazalarla ilişkilendirildiğinde iyi sonuçlar verdiğini görmüştür. Şekil 2.3'te dikey ekseninde yer alan çatışma hızı, kaçınma manevrasında bulunan taşıtın manevraya başladığı andaki hızıdır.



Şekil 2.3 İsveç tekniğine göre şiddetli çatışma tanımı (Hydén, 1996).

Svensson and Hydén (2006), sadece çarpışma rotasına sahip etkileşimlerin incelenmesi durumunda Şekil 2.2'dekinden daha farklı bir gösterim elde edileceğini belirtmiştir. Ortaya koydukları hipotez farklı olayların farklı seviyelerde etkileşim yığılması göstereceği yönündedir (Svensson and Hydén, 2006). Şekil 2.4'te olası hiyerarşi şekillerinden biri gösterilmiştir.



Şekil 2.4 Hiyerarşi şekli örneği (Svensson, 1998).

Chin and Quek (1997) trafik çatışma tekniği ile ilgili eleştirileri, çatışma tanımındaki tutarlılık, çatışma tekniğinin geçerliliği ve çatışma ölçütünün güvenilirliği olmak üzere üç başlık altında toplamıştır. Yazarlar, Perkins and Harris (1967) tarafından yapılan çatışma tanımının sürücülerin görülebilir kaçınma manevralarını esas aldığını ve kaçınma manevrası olarak genellikle fren ışıklarının yanması ya da şerit değiştirme manevralarının incelendiğini belirtmiştir. Ancak bahsedilen manevralar her koşulda bir kazanın olacağı anlamına gelmemektedir. Bazı sürücülerin daha dikkatli olduğu için riskli bir durum olmasa bile frene basmaları, bazı sürücülerin ise riskli bir durum olmasına rağmen frene basmamaları, sahada yapılan gözlemlerde önlem için yapılan manevralar ile kaçınma manevralarının ayırt edilmesinin güç olması ve çatışmanın şiddeti ile ilgili bilgi vermemesi, bazı durumlarda kazayı önlemek için yavaşlamak yerine hızın artırılmasının gerekmesi ve yol geçiş üstünlüğü olan taşıtın frene bastığı durumların çatışma olarak kabul edilmemesi gibi sebeplerden dolayı çatışmaları tespit etmek için sadece fren ışıklarının gözlemlenmesinin yeterli olmadığı belirtilmiştir (Allen et al., 1978).

TÇT'nin geçerliliği genellikle gözlenen çatışma sayıları ile kaza kayıtları arasındaki korelasyonla ölçülmüştür. Ancak kabul edilebilir korelasyon az sayıda çalışmada bulunmuştur. Bu durumun kaza raporlarının hatalı tutulması, güvenilir olmaması ve hatta bazı kazaların kayıtlarda yer almamasından kaynaklandığı belirtilmiştir (Grayson and Hakkert, 1987). Çatışmalar ile kazalar arasındaki korelasyonu arttırmak için çatışmaların ve kazaların manevra tipi ve şiddetine göre kategorilere ayrılması önerilmiştir. Amundsen and Larson (1977) kazalar ve tüm çatışmalar arasındaki korelasyonu 0,19 bulmuş ancak kazaları sadece ciddi çatışmalarla ilişkilendirdiklerinde korelasyonun 0,49'a yükseldiğini görmüşlerdir. Oppe (1986) ise korelasyon artarken örneklem büyüklüğünün küçüldüğünü belirtmiştir. Hauer and Garder (1986) çatışma ve kaza tahminlerini karşılaştırmak yerine varyans karşılaştırması yapılmasını önermiştir. Böylece en küçük varyansla en yansız

kestirimi yapan yöntem en geçerli yöntem kabul edilmiştir. Hauer (1979) çatışma tekniğinin kaza tahmini için kullanılmasından ziyade kazaları önleyici bir yöntem olarak kullanılması gerektiğini savunmuştur. Bu nedenle tekniğin geçerliliğinin kaza sayısının doğru tahmin edilmesiyle belirlenmesinin gereksiz olduğunu belirtmiştir.

Çatışma gözlemlerinde güvenilirliği etkileyen iki durum söz konusudur. İlki, tek bir gözlemciden kaynaklı tutarsızlıklar, ikincisi ise farklı gözlemcilerin yorum farklılıklarından kaynaklı tekrar edilebilirlik sorunudur (Chin and Quek, 1997). Older and Shippey (1977) aynı saha çalışmalarında iki farklı gözlem grubu arasında karşılaştırma yapmış ve iki grubun tespit ettiği çatışma sayılarında %80'lik bir uyum, ciddi çatışmalarda ise %85'lik bir örtüşme olduğunu belirlemiştir. Amundsen and Larson (1977) öncesi/sonrası çalışmalarında aynı gözlemcilerin çalışması gerektiğini belirtmiştir.

Zheng et al. (2014) çalışmalarında TÇT'nin geldiği noktayı araştırmak amacıyla geniş bir literatür taraması yapmıştır. Yazarlar, çatışma tanımını iki başlık altında gruplandırmışlardır. Bu başlıklar sırasıyla kaçınma manevrası ile belirlenen trafik çatışmaları ve zamanda (ve/veya konumda) yakınlık ile belirlenen trafik çatışmalarıdır. İlki yukarıda bahsedilen Perkins and Harris (1967) tarafından ortaya atılan yöntemdir. Bu yöntemde karmaşık donanım veya ileri teknikler kullanılmadan, gözlemciler yardımıyla kaçınma manevraları ve ilişkili trafik çatışmaları kaydedilmektedir. İkincisi ise yukarıda açıklanan Oslo Çalıştayı'nda kabul edilen yöntemdir. Araştırmalarda en çok, zamanda yakınlığı temel alan ölçütler kullanılmaktadır çünkü bu ölçütler hem konumu hem de hızı dikkate almaktadırlar. Bazı ölçütler ise sadece konumu dikkate almaktadır (Zheng et al., 2014).

TÇT ortaya çıktığından beri birçok ülkede kullanılmaya başlanmıştır ve zaman içinde geliştirilmiştir. Bu yöntemin sağladığı en önemli yarar çatışmaların kazalardan çok daha sık görülmesi ve dolayısıyla daha az gözlem süresine ihtiyaç duyulmasıdır (Hauer, 1982; Archer, 2005). Kazalar oluşmadan önce incelenen bölgenin güvenliği hakkında fikir edinilmesi de yöntemin yararlarından bir tanesidir (Archer, 2005). Chin and Quek (1997) çatışma tekniğinin etkili bir şekilde kullanılabilmesi için çatışmaların iyi tanımlanması, ölçülebilmesi ve uygulanabilir olması gerektiğini belirtmişlerdir.

Güvenlik göstergelerinin güvenlik değerlendirmesinde kullanılabilmesi için aşağıdaki koşulları sağlaması gerekmektedir (Svensson, 1998):

- Kazayla ilgili verileri tamamlamalı ve kazalardan daha sık görülmelidir.

- Trafikte gözlenebilir nitelikte olmalıdır.
- Kazalarla istatistiksel ve nedensel bir ilişkisi olmalıdır.
- Ramak kala kaza olma özelliğini taşımaktadır. Şiddet açısından değerlendirildiğinde hiyerarşide kazaların hemen yanında yer almalıdır.

Türkiye’de TÇT’ye yönelik Karayolları Genel Müdürlüğü Trafik Güvenliği Projesi kapsamında hazırlanan bir rapor bulunmaktadır. Trafik Güvenliği Projesi, 2002-2011 yılları arasında trafik kazalarında ölen kişi sayılarını, ölen korunmasız yol kullanıcılarının sayılarını ve ölen çocukların sayısını azaltmak üzere üç ana hedefle ortaya koyulmuş bir projedir. Proje ile ilgili çalışmalar 1999 yılında başlamıştır. Bu projede İsveç Çatışma Tekniği temel alınmıştır. 2001 yılında hazırlanan ilerleme raporunda TÇT’nin Çankırı ilindeki pilot uygulaması ile ilgili bilgiler yer almaktadır. Gözlemler, TÇT gözlem teknikleri konusunda eğitim almış personel tarafından yapılmıştır. Taşıt hızlarının belirlenmesinde hız tabancası kullanılmış, çatışmalar önceden hazırlanan formlara işlenmiştir (SweRoad, 2001).

Trafik çatışmaları genellikle arazide gözlemciler tarafından kaydedilmektedir ancak bu yöntem zaman alıcıdır, işgücüne ihtiyaç duymaktadır ve detay düzeyi sınırlıdır (Wang and Stamatiadis, 2014; Laureshyn et al., 2010). Bununla birlikte gözlemci hatalarından kaynaklı yanlış sonuçlar da verebilmektedir. Bahsedilen olumsuzlukları aşmak için araştırmacılar tarafından benzetim programlarının kullanımı tercih edilmektedir (Wang and Stamatiadis, 2014). Görüntü işleme tekniği de farklı yol kullanıcılarını tanıma ve izleme olanağı tanımakta aynı zamanda daha geniş bölgelerin daha kısa sürede incelenmesi ve sonuçların hata payının azalması gibi avantajlar sağlamaktadır (Laureshyn et al., 2010).

3. TEMSİLİ GÜVENLİK ÖLÇÜTLERİ

İkinci bölümde anlatılan trafik çatışma tekniğinin en çok eleştirildiği nokta çatışmaların fren ışıkları ve/veya şerit değiştirme manevraları ile tespit edilmesi olmuştur. Dünyanın birçok ülkesinden araştırmacılar TÇT üzerine çalışırken çatışmaların belirlenmesinde farklı ölçütlerin kullanılabilceğini belirtmişlerdir. Özellikle 1970’li yılların sonlarına doğru kavşaklarda meydana gelen çatışmalar dikkate alınmış ve zaman, konum ve ivme değerlerinin dikkate alındığı ölçütler önerilmiştir. Günümüzde hâlâ farklı çatışma türleri için kullanılacak ölçütler geliştirilmeye devam etmektedir.

Bu bölümde temsili güvenlik ölçütleri zaman, konum ve ivme esaslı olmak üzere üç başlık altında irdelenmiştir.

3.1 Zaman Esaslı Temsili Güvenlik Ölçütleri

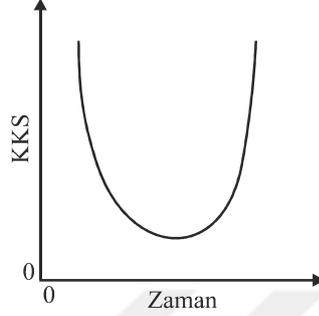
Araştırmalarda en sık kullanılan ölçütler zaman esaslı ölçütler olmuştur. İlk önerilen ölçüt olan kazadan kaçınma süresi hala birçok çalışmada kullanılan esas ölçüttür. Sonraki yıllarda bu ölçüt temel alınarak türetilen güvenlik ölçütleri de kullanılmıştır.

3.1.1 Kazadan kaçınma süresi

Hayward (1972), ramak kala kazayı “sürücülere ve yolculara normal durumdan daha fazla tehlike yaratan trafik olayı” şeklinde tanımlamıştır. Trafikte her olayın farklı tehlike seviyelerine karşılık geldiğini bu nedenle ramak kala kazaları daha az tehlikeli durumlardan ayırt edecek bir sınır değer belirlenmesi gerektiğini belirtmiştir. Ramak kala trafik olaylarının güvenlik tespiti aracı olarak kullanılması için bir tehlike aralığı belirlemenin gerekli olduğunu belirten Hayward, yılda ortalama 35–40 kazanın meydana geldiği kent içi bir kavşakta zirve saatler dışında iki taşıt arasındaki etkileşimleri incelediği çalışma sonucunda kazadan kaçınma süresi ölçütünü ortaya çıkarmıştır. Kavşakta kaydedilen görüntülerden, incelenen zaman aralığındaki her karede taşıtın hızı, ivmesi, koordinatları, uzaklık cinsinden aralığı ve kazadan kaçınma süresi (KKS) tespit edilmiştir.

Hayward (1972) KKS’yi, “İki sürücü, hızlarını ve yönlerini değiştirmeden hareket etmeye devam ederse kazanın oluşma anına kalan süredir” şeklinde tanımlamaktadır. Aslında ramak kala kazalar, küçük KKS değerleriyle ilişkilendirilen trafik olaylarıdır. Basit bir ramak kala eğrisinin teorik gösterimi Şekil 3.1’deki gibi olmaktadır. Bu şekilde bir eğri gerçek hayatta öndeki taşıtın arkadakinden daha düşük bir hıza sahip olduğu taşıt takip durumunda ortaya çıkmaktadır. Taşıtlar birbirine yaklaştıkça KKS değeri

düşmektedir. Taşıtların hızları sabit kaldığı sürece azalma doğrusal olmaktadır. Arkadaki taşıt tehlikeyi fark edip hızını düşürmeye başlar ve hızını öndeki taşıtla eşitlerse kaza gerçekleşmeyecektir. Kaza meydana gelmeyen durumda KKS değeri sonsuzdur. KKS'nin minimum değeri sürücünün intikal-reaksiyon süresine eşittir. KKS değeri bu değerinin altında ise kaza kaçınılmaz olmaktadır.



Şekil 3.1 Teorik KKS eğrisi (Hayward, 1972).

Hayward (1972) beş tip ramak kala kaza durumunu incelemiştir. Bunlar; arkadan çarpmaya sebep olacak durum, şerit değiştirme, kesme (dönüş yapan taşıtın ikinci bir taşıtın yavaşlamasına veya direksiyon kırmasına sebep olduğu durum), sarı ışık yandıktan sonra kavşaktan geçen taşıtların geçiş hakkı olan taşıtları engellediği durum ve sürücülerin birbirine geçiş hakkı vermemesidir. İncelenen tüm ramak kala durumların sonucunda ortalama en küçük KKS değeri 1,46 sn bulunmuştur. Yazar, KKS değerinin 1 sn alınmasının ramak kala kazaları ayırt etmede kullanılabileceği sonucuna varmıştır (Hayward, 1972).

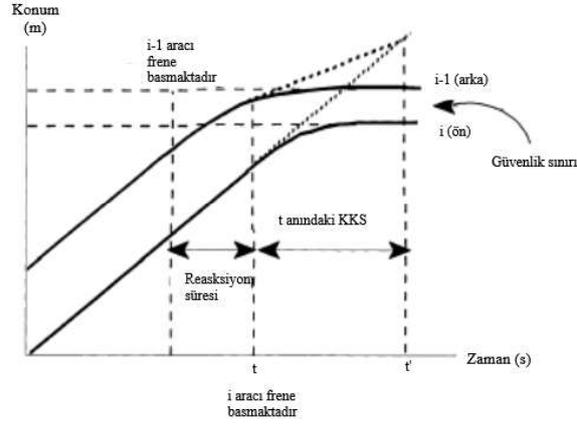
KKS, Denklem 3.1 ile ifade edilmektedir (Minderhoud and Bovy, 2001):

$$KKS_i = \frac{X_{i-1}(t) - X_i(t) - l_i}{\dot{X}_i(t) - \dot{X}_{i-1}(t)} \quad \forall \dot{X}_i(t) > \dot{X}_{i-1}(t) \quad (3.1)$$

Denklem 3.1'de $i-1$ takip edilen taşıtı, i takip eden taşıtı, \dot{X} hızı, X konumu ve l ise taşıt uzunluğunu göstermektedir.

Birbirini takip eden iki taşıttan öndeki $i-1$ taşıt sürücüsünün frene basması durumunda KKS, Şekil 3.2'deki gibi hesaplanmaktadır. Şekil 3.2'de $i-1$ taşıtının sürücüsü frene bastıktan sonra takip eden i taşıtının sürücüsü intikal-reaksiyon süresi sonunda t anında frene basmaktadır. KKS değerinin hesaplanabilmesi için taşıtların t anındaki hız farklarının sabit kaldığı kabulü yapılmaktadır. Bu koşul altında kesikli çizgilerin birleştiği

t' anında çarpışma meydana gelecektir. KKS, iki taşıtın olası çarpışma noktasına geldikleri kabul edilen t' ile t sürelerinin farkına eşittir (Minderhoud and Bovy, 2001).

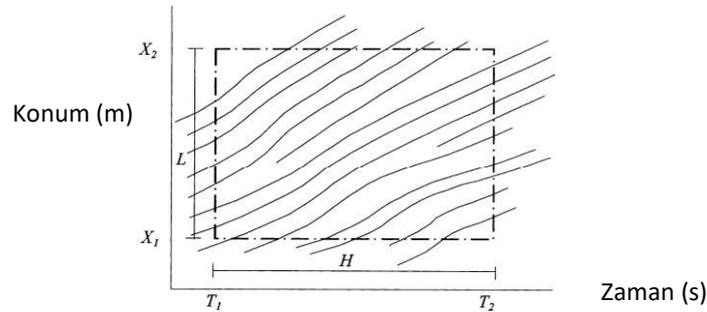


Şekil 3.2 Taşıt yörüngeleri ile KKS gösterimi (Minderhoud and Bovy, 2001).

Geleneksel KKS yönteminin lider (önde giden) taşıtın hızının takip eden taşıttan daha yüksek olması durumunda bu durumu güvenli sayması ve kaza şiddetini belirlememesi gibi kısıtlarından dolayı farklı ölçütler üzerinde çalışılmıştır (Tak et al., 2015).

3.1.2 Eşik değer altındaki toplam süre ve eşik değer altında kalan toplam alan ölçütleri

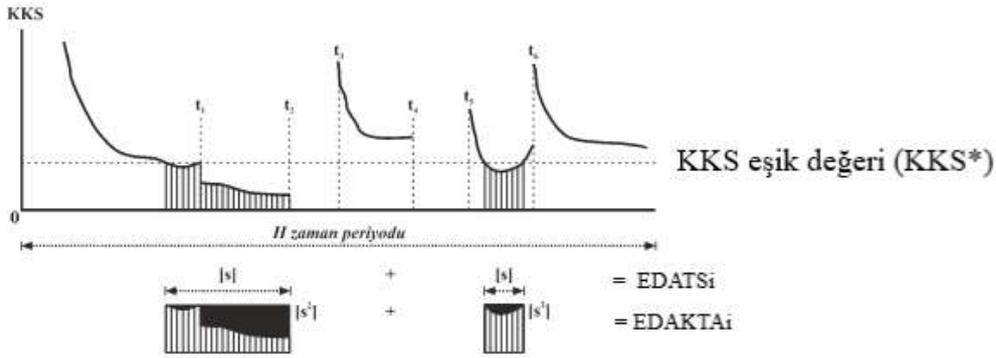
Şekil 3.3'te X_1 ile X_2 noktaları arasında kalan L uzunluğundaki bir yol kesiminde T_1 ile T_2 süreleri arasındaki H periyodunda gözlenen taşıt yörüngeleri gösterilmiştir. Bu konum-zaman grafiği kullanılarak her i aracı için Hayward'ın önerdiği bağıntı yardımıyla (Denklem 3.1) $KKS_i(t)$ profilleri Şekil 3.4'te gösterildiği gibi çıkarılabilmektedir.



Şekil 3.3 L uzunluğundaki bir yol kesiminde H periyodunda gözlenen taşıt yörüngeleri (Minderhoud and Bovy, 2001).

Şekil 3.4'te KKS* ile gösterilen sabit bir KKS eşik değeri tanımlanmıştır. Bu değer güvenli durumları riskli durumlardan ayıran değerdir. Eşik Değer Altındaki Toplam Süre (EDATS), arkadaki sürücünün öndeki sürücüye KKS* değerinden daha küçük KKS değerlerine karşılık gelen değerlerde yaklaştığı sürelerin toplamıdır. EDATS değerinin düşük olması sürüşün güvenli olduğu anlamına gelmektedir.

Şekil 3.4'te, $t=0$ anında sürücü önünde daha düşük hızla ilerleyen taşıta yaklaşmaktadır ve KKS azalmaktadır. t_1 anında sürücü şerit değiştirmektedir ve küçük bir aralıkla yeni bir lider taşıtla karşılaşmaktadır. KKS değerleri azalmaya devam etmekte ve güvenli olmayan değerlere ulaşmaktadır. t_2 ile t_3 anları arasında lider taşıt yüksek hızda ilerlemektedir ve bu nedenle pozitif bir KKS değeri görülmemektedir. t_3 anında sürücü yeni bir lider taşıtla karşılaşmaktadır. Minimum aralık sağlanacak şekilde sürücünün bu davranışı devam etmekte ve bu davranışa bağlı olarak KKS değeri de değişmektedir (Minderhoud and Bovy, 2001).



Şekil 3.4 Örnek bir KKS profili (Minderhoud and Bovy, 2001).

Veriler ayrık zamanlarda toplandı için KKS değerleri de ayrık zamanlar için elde edilmektedir. Hesap kolaylığı açısından t anındaki KKS değerinin τ_{SC} küçük zaman adımı boyunca değişmediği kabul edilmektedir. Dolayısıyla EDATS değerlerinin toplamı EDATS* ile gösterilecek olursa Denklem 3.2 ve Denklem 3.3 ile hesaplanabilmektedir:

$$EDATS_i^* = \sum_{t=0}^T \delta_i(t) \times \tau_{sc} \quad \delta_i(t) = \begin{cases} 1 & \text{eğer } 0 \leq KKS_i(t) \leq KKS^* \\ 0 & \text{aksi takdirde} \end{cases} \quad (3.2)$$

$$EDATS^* = \sum_{i=1}^N EDATS_i^* \quad (3.3)$$

Yukarıda;

τ_{SC} : Küçük zaman adımını,

T : Toplam zaman adımı sayısı ($T = H/\tau_{SC}$)

δ : İkili değişkeni (0 veya 1),

$EDATS^*$: Sınır değere göre hesaplanan gösterge değerini,

N : Sürücü sayısını,

ifade etmektedir.

EDATS ölçütü sadece KKS değerinin minimum KKS değerinin altına düştüğü süreyi göz önünde bulundurmaktadır. Burada, KKS değeri sınır değerden düşük olduğu sürece değerin kendisinin bir önemi bulunmamaktadır. Ancak, gerçekte 1 sn'lik KKS değeri 3 sn'lik KKS değerine göre daha tehlikeli kabul edilmektedir. Bu dezavantajı ortadan kaldırmak için Eşik Değer Altında Kalan Toplam Alan (EDAKTA) ölçütü önerilmiştir.

EDAKTA, Şekil 3.4'te KKS^* değerinin altında kalan ve siyah renk ile gösterilen alanlara karşılık gelmektedir. Bu alan ne kadar büyükse çarpışma riski o kadar yüksektir. EDAKTA* değeri Denklem 3.4 ve Denklem 3.5 yardımıyla bulunmaktadır:

$$EDAKTA^* = \sum_{i=1}^N \int_0^T [KKS^* - KKS_i(t)] dt, \quad \forall 0 \leq KKS_i(t) \leq KKS^* \quad (3.4)$$

$$EDAKTA^* = \sum_{i=1}^N KKS_i^* \quad (3.5)$$

Çalışma sonunda yazarlar, EDAKTA ölçütünün teorik olarak daha iyi sonuç verdiğini açıklamalarına rağmen yörünge verisinin benzetim programları araçlarıyla elde edildiği karşılaştırma çalışmalarında EDATS ölçütünün tercih edildiğini belirtmişlerdir (Minderhoud and Bovy, 2001).

3.1.3 Uyarlanmış minimum KKS

Uyarlanmış minimum KKS (KKS_{min}) geleneksel yöntemden farklı olarak çarpışma durumunda, çarpışma anındaki bağıl hızı ve çarpışma öncesindeki yavaşlama ivmesini dikkate almaktadır. Geleneksel KKS hesabına getirilen eleştiri çarpışma anında KKS değerinin 0 sn kabul edilmesidir. Bu durumda iki taşıt arasındaki hız farkının değeri

önemli olmamaktadır. Arkadaki taşıtın öndeki taşıta hafifçe dokunması ile iki taşıt arasındaki hız farkı 110 km/sa iken arkadaki taşıtın öndekine çarpması arasındaki fark geleneksel KKS yönteminde yansıtılmamaktadır. Benzer durum çarpışma hızı için de geçerlidir. Kaza olmadığı sürece, arkadaki taşıt öndekine çarpışmaya ramak kala dursa bile çarpışma hızı sıfır kabul edilmektedir. Tüm bu kısıtları dikkate alarak Brown (2005), uyarlanmış KKS ölçütünü ileri sürmüştür. Yazarın tanımına göre uyarlanmış KKS, sürücünün seçtiği kaçınma tepkisine göre sahip olduğu süredir. Pozitif değerler, yavaşlama ivmesi göz önünde bulundurulduğunda sürücünün sahip olduğu ek süreyi ifade etmektedir. Negatif değerler ise çarpışma olmaması için sürücünün ne kadar süre önce kaçınma manevrasında bulunması gerektiğini göstermektedir (Brown, 2005).

Aşağıda takip eden ve edilen taşıtların farklı durumlarına göre önerilen bağıntılar yer almaktadır. Bu bağıntılarda kaza gerçekleşmesi durumunda KKS değeri 0 sn'dir.

- İki taşıt hareket ediyor ve öndeki taşıt yavaşlıyorsa:

$$-R = \frac{1}{2} a \times KKS^2 + \dot{R} \times KKS \quad (3.6)$$

Eşitlikte R uzaklığı, \dot{R} takip edilen taşıt ile takip eden taşıt arasındaki hız farkını, a ise takip edilen taşıtın ivmesini göstermektedir. Bu eşitlikten KKS değeri çekilirse Denklem 3.7 elde edilmektedir.

$$KKS = \frac{\dot{R} + \sqrt{(\dot{R})^2 - (2a) \times (R)}}{a} \quad (3.7)$$

- Eğer takip edilen taşıt durmuşsa ya da sabit bir hız ile ilerliyorsa Denklem 3.8 kullanılmaktadır:

$$KKS = \frac{R}{-\dot{R}} \quad (3.8)$$

Kaza gerçekleşmesi durumunda uyarlanmış KKS aşağıdaki bağıntıların yardımıyla hesaplanmaktadır:

- Kaza olması durumunda kaza olmadan hemen önceki durum dikkate alınmaktadır. Eğer takip edilen taşıt durmuşsa Denklem 3.9 kullanılmaktadır.

$$KKS_{\text{uyarlanmış}} = \frac{V_F}{\bar{a}_F} \quad (3.9)$$

Eşitlikte V_F takip eden taşıtın çarpışma anındaki hızını, \bar{a}_F ise takip eden taşıtın fren başlangıcından çarpışmaya kadar geçen sürede ortalama ivmesini ifade etmektedir.

- Eğer takip edilen taşıt hareket ediyorsa ve takip eden taşıt öndeki taşıt kadar veya daha fazla yavaşlayabiliyorsa Denklem 3.10 kullanılmaktadır.

$$\text{KKS}_{\text{uyarlanmış}} = \frac{V_F - V_L}{\bar{a}_F - \bar{a}_L} \quad (3.10)$$

Eşitlikte V_F ve V_L çarpışma anında, sırasıyla takip eden ve takip edilen taşıtların hızlarını, \bar{a}_F ve \bar{a}_L ise fren başlangıcından çarpışmaya kadar sırasıyla takip eden ve takip edilen taşıtların ortalama ivmesini ifade etmektedir.

- Eğer takip edilen taşıt hareket ediyorsa ve takip eden taşıt öndeki taşıt kadar veya daha fazla yavaşlayamıyorsa uyarlanmış $\text{KKS}_{\min} = -\infty$ olarak alınmaktadır.

3.1.4 Değiştirilmiş KKS

Ozbay et al. (2008) link bazında kullanılabilir bir güvenlik ölçütü önermiş ve bu ölçütün geçerliliğini benzetim modeli ile gerçek kaza verilerini karşılaştırarak test etmiştir. Takip eden ve edilen taşıtların hız ve ivme durumlarına göre Çizelge 3.1’de gösterilen olası senaryoların gerçekleşmesi beklenmektedir.

Çizelge 3.1 Taşıt takip koşulunda iki taşıt arasındaki olası senaryolar (Ozbay et al., 2008).

V	$V_F > V_L$			$V_F \leq V_L$		
	$a_L > 0$	$a_L < 0$	$a_L = 0$	$a_L > 0$	$a_L < 0$	$a_L = 0$
$a_F > 0$	P	C	C	P	C	P
$a_F < 0$	P	P	P	I	P	I
$a_F = 0$	P	C	C	I	C	I

C: Çarpışma gerçekleşir; P: Olası çarpışma; I: Çarpışma mümkün değil

Yazarlar, çatışmanın gerçekleşip gerçekleşmeme durumunun iki taşıtın yörüngelerine bağlı olarak bağlı uzaklık, bağlı hız ve bağlı ivmenin bir arada değerlendirilmesi ile belirlendiğini ifade etmişler ve aşağıdaki bağıntılardan yararlanarak değiştirilmiş KKS (DKKS) ölçütünü önermişlerdir (Ozbay et al., 2008).

$$V_F \times t + \frac{1}{2} \times a_F \times t^2 \geq D + V_L \times t + \frac{1}{2} \times a_L \times t^2 \quad (3.11)$$

$$\frac{1}{2} \times \Delta a \times t^2 + \Delta V \times t - D \geq 0 \quad (3.12)$$

$$t_1 = \frac{-\Delta V - \sqrt{\Delta V^2 + 2 \times \Delta a \times D}}{\Delta a} \quad t_2 = \frac{-\Delta V + \sqrt{\Delta V^2 + 2 \times \Delta a \times D}}{\Delta a} \quad (3.13)$$

Yukarıda;

V_F ve V_L : Sırasıyla takip eden ve takip edilen taşıtların hızlarını (m/s),

a_F ve a_L : Sırasıyla takip eden ve takip edilen taşıtların ivmelerini (m/s²)

ΔV : Bağlı hızı ($V_F - V_L$),

Δa : Bağlı ivmeyi ($a_F - a_L$),

D : Başlangıçtaki bağlı uzaklığı (m),

t : Süreyi (sn),

ifade etmektedir.

Yukarıdaki bağıntılar dikkate alınarak arkadan çarpma durumunda düzeltilmiş KKS aşağıdaki gibi belirlenmektedir.

- $t_1 > 0$ ve $t_2 > 0$ ve $t_1 \geq t_2 \Rightarrow KKS = t_2$
- $t_1 > 0$ ve $t_2 > 0$ ve $t_1 < t_2 \Rightarrow KKS = t_1$
- $t_1 > 0$ ve $t_2 \leq 0 \Rightarrow KKS = t_1$
- $t_1 \leq 0$ ve $t_2 > 0 \Rightarrow KKS = t_2$

Çalışmada düzeltilmiş KKS için 4 sn'lik sınır değer kabul edilmiştir. Sınır değer belirlendikten sonra anlık düzeltilmiş KKS değeri sınır değerle kıyaslanmıştır.

Ward et al. (2015) da benzer yaklaşımı kullanmıştır. t_1 ve t_2 'nin negatif olması durumunda ise en küçük mutlak değerli t değerini kabul etmişlerdir.

Düzeltilmiş KKS, çarpışmanın şiddeti ile ilgi bilgi vermemektedir. KKS için geçerli olan kısıtlar burada da geçerlidir. Farklı hız ve uzaklıklar için aynı düzeltilmiş KKS değeri sonucuna varılabilmektedir. Bu nedenle yazarlar kaza indisi (Kİ) adını verdikleri yeni bir ölçüt önermişlerdir.

3.1.5 Kaza indisi

Kaza İndisi (Kİ), kaza şiddetini dikkate alan bir güvenlik ölçütü olarak ortaya atılmıştır. Ayrıca, çatışmadan önceki süre de bu ölçütte dikkate alınmaktadır. Böylece, çarpışma gerçekleşirse de olası bir çatışmanın şiddeti hakkında fikir vermektedir. Kİ, Denklem 3.14 ile bulunmaktadır:

$$Kİ = \frac{(V_F + a_F \times DKKS)^2 - (V_L + a_L \times DKKS)^2}{2} \times \frac{1}{DKKS} \quad (3.14)$$

Yukarıdaki bağıntının ilk kısmı çarpışma sırasında transfer olan kinetik enerjiyi, DKKS'nin tersine karşılık gelen ikinci kısmı ise çarpışma olasılığını göstermektedir. DKKS değeri büyüdükçe çarpışma olasılığı azalmaktadır (Ozbay et al., 2008).

3.1.6 Kaza indisi yoğunluğu

Kİ, belirli bir zaman ve konumda iki taşıt arasındaki güvenlik ilişkisini vermektedir ancak bir yol kesimi ya da yol ağı değerlendirilmek istendiğinde bu ölçüt tek başına yetersiz kalmaktadır. Bundan dolayı, Kaza İndisi Yoğunluğu (KİY) ölçütünün kullanılması tavsiye edilmiştir. KİY, denklem 3.15 ile hesaplanmaktadır (Ozbay et al., 2008):

$$KİY = \frac{\sum Kİ_{ijk} \times l_j}{T \times N \times L} \quad (3.15)$$

$Kİ_{ijk}$: k anında j linkinde hareket eden i taşıtına ait Kİ

T : Toplam analiz süresi (sn)

N : Yol ağında hareket eden toplam taşıt sayısı

l_j : İncelenen j linkinin uzunluğu (m)

L : Yol ağını oluşturan linklerin toplam uzunluğu (m)

3.1.7 Genelleştirilmiş KKS

Saffarzadeh et al. (2013) geleneksel KKS tanımındaki sabit hız varsayımını değiştirip bağıntıya hareket denklemlerini eklemiştir. Çizelge 3.2’de gösterildiği gibi KKS’yi sabit hız, sabit ivme ve doğrusal ivme olmak üzere üç ayrı durum için hesaplamışlardır. Ozbay et al. (2008) tarafından önerilen ölçütte $V_F \leq V_L$, $a_L > 0$ ve $a_F < 0$ durumu için kaza gerçekleşme olasılığı imkânsız olarak verilmiştir. Ancak yazarlar, iki taşıtın ivmelerindeki dalgalanmalar dikkate alındığında arkadan çarpma tipi kaza gerçekleşebileceğini belirtmişlerdir. Çizelge 3.2’deki KKS değerleri doğrusal (KKS₁), ikinci dereceden polinom (KKS₂) ve kübik polinom (KKS₃) denklemleriyle çözülmektedir.

Çizelge 3.2 KKS hesaplaması için farklı durumların tanımlanması (Saffarzadeh et al., 2013).

KKS türü	Kabuller	Denklemler
KKS ₁	$\dot{X}_L = cte$	$X_F = X_{0F} + \dot{X}_F t$
	$\dot{X}_F = cte$	$X_L = X_{0L} + \dot{X}_L t$
KKS ₂	$\ddot{X}_L = \ddot{X}_F = 0$	$(\dot{X}_F - \dot{X}_L)KKS - (X_L - X_F - l_L) = 0$
	$\dot{X}_L = cte$	$X_F = X_{0F} + \dot{X}_F t + \frac{1}{2} \ddot{X}_F t^2$
KKS ₃	$\ddot{X}_L = \ddot{X}_F = 0$	$\frac{1}{2}(\ddot{X}_F - \ddot{X}_L)KKS^2 + (\dot{X}_F - \dot{X}_L)KKS - (X_L - X_F - l_L) = 0$
	$\ddot{X}_L = cte$	$X_F = X_{0F} + \dot{X}_F t + \frac{1}{2} \ddot{X}_F t^2 + \frac{1}{6} \ddot{X}_F t^3$
	$\ddot{X}_F = cte$	$X_L = X_{0L} + \dot{X}_L t + \frac{1}{2} \ddot{X}_L t^2 + \frac{1}{6} \ddot{X}_L t^3$

KKS_k değerinin hesaplanması için lider ve takip eden taşıtların konumlarını belirlemek gerekmektedir. t saniye sonra, hızın $(k-1)$ 'inci türevinin sabit olması varsayımıyla taşıt konumları aşağıdaki gibi bulunmaktadır:

$$\begin{cases} X_F = X_{0F} + \sum_{n=1}^k \left(\frac{1}{n!} \times \frac{\partial^n X_F}{\partial t^n} \times t^n \right) \\ X_L = X_{0L} + \sum_{n=1}^k \left(\frac{1}{n!} \times \frac{\partial^n X_L}{\partial t^n} \times t^n \right) \end{cases} \quad k = 1, 2, 3, \dots, n \quad (3.16)$$

Denklem 3.16’da $\frac{\partial^n X}{\partial t^n}$, X ’in n ’inci türevidir. Örnek olarak, $n=3$ alınır, X yerine X_F yerleştirilirse, $\frac{\partial^3 X_F}{\partial t^3} = \ddot{X}_F$ elde edilmektedir.

Arkadan çarpma tipi kazanın gerçekleşmesi için gerekli koşul;

$$(X_F - X_L - l_L) = 0 \quad (3.17)$$

olmak üzere Denklem 3.16, Denklem 3.17'ye uyarlanırsa,

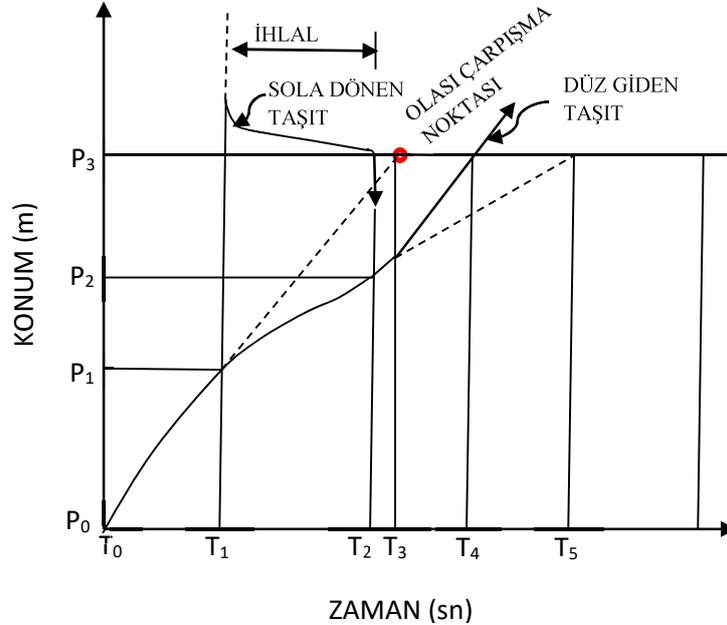
$$X_{0F} - X_{0L} + l_L + \sum_{n=1}^k \left(\frac{1}{n!} \times \left(\frac{\partial^n X_F}{\partial t^n} - \frac{\partial^n X_L}{\partial t^n} \right) \times t^n \right) = 0 \quad (3.18)$$

elde edilmektedir.

KKS_k, Denklem 3.18'in minimum, sıfır olmayan ve gerçek çözümüdür. $k=1$ olması durumunda Hayward (1972) tarafından önerilen geleneksel KKS, $k=2$ olması durumunda ise Ozbay et al. (2008) tarafından önerilen değiştirilmiş KKS elde edilmektedir. Önerilen KKS değerinin çarpışma önleyici sistemlerde kullanılması durumunda sistemin hassasiyeti artacaktır ancak ivmedeki değişimler hatalı uyarılara yol açabileceğinden sistemin güvenilirliğinde azalmaya neden olacaktır (Saffarzadeh et al., 2013).

3.1.8 İhlal süresi

Allen et al. (1978) sola dönüş çatışmalarını incelediği çalışmasında elde ettiği 347 çatışma verisine dayanarak farklı ölçütler önermiştir. İhlal Süresi (İH) bu ölçütlerden bir tanesidir ve sola dönen taşıtın düz giden taşıtın yol hakkını ihlal ettiği süre olarak tanımlanmıştır. Şekil 3.5'te $T_2 - T_1$ arası İS'ye karşılık gelmektedir.



Şekil 3.5 Çatışma-çarpışma durumunun aşamaları (Allen et al., 1978).

3.1.9 İhlal sonrası süre

İhlal Sonrası Süre (İSS), bir önceki başlıkta açıklanan ihlal süresinin bitiminde, düz giden taşıtın potansiyel çarpışma noktasına gelmesine kadar geçen süre olarak tanımlanmıştır ve çarpışmanın hangi yakınlıkla önlendiğinin bir ölçütüdür. Şekil 3.5'te $T_4 - T_2$ arası İSS'ye karşılık gelmektedir (Allen et al., 1978).

Cooper (1984), İSS için "“Soruna sebep olan” bir taşıtın potansiyel çarpışma alanından çıktığı an ile geçiş hakkına sahip "çatışan" taşıtın potansiyel çarpışma noktasına varma anı arasındaki zaman farkı" tanımını yapmıştır. KKS ile arasındaki temel fark, İSS için çarpışma rotası zorunluluğunun bulunmamasıdır. İSS'nin elde edilmesi için bağıl hız ve uzaklık verisi gerekmediğinden fotometrik analizi KKS'ye göre daha kolaydır (Archer, 2005).

İSS ölçütünün belirlenmesinde hız ve uzaklık dikkate alınmadığından incelenen çatışmaların şiddetinin hatasız belirlenmesi mümkün olmamaktadır. Ayrıca, İSS'nin dik açılı çarpışmaların incelendiği durumlarda kullanılması halinde daha etkili sonuçlar elde edilmektedir. İSS ölçütü, KKS'den farklı olarak sabit bir öngörülen çarpışma noktası gerektirmektedir (Archer, 2005). Şekil 3.6'da İSS ölçütünün hesaplanmasına ait bir örnek yer almaktadır.



Şekil 3.6 İSS ölçütünün hesaplanmasına ait bir örnek (Archer, 2005).

3.1.10 Başlangıçta teşebbüs edilen ihlal sonrası süre

Allen et al. (1978), İSS'nin çatışma şiddetinin tahminine dair makul bir ölçüt olmasına karşın çatışmanın bitiminde gerçekleşen hızlanma davranışından etkilendiğini belirtmiştir. Bu nedenle ilk hızlanma etkilerini ortadan kaldırmak için başlangıçtaki yavaşlama hızının dikkate alındığı bir ölçüt önermiştir. Başlangıçta Teşebbüs Edilen İhlal Sonrası Süre (BTEİSS) adı verilen bu ölçüt Şekil 3.5'te $T_5 - T_2$ arasına karşılık gelmektedir (Allen et al., 1978). T_5 anı Denklem 3.19 ile bulunmaktadır.

$$T_5 = T_1 + \left(\frac{P_1 P_3}{V_2}\right) \quad (3.19)$$

$P_1 P_3$: İhlalin başlangıcında düz giden taşıtın konumundan potansiyel çarpışma noktasına kadar olan mesafe

V_2 : Düz giden taşıtın ihlal süresi boyunca ortalama hızı

3.1.11 Boşluk süresi

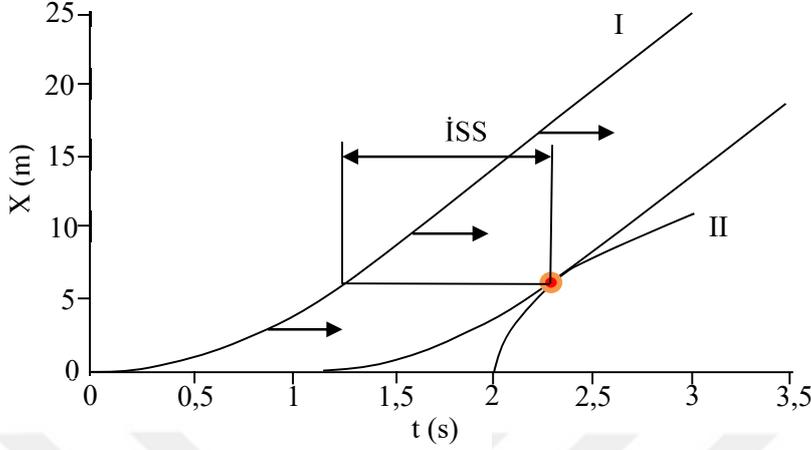
İhlal süresinin tamamlanması ile tali yoldan gelen bir taşıtın aynı hız ve yörüngede devam etmesi halinde olası çarpışma noktasına varış zamanı arasındaki süredir. Bu ölçüt Şekil 3.5'te $T_3 - T_2$ arasına karşılık gelmektedir (Allen et al., 1978). Boşluk süresi kavramı, gerçek zaman farkından ziyade potansiyel çatışma noktasına tahmini varış zamanına dayanmaktadır (Archer, 2005).

3.1.12 Zaman avantajı

Zaman Avantajı (ZA), iki yol kullanıcısının ortak bir alanı farklı zamanlarda geçerek çarpışma rotasından çıkması ve dolayısıyla kazayı önlemesi olarak tanımlanmaktadır (Hansson, 1975).

ZA, İSS kavramını daha geniş bir çerçevede ele almakta, yol kullanıcıları aynı hız ve doğrultuda devam ederse, her an için İSS değerini hesaplamaktadır. İSS ve ZA'nın geleneksel geometri temelli tanımları nedeniyle, taşıt yörüngeleri dik açıyla kesişmediği takdirde hesaplanmaları zorlaşmaktadır. Bahsedilen geometri temelli sorunun üstesinden gelmek amacıyla İSS için yeni bir tanım önerilmiştir. Buna göre, İSS bir çarpışma rotasında hareket eden ve çarpışmaya neden olacak ilk yol kullanıcısının gecikmesidir. Şekil 3.7'de iki yol kullanıcısına ait konum-zaman grafiği verilmiştir. Birinci yol kullanıcısının gecikmesi, I eğrisinin II eğrisinin üzerine gelmesi için zaman ekseninde

ötelenmesi gereken miktardır ve ihlal sonrası süreye karşılık gelmektedir. Zaman avantajı ise benzer şekilde tanımlanmaktadır ancak tahmin edilen x-t eğrileri kullanılmaktadır.



Şekil 3.7 İSS'nin gecikmeye dayalı gösterimi (Laureshyn et al., 2010).

ZA belirli bir anda küçük olsa da, yol kullanıcıları hızlarını ve yörüngelerini ayarlamak için çok fazla zamana sahip olabilirler. Geçişin yakınlığını tanımlayan bir ölçüt olarak, ikinci yol kullanıcısının "kaçınılmış çarpışma noktasına" ulaşma zamanı önerilmektedir. Güvenlik ölçütünü (T_2 olarak adlandırılmıştır) ikinci yol kullanıcısıyla ilişkilendirmek çarpışmanın gerçekleşmesi için gerekli son koşulun ikinci yol kullanıcısının çarpışma noktasına varması olduğundan mantıklı bir yaklaşım olarak kabul edilmektedir. Çarpışma rotasından geçiş rotasına geçildiği anda artık KKS'den söz edilmemektedir ancak ZA hâlâ sıfıra eşittir. Bu durumda T_2 , KKS'ye eşittir ve ikisi aynı grafik üzerinde gösterilirse sürekli bir eğri ile temsil edileceklerdir. İkinci yol kullanıcısı durduğu zaman T_2 ölçütü de KKS gibi sonsuza gidecektir (Laureshyn et al., 2010).

3.1.12 Zaman cinsinden aralık

Zaman cinsinden aralık birbirini takip eden taşıtlardan birinci taşıtın ön tamponunun belirli bir kesiti geçişi ile ikinci taşıtın ön tamponunun aynı kesitten geçişi arasındaki süre olarak tanımlanmaktadır. Zaman cinsinden aralık bağlı hızı dikkate almadığı için KKS ile karşılaştırıldığında çarpışma riski ile daha zayıf bir ilişkisi bulunmaktadır (Laureshyn et al., 2010).

Vogel (2003) zaman cinsinden aralık ile KKS ölçütünü güvenlik değerlendirmesi açısından karşılaştırmıştır. Çizelge 3.3'te bu ilişki gösterilmiştir. Dört kollu dur kontrollü bir kavşakta zaman cinsinden aralık ve KKS değerleri serbest taşıtlar (bu çalışmada zaman cinsinden aralığın 6 sn'den büyük olduğu durumda taşıtlar serbest taşıt olarak

kabul edilmiştir) haricinde takip koşullarındaki taşıtlar için belirlenmiş ve aralarında istatistiksel bir ilişkinin mevcudiyeti araştırılmıştır. Çalışma sonucunda zaman cinsinden aralık ve KKS'nin birbirinden bağımsız olduğu belirtilmiştir (Vogel, 2003).

Çizelge 3.3 Zaman cinsinden aralık ile KKS ilişkisi (Vogel, 2003).

Zaman cinsinden aralık			
		Küçük	Büyük
KKS	Küçük	Kaçınılmaz tehlike	İmkânsız
	Büyük	Olası tehlike	Güvenli

3.2 Konum Esaslı Temsili Güvenlik Ölçütleri

Bu bölümde konum esaslı temsili güvenlik ölçütleri anlatılmıştır.

3.2.1 Duruş mesafesi oranı

Sürücünün manevra yapmasına imkân veren uzaklığın çarpışma meydana gelecek uzaklığa oranının çarpışma şiddeti ile ilgili bilgi verebileceği düşünülmüş ve duruş mesafesi oranı (DMO) olarak adlandırılmıştır (Allen et al., 1978).

$$DMO = \frac{KM}{EKDM} \quad (3.20)$$

Denklem 3.20'de KM; çarpışma noktasına kalan mesafe, EKDM; en küçük duruş mesafesi ($V^2/2D$), D ise en büyük yavaşlama ivmesidir.

3.2.2 Emniyetsiz yoğunluk

Emniyetsiz Yoğunluk (EY) ölçütü, yalnızca arkadan çarpma olasılığını göz önüne almakta ve bu nedenle özellikle otoyol ağı değerlendirmeleri için uygun kabul edilmektedir. Ölçüt, serbest akım ile tıkanıklık koşulları arasındaki güvenlik düzeyi farkını ortaya koymaya olanak tanımaktadır (Pirdavani et al., 2010).

3.3 İvme Esaslı Temsili Güvenlik Ölçütleri

Bu bölümde ivme esaslı temsili güvenlik ölçütleri anlatılmıştır.

3.3.1 Çarpışma olmaması için gereken yavaşlama ivmesi

Çarpışma Olmaması İçin Gereken Yavaşlama İvmesi (ÇOGYİ), ilk olarak Cooper and Ferguson (1976) tarafından takip eden taşıtın durması ya da öndeki taşıtın hızıyla eşitlenmesi için gerekli minimum yavaşlama ivmesi olarak tanımlanmıştır. ÇOGYİ, Denklem 3.21 yardımıyla bulunmaktadır (Kuang et al., 2015):

$$\text{ÇOGYİ} = \frac{(V_F - V_L)^2}{D_{L-F}} \quad \text{eğer } V_F > V_L \quad (3.21)$$

D_{L-F} : İki taşıt arasındaki mesafe

ÇOGYİ ile KKS arasında Denklem 3.22’de açıkça görülebileceği gibi ters orantılı bir ilişki bulunmaktadır.

$$\text{ÇOGYİ} = \frac{V_F - V_L}{\text{KKS}} \quad (3.22)$$

3.3.2 Kaza potansiyel indisi

Kaza Potansiyel İndisi (KPI), ışıklı kavşakların güvenlik performansını değerlendirmek üzere Cunto and Saccomanno (2008) tarafından önerilmiştir. ÇOGYİ ölçütü, hâkim yol ve trafik koşulları altında taşıtın fren kapasitesini dikkate almadığı için eleştirilmiştir. ÇOGYİ ile birlikte maksimum uygulanabilir yavaşlama ivmesini (MUYİ) esas alan bir ölçüttür. Maksimum uygulanabilir yavaşlama ivmesi taşıttan taşıta değişmektedir.

$$\text{KPI}_i = \frac{\sum_{t=t_i}^{t_f} P(\text{ÇOGYİ}_{i,t} > \text{MUYİ}_{i,t}) \Delta t}{T_i} \quad (3.23)$$

KPI_i : i taşıtı için kaza potansiyel indisi

t_i : i taşıtı için zaman aralığı başlangıcı

t_f : i taşıtı için zaman aralığı bitimi

- Δt : Gözlem zaman aralığı
- T_i : i taşıtı için toplam benzetim süresi
- b : $\text{COGYI}_{i,t} > 0$ ise 1, değilse 0

3.3.3 Yavaşlama esaslı temsili güvenlik ölçütü

Yavaşlama Esaslı Temsili Güvenlik Ölçütü (YETGÖ), arkadan çarpma tipi kazalar için önerilen bir ölçüttür ve sürücünün çarpışma riski ortaya çıktığında hızlanma ve yavaşlama evrelerinde nasıl davrandığını dikkate almaktadır (Tak et al., 2015).

$$\text{YETGÖ} = \frac{b_n(t)}{b_{\text{maks},n}} \quad (3.24)$$

$b_n(t)$: Takip eden taşıtın t anında gerçekleşecek kazadan kaçınmak için uygulaması gereken yavaşlama ivmesi

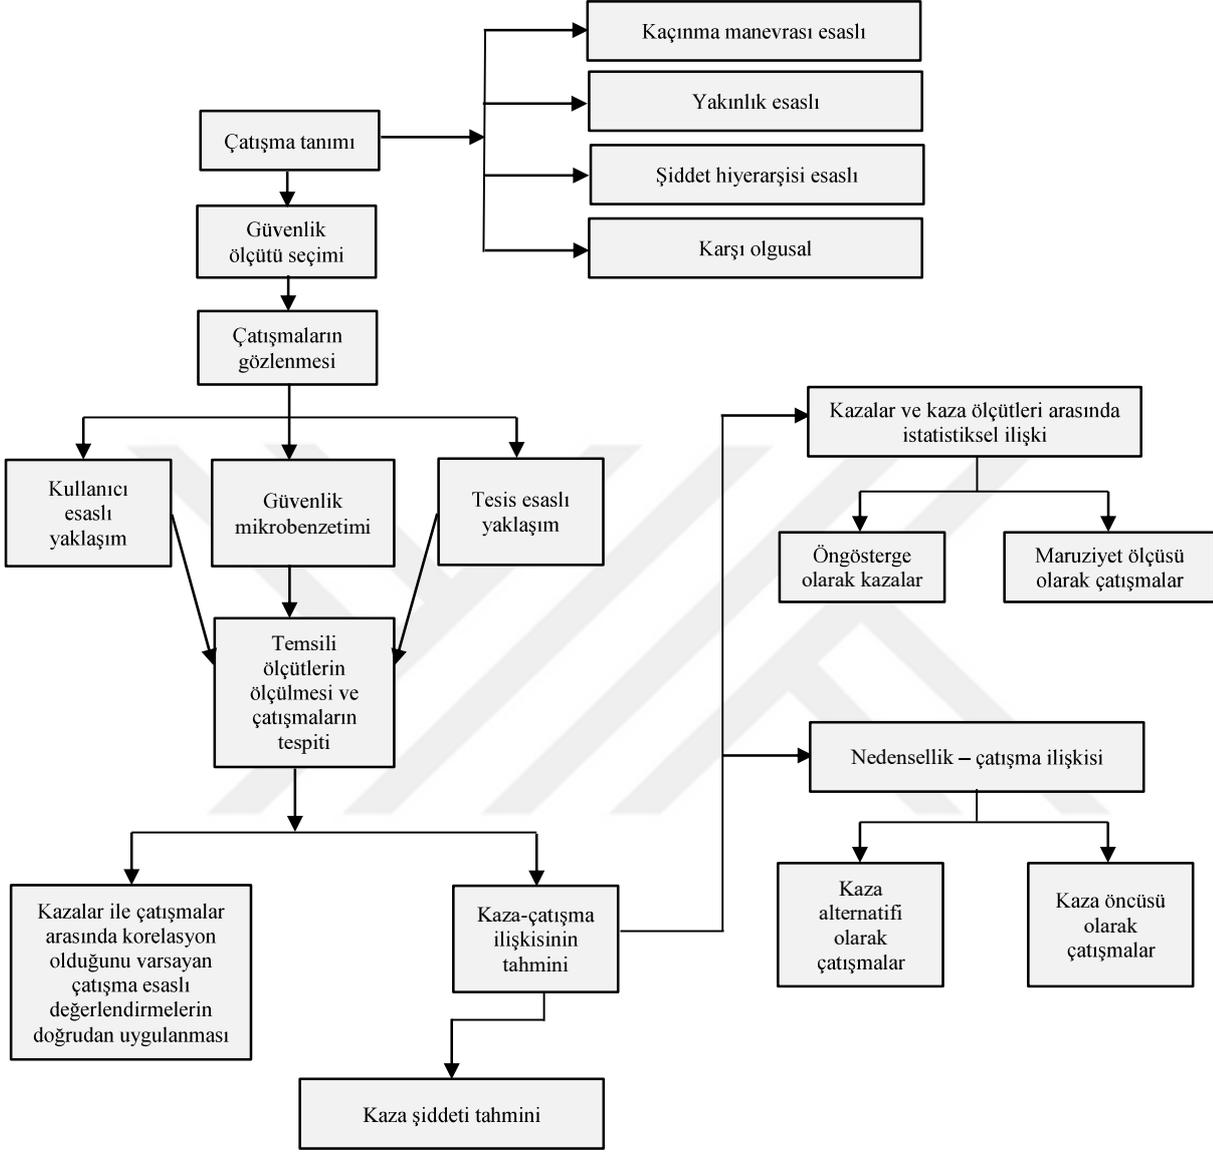
$b_{\text{maks},n}$: Takip eden taşıtın (n) maksimum fren kapasitesi

YETGÖ değerinin 1'den büyük olması riskli durumları belirtmektedir. YETGÖ'nün taşıtın mekanik özelliklerini göz önünde bulundurması nedeniyle bu ölçüt ile daha doğru analizler yapılabileceği belirtilmiştir. Çalışmada tehlikeli durumların ayrılması için sınır değer olarak 1,2 önerilmiştir. Ölçüt arkadan çarpma tipi kazalar için önerilmiş olsa da yazarlar şerit değiştirme durumlarında da kullanılabileceğini ifade etmişlerdir (Tak et al., 2015).

3.4 Temsili Güvenlik Ölçütlerinin Kullanıldığı Çalışmalar

Yukarıda 3.1, 3.2 ve 3.3 başlıkları altında anlatılan güvenlik ölçütleri, ilgili bağıntılar ve grafikler ile açıklanmıştır. Bu bölümde ise güvenlik ölçütlerinin kullanıldığı çalışmalar derlenmiştir. Literatür taraması yapılırken, Arun et al. (2021) tarafından da belirtildiği gibi trafik çatışması yerine kullanılan farklı terimlerle karşılaşılmıştır. Bunlar; kazaya yakınlık, ramak kala kaza, güvenlik açısından kritik durumlar ve riskli durumlardır. Bazı durumlarda 'güvenlik ölçütleri', trafik çatışmalarının kendisini belirtmek için kullanılsa da aslında çatışma ölçütlerini ifade etmektedir. Şekil 3.8'de temsili güvenlik değerlendirmesinin kavramsal çerçevesi gösterilmiştir. Şekil üzerinde çatışma tanımının kullandığı yaklaşımlar, çatışmaların gözlemlenmesinde kullanılan

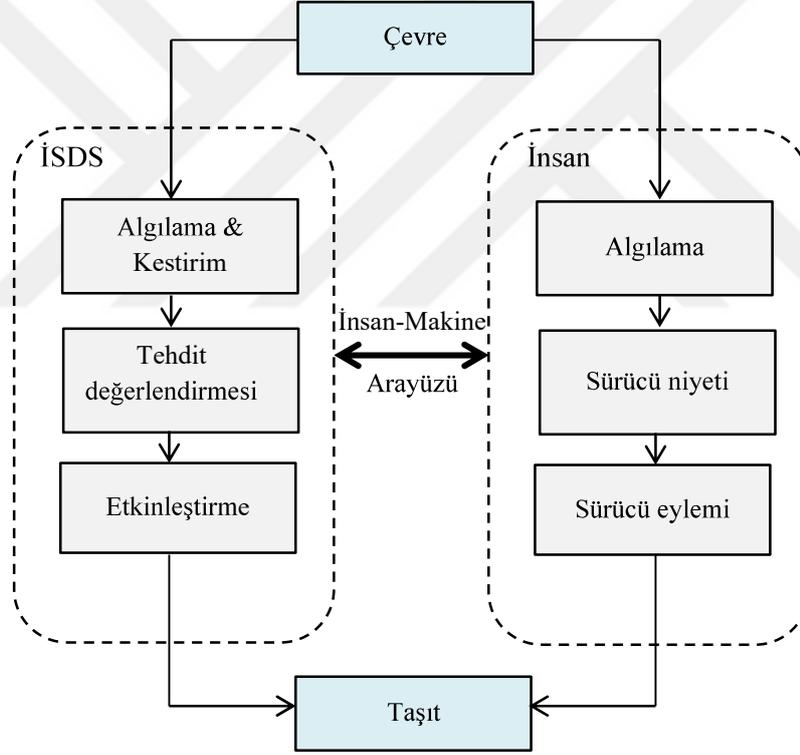
yöntemler ve kaza-çatışma ilişkisinde kullanılan yaklaşımlar özetlenmiştir (Arun et al., 2021).



Şekil 3.8 Temsili güvenlik değerlendirmesinin kavramsal çerçevesi (Arun et al., 2021).

KKS, trafik çatışmalarının şiddetinin belirlenmesinde normal sürüş davranışını kritik sürüş davranışından ayırma hususunda etkili bir yöntem olarak kullanılmaktadır. Birçok çalışmada KKS, güvenlik ile ilgili karar verme sürecinde tek başına bir ölçüt olarak kullanılmıştır. Malmö çalışmasında KKS sınır değeri İsveç ve Finlandiya ekipleri tarafından 1,5 sn olarak belirlenmiştir. Hollanda ekibi ise video kayıtlarından aldıkları ardışık karelerden sürücülerin konumlarını belirleyerek KKS eğrilerini çizmişlerdir. Bu eğrilerden en küçük KKS değerini 1,5 sn olarak bulmuşlardır (Grayson et al., 1984).

Son yıllarda taşıt üreticileri sürüş güvenliğini artırmak adına İleri Sürüş Destek Sistemlerinden (İSDS) faydalanmaktadır. Bu sistemler sayesinde taşıtlar başka şeride kaymadan kendi şeritlerinde ilerleyebilir, diğer taşıtlarla güvenli takip mesafesini koruyabilir ve tehlikeli durumlarda çarpışmayı önleyebilirler. Karmaşık trafik senaryolarında durum değerlendirmesinin doğru yapılması etkili bir güvenlik sistemi için çok önemlidir. Şekil 3.9'da yarı-otonom taşıtlarda İSDS ve insan sürüş sürecinin işleyişi gösterilmiştir. Tehdit değerlendirmesi/karar verme aşamasında zaman esaslı ölçütlerden en yaygın kullanıma sahip olanı KKS'dir. Uyarı sistemleri ya da otomatik müdahale sistemleri KKS'nin eşik değerlerinde devreye girmektedir (Dahl et al., 2018). Katrakazas et al. (2019) ise otonom taşıtlardaki yolcuların ve trafikteki diğer unsurların güvenliğini sağlamak için algılama-planlama-harekete geçme yönteminin izlenmesi gerektiğini belirtmiştir.



Şekil 3.9 İSDS ile insanın taşıt sürme işleyişi (Dahl et al., 2018).

Çarpışma Önleyici Sistemlerin (ÇÖS) sürücüyü gerçek tehlike durumunda uyarması sistemin güvenilirliği açısından önemlidir. Bu nedenle van der Horst and Hogema (1994), ÇÖS gibi sürücü destek sistemlerinin etkinleştirilmesinde KKS ölçütünü kullanmışlar ve arkadan çarpma tipi kazaların azaltılmasını hedeflemişlerdir. Çalışmada, duran bir nesneye yaklaşan sürücünün nesneye çarpmamak için frene bastığı en son an

kaydedilmiştir. Frenlemenin başlangıcındaki KKS (KKS_{fr}), kaçınma eyleminin başladığı andaki manevra alanını temsil etmektedir. Yazarlar, yaptıkları alan çalışmaları sonucunda frene basma kararı ile fren kontrolünde KKS ölçütünün temel alınabileceğini belirtmiştir. En küçük KKS değerinin yaklaşım hızından, normal veya sert frenlemeden bağımsız olarak 1,1 sn değerinde olduğu tespit edilmiştir. Normal fren durumunda KKS_{fr} 2,5 sn kabul edilerek ve intikal-reaksiyon süresi de 1,5 sn alınarak ÇÖS'ün etkinleştirilmesinde 4 sn değerinin kullanılabilmesi belirtilmiştir. Ancak kötü hava koşullarında ÇÖS'ün 4,5–5 sn aralığında etkinleştirilmesi durumunun incelenmesi önerilmiştir (van der Horst and Hogema, 1994). Ozbay et al. (2008) ise sürücülerin tepki sürelerinin farklı olduğunu ve kullanılan taşıtın performansı, hâkim trafik koşulları gibi sebeplere bağlı olarak kesin bir KKS sınır değerinden bahsetmenin anlamlı olmadığını belirtmiştir. Yine de, bir standart üzerinde anlaşmak zor olmasına rağmen mantıklı kabul edilebilecek bir sınır değer kullanmanın gerekliliğini vurgulamışlardır (Ozbay et al., 2008).

Önden çarpışma önleyici sistemlerin işlevselliğini artırmak için intikal süresi (kaza alarm başlangıcı ile sürücünün frene bastığı an arasındaki süre) ile kaza alarmına tepki olarak sürücünün yavaşlama davranışının sistem girdisi olarak ele alınması gerektiğini belirten Kiefer et al. (2005), çalışmalarında gerçek bir sürüş ortamı kullanmış ve katılımcıların son saniye frenleri ile direksiyon kırma manevralarını normal ve uzun takip aralık koşullarında kaydetmiştir. Çalışma, Ohio'da bulunan Ulaşım Araştırma Merkezi'nde gerçekleştirilmiştir. Önde giden taşıt düşük ve sabit bir hızda ilerlemiştir. Toplam 3.536 başarılı frenleme durumu incelenmiştir. Çalışmada toplanan veriler; önde giden ve takip eden taşıtların hızları, önde giden taşıtın yavaşlama ivmesi ve iki taşıt arasındaki mesafedir. Kurulan lojistik regresyon modeli ile frenin normal mi sert mi olduğu ayırt edilmeye çalışılmış ve ters KKS ölçütünün en iyi tahmin değişkeni olduğu bulunmuştur. Ters KKS; önde giden ve takip eden taşıtlar arasındaki hız farkının, bu iki taşıt arasındaki mesafeye bölünmesi ile bulunmaktadır. Çalışmada, sürücülerin sert frenleme kararları alırken önde giden taşıtın yavaşlamasına ilişkin bir varsayım kullanmadıkları belirlenmiştir (Kiefer et al., 2005).

ÇÖS, kaza sayısını azaltması ve sürücünün güvenliğini artırması gibi faydalar sağlasa da ancak sistemin güvenilirliğinin yüksek olması, bir başka deyişle çarpışmaya kalan süreyi doğru tahmin etmesi durumunda etkili olmaktadır. Sürücü, sistemin hatalı uyarı verdiğini düşünürse, bu sistemleri devre dışı bırakma eğilimi göstermektedir (Kusano et al., 2015). Sistem, kazanın önlenemez olduğunu tespit etmesiyle birlikte taşıt güvenlik önlemlerini devreye sokmalıdır (Jiménez et al., 2013). ÇÖS'ün tehlike ortaya çıktığı zamanda devreye girebilmesi için bazı araştırmacılar KKS değerini doğal sürüş çalışmalarından (DSC) elde etmişlerdir. 100-Taşıtlar DSC ismiyle gerçekleştirilen çalışma büyük ölçekte uygulanan ilk doğal sürüş çalışmalarından biridir (Dingus et al., 2005). Bu

çalışmada kazaya sebep olabilecek durumlar gereken kaçınma manevrasının büyüklüğü açısından tanımlanmıştır. Doğal sürüş çalışmalarında taşıt içi ve dışında kameralar bulunmakta, taşıt içinde ivmeölçer sensörü, savrulma oranı sensörü, GPS takibi bulunmaktadır (Kusano et al., 2015). Wu and Jovanis (2012) 100-Araç DSC verilerini kullanarak kaza-çatışma oranını belirlemişlerdir. Veri toplama sistemi ile taşıtın yanal ivmesi, kendi doğrultusundaki ivmesi ve sapma açısı merkeze iletilmekte ve değerler verilen sınır değerlerin dışına çıktığı zaman tetikleyici sistem uyarı vermektedir. Çalışmada logit model kullanılmış, rastgele fayda fonksiyonunun yerini kaza fonksiyonu almıştır. Özellikle yatay ivmelenme 0,7-g değerini aştığında kaza olasılığının 24 kat arttığı tespit edilmiştir. Örneklem büyüklüğünün 13 kaza ve 38 ramak kala kaza ile sınırlı olması çalışmanın kısıtı olmasına karşılık mevcut veriler logit model ile değerlendirildiğinde gözlenen ve tahmin edilen kaza sıklığında anlamlı bir ilişki olduğu ortaya koyulmuştur (Wu and Jovanis, 2012). Kusano et al. (2015) taşıt takip koşulları altında sürücülerin frene bastıkları andaki KKS değerini 64 sürücüden elde ettikleri doğal sürüş verileriyle tespit etmeye çalışmışlardır. Çalışmada kullanılan veri seti için 100-Araç DSC verisi kaynak olarak kullanılmıştır. Veri seti 72.123 seyahat ile 2,6 milyon fren uygulamasını içermektedir. Yazarlar, farklı sürücü grupları için risk alma davranışının değiştiğini ve bundan dolayı farklı frenleme davranışı sergileyeceklerini belirtmişlerdir. Bu noktada, tek bir alarm özelliğine sahip ön çarpışma uyarı sisteminin sürücülerin farklı davranışlarını yansıtmayacağı vurgulanmıştır. Yazarlar, ileride birden fazla veya özelleştirilebilir uyarı eşiği ayarlarına sahip ön çarpışma uyarı sistemi kullanılmasını önermişlerdir (Kusano et al., 2015).

Hou et al. (2014) KKS'nin, benzetim modellerinde yörünge belirleme karar sürecinde, sürücünün kritik unsur olduğunu belirtmektedir. Yazarlar, KKS tanımını "mevcut yörüngelerin takip edilmeye devam etmesi durumunda, bir taşıtın yakın çevresinde bulunan başka bir taşıtla çarpışması için gereken süre" olarak vermiştir. Burada, önde giden taşıt ve takip eden taşıt kabulü yerine her taşıtın en yakınındaki taşıtla etkileşimde olduğu varsayımı benimsenmiştir. Yazarlar, taşıtları iki boyutlu düzlemde ele almışlardır. Her taşıt X-Y düzleminde belirli bir konumdaki dikdörtgenle temsil edilmiştir. İki dikdörtgen üst üste geldiğinde kaza gerçekleşmiş demektir. Ancak gerçekte sürücüler diğer taşıtlarla belirli bir güvenlik mesafesi bırakmaktadırlar ve bu güvenlik alanının ihlalini çatışma olarak algılamaktadırlar. Bu nedenle, çalışmada taşıtların çevresinde bir tampon bölge belirlenmesinin daha gerçekçi bir yaklaşım olduğu ileri sürülmüştür. Tampon bölge için daire, dikdörtgen, elips-dikdörtgen geometrileri üzerinde çalışılmış hepsinin avantaj ve dezavantajları açıklandıktan sonra birleştirilmiş bir modelin uygulanmasının en iyi sonucu vereceği kanısına varılmıştır. Birleştirilmiş modelde, algoritma daire geometrisi ile başlamakta, çarpışma meydana gelmezse elips-dikdörtgen algoritması ile devam etmektedir (Hou et al., 2014).

Taşıt takip senaryolarında taşıt hareketlerinin genellikle tek boyutlu olarak ele alınmasına eleştiri getiren Ward et al. (2015) KKS hesabını düzlemsel boyuta taşımıştır. Konum vektörleri belirlenirken her zaman adımında taşıtların birbirine en yakın noktaları esas alınmıştır. Araştırmacılar, KKS kullanımını farklı trafik senaryoları altında kullanılabilir kılmayı hedeflemiştir. Çalışmada ayrıca bir taşıttan diğer taşıta iletişim bağlantısı üzerinden iletişim kuran, iki taşıt arasındaki çarpışma ihtimalini tahmin etmek için yeni bir yöntem sunulmuştur (Ward et al., 2015).

Farklı hava koşullarında trafik güvenliğinin ne yönde etkilendiğini belirlemek için de güvenlik ölçütlerinden yararlanılmıştır. Peng et al. (2017) sisten kaynaklı kısıtlı görüş koşulları altındaki kaza riskini; KKS, hız varyansı ve zaman cinsinden aralık varyansını dikkate alarak incelemiştir. Görüş netliği azaldıkça KKS değerinin azaldığı ve zaman cinsinden aralık varyansının önemli ölçüde arttığı gözlenmiştir. Çalışmada görüş netliği azaldıkça ağır taşıtlar için KKS değerinin binek otomobillere göre daha çok azaldığı tespit edilmiştir (Peng et al., 2017).

St-Aubin et al. (2013), görüntü işleme tekniğini kullandığı çalışmasında KKS'nin yol güvenliği değerlendirmesinde kullanılabilmesi için kaza olasılığı ile ilişkisinin iyi ifade edilmesi gerektiğini belirtmiştir. Henüz literatürde bu ilişki ile ilgili net bir bilgi yer almasa da konum ve zamanda yakınlık arttıkça kaza riskinin arttığı bilinen bir gerçektir. t anında, sürücü reaksiyon süresi, görüş netliği, taşıt performansı gibi bilinmeyen faktörler θ ile gösterilirse çarpışma olasılığı (ζO) aşağıdaki gibi ifade edilmektedir. KKS değerinin sıfır olması durumunda çarpışma olasılığı bir olmaktadır.

$$\zeta O(t) = f(KKS(t), \theta) \quad (3.25)$$

Oh and Kim (2010) bireysel taşıt yörünge verilerini kullanarak arkadan çarpma kaza potansiyelini tahmin etmeye çalışmışlardır. İlk olarak, söz konusu taşıtın bir şerit değiştirme olasılığı veya düz sürüşe devam etme olasılığı hesaplanmıştır. Şerit değişiklikleri için ayrık seçim davranışını modellemek adına ikili lojistik regresyon kullanılmıştır. Güvenlik ölçütü olarak KKS'yi esas almışlardır (Oh and Kim, 2010).

Pirdavani et al. (2010) dur kontrollü dört kollu kavşaklarda güvenlik analizini İSS ölçütü ile yapmıştır. Çalışmada hız sınırını değiştirmenin trafik güvenliğini etkileyip etkilemediğini S-Paramics mikroskobik benzetim programı aracılığıyla belirlemişlerdir. Benzetim sırasında tıkanıklık koşulları dikkate alınmamıştır. Anayoldaki hız arttıkça, tali yoldaki sürücüler kavşaktan geçmek için daha küçük bir aralık kabul etmiş ve buna bağlı olarak İSS ölçütünün değeri azalmıştır. Benzer sonuç tıkanıklık koşullarının altında kalınması şartıyla trafik hacminin artırılması durumunda da elde edilmiştir (Pirdavani et al., 2010).

Kazaların tahmininde benzetim yöntemlerinin kullanılması ile ilgili yapılan bir derleme çalışmasında hemen hemen tüm yaygın olarak kullanılan trafik göstergelerinin yol nesnelерinin örtüşen yörüngelerde hareket etmemesi halinde çatışmaların varlığını dikkate almadığı belirtilmiştir. Bu kısıt nedeniyle özellikle tek aracın dâhil olduğu kazalara yol açabilecek riskli durumların doğru tespit edilemediği sonucuna varılmıştır (Astarita et al., 2021).



4. SAHA ÇALIŞMASI

Bu bölümde saha çalışmasının yapıldığı örülme bölgeleri tanıtılmıştır. Örülme bölgeleri yonca kavşaklar üzerinde yer almaktadır. İncelenen kavşak bölgelerinde bir adet örülme bölgesi seçilerek video kameralar ile zirve saatlerde kayıtlar gerçekleştirilmiştir.

Çekimler Şekil 4.1’de gösterilen Ege Üniversitesi Ulaştırma Laboratuvarı tarafından yaptırılmış olan dokuz metrelik tripodlar üzerine yerleştirilen GoPro Black Session 5 model kameralar ile gerçekleştirilmiştir. Bu sayede ağır taşıtların otomobil ve motosiklet gibi daha küçük taşıtların görüntülerini engellemesinin önüne geçilmiştir. Tripod, iç içe geçebilen parçalardan oluştuğundan ihtiyaca göre yükseklik ayarlanarak çekimler yapılmıştır. Tripodlar katılma ve ayrılma bölgelerinin hemen arkasında yer alan yeşil alanlara yerleştirilmiştir.

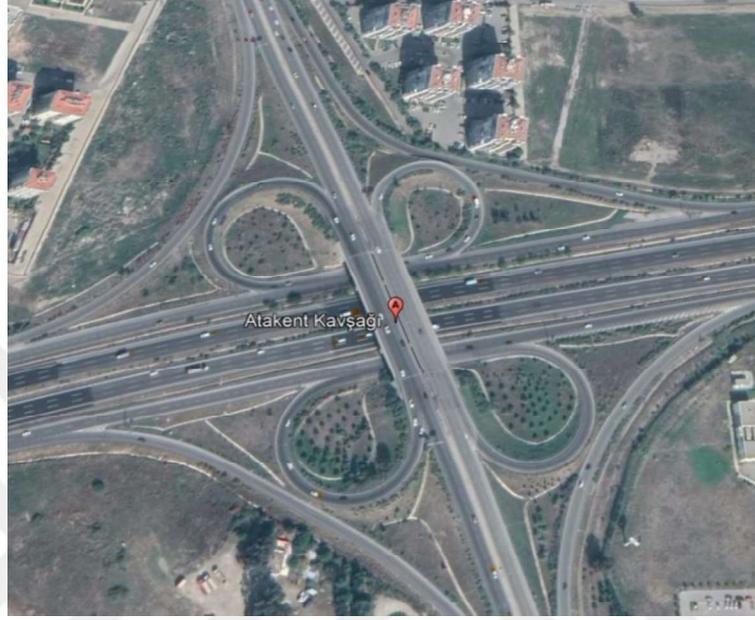
Tripodların üzerine yerleştirilen pan tilt motorlar uzaktan kumanda ile kontrol edilerek istenilen açının elde edilmesini sağlamıştır. Kullanılan GoPro kameraların kablosuz bağlantı özelliği sayesinde çekimler cep telefonundan eş zamanlı olarak seyredilebilmiştir. Böylece görüntü açısı hem kayıt başlangıcında net olarak ayarlanmış hem de çekim süresince herhangi bir değişiklik durumunda pan tilt motorların açısı değiştirilerek görüntü netleştirilmiştir.



Şekil 4.1 Özel yaptırılan tripod ve pan tilt motor.

4.1 Atakent Kavşağı

Atakent (K-17) Kavşağı, İzmir ilinin Karşıyaka ilçesinde O-30 numaralı otoyolu üzerinde yer almaktadır. Kavşak simetrik yonca kavşaktır. Çekim yapılan kavşak Şekil 4.2’de gösterilmiştir.



Şekil 4.2 Atakent kavşağı.

Örülme bölgesi içinde şerit sayısı iki ana şerit ve bir yardımcı şerit olmak üzere toplam üçtür. Şerit genişliği 3,60 metre, yan açıklık 1,80 metre olarak ölçülmüştür. Yolun örülme bölgesi uzunluğu 84 metredir. Atakent örülme bölgesindeki çekimler 18.10.2018 tarihinde saat 16:55:00-17:55:00 arasında gerçekleştirilmiştir. Şekil 4.3a ve b’de Atakent örülme bölgesinin sırasıyla katılma ve ayrılma kesimleri gösterilmiştir.



(a)



(b)

Şekil 4.3 a) Katılma ve b) ayrılma bölgesi, Atakent kavşağı.

4.2 Girne Kavşağı

Girne Kavşağı, İzmir ilinin Karşıyaka ilçesinde D550 devlet yolu üzerinde yer almaktadır. Kavşak simetrik yonca kavşaktır. Çekim yapılan kavşak Şekil 4.4'te gösterilmiştir.



Şekil 4.4 Girne kavşağı.

Örülme bölgesi içinde şerit sayısı iki ana şerit ve bir yardımcı şerit olmak üzere toplam üçtür. Şerit genişliği 3,60 metre, yan açıklık 1,80 metre olarak ölçülmüştür. Yolun örülme bölgesi uzunluğu 100 metredir. Girne örülme bölgesindeki çekimler 12.10.2018 tarihinde saat 16:38:00-17:38:00 arasında gerçekleştirilmiştir. Şekil 4.5a ve b'de Girne örülme bölgesinin sırasıyla katılma ve ayrılma kesimleri gösterilmiştir.



(a)



(b)

Şekil 4.5 a) Katılma ve b) ayrılma bölgesi, Girne kavşağı.

4.3 Gaziemir Kavşađı

Gaziemir Kavşađı, İzmir ilinin Gaziemir ilçesinde D550 devlet yolu üzerinde yer almaktadır. Kavşak simetrik yonca kavşaktır. Gözlenen kavşak Şekil 4.6’da gösterilmiştir.



Şekil 4.6 Gaziemir kavşađı.

Örülme bölgesi içinde şerit sayısı dört ana şerit ve bir yardımcı şerit olmak üzere toplam beştir. Şerit genişliđi 3,60 metre, yan açıklık 1,80 metre olarak ölçülmüştür. Yolun örülme bölgesi uzunluđu 150 metredir. Gaziemir örülme bölgesindeki çekimler 16.10.2018 tarihinde saat 17:01:00-18:01:00 arasında gerçekleştirilmiştir. Şekil 4.7a ve b’de Gaziemir örülme bölgesinin sırasıyla katılma ve ayrılma kesimleri gösterilmiştir.



(a)



(b)

Şekil 4.7 a) Katılma ve b) ayrılma bölgesi, Gaziemir kavşađı.

4.4 Otogar Kavşağı

Otogar Kavşağı, İzmir ilinin Bornova ilçesinde O5 otoyolu üzerinde yer almaktadır. Kavşak asimetrik yonca kavşaktır. Gözlenen kavşak Şekil 4.8’de gösterilmiştir.



Şekil 4.8 Otogar kavşağı.

Örülme bölgesi içinde şerit sayısı üç ana şerit ve bir yardımcı şerit olmak üzere toplam dördür. Şerit genişliği 3,60 metre, yan açıklık 1,80 metre olarak ölçülmüştür. Yolu örülme bölgesi uzunluğu 355 metredir. Otogar örülme bölgesindeki çekimler 30.10.2018 tarihinde saat 16:57:00-17:57:00 arasında gerçekleştirilmiştir. Şekil 4.9a ve b’de Otogar örülme bölgesinin sırasıyla katılma ve ayrılma kesimleri gösterilmiştir.



(a)



(b)

Şekil 4.9 a) Katılma ve b) ayrılma bölgesi, Otogar kavşağı.

4.5 Örnekköy Kavşağı

Örnekköy Kavşağı, İzmir ilinin Karşıyaka ilçesinde O30 otoyolu üzerinde yer almaktadır. Kavşak asimetrik yonca kavşaktır. Gözlenen kavşak Şekil 4.10'da gösterilmiştir.



Şekil 4.10 Örnekköy kavşağı.

Örülme bölgesi içinde şerit sayısı üç ana şerit ve bir yardımcı şerit olmak üzere toplam dördür. Şerit genişliği 3,60 metre, yan açıklık 1,80 metre olarak ölçülmüştür. Yolun örülme bölgesi uzunluğu 150 metredir. Otogar örülme bölgesindeki çekimler 11.10.2018 tarihinde saat 16:55:00-17:55:00 arasında gerçekleştirilmiştir. Şekil 4.11a ve b'de Örnekköy örülme bölgesinin sırasıyla katılma ve ayrılma kesimleri gösterilmiştir.



(a)



(b)

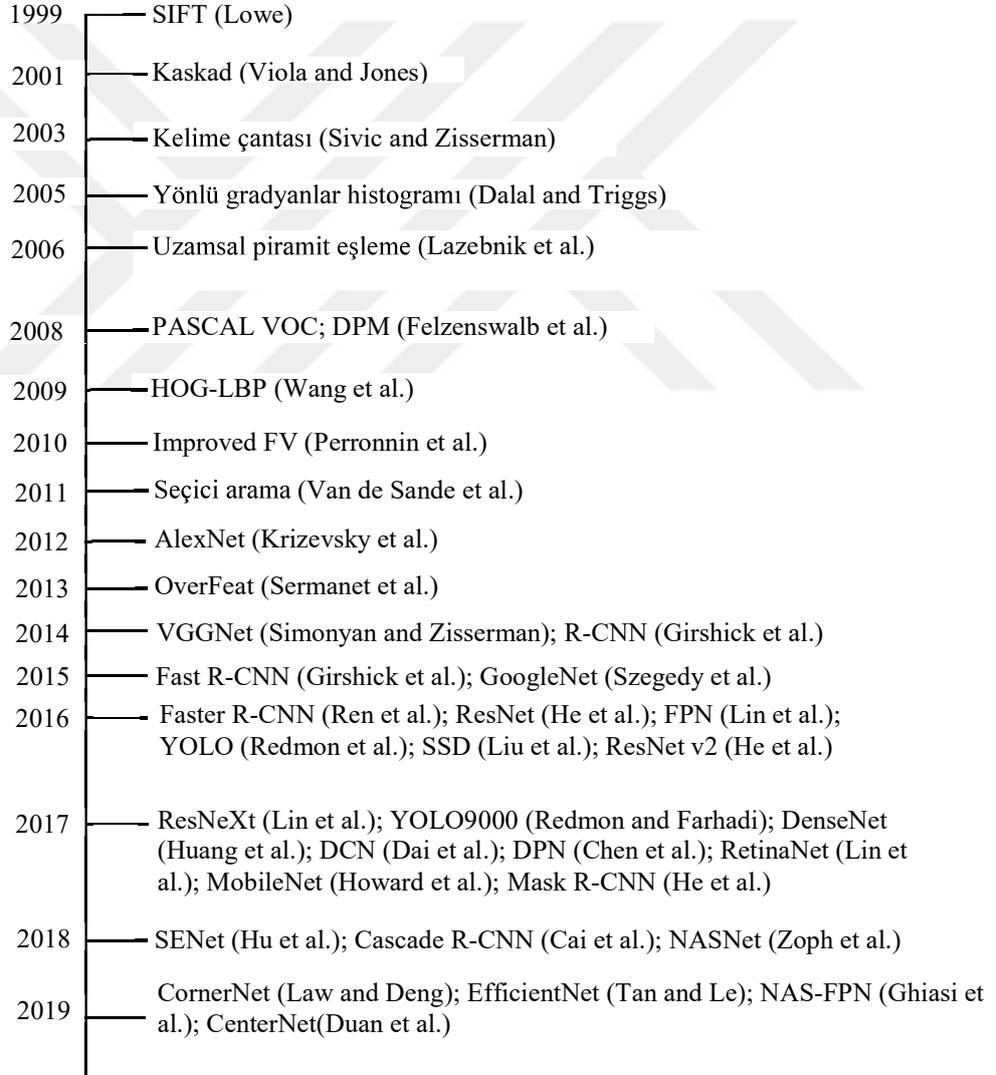
Şekil 4.11 a) Katılma ve b) ayrılma bölgesi, Örnekköy kavşağı.

5. GÖRÜNTÜ İŞLEME TEKNİĞİ

Yapay zekâ alanındaki gelişmeler her alanda olduğu gibi görüntü işleme alanında da geniş bir kullanım alanı bulmuştur. Bu bölümde nesne tanıma ve nesne takibini gerçekleştirmek için kullanılan yöntemler derlenmiştir.

5.1 Nesne Tanıma Yöntemleri

Nesne tanıma yöntemlerinin kronolojik gelişimi Şekil 5.1’de gösterilmiştir. Bu bölümde nesne tanıma öne çıkan yöntemler kısaca anlatılmış ve ardından görüntü işleme alanında kendine önemli bir yer edinen derin öğrenme yöntemleri açıklanmıştır.



Şekil 5.1 Nesne tanıma alanındaki önemli gelişmeler (Sharma and Mir, 2020).

5.1.1 Geleneksel nesne tanıma yöntemleri

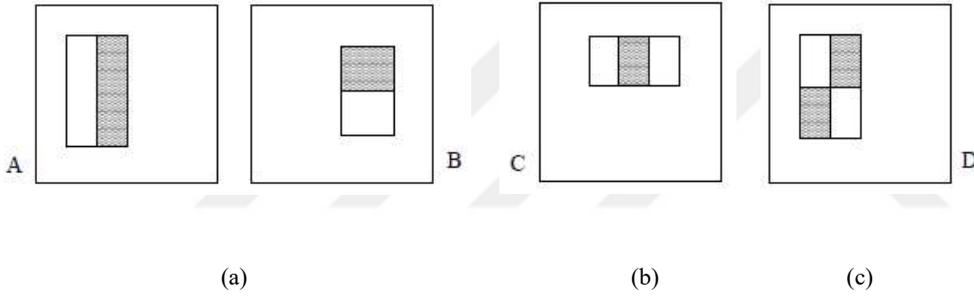
Bu bölümde, derin öğrenme yöntemlerinden önce kullanılan nesne tanıma yöntemleri anlatılmıştır. Bir görüntüde birden fazla nesne yer alabilmektedir. Nesnelerin görüntü üzerinde nerede yer aldığını tespit edebilmek için kayar pencere görüntü tarama tekniğinden faydalanılmaktadır. Çok ölçekli kayar pencere kullanıldığı takdirde farklı ölçek ve en/boy oranındaki nesnelere de bulunabilmektedir. Bu yöntemin dezavantajı çok sayıda anlamsız pencere üretmesi ve hesap yükünün fazla olmasıdır. Bir görüntüdeki farklı nesnelere tanımlamak için, algılanan nesnelere ait anlamlı bilgi verecek özneliklerin çıkarılması gerekmektedir. Bu amaçla kayar pencerenin geçtiği bölgelerden sabit boyutlu bir vektör çıkarılmaktadır. Bu bölgelerden çıkarılan özellikler, ölçekten bağımsız öznelik dönüşümü, Haar, yönlü gradyanlar histogramı gibi tanımlayıcılar ile kodlanabilmektedir. Vektörler elde edildikten sonra bir nesne sınıfını diğerlerinden ayırt etmek için sınıflandırıcılar kullanılmaktadır. En sık kullanılan sınıflandırıcı destek vektör makinesi olmakla birlikte Adaboost, torbalama (bagging) ve ayrılabilir parçalar modeli de tercih edilen sınıflandırıcılardandır (Sharma and Mir, 2020).

5.1.1.1 Ölçekten bağımsız öznelik dönüşümü

Ölçekten Bağımsız Öznelik Dönüşümü (Scale Invariant Feature Transform – SIFT), Lowe (1999) tarafından önerilen bir yöntemdir. Bu yöntemde görüntü, her biri öteleme, ölçek ve dönmeden bağımsız ve ışık değişimleri ile afin veya 3-boyutlu projeksiyona kısmen bağımlı yerel öznelik vektörlerinin toplamına dönüştürülmektedir. Sabit ölçekli öznelikler aşamalı filtreleme ile tespit edilmektedir. İlk aşamada Gauss farkı fonksiyonu ile maksimum ve minimum noktalar belirlenmektedir. Her nokta, ölçek-uzam koordinat çerçevesine göre örneklenen yerel görüntü bölgesini tanımlayan bir öznelik vektörü oluşturmak için kullanılmaktadır. Bu öznelikler görüntü gradyan konumlarını bulanıklaştırarak yerel değişimlere karşı değişmezlik sağlamaktadır. Ortaya çıkan öznelik vektörlerine SIFT anahtarları denilmektedir. Bir görüntüde ortalama 1000 SIFT anahtarı oluşmaktadır. Bu anahtarlar, aday nesnelere dizinlemek için en yakın komşu yaklaşımında kullanılmaktadır. Bir model pozunda karar kılan anahtar toplulukları ilk olarak Hough dönüşüm anahtar tablosu ile belirlenmekte, sonra en küçük kareler yöntemi ile parametrelerin kestirimi yapılmaktadır. Bir nesnenin varlığından söz edebilmek için en az üç anahtarın model parametreleri üstünde anlaşması gerekmektedir (Lowe, 1999).

5.1.1.2 Viola-Jones algoritması

Viola and Jones (2001) yüz tanıma dedektörü için geliştirdiği yöntemde üç farklı tekniği bir araya getirmiştir. Bunlar; görüntü integrali, öznelik seçimi ve basamaklandırma yöntemidir. Nesne tanımda pikseller yerine öznelikler kullanılmaktadır. Bunun nedeni özneliklerin, sınırlı miktarda eğitim verisi kullanarak öğrenilmesi zor olan geçici alan bilgilerini kodlamada görev almasıdır. Bir diğer sebep ise öznelik kullanımına dayalı sistemlerin piksel esaslı sistemlere göre daha hızlı olmasıdır. Kullanılan öznelikler Haar benzeri fonksiyonlardır. Viola-Jones nesne tanıma dedektörü iki, üç ve dört dikdörtgenli öznelikler kullanılmaktadır. İki dikdörtgen özneliği, iki dikdörtgen bölge içindeki piksellerin toplamı arasındaki farkı almaktadır (Şekil 5.2a). Üç dikdörtgen özneliğinde, ortadaki dikdörtgenin piksel toplamından dıştaki iki dikdörtgenin piksel toplamı çıkarılmaktadır (Şekil 5.2b). Dört dikdörtgen özneliğinde, köşegen dikdörtgenlerin piksel toplamının farkı alınmaktadır (Şekil 5.2c).

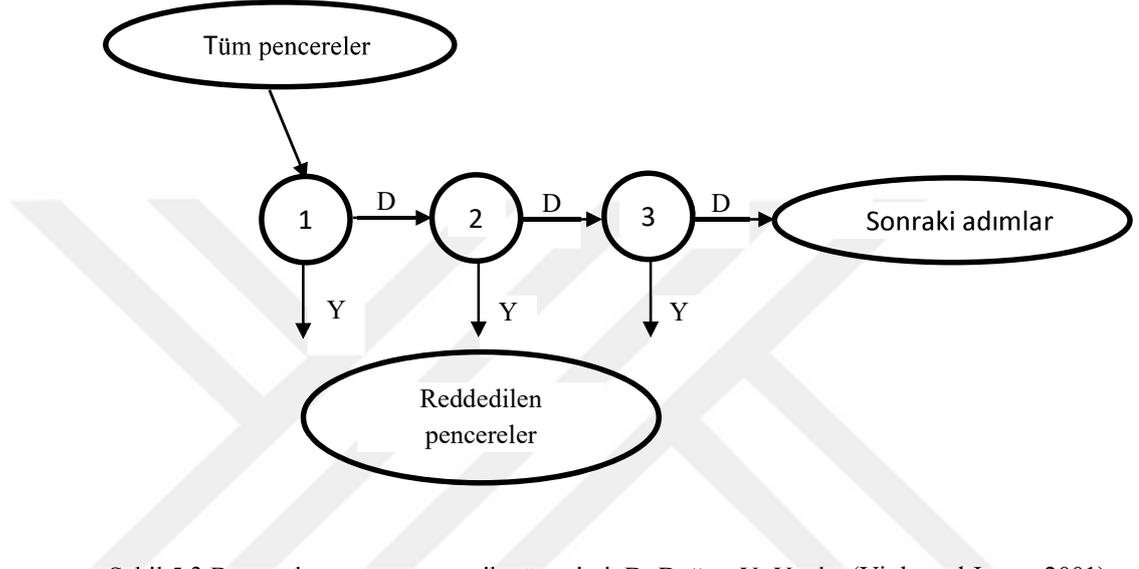


Şekil 5.2 Öznelik dikdörtgenleri a) ikili, b) üçlü, (c) dörtlü (Viola and Jones, 2001).

Çıkarılan özneliklerin hızlı ve farklı ölçeklerde hesaplanabilmesi için görüntü integrali yöntemi kullanılmıştır. Görüntü integrali yönteminde her piksel, üstündeki ve solundaki piksellerin toplamına eşittir.

Viola-Jones tanıma algoritmasında AdaBoost, sınıflandırıcının eğitilmesi ve özneliklerin çıkarılması olmak üzere iki amaçla kullanılmaktadır. Orijinal biçiminde, AdaBoost öğrenme algoritması, basit (zayıf) bir öğrenme algoritmasının sınıflandırma performansını artırmak için kullanılmaktadır. Yazarlar, oluşturdukları algoritmada zayıf öğrenme algoritmasını pozitif ve negatif örnekleri en iyi şekilde ayıran tek dikdörtgen özelliğini seçmek için tercih etmişlerdir. Zayıf öğrenici, her öznelik için en küçük sayıda yanlış sınıflandırma yapacak şekilde eşik sınıflandırma fonksiyonu değerini belirlemektedir. Nesne tespitinin gerçekleşmesi için basamak yönteminden faydalanılmaktadır. Basamağı oluşturan sınıflandırıcılar, AdaBoost kullanılarak

sınıflandırıcıların eğitilmesi ve yalancı negatifliği en düşük seviyede tutacak eşik değerin belirlenmesi ile oluşturulmaktadır. Basamak yapısının kullanılmasının sebebi mümkün olan en erken aşamalarda çok sayıda negatif alt-pencereyi reddetmektir. Her aşama bir öncekine göre daha zordur. Bir sınıflandırıcının pozitif sonucu sonraki sınıflandırıcıyı tetiklemektedir. Bu yapı Şekil 5.3'te gösterilmiştir. Viola-Jones yüz tanıma algoritması kendinden önceki algoritmalara göre 15 kat daha hızlı çalışmaktadır (Viola and Jones, 2001).



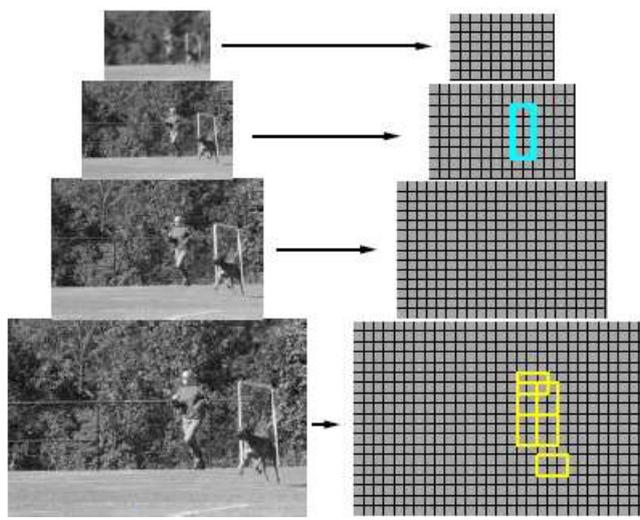
Şekil 5.3 Basamak yapısının şematik gösterimi, D: Doğru, Y: Yanlış (Viola and Jones, 2001).

5.1.1.3 Yönlü gradyanlar histogramı

Dalal and Triggs (2005) tarafından önerilen yönlü gradyanlar histogramı (YGH), SIFT ve şekil bağlamlarına benzerlik gösterse de eşit aralıklı hücrelerden oluşan yoğun bir ızgara üzerinde hesaplanmakta ve performansı arttırmak için üst üste binen yerel karşıtlık normalizasyonunu kullanmaktadır. Çalışma, yerel nesne görünümünün ve şeklinin, yerel yoğunluk gradyanlarının veya kenar yönlerinin dağılımı ile oldukça iyi karakterize edilebilmesi fikrine dayanmaktadır. Bunu gerçekleştirmek için görüntü penceresi hücrelere bölünerek, her hücrede gradyan yönlerinin veya hücre pikselleri üzerinde kenar yönlendirmelerinin yerel ve bir boyutlu histogramları toplanmaktadır. Histogram girdilerinin tümü görüntünün temsilini oluşturmaktadır. Işık ve gölge gibi durumlara karşı değişmezlik sağlamak için karşıtlık normalizasyonu yapılmaktadır. Normalize edilen tanımlayıcı bloklar yönlü gradyanlar histogramı olarak adlandırılmaktadır. Çalışmada sınıflandırıcı olarak destek vektör makinelerinden faydalanılmıştır. YGH dedektörler MIT yaya test setinde iyi sonuç verince yazarlar 1800'den fazla yaya görüntüsünü içeren daha zor bir veri seti (INRIA veri seti) oluşturmuşlardır (Dalal and Triggs, 2005).

5.1.1.4 Ayrılabilir parçalar modeli

Felzenszwalb (2008) tarafından önerilen ayrılabilir parçalar modeli yönlü gradyanlar histogramının gelişmiş bir versiyonudur. Modelde tarama penceresi yaklaşımı kullanılmaktadır. Nesne modeli, kök filtre olarak adlandırılan bir filtre ve birkaç parça modelinden oluşmaktadır. Her parça modeli, konumsal bir model ve bir parça filtresinden meydana gelmektedir. Şekil 5.4'te gösterilen mavi dikdörtgen; kök filtresine, sarı dikdörtgenler ise parça filtrelerine karşılık gelmektedir. Hem kök hem parça filtreleri, pencere içindeki bir dizi ağırlık ve yönlü gradyan öznitelikleri arasındaki skaler çarpım ile hesaplanmaktadır. Kök filtresi, yönlü gradyanlar histogramına denk gelmektedir. Model, sabit bir ölçekte tanımlanmaktadır. Nesnelere, görüntü piramidi üzerinden aranılarak tespit edilmektedir (Felzenszwalb, 2008). Ayrılabilir parçalar modeli ilerleyen yıllarda geliştirilen derin öğrenme esaslı nesne tanıma dedektörlerine ilham veren bir yöntem olmuştur.



Şekil 5.4 YGH öznitelik piramidi (Felzenszwalb, 2008).

5.1.2 Derin öğrenme yöntemleri ile nesne tanıma

Bu bölümde derin öğrenme yöntemlerinin omurga ve mimari yapıları anlatılmıştır. Derin öğrenme ile ilgili ayrıntılara geçmeden önce yapay sinir ağlarının anlaşılması gerekmektedir. Bu amaçla ilk olarak yapay sinir ağlarının yapısı anlatılmış daha sonra derin öğrenme ve görüntü işleme alanındaki kullanımı ile ilgili bilgi verilmiştir.

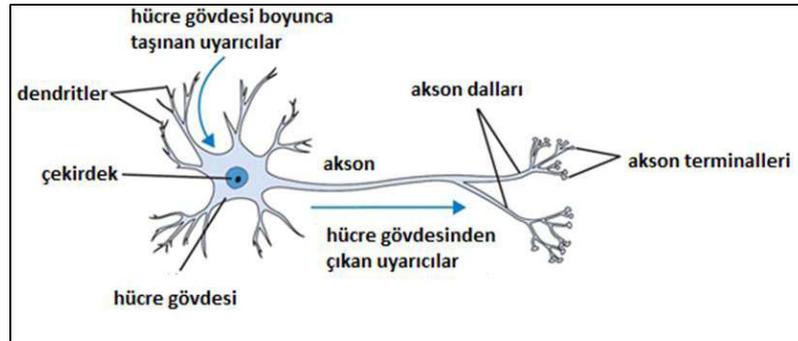
5.1.2.1 Yapay sinir ağı

Bir sinir ağı, deneysel bilginin depolanması ve kullanım için uygun hale getirilmesi eğilimine sahip basit işlem birimlerinden oluşan, büyük ölçüde paralel dağıtılmış bir işlemcidir. İnsan beynine iki açıdan benzemektedir (Haykin, 1999):

- Bilgi, çevresel bir öğrenme süreci ile ağ tarafından elde edilmektedir.
- Sinaptik ağırlıklar olarak bilinen nöronlar arası bağlantı kuvvetleri, edinilen bilgiyi depolamak için kullanılmaktadır.

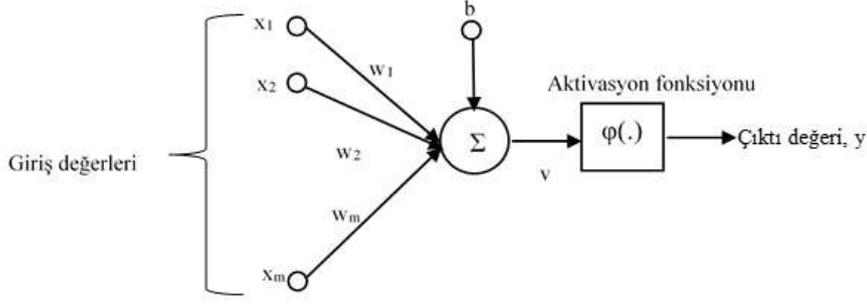
Sinir ağlarının dikkat çektiği ilk dönemlerde McCulloch and Pitts (1943); nöronun matematiksel modelini, Hebb (1949); kendi kendini organize eden öğrenmenin ilk kuralını (1943–1958) ortaya koymuş, Rosenblatt (1958) ise öğreticiyle öğrenme modeli için algılayıcı (perceptron) kullanılmasını önermiştir (Haykin, 2009):

İnsan beyninin temel birimi nörondur. Biyolojik nöron yapısı Şekil 5.5'te gösterilmiştir. Nöron, girdilerini dendrit denilen anten benzeri yapılar boyunca almaktadır. İlgili bağlantıların kuvveti ile ağırlıklandırıldıktan sonra, girdiler hücre gövdesinde toplanmaktadır. Bu toplam daha sonra hücrenin aksonu boyunca yayılan ve diğer nöronlara gönderilen yeni bir sinyale dönüşmektedir (Buduma and Locascio, 2017).



Şekil 5.5 Biyolojik nöron yapısı (Buduma and Locascio, 2017).

Yapay sinir ağı modeli Şekil 5.6'da gösterilmiştir (Haykin, 2009). Bir yapay sinir hücresi de; girdiler, ağırlıklar, toplam fonksiyonu, aktivasyon fonksiyonu ve çıktılar olmak üzere beş bölümden oluşmaktadır.



Şekil 5.6 Yapay sinir hücresi yapısı (Haykin, 2009).

Biyolojik sinir yapısındaki elemanların yapay sinir yapısındaki karşılıkları Çizelge 5.1’de gösterilmiştir.

Çizelge 5.1 Biyolojik ve yapay sinir hücresi elemanlarının karşılaştırılması (Öztürk ve Şahin, 2018).

Biyolojik sinir hücresi	Yapay sinir hücresi
Nöron	İşlemci elemanı
Dendrit	Toplam fonksiyonu
Hücre gövdesi	Transfer fonksiyonu
Akson	Yapay nöron çıkışı
Sinaps	Ağırlık

Fonksiyon girdisi v , Denklem 5.1 ile bulunmaktadır.

$$v = \sum_{i=1}^m w_i x_i + b \quad (5.1)$$

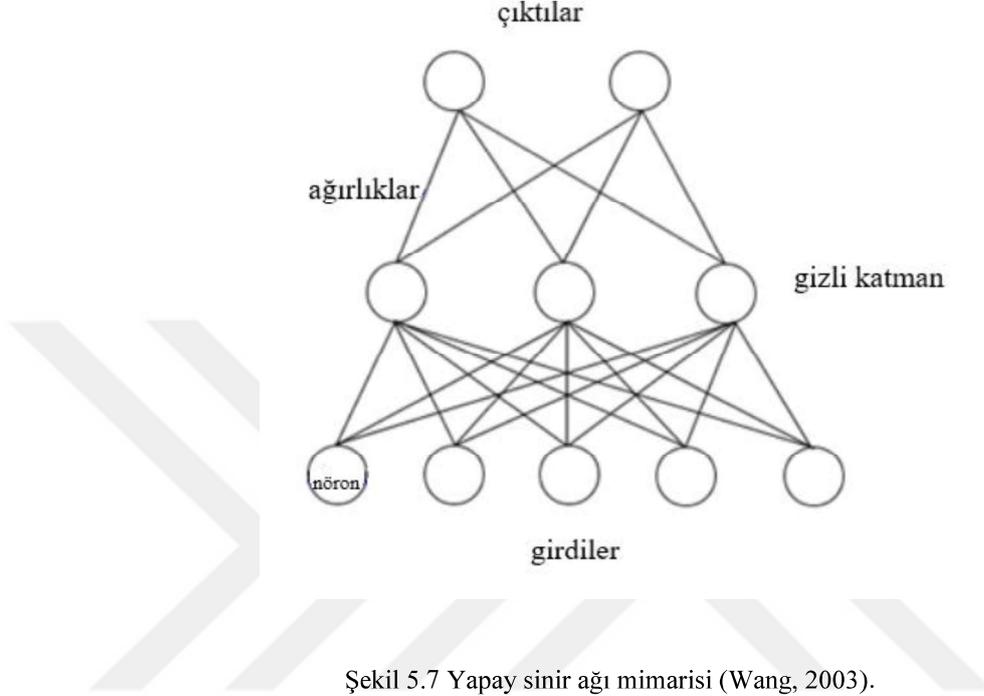
Çıkış değeri ise Denklem 5.2 ile bulunmaktadır.

$$y(x) = \varphi(\sum_{i=1}^m w_i x_i + b) \quad (5.2)$$

Yukarıdaki denklemlerde, m giriş değeri sayısını, w ağırlığı, x giriş değerlerini, b yanlılığı, y çıkış değerini, φ aktivasyon fonksiyonunu göstermektedir.

Sinir ağları girdi katmanı, bir veya daha fazla gizli katman ve bir çıktı katmanından oluşmaktadır. Tüm katmanların düğümleri ve her düğüm noktasının ağırlığı vardır. Bu ağırlıklar bir katmandan diğerine bilgi aktarılırken dikkate alınmaktadır (Wang, 2003). Şekil 5.7’de yapay sinir ağı mimarisi gösterilmiştir. Bir sinir ağının tahmin doğruluğu, kullanılan katman sayısı ile aktivasyon fonksiyonunun türüne bağlı olarak değişmektedir. Aktivasyon fonksiyonu genellikle doğrusal olmayan fonksiyonlardan seçilmektedir. Yapay sinir ağlarının bir özelliği olan “doğrusal olmama” aslında aktivasyon

fonksiyonlarının bu özelliğinden kaynaklanmaktadır. Basamak, doğrusal, sigmoid, hiperbolik tanjant, düzleştirilmiş doğrusal birim (rectified linear unit - ReLU), sızıntı ReLU, parametreleştirilmiş ReLU, üssel doğrusal birim, Swish ve SoftMax kullanılan aktivasyon fonksiyonlarıdır (Sharma et al., 2020).



Şekil 5.7 Yapay sinir ağı mimarisi (Wang, 2003).

Belirtilen fonksiyonlardan en basiti basamak fonksiyonudur. Genellikle ikili sınıflandırmaların çıkış katmanlarında tercih edilmektedir. Fonksiyon değeri Denklem 5.3'te verildiği gibidir.

$$f(v) = \begin{cases} 1 & v \geq 0 \\ 0 & v < 0 \end{cases} \quad (5.3)$$

Doğrusal aktivasyon fonksiyonu girdi ile doğru orantılıdır. Basamak fonksiyonundan farklı olarak türevlenebilir bir fonksiyondur (Denklem 5.4), ancak türev değeri sabit bir sayı olduğundan sinir ağının hatayı azaltması mümkün olmamaktadır (Sharma et al., 2020).

$$f(v) = av \quad (5.4)$$

Sigmoid aktivasyon fonksiyonu en yaygın kullanılan ve doğrusal olmayan fonksiyonlardan biridir. Daha çok sınıflandırma problemlerinde kullanılmaktadır. Bu fonksiyon, artı ve eksi sonsuz arasında değişen girdi değerlerinin her biri için sıfır ila bir

arasında bir çıkış değeri üretmektedir (Hagan et al., 1996). Sigmoid aktivasyon fonksiyonu sürekli türevlenebilir bir fonksiyondur (Sharma et al., 2020).

$$\varphi(v) = \frac{1}{1+\exp(-av)} \quad (5.5)$$

Hiperbolik tanjant fonksiyonu sigmoid gibi sürekli türevlenebilir bir fonksiyondur ancak türevi daha diktir, aralığı ise -1 ila +1 arasında değişmektedir. Fonksiyon, orijine göre simetriktir (Sharma et al., 2020).

$$\varphi(v) = \frac{\exp(v)-\exp(-v)}{\exp(v)+\exp(-v)} \quad (5.6)$$

Düzeltilmiş doğrusal birim (rectified linear unit – ReLU) fonksiyonu doğrusal olmayan bir fonksiyondur. Aldığı değerler 0 ila $+\infty$ arasında değişmektedir. Sadece gizli katmanlarda kullanılmaktadır. Tüm nöronların aynı anda aktive edilmemesi sebebiyle diğer fonksiyonlara göre hesaplama yükü daha azdır (Sharma et al., 2020).

$$\varphi(v) = \max(0, v) \quad (5.7)$$

ReLU fonksiyonunda negatif değerler sıfır alınmaktadır. Sızıntı ReLU fonksiyonunda bu durumu düzeltmek ve negatif değerler için de öğrenmeyi sağlayabilmek için çok küçük bir sızıntı değeri (0,01) verilmektedir.

$$\varphi(v) = 0.01v, \quad v < 0 \quad (5.8)$$

$$\varphi(v) = v, \quad v \geq 0 \quad (5.9)$$

Parametreleştirilmiş ReLU fonksiyonu da sızıntı ReLU fonksiyonu gibi negatif değerlerde öğrenme sağlamaktadır. Bu fonksiyonun farkı ise sızıntı değeri olarak 0,01 değeri yerine bir fonksiyon tanımlanmasıdır. Denklem 5.10'daki a katsayısı eğitilebilmektedir (Sharma et al., 2020).

$$\varphi(v) = av, \quad v < 0 \quad (5.10)$$

$$\varphi(v) = v, \quad v \geq 0 \quad (5.11)$$

Üssel doğrusal birim fonksiyonu da ReLU fonksiyonuna benzemekte ancak negatif değerler için logaritmik eğri kullanılmaktadır (Sharma et al., 2020).

$$\varphi(v) = a(e^v - 1), \quad v < 0 \quad (5.12)$$

$$\varphi(v) = v, \quad v \geq 0 \quad (5.13)$$

Swish fonksiyonu Google çalışanları tarafından geliştirilmiş bir fonksiyondur. Fonksiyonun değeri girdi değerleri artsa bile azalabilmektedir, bir başka deyişle monoton yapıda değildir (Sharma et al., 2020).

$$\varphi(v) = \text{sigmoid}(v) \quad (5.14)$$

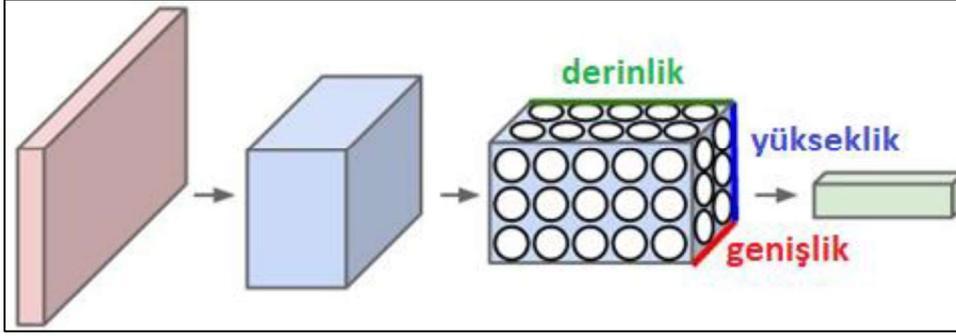
$$\varphi(v) = v/(1 - e^v) \quad (5.15)$$

Softmax fonksiyonu, ikili sınıflandırmada kullanılan sigmoid fonksiyonlarından farklı olarak çoklu sınıflandırma yapabilmektedir. Çıkış katmanında kullanılmakta ve girdinin hangi sınıfa ait olduğuna dair olasılık değeri üretmektedir (Sharma et al., 2020).

5.1.2.2 Evrişimli sinir ağları

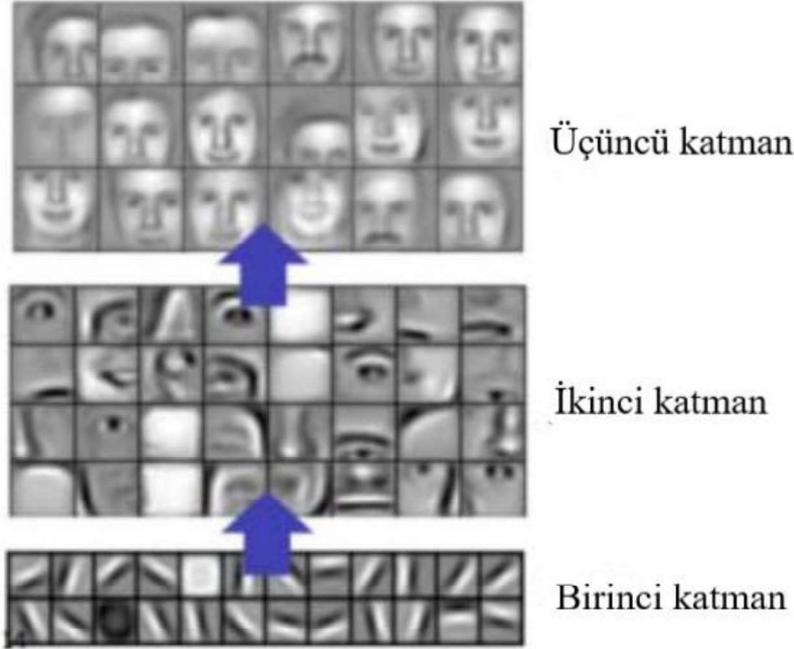
Bilgisayarlı görü alanında geniş bir kullanım alanı bulan derin öğrenme modellerinden biri evrişimli sinir ağıdır. Evrişimli sinir ağları (ESA) yapay sinir ağlarındaki parametre sayısını azaltmaları nedeni ile karmaşık görevleri çözme konusunda tercih edilmektedir (Albawi et al., 2017). Yapay sinir ağ yapısı küçük ölçekli veri setleri için iyi sonuç verirken büyük ölçekli bir çalışma yürütülmek istenildiğinde hesaplama gücü yetersiz kalabilmektedir. Örnek olarak $32 \times 32 \times 3$ boyutlu bir görüntüde nöronların katmanlar arasında tam bağlanması durumunda her nöron $32 \times 32 \times 3 = 3072$ ağırlık üretecektir. Görüntü boyutu artırıldığında üretilen ağırlık sayısı da artacaktır (Di et al., 2018).

ESA, giriş verilerini genişlik, yükseklik ve derinliği temsil ederek Şekil 5.8'de gösterilen üç boyutlu tensör benzeri bir yapı ile düzenlemektedir. Bir katmandaki her nöron, görüntünün sadece küçük bir kısmına odaklanmaktadır (N-Yo, 2018). Daha küçük kısımlara odaklanmanın sebebi üretilen ağırlık sayısını azaltmaktır. Tüm görüntüyü ele almak yerine görüntü üzerinde yerel bölgeler dikkate alınarak ağırlıklar bir sonraki katmandaki gizli nöronlara aktarılmaktadır (Albawi et al., 2017). Ağırlık sayısının azaltılmasını sağlayan bir diğer yöntem ise yerel bağlantı ağırlıklarının sabit tutulmasıdır. Böylece bir sonraki katmandaki nöronlar bir önceki katmanın yerel bölgesine aynı ağırlıkta bağlanmaktadır (Albawi et al., 2017).



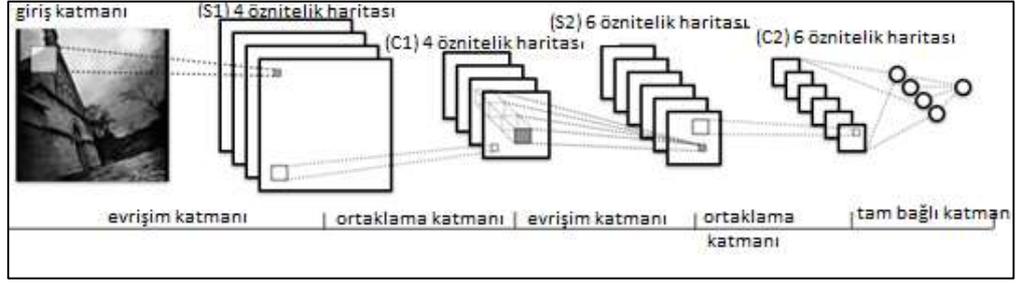
Şekil 5.8 Üç boyutlu ESA yapısı (Stanford, 2018).

ESA, nesnenin görüntüde nerede bulunduğundan bağımsız olarak nesnenin kendisini algılamaya olanak vermektedir. ESA'nın bir diğer özelliği ise katmanlar boyunca ilerledikçe nesnelere ait farklı özelliklerin algılanmasıdır. Şekil 5.9'da yüz tanımanın nasıl gerçekleştiğine dair bir örnek gösterilmiştir. Birinci katmanda köşeler, ikinci katmanda basit geometrik şekiller, üçüncü katmanda ise yüksek seviyeli öznitelikler tanınmaktadır (Albawi et al., 2017).



Şekil 5.9 ESA katmanlarında öznitelik çıkarımı (Albawi et al., 2017).

Tipik bir ESA bir dizi katmandan oluşmaktadır. Bunlar; giriş katmanı, evrişim katmanları, ortaklama katmanı ve tam bağlı katmandır (Di et al., 2018). Şekil 5.10'da bu yapı gösterilmiştir.

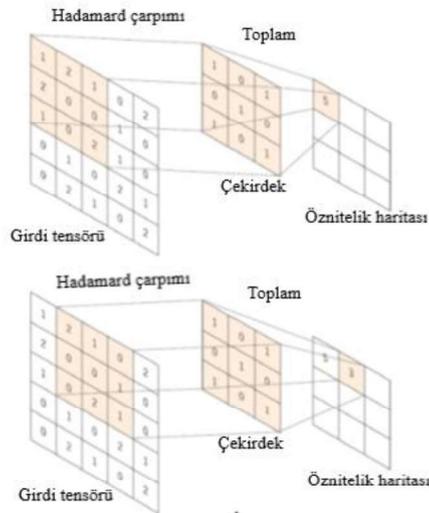


Şekil 5.10 ESA mimarisi (Di et al., 2018).

Giriş katmanı görüntünün piksel değerlerini tutmaktadır. (O'Shea and Nash, 2015). Ağa ismini veren evrişim (konvolüsyon), çekirdek (kernel) adı verilen küçük bir sayı dizisinin tensör adı verilen bir sayı dizisi olan girdi boyunca uygulandığı, öznelik çıkarımında kullanılan özel bir doğrusal işlem türüdür. Tensörün her konumunda çekirdeğin her elemanı ile giriş tensörünün arasında Hadamard (eleman elemana) çarpımı yapılır ve öznelik haritası olarak adlandırılan çıkış tensörünün karşılık gelen konumunda çıkış değerini elde etmek için toplanır (Yamashita et al., 2018). Bu işlemler Denklem 5.16 ile ifade edilmektedir (Di et al., 2018). Denklem 5.16'da x ; giriş tensörünü, w ; çekirdek matrisi, s ise öznelik haritasını ifade etmektedir.

$$s(t) = (x \odot w)(t) = \int_{-\infty}^{\infty} x(k)w(t - k)dk \quad (5.16)$$

Evrişimi tanımlayan iki hiperparametre (öğrenme sürecini kontrol eden parametre) çekirdek matrisinin boyutu ve sayısıdır. Matris, genellikle 3x3, 5x5 veya 7x7 boyuttadır. Çekirdek sayısı ise öznelik haritalarının derinliğini belirlemektedir (Yamashita et al., 2018). Şekil 5.11'de öznelik haritasının çıkarımı özetlenmiştir.



Şekil 5.11 ESA mimarisi ve öznelik haritası çıkarımı (Di et al., 2018).

Evrişim aşamasında görüntünün sınırındaki bilgiler kaybolmaktadır. Bunun sebebi çekirdek matrisin merkezinin girdi tensörünün en dıştaki elemanını yakalamamasıdır. Bu sorun girdi tensörünün her kenarına sıfırlardan oluşan pikseller eklenmesiyle (zero-padding) çözülmektedir. Çekirdek matrisi girdi tensörü üzerinde kaydırma adımı (stride) kadar hareket ettirilmektedir. Kaydırma adımı genellikle bir alınmakla birlikte oluşacak öznelik haritasını küçültmek için daha büyük değerler de alınabilmektedir (Albawi et al., 2017; Yamashita et al., 2018).

Evrişim işleminin çıktıları doğrusal olmayan bir aktivasyon fonksiyonundan geçirilmektedir. Bu aşamada kullanılan aktivasyon fonksiyonları 5.1.2.1 başlığı altında anlatılmıştır. En sık kullanılan fonksiyon ReLU fonksiyondur.

Ortaklama (pooling) katmanı evrişim katmanından sonra gelmektedir ve giriş matrisinin kanal sayısını sabit tutarak yükseklik ve genişlik bilgisini azaltmaktadır. Bu katmanın esas görevi ağıın öğreneceği parametre sayısını azaltmaktır ancak bunu yaparken aynı zamanda en önemli bilgileri tutmaktır. Bu katmanı kullanmanın sağladığı yararlardan bir tanesi model ezberlemeyi azaltmasıdır. Ortalama, toplam ve en büyük ortaklama türleri bulunmakla birlikte en çok tercih edileni en büyük ortaklamadır. En büyük ortalama, öznelik haritasında ortaklama alanı içindeki en büyük değer kullanılmasıdır (Di et al., 2018). Genellikle 2×2 filtre ve iki birimlik kaydırma adımı kullanılmaktadır. Öznelik haritalarının yükseklik ve genişliğinin aksine derinlik boyutu sabit kalmaktadır (Yamashita et al., 2018).

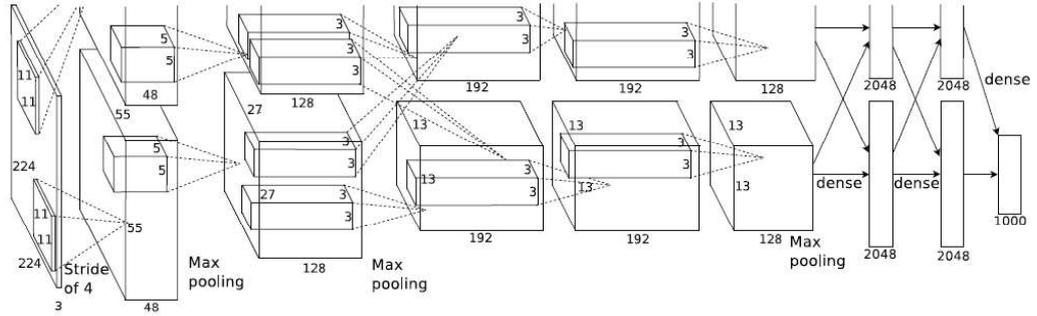
Evrişimli sinir ağının son katmanı tam bağlı katmandır. Bu katmandaki nöronlar önceki katmandaki tüm aktivasyonlara tam bağlıdır. Bu katmanın çıktı değeri sınıf değeridir ve nöron sayısı sınıf sayısına eşittir (Di et al., 2018).

5.1.2.3 Nesne tanımda kullanılan omurga yapıları

Kamuya açık büyük bir veri seti kaynağı olan ImageNet, Büyük Ölçekli Görsel Tanıma Yarışması (ImageNet Large Scale Visual Recognition Challenge - ILSVRC) ile derin görsel tanıma mimarilerinin ilerlemesinde önemli bir rol oynamıştır. ILSVRC, yüzlerce nesne kategorisi ve milyonlarca görüntü üzerinde nesne kategorisi sınıflandırması ve tespiti yapan bir ölçüttür. Yarışma, 2010 yılından günümüze kadar, elliden fazla kurumun katılımı ile yürütülmektedir. ILSVRC iki bileşenden oluşmaktadır: (1) kamuya açık bir veri seti ve (2) her yıl düzenlenen bir yarışma ve çalıştay. Veri kümesi, bir dizi etiketlenmiş eğitim görüntüsü içermektedir. Katılımcılar, eğitim

görüntülerini kullanarak algoritmalarını eğitmekte ve ardından test resimlerini otomatik olarak etiketlendirmektedirler (Russakovsky et al., 2015).

Krizhevsky et al. (2012) 1,2 milyon yüksek çözünürlüklü görüntüyü 1000 sınıfa ayırmıştır. ILSVRC-2010 ve ILSVRC-2012 yarışmalarında kullanılan ImageNet'in alt kümeleri için o güne kadarki en büyük evrişimli sinir ağlarından birini eğitmişler ve aynı veri seti üzerindeki en iyi sonuca ulaşmışlardır. Ağ, piksellerin ham RGB değerleri ile eğitilmiştir. Tek bir GPU kullanarak 1,2 milyon görüntünün eğitilmesi mümkün olmadığından çalışmada paralel iki GPU kullanılmıştır. GPU'lar belirli katmanlarda birbirleriyle iletişime geçmişlerdir. Ağ, beş adet evrişimli ve üç adet tam bağlı katmandan oluşmaktadır. AlexNet ağ mimarisi Şekil 5.12'de gösterilmiştir. İlk evrişim katmanı, $227 \times 227 \times 3$ giriş görüntüsünü, $11 \times 11 \times 3$ boyutundaki 96 çekirdek matrisle dört piksellik bir kaydırma adımı kullanarak filtrelemektedir. İkinci evrişim katmanı, ilk evrişim katmanının (normalleştirilmiş ve ortaklanmış) çıktısını almakta ve $5 \times 5 \times 48$ boyutundaki 256 çekirdek matris ile filtrelemektedir. Üçüncü, dördüncü ve beşinci evrişim katmanları araya giren ortaklama katmanları olmaksızın birbirine bağlanmaktadır. Üçüncü evrişim katmanı $3 \times 3 \times 256$ boyutlu 384 çekirdek matris ile ikinci evrişim katmanının çıktısına bağlanmaktadır. Dördüncü evrişim katmanında $3 \times 3 \times 192$ boyutlu 384 çekirdek matris, beşinci evrişim katmanında ise $3 \times 3 \times 192$ boyutlu 256 çekirdek matris bulunmaktadır. Tam bağlantılı katmanların her birinde 4096 nöron bulunmaktadır. İlk iki tam bağlı katmanda model ezberlemeyi (overfitting) azaltmak için unutma (dropout) yöntemi uygulanmıştır (Krizhevsky et al., 2012).



Şekil 5.12 AlexNet mimarisi (Krizhevsky et al., 2012).

Bir ağda model ezberleme olduğunda, sınıflandırıcı eğitim veri setinde yüksek doğrulukla çalışmakta test setinde ise düşük doğruluk vermektedir (Subramanian and Simon, 2013). Unutma, eğitim aşamasında rastgele seçilen nöronların göz ardı edilmesi anlamına gelmektedir. Her bir eğitim aşamasında, her gizli nöronun çıktısı 0,5 olasılıkla sıfırlanmaktadır (Hinton et al., 2012; Krizhevsky et al., 2012).

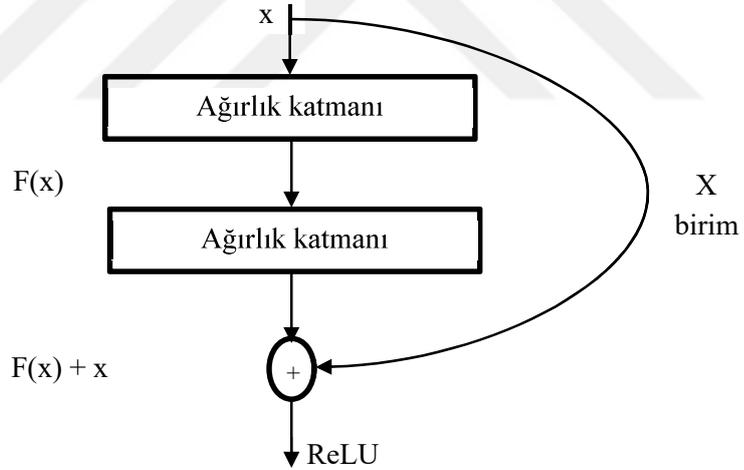
AlexNet'in kazandığı başarı sonrasında araştırmacılar ESA'yı bilgisayarlı görü alanında daha fazla kullanmaya başlamış ve AlexNet'i geliştirmek için çalışmışlardır. Simonyan and Zisserman (2015), VGG evrişimli ağ mimarisinde derinliği kullanmışlardır. Tüm katmanlarda 3×3 boyutlu evrişim filtrelerinin kullanılması nedeniyle mümkün olan daha fazla evrişim katmanları eklenerek ağın derinliğinin sürekli olarak artırılmasını sağlamışlardır. Girdi olarak 224×224 sabit boyutlu bir RGB görüntüsü kullanılmaktadır. Her pikselden eğitim setinde hesaplanan ortalama RGB değeri çıkarılarak önışlem uygulanmaktadır. Görüntü, AlexNet'te kullanılan 11×11 boyutlu matrisin aksine çok küçük bir alıcı alanı (3×3) olan filtreler kullanılarak bir dizi evrişimli katmandan geçirilmektedir. Kaydırma adımı bir piksele sabitlenmiştir. En büyük ortaklama, iki kaydırma adımlı 2×2 boyutlu piksel penceresi üzerinde gerçekleştirilmektedir. Gizli katmanlarda ReLU fonksiyonu kullanılmıştır. Evrişimli katmanları üç adet tam bağlı katman takip etmektedir (Simonyan and Zisserman, 2015).

Szegedy et al. (2015), AlexNet ve VGG'den farklı olarak başlangıç (inception) bloklarını kullandıkları GoogLeNet modelini oluşturmuşlardır. Başlangıç bloklarının kullanılmasındaki asıl amaç en iyi yerel yapıyı bulup bunu tekrar etmektir. Başlangıç bloklarında kullanılan tüm filtreler öğrenilmektedir. Aktivasyon fonksiyonu olarak ReLU seçilmiştir. Modelde tam bağlı katmanlar yerine ortalama ortaklama katmanı kullanılması tercih edilmiştir. GoogLeNet, kaynaklarda Inceptionv1 olarak da geçmektedir (Szegedy et al., 2015).

Her katmandaki girdi dağılımının önceki katmanlardaki parametrelerin değişimine bağlı olarak farklılık göstermesi derin sinir ağlarının eğitimini zorlaştırmaktadır. Daha düşük öğrenme hızları ve parametre başlangıç seçiminin özen gerektirmesi eğitim sürecinin uzamasına sebep olmaktadır. Ioffe and Szegedy (2015), eğitim sırasında ağ parametrelerindeki değişime bağlı olarak ortaya çıkan ağ aktivasyonlarının dağılımındaki değişimi dâhili eşdeğişken kayması (internal covariate shift) olarak adlandırmışlar ve çözüm için katman girdilerini normalize etmişlerdir. Normalizasyon, model mimarisinin bir parçası olarak ele alınmış ve her mini-yığın için gerçekleştirilmiştir. Normalizasyon, her skaler özniteliğin ortalamasının sıfır, varyansının bir yapılmasıdır. Bu sayede öğrenme hızı ve başlangıç parametre seçimi ile ilgili sorunlar ortadan kaldırılmıştır. Yığın normalizasyonu (batch normalisation) denilen bu yöntem sayesinde geleneksel derin ağlarda yüksek öğrenme hızı neticesinde ortaya çıkan yerel minimumda takılı kalma ile gradyanların kaybolması veya patlaması durumunun da üstesinden gelinmektedir. Bazı durumlarda ise unutmaya ihtiyacını ortadan kaldıran bir düzenleyici görevi görmektedir. Yığın normalizasyonu, GoogLeNet modelinin farklı bir türüne uygulanmıştır. Bu modelin farklı 5×5 boyutlu evrişimli katman yerine iki adet 3×3 boyutlu katmanın

kullanılmasıdır. Model, mini-yığın büyüklüğü 32 alınarak momentumlu stokastik gradyan iniş ile eğitilmiştir (Ioffe and Szegedy, 2015).

Derin ağların derinliğini daha da artırdıkça eğitimi zorlaşmaktadır. Daha derin ağlar yakınsamaya başladığında degradasyon sorunu ortaya çıkmaktadır. Ağın derinliği arttıkça doğruluk doyunluğa ulaşmakta ve sonra aniden düşmektedir. He et al. (2016) belirtilen bu sorunu çözmek için derin artık öğrenme (deep residual learning) yöntemini önermiştir. ResNet adı verilen bu modelde her katman grubunun doğrudan istenilen öznetelik eşlemesine uymasını beklemek yerine bu katmanların artık öznetelik eşlemesine uyması sağlanmıştır. ResNet'in ilk iki katmanı GoogLeNet ile aynıdır ancak ResNet'te başlangıç blokları yerine artık bloklar kullanılmaktadır. Her evrişimden sonra ve aktivasyondan önce yığın normalizasyonu uygulanmaktadır. Son ReLU aktivasyon fonksiyonundan önce bu iki evrişim işlemi atlanarak girdi değeri eklenmektedir. Ekleme işleminin yapılabilmesi için girdi ile evrişim katmanlarının çıktısı aynı boyutta olmalıdır, bu nedenle 1×1 ek bir evrişim katmanı eklenmektedir. ResNet-34, ResNet-50, ResNet-101 ve ResNet-152 gibi farklı model yapıları bulunmaktadır. ResNet'e ait bir artık blok Şekil 5.13'te gösterilmiştir.



Şekil 5.13 ResNet artık blok (He et al., 2016).

ResNet yapısı zaman içerisinde geliştirilerek farklı isimler almıştır. Xie et al. (2017) ResNet bloklarına kardinalite ekleyerek daha az öznetelik eşlemesi ile paralel evrişim işleminin yapılmasını sağlamıştır. ResNeXt adı verilen bu modelde az sayıda hiperparametre belirlenerek homojen ve çok dallı bir mimari elde edilmektedir. Bu mimari yapıda derinlik ve genişlik boyutlarının yanında kardinalite de kullanılmaktadır.

Girdi ve çıktıya yakın katmanlar arasındaki bağlantılar kısaldıkça ağların daha derin, daha doğru ve daha verimli eğitilebilir oldukları göz önünde bulundurularak Huang et al. (2018) her katmanı bir sonraki katmana ileri beslemeli şekilde bağlayan Yoğun Evrişimli Ağ (Dense Convolutional Network) yapısını önermiştir. Her katmanda kendinden önceki tüm katmanlardan gelen öznitelik haritaları girdi olarak kullanılmakta ve üretilen öznitelik haritaları da sonraki tüm katmanlara girdi oluşturmaktadır. ResNet'ten farklı olarak öznitelikler sonraki katmana toplanarak aktarılmamaktadır, bunun yerine öznitelikler birbirine ardışık olarak bağlanmakta ve tek bir tensöre dönüştürülmektedir. Bir örnekle açıklanacak olursa l katmanı kendinden önceki tüm katmanlardan gelen öznitelik haritalarını girdi olarak almaktadır:

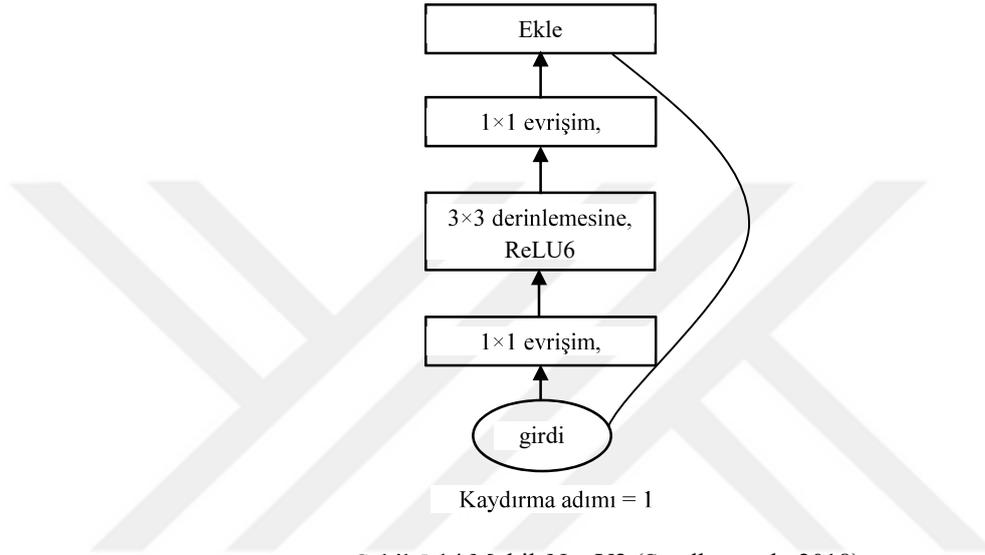
$$x_l = H_l([x_0, x_1, \dots, x_{l-1}]) \quad (5.17)$$

Yukarıdaki denklemde $[x_0, x_1, \dots, x_{l-1}]$ sıfırdan bire kadar olan katmanlarda üretilen öznitelik haritalarının ardışık dizilmesiyle oluşturulmaktadır. Parametre sayısını azaltmak için ağ, yoğun bloklara (dense blocks) ayrılmaktadır. Bloklar arasındaki katmanlar geçiş katmanları olarak isimlendirilmektedir. Geçiş katmanlarında yığın normalizasyonu, 1×1 evrişim katmanı ve 2×2 ortalama ortaklama katmanı yer almaktadır. DenseNet-121, DenseNet-169, DenseNet-201 ve DenseNet-264 gibi farklı model yapıları bulunmaktadır.

Hoeser and Kuenzer (2020), derin öğrenmenin günlük hayata dair sorunların çözümünde kullanılmasını sağlamak için mobil cihazlarda çalışması gerektiğini belirtmiş ve buna olanak veren modelleri *etkili tasarımlar* adı altında gruplandırmıştır. Bu kısımda ilk olarak MobileNet ailesi açıklanmıştır. MobileNet, derinlemesine ayrılabilir evrişimler kullanan bir mimariye dayanmaktadır. Derinlemesine ayrılabilir evrişim; (1) her girdi kanalına tek bir filtre uygulayan derinlemesine evrişim ve (2) derin katman çıktısının doğrusal birleşimini oluşturmada kullanılan 1×1 boyutlu noktasal evrişim olmak üzere iki kısımdan oluşmaktadır. Derinlemesine evrişim standart evrişime göre çok daha etkili olsa da sadece girdi kanallarını filtrelemesi ve bunları yeni öznitelik oluşturmak için birleştirmemesi nedeniyle ek bir katmana (noktasal evrişim) ihtiyaç duymaktadır. Her iki katmanda da yığın normalizasyonu ve ReLU fonksiyonları kullanılmaktadır. Son katman ise sınıflandırmanın yapılacağı softmax katmanıdır. Derin ve noktasal evrişim katmanları dâhil olmak üzere MobileNet toplam 28 katmandan oluşmaktadır.

MobileNet yapısı küçük olmasına rağmen daha küçük modeller oluşturmak için genişlik ve çözünürlük çarpanlarının kullanılması önerilmiştir. Genişlik çarpanı, ağ incelemeye olanak sağlarken, çözünürlük çarpanı, görüntünün giriş boyutlarını

değiştirmektedir. MobileNet nesne tanıma sistemlerinde de etkin olarak kullanılmaktadır (Howard et al., 2017). MobileNet-V2, bir önceki versiyonu artık bağlantılı ters derin evrişim uygulayarak geliştirmiştir. Önce, 1×1 boyutlu noktasal evrişim ile öznetelik haritalarının derinliği artırılmakta ve 3×3 derin evrişim gerçekleştirilmektedir. Ardından 1×1 noktasal evrişim tekrar uygulanarak çıktı derinliği belirlenmektedir. Artık bağlantı darboğaz katmanını kullanarak girdiyi çıktıya bağlamaktadır (Sandler et al., 2018). Şekil 5.14'te bu yapı gösterilmiştir.



Şekil 5.14 MobileNet-V2 (Sandler et al., 2018).

Etkili tasarımların bir diğer alt grubu *sinir mimarisi araması (neural architecture search)* yapısı ile ilişkilidir. Zoph and Le (2017) sinir mimarisi aramasını (SMA) iyi mimari yapıların bulunması için kullanılan gradyan esaslı yöntem şeklinde tanımlamıştır. Yazarlar sinir ağı yapısı ve bağlantısının genellikle değişken uzunluklu bir dizi ile belirlenebileceğini gözlemlemişler ve böyle bir diziyi oluşturacak denetici bir yinelemeli sinir ağının kullanılmasının uygun olacağını ifade etmişlerdir. Çalışmada doğruluk değeri ödül sinyali olarak kullanılmış (pekiştirmeli öğrenme) ve denetici zamanla yüksek doğruluk değerlerinin elde edildiği mimarilere daha yüksek olasılık atamıştır. Yazarlar SMA ile diğer yöntemlerle tasarlanması mümkün olmayan modellerin sıfırdan tasarlanabileceğini ileri sürmüşlerdir. Eğitim süresini hızlandırmak için dağıtılmış eğitim ve eşzamansız parametre güncellemeleri kullanılmıştır.

SMA'nın büyük veri setlerine doğrudan uygulanması hesap açısından yük getirmektedir. Zoph et al. (2018) bu nedenle temsili bir veri setinde mimari yapının araştırılması ve daha sonra öğrenilen mimarinin büyük veri setine transfer edilmesini önermiştir. Yazarlar arama uzayını NASNet olarak isimlendirmişlerdir. Önerdikleri

modelde evrişim hücreleri aynı mimariye sahiptir ve birçok kez tekrarlanmaktadır, değişen sadece ağırlıklarıdır (Zoph et al., 2018).

Tan et al. (2019) çok amaçlı sinir mimari aramasında doğruluğu ve önceki modellerden farklı olarak gerçek-dünya gecikmesini optimize etmeye çalışmışlardır. Çok amaçlı arama probleminde Pareto-optimal sonuçları bulmak için pekiştirmeli öğrenme yöntemi kullanılmıştır. Yazarlar, esneklik ile arama uzayı arasındaki dengeyi bozmadan katman çeşitliliğini sağlamak için ayrılmış hiyerarşik arama uzayı kullanmışlardır. Ağ katmanları önceden belirlenmiş sayıdaki bloklara ayrılmaktadır. Her blok değişken sayıda tekrarlanan özdeş katmanlar içermektedir. Her blokta, her bir katman için gerçekleşen işlemler ve bağlantılar ile katman sayısı aranmakta ve aynı katman, katman sayısı kadar tekrarlanmaktadır. Bu model MnasNet olarak isimlendirilmiştir. Bu başlık altında bahsedilecek son model EfficientNet modelidir. Bu modelde MnasNet'ten farklı olarak derinliği, genişliği ve çözünürlüğü dengeleyen bileşik ölçeklendirme yaklaşımı kullanılmıştır (Tan and Le, 2019).

Çizelge 5.2'de yukarıda anlatılan modeller, kullandıkları parametre sayıları ve Top-5 doğruluk oranları ile birlikte verilmiştir. Krizhevsky et al. (2012) tarafından geliştirilen öncü niteliğindeki AlexNet mimarisinden sonra önerilen modellerin Top-5 doğruluk oranlarının %90'ın üzerine çıktığı anlaşılmaktadır. MobileNet ve Inception ailelerinin parametre sayılarının diğer yapılara göre daha az olduğu görülmektedir.

Çizelge 5.2 Omurga yapılarının karşılaştırılması (Hoeser and Kuenzer, 2020).

Omurga yapısı	Parametre (milyon)	Top-5 doğruluk (%)
AlexNet	62	81,8
VGG-19	144	91,9
InceptionV1(GoogleNet)	11	92,2
ResNet-152	60	95,5
InceptionV3	24	94,4
DenseNet-264	34	93,9
Xception	23	94,5
ResNeXt-101	84	95,6
MobileNet-224	4,2	89,9
NasNet	89	96,2
MobileNetV2	6,1	92,5
MnasNet	5,2	93,3
EfficientNet-B7	66	97,1

5.1.2.4 Nesne tanıma dedektörleri

Derin öğrenme esaslı nesne tanıma dedektörleri genellikle iki kısımdan oluşmaktadır. Bu kısımlardan ilki ImageNet üzerinde önceden eğitilmiş bir omurga yapısı (VGG, ResNet, ResNeXt, Darknet vb.), ikincisi ise nesne sınıflarını ve sınırlayıcı kutularını belirleyen bir kafa yapısıdır. Bazı nesne tanıma dedektörlerinde omurga ile kafa arasında boyun yapısı da yer almaktadır (Bochkovskiy et al., 2020). Kafa kısmı, tek aşamalı ve iki aşamalı dedektörler olmak üzere iki grupta ele alınmaktadır. İki aşamalı modellerde öncelikle az sayıda bir öneri seti üretilmekte, sonraki aşamada öznitelik vektörleri çıkarılmakta ve ESA kullanılarak önceden tanımlanmış sınıf tahminleri yapılmaktadır. Tek aşamalı modellerde ise görüntü üzerindeki tüm konumlar olası hedef olarak değerlendirilmekte ve her ilgi bölgesi (region of interest - ROI), nesne veya arka plan olarak sınıflandırılmaktadır. İki dedektör hız açısından karşılaştırıldığında tek aşamalı dedektörler üstünlük göstermektedir ve gerçek zamanlı uygulamalar için daha uygundur. Öte yandan iki aşamalı dedektörler doğru tanıma oranı açısından daha yüksek performans göstermektedirler.

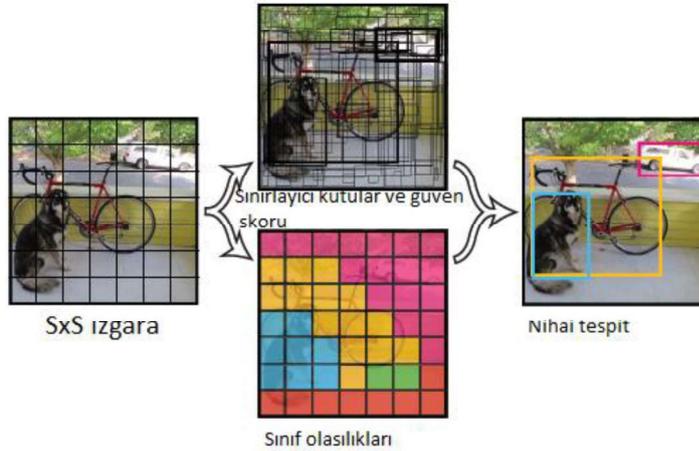
Tek aşamalı nesne tanıma dedektörlerinin en sık kullanılanları YOLO ailesi ve tek çekim dedektörleridir. YOLO “sadece bir kere bak” anlamına gelen “you only look once” kelimelerinin baş harflerinden oluşmaktadır. Redmon et al. (2016) tarafından önerilen modelde nesne tanıma, bir regresyon problemi olarak ele alınmıştır. Evrişimli ağ eş zamanlı olarak çok sayıda sınırlayıcı kutu ve sınıfa ait olma olasılıklarını tahmin etmektedir. Kayar pencere ve bölge önerisine dayalı tekniklerin aksine eğitim ve test süresi boyunca tüm görüntü değerlendirilmektedir. YOLO, nesnelere hızlı bir şekilde tanımlanmaktadır ancak özellikle küçük nesnelere görüntü üzerindeki yerinin tam olarak tespit edilmesi hususunda zorlanmaktadır.

YOLO, görüntüyü $S \times S$ ızgaraya ayırmaktadır. Nesnenin merkezi ızgara hücresine denk geliyorsa, o hücre nesnenin tanınmasından sorumlu olmaktadır. Her ızgara hücresi sınırlayıcı kutuları ve güven skorlarını hesaplamaktadır. Güven skoru, kutunun nesneyi içerdiğinden ne kadar emin olduğunu göstermektedir. Eğer hücrede nesne yoksa güven skoru sıfırdır. Hücrede nesne olması durumunda güven skorunun tahmin edilen kutu ile kesin referans arasındaki kesişim/birleşim (intersection over union - IOU) değerine eşit olması beklenmektedir. Her sınırlayıcı kutu beş değerden oluşmaktadır. Bunlar; x, y, w, h ve *güven skoru* değerleridir. Sınırlayıcı kutunun merkez koordinatları (x, y) ile gösterilmektedir. Koordinatlar, hücreleri referans almaktadır ve değerleri sıfır ila bir arasında değişmektedir. Genişlik w ile yükseklik ise h ile gösterilmektedir. Sınırlayıcı kutunun genişlik ve yüksekliği görüntünün genişliği ve yüksekliği ile normalize edilerek

sıfır ila bir arasında bir değer aralığına denk getirilmektedir. Hücrede nesne bulunması durumunda ayrıca o nesnenin hangi sınıfa hangi olasılıkla ait olduğu da tahmin edilmektedir. Test aşamasında, koşullu sınıf olasılıkları ile her kutunun güven skoru tahminleri çarpılmakta ve her kutu için sınıfa özgü güven skorları elde edilmektedir. Denklem 5.18’de anlatılan işlemler gösterilmiştir.

$$P(\text{Sınıf}_i | \text{Nesne}) \times P(\text{Nesne}) \times IOU_{\text{tahmin}}^{\text{kesin referans}} = P(\text{Sınıf}_i) \times IOU_{\text{tahmin}}^{\text{kesin referans}} \quad (5.18)$$

YOLO ağ yapısı GoogLeNet’e benzemektedir. Ağda 24 evrişim katmanı ve iki tam bağlı katman yer almaktadır. Başlangıç modülleri yerine 1×1 azaltma katmanları ve ardından 3×3 evrişim katmanları, son katmanda ise parametreleştirilmiş ReLU fonksiyonu kullanılmaktadır. Model ezberlemeyi azaltmak için unutmaya ve veri artırımından yararlanılmaktadır. Bazı büyük nesnelerin birden fazla hücrede yer alması durumunda aynı nesnenin birden fazla kez tanınmasının önüne geçmek için en büyük olmayı bastırma (non-maxima suppression) yöntemi kullanılmaktadır. Böylece sınırlayıcı kutulardan güven skoru belirtilen eşik değerinin altında kalanlar değerlendirmeye alınmamaktadır. YOLO ailesinin ilk versiyonu olan bu modelde her hücrede tek bir nesne sınıfı tanınabilmektedir (Redmon et al., 2016). YOLO çalışma ilkesi Şekil 5.15’te gösterilmiştir.



Şekil 5.15 YOLO modeli (Redmon et al., 2016).

Redmon and Farhadi (2017) YOLO’yu geliştirerek YOLOv2 versiyonunu ortaya koymuşlardır. Bu model ile ImageNet’te 9000’den fazla nesneyi tanımayı başarmışlardır. Tüm evrişimli katmanlarda yığın normalizasyonu kullanılmıştır. İlk YOLO modelinde sınıflandırıcı ağı 224×224 görüntülerle eğitilmekte ve sonra nesne tanıma için 448×448 ’e artırılmaktadır. YOLOv2’de ise sınıflandırıcı ağının ImageNet’te 10 epok boyunca 448×448 çözünürlükte ince ayarı yapılmaktadır. Böylece ağa, yüksek çözünürlüklü

girdilerle çalışmak adına filtrelerini düzenlemek için gereken zaman kazandırılmaktadır. YOLOv2'nin bir diğer ve en önemli farklılığı ise tam bağı katmanların kaldırılıp yerine ilk olarak *daha hızlı R-CNN*'de kullanılan tespit kutularının (anchor boxes) getirilmesidir. Girdi çözünürlüğü ise 416'ya düşürülmüştür. Böylece 32 altörneklem ile 13×13 öznitelik haritaları elde edilmiştir. YOLO görüntü başına 98 sınırlayıcı kutu oluştururken tespit kutuları sayesinde binden fazla kutu oluşturulabilmektedir. Tespit kutularının boyutları önceden seçilmektedir. Redmon and Farhadi (2017) bu yöntemin yerine k-ortalama kümesini kullanarak süreci otomatikleştirmiştir. YOLOv2'nin omurga yapısı Darknet-19'dur. VGG'ye benzer olarak genellikle 3×3 filtreler kullanılmakta ve her ortaklama adımından sonra kanal sayısı ikiye katlanmaktadır. Tahminler için ortalama ortaklama ve öznitelik temsillerini 3×3 evrişimler arasında sıkıştırmak için 1×1 filtreler kullanılmaktadır. Ayrıca yakınsamayı hızlandırmak için yığın normalizasyonundan faydalanılmaktadır. Darknet-19, 19 evrişim katmanı ve beş en büyük ortaklama katmanından oluşmaktadır. ImageNet'te top-5 doğruluk değeri %91,2'dir (Redmon and Farhadi, 2017).

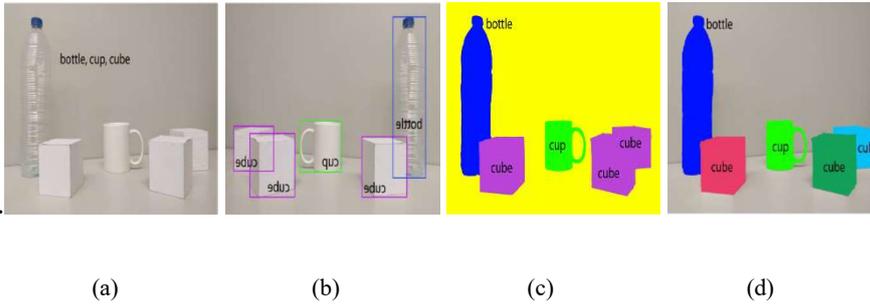
YOLOv3'te softmax yerine bağımsız lojistik sınıflandırıcılar kullanılmış ve küçük nesnelere tanınması konusunda ilerleme kaydedilmiştir. Öznitelikler, öznitelik piramitlerine benzer bir yapıdan çıkarılmaktadır. Eklenen evrişimli ağların sonuncusu; sınırlayıcı kutuyu, nesnelik skorunu (bir bölgenin nesne içermesi olasılığı) ve sınıf tahminini içeren üç boyutlu bir tensör tahmin etmektedir. YOLOv2'de tasarlanan Darknet-19 daha da geliştirilerek 53 evrişim katmanlı Darknet-53 oluşturulmuştur. ResNet yapısında olduğu gibi artık katmanlar kullanılmıştır (Redmon and Farhadi, 2018).

YOLOv4, geleneksel bir GPU ile gerçek zamanlı çalışacak bir ESA'ya sahiptir. Geleneksel nesne dedektörleri çevrimdışı eğitilmektedir. Araştırmacılar çıkarım maliyetini (inference cost) arttırmadan daha yüksek doğruluklu eğitim yöntemlerini geliştirmeye çalışmaktadırlar. Eğitim stratejisini veya model doğruluğunu arttırmak için eğitim maliyetini değiştiren yöntemler *hediye çantası (bag of freebies)* olarak adlandırılmıştır. Bu yöntemlerden biri veri artırımıdır. Veri artırımı ile girdi görüntülerinin çeşitliliği artırılarak nesne dedektörünün farklı ortamlardan elde edilen görüntülere karşı daha güçlü olması sağlanmaktadır. Veri setindeki semantik dağılım yanlılığının önüne geçmek için negatif madenciliği kullanılmaktadır. Bu durum sınıflardaki veri sayılarının dengesizliğinden kaynaklanmaktadır. Negatif madenciliği yoğun kestirim mimarisine uygun olduğundan tek aşamalı dedektörlerde kullanılmamaktadır. Bir diğer hediye çantası yöntemi sınırlayıcı kutunun amaç (kayıp) fonksiyonunun belirlenmesidir. Nesnenin bütünlüğünü dikkate almayan koordinat hesabı yaklaşımı yerine kesişim/birleşim oranı (IoU) önerilmiştir. Çalışmada çıkarım maliyetini

az miktarda artırıp dedektörün doğruluğunu önemli ölçüde artıran eklentiler ve ileri işlemci modülleri *özel durum çantası (bag of specials)* olarak isimlendirilmiştir. Alıcı alanının büyütülmesi, seçici dikkat mekanizmasının kullanılması, öznitelik bütünleşmesinin kuvvetlendirilmesi özel durum çantası yöntemlerine örnek gösterilebilir (Bochkovskiy et al., 2020).

YOLOv4'ün mimarisinde omurga yapısı olarak CSPDarknet53 kullanıldığında MS COCO (Microsoft Common Objects in COntext) veri setinde CSPResNeXt50'ye göre daha iyi tanıma sonuçları elde edildiği görülmüştür. MS COCO veri seti, 328.000'den fazla görüntüde 2.5 milyon etiketlenmiş örnek içermektedir ve 80 nesne kategorisi bulunmaktadır (Lin et al., 2014). YOLOv4'te kullanılan omurga yapılarında Darknet53 ve ResNeXt50'nin önünde yer alan CSP (çapraz aşamalı kısmi ağ (cross-stage partial net)), CSPNet'ten gelmektedir. CSPNet'in amacı hesap miktarı azaltılırken daha zengin bir gradyan kombinasyonu elde etmektir (Wang et al., 2020).

YOLOv4'te alıcı alanını önemli ölçüde arttırdığı, en önemli bağlam özelliklerini ayırdığı ve ağ işlem hızında neredeyse hiç azalmaya sebep olmadığı için uzamsal piramit ortaklama (spatial pyramid pooling - SPP) bloğu eklenmiştir. Boyun kısmında SPP haricinde farklı dedektör katmanları için farklı omurga katmanlarından parametre toplama yöntemi olan PANet (güzergâh toplama ağı (path aggregation network)) kullanılmıştır. PANet'te öznitelik hiyerarşisi, alt katmanlar ile en üstteki öznitelik arasındaki bilgi yolunu kısaltmaktadır (Liu et al., 2018). PANet esasen örnek bölütleme (instance segmentation) için geliştirilmiştir. Örnek bölütleme sadece nesnelere belirlemekle kalmayıp bir nesneye ait tüm görüntüleri de ayırt etmektedir (Şekil 5.16). YOLOv4'ün kafa kısmında ise YOLOv3 yer almaktadır.

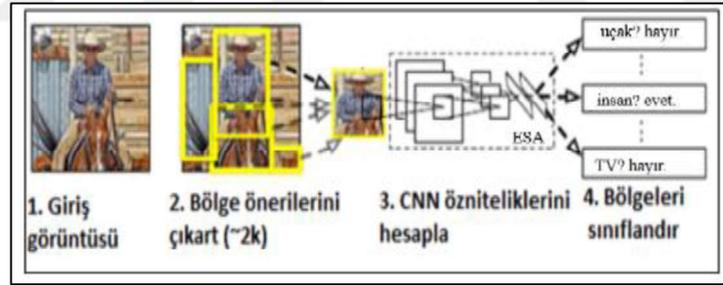


Şekil 5.16 Nesne sınıflandırma türleri a) sınıflandırma b) tanıma c) anlamsal bölütleme d) örnek bölütleme (Wu et al., 2020).

Tek Çekim Dedektörü (Single Shot Detector - SSD) hız ve doğruluk arasında iyi bir denge sağlamaktadır. SSD, giriş görüntüsünde yalnızca bir kez evrişimli ağ

çalıştırarak öznitelik haritası oluşturmaktadır. Sınırlayıcı kutuları ve sınıflandırma olasılığını tahmin etmek için bu öznitelik haritasında 3×3 boyutunda küçük bir matris çekirdeği kullanılmaktadır. SSD, sınırlayıcı kutuların çıkış alanını, her öznitelik haritası konumu için farklı en boy oranları ve ölççekler üzerinden bir dizi önceden tanımlı kutuya ayırmaktadır (Liu et al., 2016).

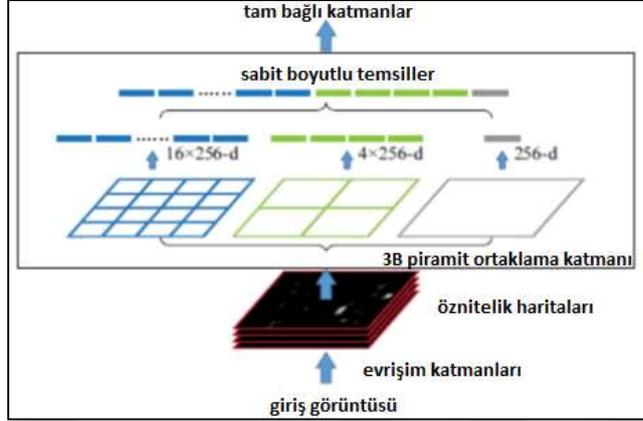
İki aşamalı nesne tanıma dedektörlerinin en sık kullanılanları R-CNN, SPP-Net, Fast R-CNN, Faster R-CNN ve Mask R-CNN dedektörleridir. R-CNN, evrişimli sinir ağı bölgeler (regions with convolutional neural network) anlamına gelmektedir. Girshick et al. (2014), Pascal VOC veri setinde evrişimli sinir ağı kullanılarak çok yüksek nesne tanıma başarımı elde edilebileceğini gösteren ilk çalışmayı yapmıştır. Pascal VOC, 20 nesne sınıfı ve 11000 görüntüden oluşan bir veri setidir (Everingham et al., 2010). Yazarlar evrişimli sinir ağının konumlandırma sorununu “bölgeleri tanıma” yöntemi ile çözmüşlerdir. Kullanılan yöntemde giriş görüntüsü için, kategoriden bağımsız 2000 adet bölge üretilmiş, her bölgede evrişimli sinir ağı kullanılarak sabit uzunlukta bir öznitelik vektörü çıkarılmış ve her bölge kategoriye özgü doğrusal destek vektör makinesi ile sınıflandırılmıştır. R-CNN işleyişi Şekil 5.17’de gösterilmiştir (Girshick et al., 2014). R-CNN, eğitim öncesinde çok sayıda negatif görüntüyü eleyerek öğrenme hızının artırılmasını ve yalancı pozitiflerin sayısının azaltılmasını sağlamaktadır.



Şekil 5.17 R-CNN işleyişi (Girshick et al., 2014).

Mevcut evrişimli sinir ağlarında sabit boyutlu (32x32, 64x64, vs) bir giriş görüntüsü kullanılmaktadır. Bunun sebebi, evrişimli katmanlar kayar pencere prensibi ile çalışırken herhangi bir boyutta öznitelik haritası oluşturabilmesine rağmen tam bağlı katmanların sabit boyutlu girdilere ihtiyaç duymasıdır. Sabit boyut zorunluluğunu ortadan kaldırmak için görüntü boyutundan bağımsız olarak sabit boyutlu temsiller üretebilen SPP-net ağ yapısı önerilmiştir. SPP-net kullanılarak görüntünün tamamından sadece bir kez öznitelik haritası oluşturulmaktadır, daha sonra alt örneklerde sabit boyutlu temsiller oluşturmak için ortaklama yapılmaktadır. Bu yöntem, evrişim özelliklerinin tekrar tekrar hesaplanmasını önlemektedir. Böylece, R-CNN’e kıyasla 100 kat daha hızlı çalışan bir

model elde edilmektedir. Ayrıca, farklı boyutlara sahip görüntülerle eğitim sayesinde ölçek değişmezliği artmakta ve model ezberleme azalmaktadır (He et al., 2015). Şekil 5.18’de SPP-net ağ yapısı gösterilmiştir.



Şekil 5.18 Uzamsal piramit ortaklama katmanlı ağ yapısı (He et al., 2015).

Hızlı R-CNN (Fast R-CNN), R-CNN ve SPPnet modellerinin hızlarını ve doğruluğunu arttıran yeni bir eğitim algoritması olarak önerilmiştir. Hızlı R-CNN; daha yüksek tanıma oranı, tek aşamalı eğitim, eğitimin tüm ağ katmanlarını güncellemesi ve özniteliklerin önbelleğe alınması için disk alanına gerek olmaması gibi avantajlara sahiptir. Ağ ilk olarak öznitelik haritası oluşturmak için tüm görüntüyü birkaç evrişim ve ortaklama katmanı ile işlemektedir. Daha sonra, her nesne önerisi için ilgi bölgesi ortaklama katmanı ile sabit boyutlu bir öznitelik vektörü oluşturulmaktadır. İlgi bölgesi katmanı, SSP-net’te kullanılan uzamsal piramit ortaklama katmanının özel bir durumudur ve sadece bir piramit seviyesi bulunmaktadır. Her öznitelik vektörü bir dizi tam bağı katmana girmekte ve iki çıktı katmanına ayrılmaktadır. Bir katman softmax olasılık tahminleri ile arka plan sınıfını vermekte, diğer katman ise K nesne sınıfı için sınırlayıcı kutu koordinatlarını oluşturmaktadır (Girshick, 2015).

Daha hızlı R-CNN (Faster R-CNN), bölge öneri ağı (region proposal network - RPN) yaklaşımının ilk kez kullanıldığı bir modeldir. Bölge Öneri Ağı (BÖA) çeşitli boyutlardaki rastgele görüntüler üzerinde çalışan tam evrişimli bir katmandır ve hemen hemen her öznitelik haritası konumunda bir dizi öneri üretmektedir. BÖA, yüksek kaliteli bölge önerileri oluşturmak için uçtan uca eğitilmektedir ve bu şekilde eğitilen ilk model olarak kabul edilmektedir. BÖA ve hızlı R-CNN’nin evrişimli özellikleri seçici dikkat mekanizmaları aracılığıyla tek bir ağda birleştirilmektedir. BÖA, bu ağa nereye bakması gerektiğini söyleyen bileşendir. Ayrıca, tespit kutularının kullanıldığı ilk model olma özelliğini de taşımaktadır (Ren et al., 2016).

Maske R-CNN sınırlayıcı kutuları ve bölütleme maskelerini paralel olarak tahmin etmektedir. Daha hızlı R-CNN'den sonra geliştirilen bir modeldir ve her ilgi bölgesindeki bölütleme maskelerini tahmin etmek için küçük bir tam evrişimli ağ kullanmaktadır (He et al., 2017).

5.2 Nesne Takibi

Nesnelerin birbirini takip eden çerçeveler boyunca konumlandırılmasına takip denilmektedir. Nesnelerin takip edilmesi; üç boyutlu dünyanın iki boyutlu bir görüntüye yansıtılmasından kaynaklanan bilgi kaybı, görüntülerdeki gürültü, karmaşık nesne hareketi, nesnelerin esnek veya parçalı yapısı, nesnelerin kısmen veya tamamen kapanması, karmaşık nesne şekilleri, ışıktaki değişimler ve gerçek zamanlı işlem gereksinimleri gibi sebeplerden dolayı zordur (Yılmaz et al., 2006):

Nesne takibi için izlenen adımlar nesnenin tespiti, nesnenin sınıflandırılması ve nesnenin takibi olarak verilmektedir (Parekh et al., 2014; Hanbay ve Üzen, 2017). Nesne takip algoritmaları nokta tabanlı, çekirdek tabanlı ve silüet tabanlı olmak üzere üç grupta incelenmektedir. Ancak son dönemde tanımaya dayalı takip modelleri de kullanılmaya başlamış ve etkili sonuçlar vermiştir. Bu nedenle nesne takip algoritmalarının Çizelge 5.3'te gösterildiği gibi dört grup altında incelenmesine karar verilmiştir.

Çizelge 5.3 Nesne takibi yöntemleri (Athanesious and Suresh, 2012).

Nesne Takibi			
Nesne Tabanlı	Çekirdek Tabanlı	Silüet Tabanlı	Tanıma Dayalı
Kalman filtresi	Temel şablon eşleştirme	Kontur eşleştirme	SORT
Parçacık filtresi	Ortalama kaydırma yöntemi	Şekil eşleştirme	Deep-SORT
Çoklu hipotez takibi	Sürekli adaptif ortalama kaydırma yöntemi		
	Kanade-Lucas-Tomasi yöntemi		
	Katman esaslı takip		
	Destek vektör makinesi		

5.2.1 Nokta tabanlı takip yöntemleri

Ardışık karelerde tespit edilen nesnelere noktalarla temsil edilmektedir. Noktaların bir sonraki yeri, nesnenin bir önceki konum ve hareket durumuna bağlıdır (Yılmaz et al., 2006).

Nokta tabanlı takip yöntemleri, tek bir noktayla temsil edilebilecek çok küçük nesnelere takip etmek için uygundur. Daha büyük nesnelere izlemek için birden çok noktaya ihtiyaç duyulmaktadır. Birden çok nokta kullanarak nesnelere takip edildiğinde, aynı nesneye ait olan noktaların otomatik olarak kümelenebileceği önemli bir sorun teşkil etmektedir. Bu durum, çok sayıda nesne arasında ve nesnelere ile arka plan arasında ayırım yapma gereksiniminden kaynaklanmaktadır (Yılmaz et al., 2006).

5.2.1.1 Kalman filtresi

Matematiksel olarak Kalman filtresi, çok çeşitli doğrusal işlemlerin durumlarını öngören ve düzelten bir tahmin edicidir (Pathan et al., 2009). Kalman (1960) dik izdüşüm yöntemi ile gözlenemeyen durum vektörünün gözlem vektörleri kullanılarak tahmin edilmesini sağlamıştır (Köksal Babacan ve diğ., 2011). Optimal durum en düşük varyans hatası ile yinelemeli olarak bulunmaktadır. Hedefin dinamik davranışını temsil eden durum vektörü x_k olmak üzere;

1. İşlem denklemi

$$x_k = Ax_{k-1} + w_{k-1} \quad (5.19)$$

k: Ayırık zaman

A: Geçiş matrisi

w_{k-1} : Normal olasılık dağılımlı (N(.)) Gauss işlem gürültüsü $p(w)$

$$p(w) \sim N(0, Q) \quad (5.20)$$

Asıl amaç z_k ölçüm değerinden x_k değerini tahmin etmektir.

2. Ölçüm denklemi

$$z_k = Hx_k + v_k \quad (5.21)$$

H: Ölçüm matrisi

v_k : Normal olasılık dağılımlı (N(.)) Gauss ölçüm gürültüsü $p(v)$

$$p(v) \sim N(0, R) \quad (5.22)$$

3. Zaman güncelleme denklemleri

x_k değeri doğrudan ölçülemediği için güncelleme z_k ölçümünden gelen bilgi ile yapılmaktadır. Bir sonraki k zaman adımı için \hat{x}_k^- durumunun önsel kestirimi ve P_k^- kovaryans hatası elde edilmektedir.

$$\hat{x}_k^- = \mathbf{A}\hat{x}_{k-1} + w_k \quad (5.23)$$

$$P_k^- = \mathbf{A}P_{k-1}\mathbf{A}^T + Q \quad (5.24)$$

4. Ölçüm güncelleme denklemleri

Bu denklemler sistemin geri bildirimini ilgilidir. Buradaki amaç, yeni z_k ölçümü ile \hat{x}_k^- 'nin önsel kestiriminin doğrusal bir kombinasyonu olan \hat{x}_k 'nin son değerini belirlemektir.

$$K_k = P_k^- H^T (H P_k^- H^T + R)^{-1} \quad (5.25)$$

$$\hat{x}_k = \hat{x}_k^- + K_k (z_k - H \hat{x}_k^-) \quad (5.26)$$

$$P_k = (I - K_k H) P_k^- \quad (5.27)$$

K_k : Kalman kazancı

Yukarıdaki işlemler bulunan \hat{x}_k ve P_k değerleri ile tekrarlanmaktadır (Pathan et al., 2009).

Kalman filtresi kullanılarak, tespit edilen nesneye ait koordinatların iyileştirilmesi ve kareler boyunca daha düzgün bir yörünge elde edilmesi sağlanmaktadır (Hamuda et al., 2018). Kalman filtresi ile her zaman en uygun sonuçlar elde edilmektedir, gürültü ortadan kaldırılmaktadır ve hem tek hem çoklu nesne takibi yapılmaktadır (Athanesious and Suresh, 2012).

5.2.1.2 Parçacık filtresi

Kalman filtresi, durum değişkenlerinin normal dağılıma uyduğunu kabul etmektedir. Bu nedenle, farklı dağılıma uyan durumlarda kestirimler iyi olmamaktadır. Bu kısıtın üstesinden gelmek için parçacık filtrelerinin kullanılması önerilmiştir (Yılmaz et al., 2006).

Bu algoritma genellikle konturları, renk özelliklerini veya doku eşlemesini kullanmaktadır (Athanesious and Suresh, 2012). Parçacık filtresi yönteminde doğrudan durum uzayında örneklenen bir dizi bağımsız rastgele değişken (parçacık) kullanılmaktadır (Chen, 2003).

5.2.1.3 Çoklu hipotez takibi

Çoklu Hipotez Takibi (ÇHT) birkaç çerçevenin gözlemlendiği yinelemeli bir yöntemdir. Yineleme, bir dizi mevcut hipotez ile başlamaktadır. Her hipotez için, nesnenin sonraki karedeki konumunun bir tahmini yapılmaktadır. Tahminler daha sonra bir uzaklık ölçüsü hesaplanarak karşılaştırılmaktadır. ÇHT, birden fazla nesneyi izleme ve en uygun çözümlerin hesaplanması yeteneğine sahiptir (Parekh et al., 2014).

Algoritma, görüş alanına giren nesnelere için yeni bir izleme numarası (id) tanımlama ve görüş alanından çıkan nesnelere için takibi durdurma özelliğine sahiptir (Yılmaz et al., 2006).

5.2.2 Çekirdek tabanlı takip yöntemleri

Çekirdek tabanlı takip yönteminde nesne basit bir geometrik şekil ile çerçevenmektedir. Takip, bu çerçeve içerisinde bulunan nesne parçasının anlamlı bilgilerinin hesaplanmasıyla gerçekleştirilmektedir. Bu algoritmalar, kullanılan görünüm temsili, izlenen nesne sayısı ve nesne hareketini tahmin etmek için kullanılan yöntem açısından farklılık göstermektedir (Yılmaz et al., 2006).

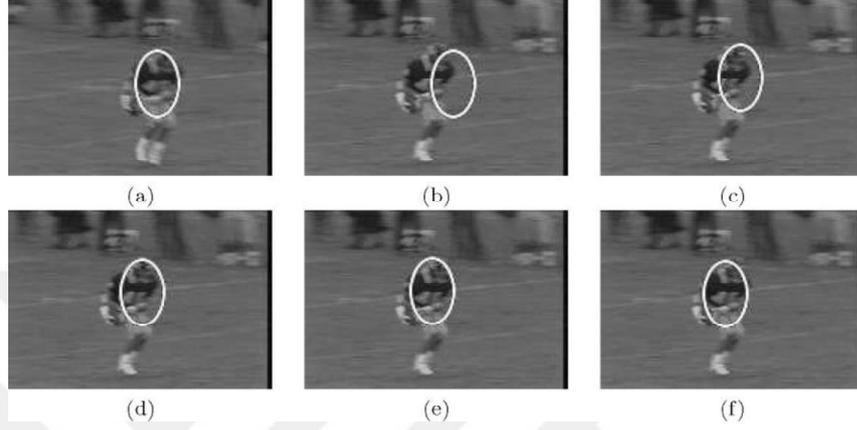
5.2.2.1 Temel şablon eşleştirme

Temel şablon eşleştirme, bir önceki çerçevede tanımlanan nesne şablonuna benzer bir bölgenin diğer çerçevelerde tüm görüntü üzerinde aranması yöntemidir. Şablonları oluşturmak için genellikle görüntü yoğunluğu veya renk özellikleri kullanılmaktadır (Yılmaz et al., 2006). Bu yöntem ile videoda tek bir nesne takip edilmektedir ve işlem maliyeti yüksektir (Yılmaz et al., 2006; Athanesious and Suresh, 2012).

5.2.2.2 Ortalama kaydırma yöntemi

Ortalama kaydırma (mean-shift) izleyicisi, her karede, renk histogramının hedefin referans renk histogramına en yakın olan bir görüntü bölgesinin konumunu arayarak çalışmaktadır (Leichter et al., 2010). Takip edilmesi istenilen bir ilgi bölgesi seçildiğinde

renk histogramlarını esas alan bir dizi nokta seçilmiş olmaktadır. Bu noktaların ağırlık merkezi ilgi bölgesinin içinde kalıyorsa nesnenin hareket etmediği anlaşılmaktadır. Ağırlık merkezinin hareketi nesnenin hareket ettiği yönü kontrol etmektedir. Bu yöntemin adı, ağırlık merkezinin kaydırılmasından gelmektedir. Bu yöntemde takip edilen nesnenin büyüklüğü değişse de onu çevreleyen pencerenin büyüklüğü sabit kalmaktadır (Joshi et al., 2016). Bu nedenle sürekli adaptif ortalama kaydırma yöntemi önerilmiştir.



Şekil 5.19 Ortalama-kaydırma yöntemi iterasyonları. (a) $t - 1$ anında tahmin edilen nesne konumu, (b) önceki nesne konumu kullanılarak t anındaki konum (c), (d), (e) ortalama kaydırma iterasyonları ile konum güncellenmesi, (f) t anındaki son nesne konumu.

5.2.2.3 Sürekli adaptif ortalama kaydırma yöntemi

Bu yöntemde ilk önce ortalama kaydırma yöntemi kullanılmakta ve daha sonra pencere yeniden boyutlandırılmaktadır (OpenCV, 2019). En büyük piksel değerinin 255 olduğu iki boyutlu renk olasılık dağılımları için, pencere genişliğinin boyutu aşağıdaki gibi uyarlanmaktadır (Bradski, 1998):

$$s = 2 \sqrt{\frac{M_{00}}{256}} \quad (5.28)$$

Bulunan alanı piksel sayısı birimine dönüştürmek için M_{00} alanı 256'ya bölünmektedir. Elde edilen iki boyutlu bölgeyi bir boyutlu pencere kenar uzunluğuna dönüştürmek için bulunan değerın karekökü alınmaktadır (Bradski, 1998).

5.2.2.4 Kanade-Lucas-Tomasi yöntemi

Bir görüntü ile tanımlanan bölgenin takip edilmesine yönelik yaklaşımlardan bir diğeri, optik akış yöntemi ile yer değiştirmenin hesaplanmasıdır. Optik akış yöntemleri,

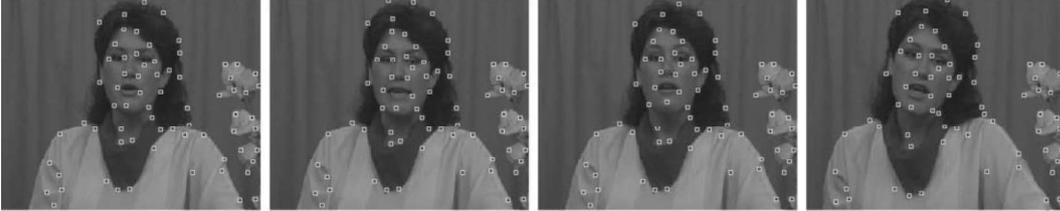
her pikselin akış vektörünü parlaklık sınırlaması kısıtı altında hesaplayarak yoğun akış alanları oluşturmaktadırlar (Yılmaz et al., 2006).

Lucas and Kanade (1981), Newton-Raphson iterasyon tekniği ile görüntülerin uzamsal yoğunluk gradyanını kullanarak iyi bir eşleşmesini bulmaya çalışmışlardır. Yöntem, az sayıda olası eşleşmeler üzerinden çalıştığı için daha hızlıdır.

Shi and Tomasi (1994), merkezi ilgi bölgesinde yer alan bir bölgenin ötelenmesini yinelemeli olarak hesaplayan Kanade-Lucas-Tomasi (KLT) izleyicisini önermiştir. Kamera hareket ettikçe, görüntü yoğunluğu yapısı değişmektedir. Genel olarak, ayrık x ve y konum değişkenleri ile t zaman değişkeninin herhangi bir fonksiyonu $I(x; y; t)$, bir görüntü dizisini temsil etmektedir. Bununla birlikte, yakın zaman dilimlerinde çekilmiş olan görüntüler birbirleriyle güçlü bir şekilde ilişkilidir (Shi and Tomasi, 1994).

$$I(x, y, t + \tau) = I(X - \xi, Y - \eta, t) \quad (5.29)$$

Denklem 5.29'da, $\delta = (\xi, \eta)$ hareket miktarı, $x=(x, y)$ noktasındaki ötelenmedir. Nesne takibi için kullanılan küçük pencerelerde bile δ değerindeki değişimler belirgindir. Aslında öznitelik penceresinde tek bir ötelenme değeri yerine aynı pencere içindeki farklı ötelenmelerden bahsedilmesi gerekmektedir (Shi and Tomasi, 1994). Şekil 5.20'de KLT izleyicisi ile takip durumuna bir örnek gösterilmiştir.



Şekil 5.20 KLT izleyicisi ile takip edilen özellikler (Yılmaz et al., 2006).

5.2.2.5 Katman esaslı takip

Bu yöntemde tüm görüntünün bir dizi katmandan oluştuğu kabul edilmektedir. Görüntü bir arka plan katmanından ve her nesne için bir katmandan oluşmaktadır (Yılmaz et al., 2006). Her katman öncelikli şekillerden (elips) (Φ_t) , hareket modelinden (ötelenme ve dönme) (θ_t) ve katman görünümünden (A_t) oluşmaktadır. Herhangi bir t anındaki dinamik katman gösterimi aşağıdaki gibidir (Tao et al., 2002):

$$A_t = (\Phi_t, \theta_t, A_t) \quad (5.30)$$

Bir katmanın t anında gözlemlenmesini en yüksek yapan model parametreleri iteratif olarak beklenti maksimizasyon algoritması ile bulunmaktadır. Ancak, parametrelerin eşzamanlı olarak tahmin edilmesindeki zorluk nedeniyle, yazarlar diğerlerini sabit tutup tek parametreyi tahmin etmektedirler (Yılmaz et al., 2006).

5.2.2.6 Destek vektör makinesi ile takip

Yukarıda anlatılan yöntemlerde görünüm modelleri (histogramlar, şablonlar, vs.) genellikle takip anında oluşturulmaktadır. Modeller, nesnenin son görünümünden gelen bilgiyi esas alarak çalışmaktadırlar. Ancak, nesnelerin değişik açılardan görünüşleri farklıdır ve takip sırasında nesnenin görünümü aniden değişirse nesne takibi sona erecek ve yukarıdaki modeller geçerliliğini yitirecektir. Bu sorunun üstesinden gelmek için nesnenin farklı açılardan görünüşlerinin takip öncesinde öğrenildiği modeller önerilmiştir (Yılmaz et al., 2006).

Destek vektör takipçisi, destek vektör makinesi sınıflandırıcısını optik akış tabanlı bir izleyici ile bütünleştirmektedir. Takip algoritmaları, bir görüntü bölgesinin bir çerçeveden diğerine nasıl geçtiğini bulmaktadır. Bu durum, iki görüntü bölgesi arasında minimize edilmesi gereken bir hata fonksiyonunun (karesel farkların toplamı gibi) varlığına işaret etmektedir. Hata fonksiyonu, sabit parlaklık varsayımı yapmaktadır, ancak nesnenin ait olduğu sınıfla ilgili herhangi bir bilgi vermemektedir. Bu amaçla arka plan ve nesneyi ayırarak belirli bir nesnenin izlenmesini mümkün kılan destek vektör makinesinin kullanılması önerilmiştir. Bu yöntemde karesel farkların toplamını minimize etmek yerine sınıflandırma puanının en yüksek değeri elde edilmektedir. Bu şekilde, sınıflandırıcı tarafından yakalanan önceki tüm bilgiler takip süreciyle doğrudan bütünleştirilmektedir (Avidan, 2004).

Destek vektör makinesi, bir dizi pozitif ve negatif eğitim örneği verildiğinde, iki sınıf arasındaki mesafeleri en büyük yapan ayırıcı bir hiperdüzlem bulmaktadır (Avidan, 2004; Yılmaz et al., 2006). Burada mesafe, en yakın noktanın hiperdüzleme olan uzaklığıdır. Ayırıcı hiperdüzlem eğitim örneklerinin doğrusal kombinasyonu olarak ifade edilmektedir. Yeni test modelinin sınıflandırılması Denklem 5.31 kullanılarak yapılmaktadır (Avidan, 2004):

$$f(x) = \sum_{i=1}^l \alpha_i y_i k(x, x_i) + b \quad (5.31)$$

$k(x, x_i)$: Çekirdek fonksiyonu

$f(x)$ fonksiyonunun işareti x 'in hangi sınıfa ait olduğunu göstermektedir. En uygun hiperdüzlemin oluşturulması α_i 'nin sıfır olmayan değerinin bulunması anlamına gelmektedir. Bu değere karşılık gelen herhangi bir x_i noktasına destek vektörü denilmektedir (Avidan, 2004). Bu yaklaşımın avantajı, arka plan nesnelere (takip edilmeyen negatif örnekler) hakkındaki bilginin, izleyiciye doğrudan dâhil edilmiş olmasıdır (Yılmaz et al., 2006).

5.2.3 Silüet tabanlı takip yöntemleri

Takip edilen nesnelere her zaman basit geometrik şekillerle tanımlanamamaktadırlar. Karmaşık şekilleri iyi bir şekilde tanımlayabilmek için silüet tabanlı yöntemler kullanılmaktadır. Silüet tabanlı takip yöntemleri kontur eşleştirme ve şekil eşleştirme olmak üzere iki kategoriye ayrılmaktadır (Yılmaz et al., 2006).

5.2.3.1 Kontur eşleştirme

Kontur takip yöntemleri, güncel nesne konumunda yeni bir kontur geliştirmek için önceki karedeki konturu, güncel karedeki ilk kontur olarak kullanmaktadır. Yöntem, ışık değişikliklerine duyarlı olan kenar temelli özellikleri kullanmaktadır. Tüm nesne yerine sınırları kullandığı için şekil eşleştirmeden daha hızlıdır. Bu yöntemin çalışması için önceki karedeki nesne bölgesinin en azından bir kısmının güncel karedeki nesne bölgesi ile örtüşmesi gerekmektedir (Ågren, 2017).

5.2.3.2 Şekil eşleştirme

Şekil eşleştirme yönteminde, önceki karedeki nesne silüeti esas alınarak bir model oluşturulmakta ve nesnenin güncel karedeki benzerliğini hesaplamak için kullanılmaktadır. Bu yaklaşımda, nesne modeli genellikle bir renk veya kenar histogramı, nesne kenarları veya bu modellerin bir birleşimi şeklindedir. Işık değişiklikleri veya görüş açısı değişiklikleri gibi izleme zorlukları ile başa çıkmak için nesne modeli her karede tespit edildikten sonra güncellenmektedir.

Başka bir yaklaşım, ardışık iki kareye bakmak ve uyumlu silüetler bularak şekilleri eşleştirmektir. Bu yöntem nokta tabanlı yöntemlerle benzerlik göstermektedir ancak nokta tabanlı yöntemlerde hareket ve konuma bağlı özelliklerden yararlanılırken şekil eşleştirme yöntemlerinde nesneye ait tüm bölge kullanıldığından görünüm özelliklerinden de faydalanılmaktadır (Ågren, 2017).

5.2.4 Tanımaya dayalı takip yöntemleri

Bu başlık altında anlatılan yöntemlerde nesnelere her karede tanınmakta ve sınırlayıcı kutular ile çevrelenmektedir. Mevcut ve bir önceki karede tanınan nesnelere izleyiciye aktarılmaktadır. Tanımaya dayalı takip yöntemleri gerçek zamanlı çoklu nesne takibi için etkili yöntemlerdir.

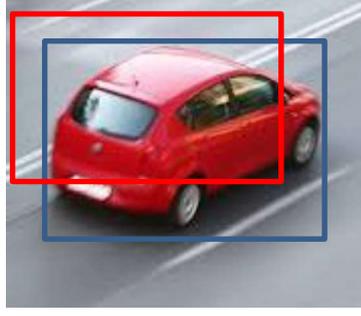
5.2.4.1 Basit çevrimiçi ve gerçek zamanlı takip

Basit çevrimiçi ve gerçek zamanlı takip (Simple Online and Realtime Tracking - SORT), Bewley et al. (2016) tarafından önerilen çoklu nesne takip algoritmasıdır. Nesnenin takibinde sadece nesneyi çevreleyen kutunun konumu ve büyüklüğü dikkate alınmaktadır. SORT takip algoritması, nesne tanımada evrişimli sinir ağlarını kullanmakta daha sonra nesneyi Kalman filtresi ve Macar algoritması kullanarak takip etmektedir.

SORT algoritması ilk olarak yaya takibi için kullanılmıştır. Kısa süre içinde farklı nesnelere takibinde de kullanılmaya başlanmıştır. Takip algoritmasının başarısı nesne tanıma algoritmasının başarısı ile ilişkilidir.

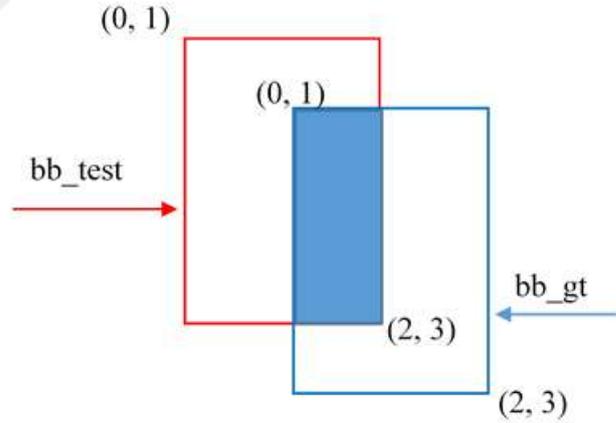
SORT algoritmasının detaylarına geçmeden önce bazı tanımlar üzerinde durulacaktır:

- Kesin referans (Ground truth): Kısaca hedef değerdir. Görüntü işleme açısından düşünüldüğünde bir nesneyi çevrelemesi gereken dikdörtgendir. Eğer makine öğrenmesi ile bir otomobil tanımlanmak isteniyorsa, kesin referans dikdörtgeni otomobilin tamamını içine alan dikdörtgendir.
- Kesişim/Birleşim oranı (Intersection over Union): Nesneyi çevreleyen iki dikdörtgenin kesişim alanlarının iki dikdörtgenin toplam alanına bölümü ile hesaplanmaktadır. Şekil 5.21'de kırmızı dikdörtgen ile gösterilen model tahmini, mavi dikdörtgen ile gösterilen ise kesin referanstır.



Şekil 5.21 Model tahmini ve kesin referans.

SORT algoritması kesişim/birleşim oranının belirlenmesiyle başlamaktadır. Sınırlayıcı kutular, sol üst köşelerinin $(0, 1)$ ve sağ alt köşelerinin $(2, 3)$ koordinatları ile tanımlanmaktadır. İlk önce Şekil 5.22’de mavi ile gösterilen kesişim dikdörtgeninin sol üst ve sağ alt köşesine ait koordinatlar bulunmakta ve genişlik (w) ve yükseklik (h) değerlerine dönüştürülmektedir. İkinci aşamada bu dikdörtgenin alanı hesaplanmakta (wh) ve pay değeri olarak kullanılmaktadır. Üçüncü aşamada kırmızı (bb_test) ve mavi (bb_gt) dikdörtgenlerin alanı hesaplanmakta ve toplam alandan kesişen alan çıkarılarak payda değeri elde edilmektedir. Bu iki değer birbirine bölünmesiyle kesişim/birleşim değeri elde edilmektedir.



Şekil 5.22 Kesişim/birleşim oranı hesabında kullanılan sınırlayıcı kutular.

Sınırlayıcı kutular dört koordinat değeri ile belirlenmektedir. Her bir dikdörtgen için alınan $[x_1, y_1, x_2, y_2]$ koordinatları $[x, y, s, r]$ formatına dönüştürülmektedir. x_1, y_1, x_2 ve y_2 köşe noktalara ait koordinatlar iken x ve y dikdörtgenin merkezinin koordinatlarıdır. Ölçeklendirme faktörü “ s ”, en boy oranı ise “ r ” ile gösterilmiştir. Nesnelere yaklaştıkça ya da uzaklaştıkça, onları sınırlayan dikdörtgenlerin de boyutları değişecektir. Bu nedenle

ölçeklendirme ve en boy oranı dikkate alınmaktadır. Boyutları değişen dikdörtgenlerin yeniden sol üst ve sağ alt köşelerinin koordinatları hesaplanmaktadır.

Nesneler görüntüye girdiğinde, her birine özgü izleme numarası (id) atanmakta ve nesneler görüntüden çıktığında izleme numaraları silinmektedir. Nesnenin takip edilmesi için kesişim/birleşim oranının belirtilen eşik değerin üstünde olması gerekmektedir (Bewley et al., 2016).

SORT algoritmasının bundan sonraki kısmında Kalman filtresi kullanılmaktadır. Kalman filtresinin denklemleri 5.2.1.1 başlığı altında sunulmuştur. Kalman filtresinden sonra, tanınan nesneler ile takip edilen nesneler ilişkilendirilmektedir. Bu ilişkilendirilmenin yapılması için Macar (Munkres veya Kuhn-Munkres) algoritmasından faydalanılmaktadır. Son adımda, eşleşmeler, eşleşmeyen tanınmalar ve eşleşmeyen takipler olmak üzere üç liste oluşturulmaktadır.

5.2.4.2 Derin basit çevrimiçi ve gerçek zamanlı takip

Derin basit çevrimiçi ve gerçek zamanlı takip (Deep-SORT) ile SORT algoritmasının performansı görünüm bilgilerinin eklenmesiyle artırılmıştır. Nesnelerin, başka nesneler tarafından kapanması ve sonra yeniden görüntüye girmesi durumunda izleme numarasının değiştiği gözlemlenmiştir. Deep SORT sayesinde aynı nesneye ait izleme numarasının kareler boyunca değişimi %45 oranında azaltılmıştır (Wojke et al., 2017).

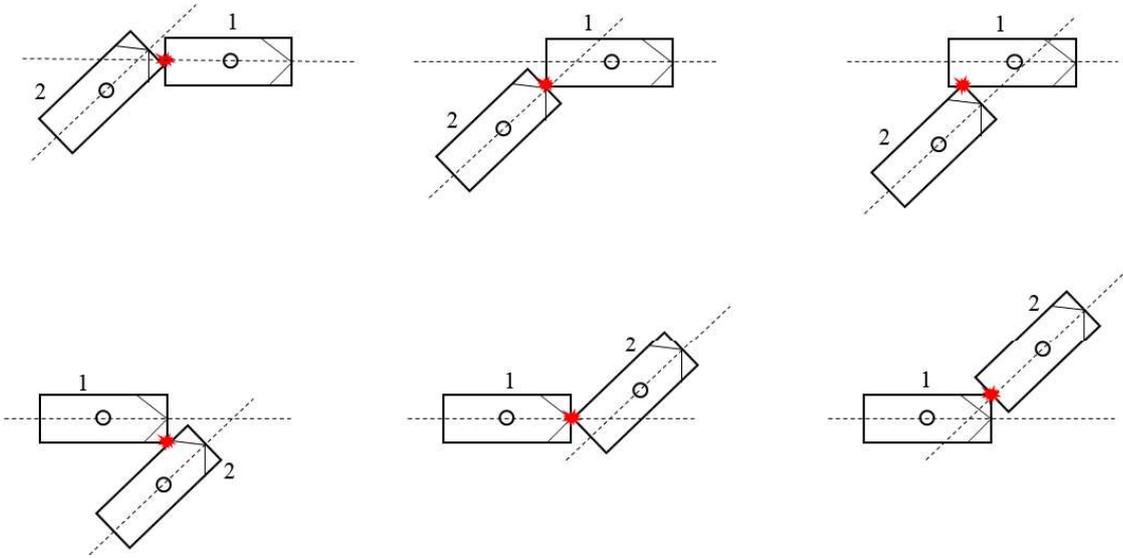
Wojke et al. (2017) tarafından önerilen bu yöntemde de atama Macar algoritması ile gerçekleştirilmektedir. Hareket bilgilerinin modele dâhil edilmesi için Kalman durumları ile yeni ölçümler arasındaki Mahalanobis mesafesinin karesi kullanılmaktadır.

6. KAZADAN KAÇINMA SÜRESİNİN TESPİT EDİLMESİ

Bu tez kapsamında çekim yapılan örülme bölgelerinde şerit değiştiren taşıtlar belirlenmiş ve olası çatışma noktalarının yeri tespit edilerek çatışma rotasındaki taşıtların bu noktaya ne kadar süre sonunda varacakları hesaplanmıştır. Taşıtların varış süreleri hesaplandıktan sonra olası kaza tipine göre kritik KKS değerleri tespit edilmiştir.

6.1 Şerit Değiştiren Taşıtlar için Kazadan Kaçınma Süresinin Hesaplanması

KKS hesapları çoğunlukla yol kullanıcılarının yörüngelerinin dik veya paralel açı (arkadan çarpma veya kafa kafaya çarpışma) ile kesiştiği kabulü ile yapılmaktadır. Ancak, gerçekte taşıtlar birbirine herhangi bir açı ile yaklaşabilmektedirler (Laureshyn et al., 2010). Aynı açı için farklı çarpışma türleri de gözlemlenmektedir. Şekil 6.1’de bu duruma örnek teşkil eden durumlar gösterilmiştir.

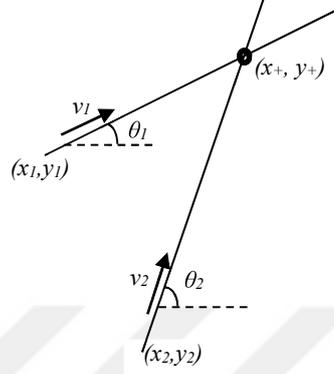


Şekil 6.1 Aynı açı ile gerçekleşen farklı kaza tipleri (Laureshyn et al., 2010).

Jimenez et al. (2013), iki taşıt arasındaki KKS'yi hesaplamak için ilk yaklaşımlarında taşıtları birer nokta kabul ederek ilk konumlarını, hızlarını ve doğrultularını dikkate almışlardır. İki aracın doğrultusunu birleştirerek kesişim noktasını bulmuşlar ve koordinatlarını belirlemişlerdir. Her iki taşıtın kesişim noktasına ulaşmak için gereken süreyi hesaplamış ve değerlerin eşit çıkması halinde, bu değeri KKS olarak kabul etmişlerdir. Bu durum Şekil 6.2’de gösterilmiş ve kesişim noktasının koordinatları Denklem 6.1 ve Denklem 6.2 ile verilmiştir.

$$x_+ = \frac{(y_2 - y_1) - (x_2 \tan \theta_2 - x_1 \tan \theta_1)}{\tan \theta_1 - \tan \theta_2} \quad (6.1)$$

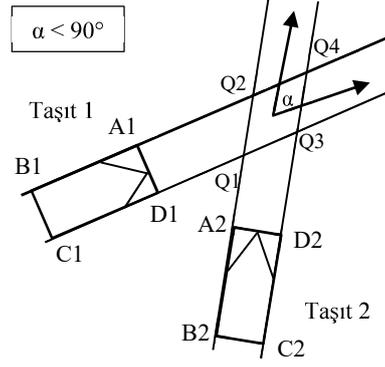
$$y_+ = \frac{(x_2 - x_1) - (y_2 \cot \theta_2 - y_1 \cot \theta_1)}{\cot \theta_1 - \cot \theta_2} \quad (6.2)$$



Şekil 6.2 Taşıtların nokta kabulü ile kesişim noktasının belirlenmesi (Jimenez et al, 2013).

Yazarlar, ikinci yaklaşımlarında ise taşıtları dikdörtgen olarak kabul etmiş ve iki taşıtın arasındaki α açısının 90 dereceden küçük veya büyük olması durumuna göre 10 farklı çarpışma türü üzerinde çalışmışlardır. Taşıtlar dikdörtgen şeklinde kabul edilip bir taşıtın köşesinin diğer taşıtın kenarıyla çarpıştığı dikkate alınırsa 32 çarpışma türünün gerçekleşme olasılığı bulunmaktadır (Laureshyn et al., 2010). Çalışma sonucunda ikinci yaklaşımın daha gerçekçi sonuçlar verdiği belirtilmiştir (Jiménez et al., 2013).

Şekil 6.3'te α açısının 90 dereceden küçük olduğu ve bir taşıtın köşesinin diğer taşıtın kenarına çarptığı bir durum gösterilmiştir. A1, B1, C1, D1 birinci taşıtın köşe noktalarını, A2, B2, C2 ve D2 ikinci taşıtın köşe noktalarını, Q1, Q2, Q3 ve Q4 ise kazanın gerçekleşebileceği dört noktayı göstermektedir. Köşe noktalarının olası kaza noktalarına varış sürelerinin gösteriminde önce köşe noktası sonra kaza noktası belirtilmiştir. Örnek olarak TB22; B2 köşesinin 2 numaralı kaza noktasına varış süresini göstermektedir. Şekil 6.3'te gösterilen durumda ikinci taşıtın A2 ile gösterilen köşesi birinci taşıtın C1D1 kenarına çarpacaktır ve kesişme noktası Q1 olacaktır. Çarpışmanın olması için gerçekleşmesi gereken koşullar; A2 noktasının D1'den daha sonra Q1 noktasına varması ve A2'nin Q1 noktasına varması için gereken sürenin C1'in Q1 noktasına varması için gereken süreden az olmasıdır. Koşullar birlikte değerlendirildiğinde ortaya $TC11 \geq TA21 \geq TD11$ eşitliği çıkmaktadır. KKS değeri ise TA21'e eşit olmaktadır.



Şekil 6.3 $\alpha < 90^\circ$ durumuna örnek (Jimenez et al, 2013).

Tez kapsamında incelenen örülme bölgelerinde taşıtlar birbirine 90 dereceden küçük açı ile yaklaşmaktadırlar. Jimenez et al. (2013) α açısının 90 dereceden küçük olduğu durumları Çizelge 6.1’de gösterildiği gibi özetlemiştir.

Çizelge 6.1 $\alpha < 90^\circ$ durumunda kaza oluşum şekilleri (Jimenez et al., 2013).

Durum	Diyagram	Süre koşulları	KKS														
A) İkinci taşıtın köşesi birinci taşıtın kenarına çarpıyor		<table border="1"> <tr> <td>TC11</td> <td>></td> <td>TA21</td> <td>></td> <td>TD11</td> </tr> <tr> <td></td> <td>B</td> <td></td> <td>D</td> <td></td> </tr> </table>	TC11	>	TA21	>	TD11		B		D		TA21				
TC11	>	TA21	>	TD11													
	B		D														
B) İkinci taşıtın önü birinci taşıtın köşesine çarpıyor		<table border="1"> <tr> <td>TC13</td> <td>></td> <td>TD23</td> <td>></td> <td>TA21</td> <td>></td> <td>TC11</td> </tr> <tr> <td></td> <td>C</td> <td></td> <td>*</td> <td></td> <td>A</td> <td></td> </tr> </table>	TC13	>	TD23	>	TA21	>	TC11		C		*		A		(TA21, TD23)
TC13	>	TD23	>	TA21	>	TC11											
	C		*		A												
C) İkinci taşıtın köşesi birinci taşıtın arkasına çarpıyor		<table border="1"> <tr> <td>TB14</td> <td>></td> <td>TD24</td> <td>></td> <td>TD23</td> <td>></td> <td>TC13</td> </tr> <tr> <td></td> <td>X</td> <td></td> <td>*</td> <td></td> <td>B</td> <td></td> </tr> </table>	TB14	>	TD24	>	TD23	>	TC13		X		*		B		(TD23, TD24)
TB14	>	TD24	>	TD23	>	TC13											
	X		*		B												
D) Birinci taşıtın köşesi ikinci taşıtın kenarına çarpıyor		<table border="1"> <tr> <td>TB21</td> <td>></td> <td>TD11</td> <td>></td> <td>TA21</td> </tr> <tr> <td></td> <td>E</td> <td></td> <td>A</td> <td></td> </tr> </table>	TB21	>	TD11	>	TA21		E		A		TD11				
TB21	>	TD11	>	TA21													
	E		A														

	Durum	Diyagram	Süre koşulları						KKS	
			TB22	>	TA12	>	TD11	>		TB21
E)	Birinci taşıtın önü ikinci taşıtın köşesine çarpıyor									(TD11, TA12)
			F		*		D			
F)	Birinci taşıtın köşesi ikinci taşıtın arkasına çarpıyor									(TA12, TA14)
			X		*		E			

* = Her zaman sağlanmaktadır X = Kaza oluşmaz

KKS, sürekli bir parametredir ve taşıtlar çatışma rotasına girdiği andan itibaren hesaplanmaktadır. Yukarıda anlatılan çalışmaların ışığında örülme bölgelerinde şerit değiştirme nedeniyle çatışma rotasına giren taşıtların KKS değerleri hesaplanmıştır. Görüntü işleme kullanılan önceki çalışmalarda geleneksel takip yöntemleri tercih edilmiştir. Bu tez kapsamında ise geçmişi geleneksel yöntemlere göre çok daha yakın zamana dayanan (2012 sonrası) derin öğrenme yöntemlerinden faydalanılmıştır.

6.2 Görüntü İşleme Tekniği ile Kazadan Kaçınma Süresinin Hesaplanması

KKS değerlerinin bulunmasında önceden eğitilen YOLOv4 nesne tanıma algoritması ile SORT takip algoritmasından faydalanılmıştır. Tanıma algoritması sayesinde her taşıtın çevresine bir dikdörtgen çizilmekte ve bu dikdörtgenin merkezi SORT takip algoritması ile takip edilmektedir. Bu merkez nokta temel alınarak dikdörtgen üzerinde taşıtın sol ve sağ ön ile sol ve sağ arka köşelerine denk gelen noktalar çizilmiştir. Bu noktaların koordinatları her resim karesi için Excel dosyasına kaydedilmiştir. Oluşturulan dosyada, her taşıtın ID numarası, resim karesinin numarası ve dört noktanın koordinatları yer almaktadır. Daha sonra kaydedilen videolardan şerit değiştiren taşıtlar belirlenerek Python dilinde yazılan kod ile taşıtların sadece ID numarası girilerek KKS değerleri otomatik olarak hesaplanmıştır. Çalışmada, Çizelge 6.1'deki olası kaza durumları dikkate alınarak çatışma rotasındaki taşıtlar belirlenmiştir.

Şerit değiştirmenin çok geriden başladığı bazı durumlarda nesne tanıma algoritmasının taşıtı tanıması gecikmektedir. Şekil 6.4'te Atakent kavşağına ait örülme bölgesinde şerit değiştiren taşıtın yarattığı çatışma durumuna bir örnek gösterilmiştir. Bu durumda yeşil çerçeveli taşıtın (Taşıt 2) köşesinin kırmızı çerçeveli taşıtın (Taşıt 1) kenarına çarpması durumunun gerçekleşme olasılığı bulunmaktadır. Bu çatışma

durumunda KKS değerlerini belirlemek için birinci taşıtın şerit değiştirmeye başladığı andan itibaren taşıtın sağ ön köşesinin koordinatları ile ikinci taşıtın sol ön köşesinin koordinatları kaydedilmeye başlanmıştır.



Şekil 6.4 Şerit değiştirme durumuna bir örnek.

Taşıt şerit değiştirmeye başlayınca görüntü durdurulmuş ve taşıt üzerindeki nokta seçilerek koordinatı piksel cinsinden kaydedilmiştir. Bir önceki yöntemde olduğu gibi koordinatlar ve resim karesi numarası otomatik olarak Excel dosyasına kaydedilmiştir. Sadece taşıt ID numarası kullanıcı tarafından girilmiştir. Sonrasında izlenen yöntem önceki yöntemle aynıdır. Taşıt ID numarası girilerek KKS değerleri belirlenmektedir.

KKS değerinin hesaplanmasında iki noktadan bir doğru geçer kuralından faydalanılmıştır. Şekil 6.3'te gösterildiği gibi KKS değerinin hesaplanmasında taşıt kenarlarından uzatılan doğruların kesişme noktasının hesaplanması gerekmektedir. Çizelge 6.2'de iki taşıtın koordinat verileri örnek olarak gösterilmiş ve bu örnek üzerinden KKS hesabı anlatılmıştır.

Çizelge 6.2 Çatışma rotasındaki taşıtların örnek koordinat değerleri.

ID	Resim karesi numarası	X koordinatı	Y koordinatı
Taşıt 1	296	453	380
Taşıt 2	296	467	384
Taşıt 1	314	458	385
Taşıt 2	314	476	391
Taşıt 1	328	464	392
Taşıt 2	328	482	402

Birinci taşıt şerit değiştirmeye başladığı anda iki taşıtın doğrultusunun kesişim noktasının koordinatları (422, 349) olarak bulunmuştur. Daha sonra, birinci taşıtın sağ ön köşesi ile ikinci taşıtın sol ön köşesinin kesişim noktasına varış süreleri yazılan kod ile tespit edilmiştir. Kazanın gerçekleşmesi için birinci taşıtın sağ ön köşesinin kesişim noktasına varma süresi ikinci taşıtın sol köşesinin aynı noktaya varma süresinden küçük

olmalıdır. Bu durumda KKS değeri ikinci taşıtın sol köşesinin kesişim noktasına varma süresi olmaktadır.

Taşıtların kesişim noktasına geliş sürelerini hesaplamak için ilk önce, taşıtların kareler arasında kat ettiği mesafe hesaplanmıştır. Videonun saniye başına kare sayısı olan fps değeri bilindiği için (30 fps) bu mesafenin kaç saniyede alındığı hesaplanmıştır. Daha sonra, hızın söz konusu resim kareleri arasında sabit kaldığı kabulü ile taşıtların kesişim noktasına kaç saniye sonra varacağı hesaplanmıştır. Çizelge 6.2’de gösterim amaçlı resim kareleri arasındaki fark büyük tutulmuştur. Otomatik kayıta her karedeki koordinatlar kaydedilirken manuel yöntemde en fazla beş resim karesi atlanarak işaretleme yapılmıştır. Bu nedenle sabit hız kabulünün uygun olduğu düşünülmektedir. Örnek olarak, 296 ila 314 numaralı çerçeveler arasında birinci taşıt 7,071 piksel, ikinci taşıt 11,402 piksel yol almıştır. Birinci taşıtın kesişim noktasına varması için kat etmesi gereken mesafe 50,92 piksel, ikinci aracın kat etmesi gereken mesafe ise 68,41 pikseldir. Bu durumda;

$$KKS1 = (50,92 * (18/30)) / 7,07 = 4,32 \text{ sn}$$

$$KKS2 = (68,41 * (18/30)) / 11,41 = 3,60 \text{ sn}$$

olarak bulunmaktadır. KKS, sürekli ölçülen bir ölçüt olduğundan taşıtlar çatışma rotasından çıkana kadar KKS değerleri hesaplanmaktadır.

Bir sonraki adımda bulunan KKS değerleri ise aşağıdaki gibidir.

$$KKS1 = (53,02 * (14/30)) / 9,22 = 2,68 \text{ sn}$$

$$KKS2 = (34,46 * (14/30)) / 12,53 = 1,28 \text{ sn}$$

Taşıtlar birbirine yaklaştıkça KKS değerleri küçülmektedir. Elde edilen KKS değerlerinden kritik olan değer en küçük değer olarak belirlenmiştir.

6.2.1 Atakent kavşağı örülme bölgesi KKS değerleri

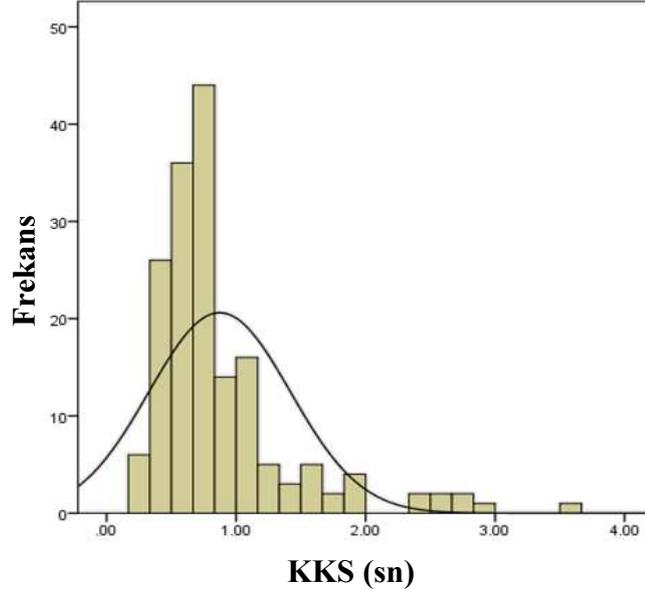
Atakent kavşağı üzerinde incelenen örülme bölgesi iki ana şerit ve bir yardımcı şerit olmak üzere toplam üç şeritlidir. Örülme mesafesi ise 84 metredir. İncelenen örülme bölgeleri içinde en kısa örülme uzunluğu bu kavşağa aittir. Örülme bölgesinin kısa olması nedeniyle şerit değiştirmelerin gerçekleşeceği bölge de kısıtlı olmaktadır. HCM 2016’da

belirtildiği gibi örülme uzunluğu artıkça sürücülere şerit değiştirmeler için daha fazla zaman ve alan yaratılmaktadır.

Bu bölgede yapılan bir saatlik çekim sonucunda KKS değerleri 6.1 ve 6.2 başlıkları altında açıklanan yöntemler ile hesaplanmış ve kritik KKS değerleri Çizelge 6.3'teki gibi bulunmuştur. Toplam 169 adet çatışma rotasına sahip şerit değiştirme kaynaklı çatışma tespit edilmiştir. Hesaplanan kritik değerler değerlendirildiğinde 0,25 – 3,55 sn arasında değiştiği, ortalamasının 0,87 sn, standart sapmasının 0,55 sn, mod değerinin 0,65 sn, medyan değerinin ise 0,73 sn olduğu görülmüştür. Şekil 6.5'te Atakent kavşağına ait KKS değerlerinin dağılımı gösterilmiştir.

Çizelge 6.3 Atakent kavşağı kritik KKS değerleri.

Kritik KKS değerleri (sn)				
0,25	0,51	0,67	0,80	1,09
0,26	0,52	0,68	0,80	1,10
0,28	0,52	0,68	0,80	1,11
0,31	0,53	0,69	0,81	1,11
0,33	0,53	0,70	0,81	1,15
0,33	0,53	0,70	0,82	1,16
0,34	0,54	0,70	0,82	1,17
0,34	0,55	0,71	0,82	1,20
0,34	0,56	0,71	0,83	1,25
0,35	0,56	0,71	0,83	1,26
0,37	0,57	0,71	0,84	1,27
0,37	0,57	0,71	0,84	1,34
0,37	0,58	0,72	0,85	1,36
0,37	0,58	0,72	0,85	1,43
0,38	0,59	0,73	0,85	1,53
0,41	0,59	0,73	0,87	1,55
0,43	0,59	0,73	0,87	1,56
0,44	0,60	0,73	0,88	1,56
0,45	0,60	0,73	0,89	1,60
0,45	0,60	0,74	0,89	1,70
0,45	0,62	0,74	0,89	1,72
0,46	0,62	0,74	0,90	1,84
0,46	0,63	0,74	0,94	1,86
0,46	0,63	0,74	1,00	1,94
0,47	0,63	0,75	1,02	1,98
0,47	0,64	0,75	1,02	2,38
0,48	0,64	0,76	1,02	2,49
0,48	0,65	0,76	1,03	2,59
0,48	0,65	0,76	1,03	2,60
0,49	0,65	0,76	1,03	2,68
0,49	0,65	0,77	1,04	2,76
0,50	0,65	0,78	1,04	2,87
0,51	0,65	0,78	1,05	3,55
0,51	0,66	0,79	1,07	



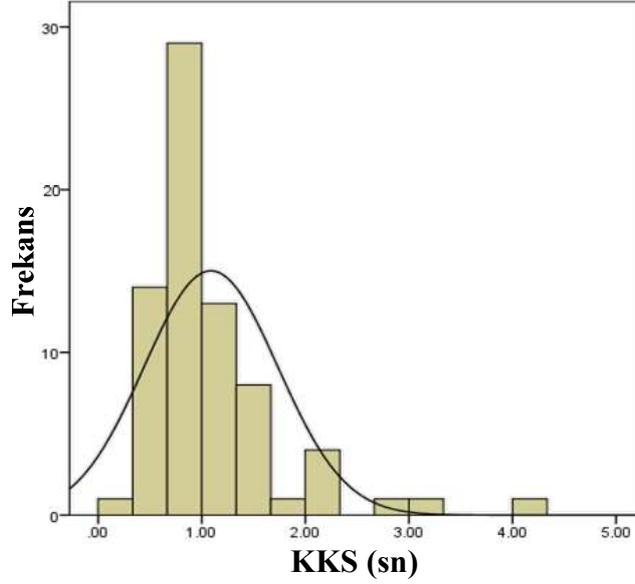
Şekil 6.5 Atakent kavşağı KKS değerlerinin dağılımı.

6.2.2 Girne kavşağı örülme bölgesi KKS değerleri

Girne kavşağı üzerinde incelen örülme bölgesi iki ana şerit ve bir yardımcı şerit olmak üzere toplam üç şeritlidir. Örülme mesafesi ise 100 metredir. Bu bölgede hesaplanan kritik KKS değerleri Çizelge 6.4'teki gibi bulunmuştur. Toplam 73 adet çatışma rotasına sahip şerit değiştirme kaynaklı çatışma tespit edilmiştir. Hesaplanan kritik değerler değerlendirildiğinde 0,30 – 4,09 sn arasında değiştiği, ortalamasının 1,09 sn, standart sapmasının 0,65 sn, mod değerinin 0,74 sn, medyan değerinin 0,93 sn olduğu görülmüştür. Şekil 6.6'da Girne kavşağına ait KKS değerlerinin dağılımı gösterilmiştir.

Çizelge 6.4 Girne kavşağı kritik KKS değerleri.

Kritik KKS değerleri (sn)				
0,30	0,68	0,82	1,02	1,49
0,41	0,69	0,86	1,02	1,51
0,42	0,71	0,87	1,03	1,53
0,48	0,71	0,88	1,04	1,63
0,49	0,74	0,90	1,12	1,65
0,49	0,74	0,92	1,15	1,82
0,52	0,74	0,93	1,18	2,03
0,53	0,75	0,93	1,19	2,07
0,53	0,76	0,95	1,23	2,27
0,56	0,77	0,96	1,28	2,31
0,57	0,78	0,97	1,30	2,68
0,58	0,79	0,99	1,33	3,17
0,60	0,79	0,99	1,43	4,09
0,61	0,80	0,99	1,44	
0,63	0,81	1,00	1,49	



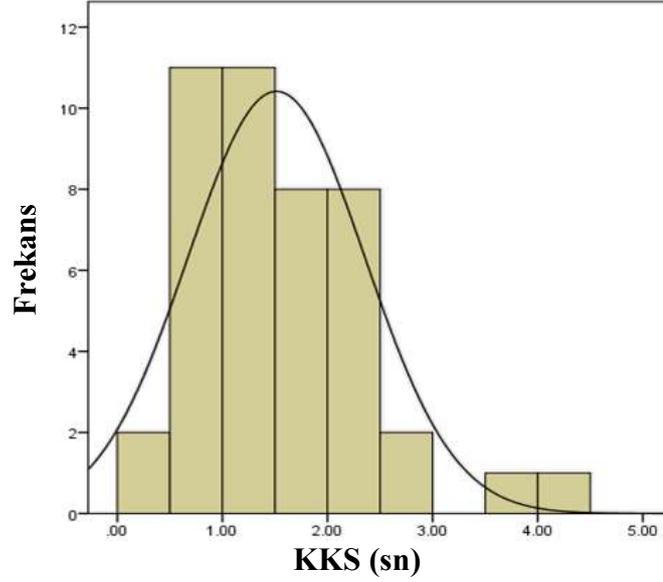
Şekil 6.6 Girne kavşağı KKS değerlerinin dağılımı.

6.2.3 Gaziemir kavşağı örülme bölgesi KKS değerleri

Gaziemir kavşağı üzerinde incelenen örülme bölgesi dört ana şerit ve bir yardımcı şerit olmak üzere toplam beş şeritlidir. Örülme mesafesi ise 150 metredir. Bu bölgede yapılan bir saatlik çekim sonucunda kritik KKS değerleri Çizelge 6.5'teki gibi bulunmuştur. Toplam 44 adet çatışma rotasına sahip şerit değiştirme kaynaklı çatışma tespit edilmiştir. Hesaplanan kritik değerler değerlendirildiğinde ortalamasının 1,51 sn, standart sapmasının 0,84 sn, mod değerinin 0,53 sn, medyan değerinin ise 1,44 sn olduğu görülmüştür. Şekil 6.7'de Gaziemir kavşağına ait KKS değerlerinin dağılımı gösterilmiştir. Değerlerin sağ çarpık dağılıma uyduğu görülmektedir.

Çizelge 6.5 Gaziemir kavşağı kritik KKS değerleri.

Kritik KKS değerleri (sn)				
0,29	0,76	1,26	1,56	2,24
0,44	0,78	1,27	1,85	2,33
0,53	0,83	1,32	1,92	2,40
0,53	0,88	1,44	1,93	2,43
0,56	1,01	1,44	1,94	2,58
0,57	1,08	1,46	2,03	2,61
0,67	1,14	1,51	2,03	3,63
0,68	1,17	1,51	2,06	4,29
0,72	1,26	1,53	2,13	



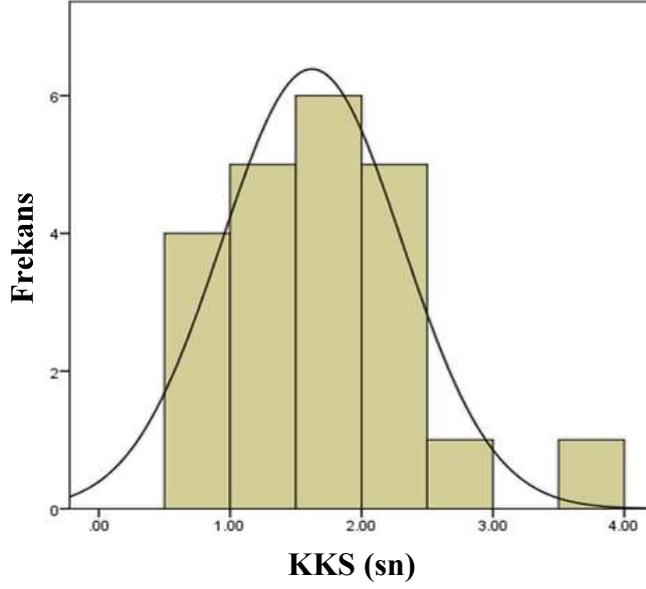
Şekil 6.7 Gaziemir kavşağı KKS değerlerinin dağılımı.

6.2.4 Otogar kavşağı örülme bölgesi KKS değerleri

Otogar kavşağı üzerinde incelenen örülme bölgesi üç ana şerit ve bir yardımcı şerit olmak üzere toplam dört şeritlidir. Örülme mesafesi ise 355 metredir. Bu bölgede yapılan bir saatlik çekim sonucunda kritik KKS değerleri Çizelge 6.6'daki gibi bulunmuştur. Toplam 22 adet çatışma rotasına sahip şerit değiştirme kaynaklı çatışma tespit edilmiştir. Hesaplanan kritik değerler değerlendirildiğinde ortalamasının 1,62 sn, standart sapmasının 0,68 sn, mod değerinin 0,76 sn, medyan değerinin ise 1,56 sn olduğu görülmüştür. Şekil 6.8'de Otogar kavşağına ait KKS değerlerinin dağılımı gösterilmiştir. Değerlerin sağ çarpık dağılıma uyduğu görülmektedir.

Çizelge 6.6 Otogar kavşağı kritik KKS değerleri.

Kritik KKS değerleri (sn)				
0,76	1,06	1,55	2,00	2,80
0,90	1,13	1,57	2,01	3,65
0,96	1,14	1,59	2,04	
0,97	1,42	1,61	2,10	
1,00	1,53	1,69	2,21	



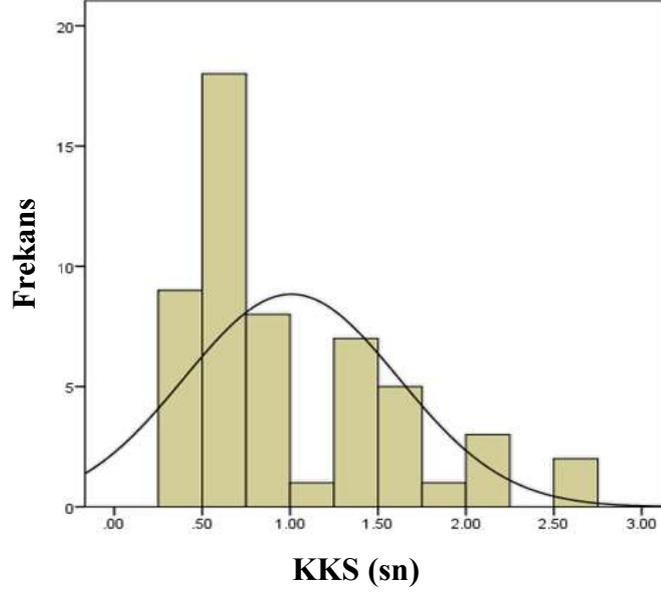
Şekil 6.8 Otogar kavşağı KKS değerlerinin dağılımı.

6.2.5 Örnekköy kavşağı örülme bölgesi KKS değerleri

Örnekköy kavşağı üzerinde incelenen örülme bölgesi üç ana şerit ve bir yardımcı şerit olmak üzere toplam dört şeritlidir. Örülme mesafesi ise 150 metredir. Bu bölgede yapılan bir saatlik çekim sonucunda kritik KKS değerleri Çizelge 6.7'deki gibi bulunmuştur. Toplam 54 adet çatışma rotasına sahip şerit değiştirme kaynaklı çatışma tespit edilmiştir. Hesaplanan kritik değerler değerlendirildiğinde ortalamasının 1,01 sn, standart sapmasının 0,60 sn, mod değerinin 0,65 sn, medyan değerinin ise 0,76 sn olduğu görülmüştür. Şekil 6.9'da Örnekköy kavşağına ait KKS değerlerinin dağılımı gösterilmiştir. Değerlerin sağ çarpık dağılıma uyduğu görülmektedir.

Çizelge 6.7 Örnekköy kavşağı kritik KKS değerleri.

Kritik KKS değerleri (sn)				
0,31	0,55	0,65	0,92	1,54
0,36	0,56	0,69	0,95	1,64
0,39	0,56	0,71	1,22	1,66
0,39	0,59	0,73	1,25	1,71
0,40	0,60	0,73	1,25	1,91
0,40	0,61	0,79	1,26	2,12
0,41	0,62	0,86	1,37	2,12
0,41	0,63	0,89	1,39	2,24
0,47	0,64	0,90	1,43	2,68
0,51	0,65	0,90	1,49	2,73
0,51	0,65	0,90	1,54	



Şekil 6.9 Örnekköy kavşağı KKS değerlerinin dağılımı.

Saha çalışması yapılan örülme bölgelerinde gözlemlenen çatışma sayıları, KKS değerlerinin alt ve üst sınırları ile kritik değerleri Çizelge 6.8’de özetlenmiştir. Örülme bölgesinin uzunluğu arttıkça çatışma sayıları azalmaktadır. Kritik KKS değerinin ise benzer olduğu ve 0,53 – 0,76 sn arasında değiştiği tespit edilmiştir.

Çizelge 6.8 İncelenen örülme bölgelerinde elde edilen verilerin toplu gösterimi.

Örülme bölgesi	Örülme uzunluğu (m)	Çatışma sayısı	KKS aralığı (sn)	Kritik KKS (sn)
Atakent	84	169	0,25 – 3,55	0,65
Girne	100	73	0,30 – 4,09	0,74
Gaziemir	150	44	0,29 – 4,29	0,53
Örnekköy	150	54	0,31 – 2,73	0,65
Otogar	355	22	0,76 -3,65	0,76

Tüm veriler birlikte analiz edildiğinde ortalama KKS değeri 1,05 sn, mod değeri ise 0,74 sn bulunmuştur. Şerit değiştirme esnasında taşıt içi uyarı sistemlerinin KKS 0,74 sn değerine düştüğünde aktifleşmesi önerilmektedir.

7. ÇATIŞMA VERİLERİNİN KALİBRASYONU

Güvenlik değerlendirmesinde benzetim modellerinin kullanılması planlanan önlemlerin uygulamaya geçirilmeden önce sağlayacakları faydayı tespit edebilmek açısından yarar sağlamaktadır.

Young et al. (2014) veri toplama yöntemlerini, mikro-benzetim modellerinin trafik güvenliği değerlendirilmesinde kullanımının geldiği noktayı ve gelişmeye açık yönlerini ayrıntılı bir şekilde özetlemiştir. Benzetim modelleri ilk olarak dur kontrollü kavşaklarda kullanılmıştır. 1970'li yılların ikinci yarısından itibaren mikro-benzetim modelleri güvenlik analizinde kullanılmaya başlanmıştır (Cooper and Ferguson, 1976; Darzentas et al., 1980). Ancak son yıllardaki gelişen veri toplama teknolojisi, bilgisayar kapasitesindeki artış ve iletişim araçlarındaki yeniliklerle birlikte benzetim modellerinin gelişimi hızlanmıştır (Young et al., 2014).

Benzetim modellerinin uygulamasındaki en önemli adımlardan biri, önemli model girdilerinin gözlemsel verilere dayanılarak doğru bir şekilde belirlenmesi ve bu benzetim modellerinin gerçek dünya gözlemlerinden doğrulanabilecek güvenlik performansı tahminleri üretmesini sağlamaktır (Cunto and Saccomanno, 2008).

CORSIM, SimTraffic, VISSIM, HUTSIM, Paramics, Texas, Aimsun benzetim programları çalışmalarda sıklıkla kullanılan benzetim programları arasında yer almaktadır. Trafik güvenlik ölçütleri ile ilgili yapılan çalışmalarda ise VISSIM benzetim programının diğerlerinin arasında öne çıktığı görülmektedir.

7.1 Wiedemann Taşıt Takip Modelleri

Bu tez kapsamında incelenen örülme bölgelerinin benzetimleri VISSIM programı ile yapılmıştır. VISSIM programı, psikofiziksel modeller olan Wiedemann 1974 ve Wiedemann 1999 taşıt takip modellerini kullanmaktadır.

Psikofiziksel modeller, sürücünün davranışını değiştirdiği eşikleri veya eylem noktalarını kullanmaktadır (Olstam and Tapani, 2004). Bu model, hız farkının ve mesafenin bir fonksiyonu olarak ifade edilen bir eşığe ulaşıldığında sürücünün bir eylem gerçekleştireceği varsayımına dayanmaktadır (Panwai and Dia, 2005). Michaels (1963) sürücülerin öndeki taşıtın hızını, taşıtın görünen büyüklüğüne göre değerlendirdiklerini belirtmiştir. İkinci eşik değer ise mesafeye dayalıdır ve buna genellikle eylem noktası denilmektedir. Bu eşik değer kullanımı hız farklarının sınır değerinin altında olduğu

küçük aralıklarda uygundur. Evans and Rothery (1973), Michaels tarafından önerilen eşik değerleri ölçmek için deneysel bir çalışma yapmıştır. Test taşıtındaki yolculardan 1 sn ve 2 sn süre içerisinde takip edilen taşıtla aralarındaki mesafenin yeterli olup olmadığı ve mesafenin açıldığı/kapandığı konusundaki görüşlerini belirtmeleri istenmiştir. Doğru kararın $v/\Delta x$ ile gözlem süresinin bir fonksiyonu olduğu sonucuna varılmıştır (Brackstone and McDonald, 1999).

Rainer Wiedemann tarafından 1974 yılında öne sürülen taşıt takip modeli en çok tercih edilen modellerden birisidir (Pourabdollah et al., 2017). Bu modelin temelinde daha hızlı hareket eden taşıt sürücüsünün kendi algı eşliğinde daha yavaş hareket eden bir taşıta yaklaştığında yavaşlaması yatmaktadır. Sürücü, yavaş hareket eden taşıtın hızını tam olarak bilemediği için hızını yavaş giden taşıtın altına düşürecek ve sonra yeni bir algı eşğine gelene kadar tekrar hızlanmaya başlayacaktır. Farklı sürücü davranışları hız ve mesafe dağılım fonksiyonları ile dikkate alınmaktadır (PTV, 2018).

Şekil 7.1’de Wiedemann 1974 taşıt takip modeli gösterilmiştir. 1 bölgesi serbest akım durumunu, 2 bölgesi taşıt takip durumunu, 3 bölgesi yaklaşım durumunu, 4 bölgesi frenleme durumunu, 5 bölgesi ise çarpışma durumunu ifade etmektedir (PTV, 2018; Olstam and Tapani, 2004). Bir sürücü kendisinden daha düşük hızla ilerleyen bir taşıta yaklaşırken hızını düşürecek ve öndeki taşıtla arasındaki güvenli mesafeyi korumak için hızını değiştirmeyecektir. Ancak öndeki taşıtla tamamen aynı hızda ilerlemesi (hız farkının sıfır olması durumu) mümkün olmadığından 2 ile gösterilen takip bölgesinde hız farkında değişimler gözlemlenecektir.

Eşik değerlerin belirlenmesi psikofiziksel modellerin zorluklarından biridir. Modellerin gerçekçi biçimde kalibre edilmesi için farklı trafik koşullarında sürekli ölçümlere ihtiyaç duyulmaktadır (Panwai and Dia, 2005). Şekil 7.1’de gösterilen sınır değerler aşağıda tanımlanmıştır:

SDV: Sürücünün yavaşlayan taşıtı bilinçli olarak gözlemlediği eylem noktasıdır. Hız farkı arttıkça SDV değeri de artmaktadır.

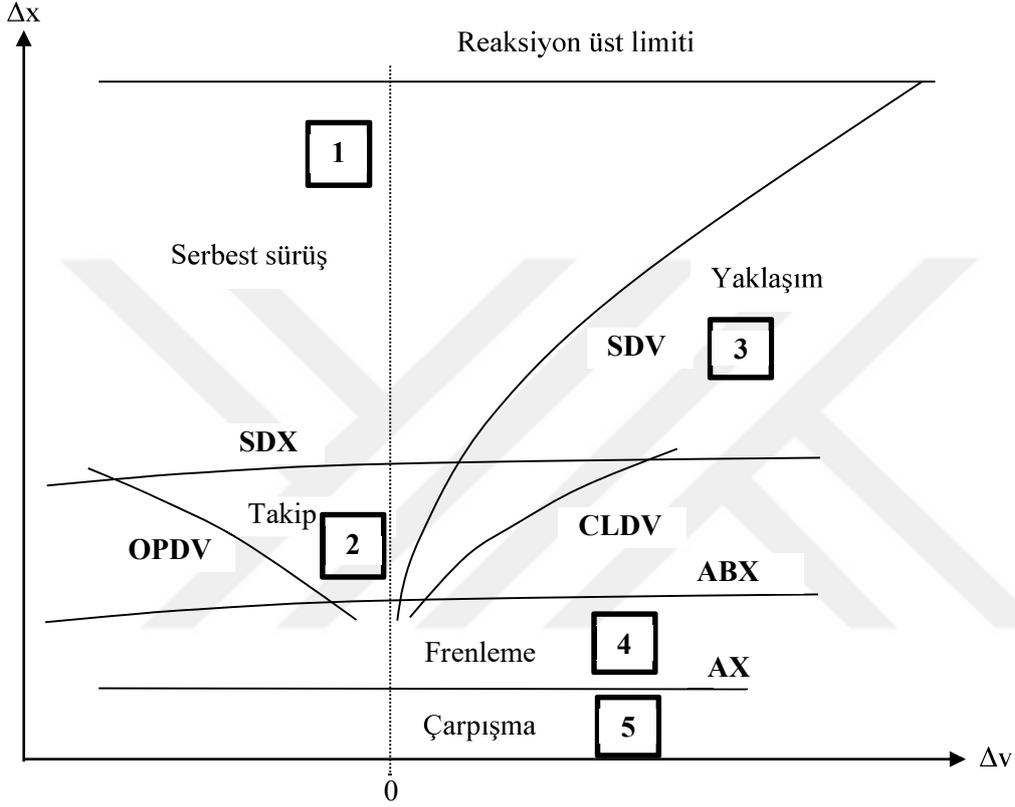
CLDV: Kısa ve azalan mesafelerdeki küçük hız farklarını modellemek için kullanılan algı eşliğidir.

SDX: En büyük takip mesafesini modellemek için kullanılan algı eşliğidir. En küçük takip mesafesinin (ABX) 1,5 – 2,5 katı arasında değişmektedir.

OPDV: Takip halindeki taşıt sürücülerinin önlerinde ilerleyen taşıttan daha düşük hızda gittiklerini fark edip hızlandıkları eylem noktasıdır.

AX: Duran taşıtlar arasındaki arzu edilen mesafedir.

ABX: Küçük hız farklarında arzu edilen minimum takip mesafesidir.



Şekil 7.1 Wiedemann 1974 taşıt takip modeli.

VISSIM programının trafik akım modeli, sürücü-taşıt birimlerini temel unsurlar olarak gören, stokastik, zaman adımına dayalı, mikroskobik bir modeldir. Wiedemann'ın trafik akım modeli, bir sürücü için temel olarak dört farklı sürüş durumu olduğu varsayımına dayanmaktadır (PTV, 2018). Bu yaklaşımlar aşağıda özetlenmiştir:

Serbest sürüş: Öndeki taşıtların etkisi gözlenmemektedir. Bu durumda sürücü arzu edilen hız değerine ulaşmak ve o hızda hareket etmek istemektedir.

Yaklaşım: Sürücünün önde daha düşük hızla ilerleyen bir taşıta hızını uydurması durumudur.

Takip: Sürücü öndeki taşıtı bilinçli bir şekilde yavaşlamadan veya hızlanmadan izlemektedir. Takip mesafesini genellikle korumaktadır.

Frenleme: Sürücü öndeki taşıtla mesafesinin güvenli mesafenin altına düştüğünü fark ederse hızını azaltmaktadır. Bu durum, öndeki taşıtın sürücüsü ani bir şekilde hızını değiştirdiğinde ya da üçüncü bir taşıtın sürücüsü iki taşıt arasına girecek şekilde şerit değiştirdiğinde gerçekleşebilmektedir.

Wiedemann 1974 modeli üç parametreye sahiptir. Bunlar:

ax : Duran taşıtlar arasındaki arzu edilen mesafeyi göstermektedir.

bx_{add} : Güvenli mesafenin ek kısmıdır. Takip mesafesini hıza bağlı olarak artırmaktadır.

bx : Güvenli mesafenin çarpan kısmıdır. Takip mesafesindeki değişimi kontrol etmektedir.

Güvenli mesafe d , Denklem 7.1 ile hesaplanmaktadır.

$$d = ax + bx \quad (7.1)$$

$$bx = (bx_{add} + bx_{mult} \times z) \times \sqrt{v} \quad (7.2)$$

Denklem 7.2'de v , araç hızını; z ise [0-1] aralığında değişen bir değeri ifade etmektedir.

Wiedemann 1999 modeli ise 10 parametreye sahiptir (PTV , 2018). Bunlar:

CCO: Durma mesafesidir. İki taşıt arasındaki arzu edilen duruş mesafesini göstermektedir. Birimi metredir.

CC1: Zaman cinsinden aralıktır. Bu değer ne kadar büyükse sürücü o kadar dikkatlidir. Birimi saniyedir.

CC2: Bir taşıtın güvenli mesafesine ek olarak gerek duyduğu mesafedir. Bir sürücünün bilinçli olarak kendisinden öndeki taşıta yaklaşmadan önce izin verdiği mesafe farkını kısıtlamaktadır.

CC3: Takip durumuna girme eşiğidir. Yavaşlamanın başlama sürecini tanımlamaktadır. Sürücü önde kendisinden düşük bir hıza sahip taşıtı fark etmekte ve yavaşlamaya başlamaktadır. Sürücünün güvenli mesafeye ulaşmadan kaç saniye önce yavaşlamaya başlaması gerektiğini göstermektedir. Birimi saniyedir.

CC4: Takip durumunda negatif hız farkını tanımlamaktadır. Küçük değerler, sürücülerin öndeki taşıtın hızlanmalarına veya yavaşlamalarına daha hassas reaksiyon göstermeleri ile sonuçlanmaktadır. Birimi m/sn' dir.

CC5: Takip durumunda pozitif hız farkını tanımlamaktadır. Küçük değerler, sürücülerin öndeki taşıtın hızlanmalarına veya yavaşlamalarına daha hassas reaksiyon göstermeleri ile sonuçlanmaktadır. Birimi m/sn' dir.

CC6: Takip durumunda mesafenin hızdaki dalgalanmaya olan etkisini tanımlamaktadır. Bu değer 0 olarak girilirse, hızdaki dalgalanma öndeki taşıtla olan mesafeden bağımsızdır. Daha büyük değerler girilirse mesafenin artması hızda daha büyük dalgalanmalara sebep olmaktadır. Birimi $1/(m \times sn)$ 'dir.

CC7: Hızlanma aşamasındaki dalgalanmayı göstermektedir. Birimi m/sn^2 'dir.

CC8: Taşıt duruş halinden hareket haline geçerken arzu edilen ivmesidir. İvme eğrilerindeki en yüksek değerle sınırlıdır. Birimi m/sn^2 'dir.

CC9: 80 km/sa hızdaki arzu edilen ivme değeridir. İvme eğrilerindeki en yüksek değerle sınırlıdır. Birimi m/sn^2 'dir.

Bu tez kapsamında incelenen örülme bölgeleri VISSIM programında oluşturulmuş, bir saatlik çekimlerden elde edilen trafik hacimleri atanmış ve Wiedemann 99 modeli seçilerek benzetimler gerçekleştirilmiştir. Benzetimler sonucunda yörünge dosyaları elde edilmiştir.

7.2 VISSIM ile Örülme Bölgelerinin Benzetiminin Yapılması

İncelenen örülme bölgelerinin VISSIM programında oluşturulması için izlenen adımlar aşağıda sıralanmıştır:

- Örülme bölgesinin çizilmesi: Bu tez kapsamında incelenen örülme bölgeleri Open Street Maps haritası arka plana yerleştirilerek çizilmiştir. Şerit sayısı, şerit

geniřlięi ve örölme bölgesinin uzunluęu bilindięi için bu deęerler girilerek örölme bölgesi oluşturulmuřtur. Yonca kavřakların katılma ve ayrılma kollarında hız azaltma bölgeleri tanımlanmuřtur.

- Benzetim süresinin girilmesi: Saha gözlemleri bir saatlik zaman dilimi için yapılmıřtır. Bu nedenle benzetim süresi 3600 sn olarak girilmiřtir.
- Trafik kompozisyonunun oluşturulması: Trafik sayımları sırasında tařıtlar; otomobil, otobüs, ağır tařıt (kamyon-tır), hafif ticari ve motosiklet sınıflarına ayrılmıřtır. Ancak programa giriş yapılırken otomobil, ağır tařıt ve otobüs sınıfları kullanılmıřtır. Hafif ticari tařıtların ve motosikletlerin sayısı birim otomobil dönüşümü yapılarak otomobil sayısına eklenmiřtir. Trafik kompozisyonu oluşturulurken her tařıt türünün toplam tařıt sayısı içindeki yüzdeler kullanılmaktadır.
- Arzu edilen hız daęılımının oluşturulması: VISSIM programının kendi içinde farklı deęerlere ait hız daęılımları bulunmaktadır. Bu hız daęılımları farklı tařıt türlerine atanabilmektedir. Gerçekçi sonuçlar elde edebilmek adına her örölme bölgesinde gözlemlenen hız deęerlerinin tařıt türlerine göre daęılımı kutu grafikleri oluşturularak belirlenmiř ve yeni hız daęılımı olarak programa eklenmiřtir.
- Trafik hacminin girilmesi: Katılma kolundan ve anayoldan gelen trafik hacmi programa girilmiřtir.
- Yönlerin belirlenmesi: Anayoldan gelen tařıtlar anayola veya ayrılma koluna doęru devam etmektedirler. Katılma kolundan gelen tařıtlar ise anayola devam etmekte veya örölme řeridini takip ederek ayrılma kolundan çıkmaktadırlar. Tařıtların yön daęılımı yüzdeler olarak girilmiřtir.
- Benzetim modelinin çalıştırılması: VISSIM programının yürünge dosyası oluşturması istendięi için deęerlendirme kısmında SSAM aktif hale getirilmiřtir.

Tařıtlar, VISSIM programına otomobil, ağır tařıt ve otobüs olmak üzere üç sınıfta girilmiřtir. Hafif ticari tařıtlar ve motosikletler için TS 6407 řehir İçi Ulařım Hesaplamalarında Kullanılan Araç Tiplerine Göre Otomobil Eřdeęeri Katsayıları

standardından faydalanılmıştır. Çizelge 7.1’de birim otomobil dönüşümü için kullanılan katsayılar gösterilmiştir.

Çizelge 7.1 Birim otomobil tablosu (TS 6407, 2013).

Birim Otomobil Katsayısı	Otomobil	Hafif Ticari	Otobüs	Ağır Taşıt	Motosiklet
Toplam	1,00	1,25	2,25	2,25	0,33

Yukarıda anlatılan adımlar her bir örülme bölgesi için uygulanmış ve program ilk olarak kendi varsayılan parametre değerleri ile çalıştırılmıştır. 7.2.1 - 7.2.5 başlıkları arasında örülme bölgelerine ait trafik hacimleri, trafik kompozisyonları, hız dağılımları ve yön dağılımları sunulmuştur.

7.2.1 Atakent kavşağı örülme bölgesi benzetimi

Atakent kavşağı örülme bölgesinde anayoldan giren toplam taşıt sayısı 1515, katılma kolundan giren toplam taşıt sayısı ise 603’tür. Trafik kompozisyonu Çizelge 7.2’de gösterilmiştir. Anayoldan ve katılmadan gelen taşıtların %93,53’lük bölümünü otomobiller oluşturmaktadır.

Çizelge 7.2 Atakent kavşağı trafik kompozisyonu.

	Otomobil	Ağır taşıt	Otobüs
Anayol	1417 (%93,53)	29 (%1,92)	69 (%4,55)
Katılma	564 (%93,53)	15 (%2,48)	24 (%3,99)

Çizelge 7.3’te ise taşıtların yönlere göre dağılım yüzdeleri gösterilmiştir. Gözlem yapılan zaman dilimi içinde katılmadan ayrılmaya devam eden taşıt tespit edilmemiştir. Katılmadan giren hacmin tamamı anayoldan devam ederek örülme bölgesinden çıkmıştır. Anayoldan giren trafik hacminin %80’lik kısmı ise ayrılma koluna geçerek örülme bölgesinden çıkmıştır. Değerlerden görüleceği üzere Atakent kavşağı üzerinde yer alan örülme bölgesinde örülme hareketleri yoğun olarak gerçekleşmiştir.

Çizelge 7.3 Atakent kavşağı trafiğin yönlere dağılımı.

Yön	Yüzde dağılım
Anayoldan anayola	19,94
Anayoldan ayrılmaya	80,06
Katılmadan anayola	100,00
Katılmadan ayrılmaya	0,00

Çizelge 7.4'te ve Çizelge 7.5'te anayoldan ve katılma kolundan giriş yapan taşıtların hız dağılımları gösterilmiştir. Otomobil, ağır taşıt ve otobüs olmak üzere üç taşıt sınıfının en düşük ve en yüksek hız değerleri ile %25, %50 ve %75'lik değerleri F(X) sütununda gösterilmiştir.

Çizelge 7.4 Atakent kavşağı anayol hacmi hız dağılımı.

X_{otomobil} (km/sa)	$X_{\text{ağır taşıt}}$ (km/sa)	$X_{\text{otobüs}}$ (km/sa)	F(X)
36,97	41,94	34,78	0,00
48,71	52,69	52,00	0,25
52,44	58,78	60,82	0,50
59,18	64,73	68,37	0,75
95,70	73,98	87,64	1,00

Çizelge 7.5 Atakent kavşağı katılma hacmi hız dağılımı.

X_{otomobil} (km/sa)	$X_{\text{ağır taşıt}}$ (km/sa)	$X_{\text{otobüs}}$ (km/sa)	F(X)
42,71	50,35	49,47	0,00
54,29	51,99	57,44	0,25
58,54	57,38	68,91	0,50
63,67	63,95	73,87	0,75
105,05	72,37	87,22	1,00

7.2.2 Girne kavşağı örülme bölgesi benzetimi

Girne kavşağı örülme bölgesinde anayoldan giren toplam taşıt sayısı 3049, katılma kolundan giren toplam taşıt sayısı ise 1058'dir. Trafik kompozisyonu Çizelge 7.6'da gösterilmiştir. Bu bölgede hâkim olan taşıt türü otomobildir ve hem anayolda hem de katılmada %90'dan büyük bir paya sahiptir.

Çizelge 7.6 Girne kavşağı trafik kompozisyonu.

	Otomobil	Ağır taşıt	Otobüs
Anayol	2833 (%92,92)	155 (%5,08)	61 (%2,00)
Katılma	986 (%93,19)	49 (%4,63)	23 (%2,18)

Çizelge 7.7'de taşıtların yönlere göre dağılım yüzdeleri gösterilmiştir. Gözlem yapılan zaman dilimi içinde katılmadan gelen trafik hacminin %3,03'ünün ayrılmaya devam ettiği tespit edilmiştir. Anayoldan giren trafik hacminin yaklaşık %60'ı yine anayoldan devam etmiştir.

Çizelge 7.7 Girne kavşağı trafiğın yönlere dağılımı.

Yön	Yüzde dağılım
Anayoldan anayola	59,79
Anayoldan ayrılmaya	40,21
Katılmadan anayola	96,97
Katılmadan ayrılmaya	3,03

Çizelge 7.8’de ve Çizelge 7.9’da anayoldan ve katılma kolundan giriş yapan taşıtların hız dağılımları gösterilmiştir. En düşük hız 25,69 km/sa, en yüksek hız ise 104,07 km/sa olarak gözlenmiştir.

Çizelge 7.8 Girne kavşağı anayol hacmi hız dağılımı.

X _{otomobil} (km/sa)	X _{ağır taşıt} (km/sa)	X _{otobüs} (km/sa)	F(X)
29,69	32,80	25,69	0,00
43,61	48,62	48,92	0,25
48,14	54,99	56,44	0,50
51,77	62,06	64,44	0,75
94,47	99,74	86,58	1,00

Çizelge 7.9 Girne kavşağı katılma hacmi hız dağılımı.

X _{otomobil} (km/sa)	X _{ağır taşıt} (km/sa)	X _{otobüs} (km/sa)	F(X)
31,03	32,46	36,32	0,00
43,52	47,15	46,78	0,25
46,89	53,42	57,61	0,50
53,00	61,13	73,01	0,75
104,07	88,93	96,32	1,00

7.2.3 Gaziemir kavşağı örülme bölgesi benzetimi

Gaziemir kavşağı örülme bölgesinde anayoldan giren toplam taşıt sayısı 3990, katılma kolundan giren toplam taşıt sayısı ise 517’dir. Trafik kompozisyonu Çizelge 7.10’da gösterilmiştir. Otomobiller trafik hacmi içindeki en yüksek paya sahip olmakla birlikte katılma kolunda %10,83 oranında ağır taşıt trafiği gözlenmiştir.

Çizelge 7.10 Gaziemir kavşağı trafik kompozisyonu.

	Otomobil	Ağır taşıt	Otobüs
Anayol	3624 (%90,83)	278 (%6,97)	88 (%2,20)
Katılma	451 (%87,24)	56 (%10,83)	10 (%1,93)

Çizelge 7.11’de taşıtların yönlere göre dağılım yüzdeleri gösterilmiştir. Gözlem yapılan zaman dilimi içinde katılmadan ayrılmaya devam eden taşıt tespit edilmemiştir. Katılmadan giren hacmin tamamı anayoldan devam ederek örülme bölgesinden çıkmıştır. Anayoldan giren trafik hacminin yaklaşık %40’lık kısmı ise ayrılma koluna geçerek örülme bölgesinden çıkmıştır.

Çizelge 7.11 Gaziemir kavşağı trafiğın yönlere dağılımı.

Yön	Yüzde dağılım
Anayoldan anayola	60,60
Anayoldan ayrılmaya	39,40
Katılmadan anayola	100,00
Katılmadan ayrılmaya	0,00

Çizelge 7.12’de ve Çizelge 7.13’te anayoldan ve katılma kolundan giriş yapan taşıtların hız dağılımları gösterilmiştir.

Çizelge 7.12 Gaziemir kavşağı anayol hacmi hız dağılımı.

X _{otomobil} (km/sa)	X _{ağır taşıt} (km/sa)	X _{otobüs} (km/sa)	F(X)
36,40	43,75	35,76	0,00
62,48	63,82	63,21	0,25
75,19	76,12	75,87	0,50
86,65	83,56	85,21	0,75
128,66	121,37	109,39	1,00

Çizelge 7.13 Gaziemir kavşağı katılma hacmi hız dağılımı.

X _{otomobil} (km/sa)	X _{ağır taşıt} (km/sa)	X _{otobüs} (km/sa)	F(X)
31,34	41,70	52,74	0,00
56,57	57,14	60,09	0,25
64,39	68,89	72,82	0,50
79,44	87,55	81,71	0,75
118,44	115,26	102,86	1,00

7.2.4 Otogar kavşağı örülme bölgesi benzetimi

Otogar kavşağı örülme bölgesinde anayoldan giren toplam taşıt sayısı 1307, katılma kolundan giren toplam taşıt sayısı ise 463’tür. Trafik kompozisyonu Çizelge 7.14’te gösterilmiştir. Bu bölgede katılma bölgesinden gelen trafik hacminin %22,03’ünü ağır taşıtlar oluşturmaktadır.

Çizelge 7.14 Otogar kavşağı trafik kompozisyonu.

	Otomobil	Ağır taşıt	Otobüs
Anayol	1153 (%88,22)	87 (%6,65)	67 (%5,13)
Katılma	358 (%77,32)	102 (%22,03)	3 (%0,65)

Çizelge 7.15'te taşıtların yönlere göre dağılım yüzdeleri gösterilmiştir. Gözlem yapılan zaman dilimi içinde katılmadan gelen trafik hacminin %10,37'sinin ayrılmaya devam ettiği tespit edilmiştir. Anayoldan giren trafik hacminin %73,22'si örülme hareketinde bulunarak ayrılma koluna devam etmiştir.

Çizelge 7.15 Otogar kavşağı trafiğin yönlere dağılımı.

Yön	Yüzde dağılım
Anayoldan anayola	26,78
Anayoldan ayrılmaya	73,22
Katılmadan anayola	89,63
Katılmadan ayrılmaya	10,37

Çizelge 7.16'da ve Çizelge 7.17'de anayoldan ve katılma kolundan giriş yapan taşıtların hız dağılımları gösterilmiştir.

Çizelge 7.16 Otogar kavşağı anayol hacmi hız dağılımı.

X_{otomobil} (km/sa)	X_{ağır taşıt} (km/sa)	X_{otobüs} (km/sa)	F(X)
45,81	45,87	67,25	0,00
86,61	88,67	86,33	0,25
90,99	93,68	95,60	0,50
95,30	101,91	100,96	0,75
127,95	123,03	114,86	1,00

Çizelge 7.17 Otogar kavşağı katılma hacmi hız dağılımı.

X_{otomobil} (km/sa)	X_{ağır taşıt} (km/sa)	X_{otobüs} (km/sa)	F(X)
47,83	67,00	74,76	0,00
85,41	81,61	74,76	0,25
92,52	90,16	99,35	0,50
97,02	100,84		0,75
116,79	108,55	103,00	1,00

7.2.5 Örnekköy kavşağı örülme bölgesi benzetimi

Örnekköy kavşağı örülme bölgesinde anayoldan giren toplam taşıt sayısı 3547, katılma kolundan giren toplam taşıt sayısı ise 670'tir. Trafik kompozisyonu Çizelge 7.18'de gösterilmiştir. Bu bölgede hâkim olan taşıt türü otomobildir ve hem anayolda hem de katılmada %90'dan büyük bir paya sahiptir.

Çizelge 7.18 Örnekköy kavşağı trafik kompozisyonu.

	Otomobil	Ağır taşıt	Otobüs
Anayol	3212(%90,55)	295(%8,32)	40(%1,13)
Katılma	626(%93,43)	40(%5,97)	4(%0,60)

Çizelge 7.19'da taşıtların yönlere göre dağılım yüzdeleri gösterilmiştir. Gözlem yapılan zaman dilimi içinde katılmadan gelen trafik hacminin %0,45'inin ayrılmaya devam ettiği tespit edilmiştir.

Çizelge 7.19 Örnekköy kavşağı trafiğin yönlere dağılımı.

Yön	Yüzde dağılım
Anayoldan anayola	70,57
Anayoldan ayrılmaya	29,43
Katılmadan anayola	99,55
Katılmadan ayrılmaya	0,45

Çizelge 7.20'de ve Çizelge 7.21'de anayoldan ve katılma kolundan giriş yapan taşıtların hız dağılımları gösterilmiştir.

Çizelge 7.20 Örnekköy kavşağı anayol hacmi hız dağılımı.

X_{otomobil} (km/sa)	$X_{\text{ağır taşıt}}$ (km/sa)	$X_{\text{otobüs}}$ (km/sa)	F(X)
60,00	60,08	62,12	0,00
77,62	75,94	76,27	0,25
84,59	89,73	85,84	0,50
99,95	99,00	101,36	0,75
127,50	122	116,27	1,00

Çizelge 7.21 Örnekköy kavşağı katılma hacmi hız dağılımı.

(km/sa)	X _{ağır taşıt} (km/sa)	X _{otobüs} (km/sa)	F(X)
59,75	60,56	92,36	0,00
86,51	83,91	92,94	0,25
91,58	89,37	94,93	0,50
97,21	95,26	99,17	0,75
119,91	117,86	100,56	1,00

7.3 VISSIM Programının Kalibrasyonu

Kalibrasyon, benzetim programlarından elde edilen ölçümlerin (trafik hacimleri, hızlar, seyahat süreleri, vb.) sahada gözlemlenen ölçümlerle eşleşmesi için parametrelerin düzenlenmesidir (Ma et al., 2007). Benzetim modellerinin kullanıldığı birçok çalışmada programlarda varsayılan değerler kullanıldığında gerçek koşulların yansıtılmadığı görülmüştür. Bu amaçla benzetim programlarındaki parametrelerin kalibre edilmesi gerektiği sonucuna varılmıştır. Ancak parametre sayısının çok olması kalibrasyonun elle farklı değerlerin denenerek yapılmasını zorlaştırmakta bu nedenle otomatik bir kalibrasyon işlemine ihtiyaç duyulmaktadır. Genetik algoritmalar, yapay sinir ağları ve çoklu başlangıç algoritmaları gibi yöntemler kullanılarak kalibrasyonun daha kısa sürede yapılması sağlanmaktadır. Bu yöntemlerin içinde genetik algoritma sıklıkla tercih edilmiştir (Gallelli et al., 2017).

Yapılan çalışmalarda kalibrasyonun üç model parametresi için gerçekleştirildiği görülmüştür. Bunlar; trafik kontrol yönetimi, trafik akımının karakteristikleri ve sürücü davranışı olarak karşımıza çıkmaktadır (Milam and Choa, 2001).

Gallelli et al. (2019) çalışmalarında beş kollu bir dönele kavşaktaki arkadan çarpma tipi çatışmaların dağılımını incelemişler ve çatışma analizinde KKS ölçütünü kullanmışlardır. İlk olarak kavşak kollarındaki gecikmelerin gerçek değerleri ile VISSIM programının verdiği gecikme değerlerini gerçek değerlere yaklaştırmak için programın kalibrasyonu gerçekleştirilmiştir. Bu amaçla gecikme değerini etkileyebilecek 12 adet parametre (arzu edilen hız, arzu edilen hızın standart sapması, arzu edilen yavaşlama ivmesi, ileride gözlenen taşıt sayısı ile Wiedemann 99 modeli parametrelerinden CCO, CC1, CC2, CC3, CC5, CC6, CC7 ve CC8) Plackett-Burman deney tasarımı ile dokuz adet parametreye düşürülmüştür. İkinci aşamada genetik algoritma kullanılarak bu parametrelerin en uygun değerleri bulunmuştur. Yazarlar farklı ölçütler, farklı çatışma

türleri ve örölme bölgeleri de dahil olmak üzere farklı çalışma alanlarında da kalibrasyon çalışmalarının yapılmasını önermişlerdir.

Huang et al. (2013) iki aşamalı bir kalibrasyon önermiştir. Çin’de 10 adet ışıklı kavşaktan toplanan verilerden trafik hacmi ve hızının gerçek değerleri ile benzetim değerleri için Chi-kare testi yapılmış ve anlamlı bir farklılık bulunmamıştır. Daha sonra zaman cinsinden aralık kullanılarak kalibrasyon gerçekleştirilmiştir. Duyarlılık analizi ile tespit edilen duran taşıtlar arasındaki güvenli mesafe, güvenli mesafenin toplanan kısmı ve çarpılan kısmı parametrelerinin en iyi değerleri genetik algoritma ile bulunmuştur. İkinci kalibrasyon aşamasında ise sahada gözlemlenen çatışmaların SSAM programı tarafından tekrarlanması hedeflenmiştir. Sahada KKS değerlerinin 0,7 ila 3,0 sn arasında değiştiği belirlenmiş ve gerçek çatışmalarla benzetim programından gelen çatışmaların ortalama mutlak yüzde hatasını en küçükleyen KKS değeri 1,6 sn olarak bulunmuştur. Bu çalışmada trafik çatışmaları, taşıtların kaçınma manevraları (fren, direksiyon kırma, fark edilir yavaşlama) dikkate alınarak belirlenmiştir. Wang et al. (2018) da çalışmalarında aynı yöntemi kullanarak ışıklı kavşaklarda çatışmaları belirlemiştir. Kalibrasyon için üç yöntem uygulanmıştır. Bu yöntemlerden ilki programın kendi varsayılan değerlerinin kullanılması, ikincisi sürücü davranış parametrelerinin değiştirilmesi, üçüncüsü ise sahada gözlemlenen çatışma sayılarını oluşturacak şekilde sürücü davranış parametrelerinin değiştirilmesidir. Çalışmada uç değer teorisi ile yıllık beklenen kaza sıklığı elde edilmeye çalışılmıştır.

Cunto (2008) çalışmasında kalibrasyon için uygulanan adımları aşağıdaki gibi sıralanmıştır:

- Modelin ilk girdilerinin belirlenmesi
- Girdilerin ilk istatistiksel taraması
- Önemli girdileri güvenlik performansı ile ilişkilendiren doğrusal ifadenin oluşturulması
- Genetik algoritma kullanılarak model girdilerinin en iyi tahminlerinin elde edilmesi

Literatürde VISSIM programının kalibre edildiği çalışmalar Çizelge 7.22’de özetlenmiştir. Farklı geometrilere sahip ışıklı ve ışısız kavşaklar, erişim kontrollü yollar, yol ağları gibi farklı bölgelerde kalibrasyon çalışmaları gerçekleştirilmiştir. Parametre

seçiminde önceki çalışmalardan elde edilen veriler kullanıldığı gibi istatistiksel yöntemler kullanılarak kalibrasyon ölçütü üzerinde en çok etkisi olan parametreler de belirlenmiştir. Kalibrasyonun iki aşamada gerçekleştiği çalışmalarda ilk kalibrasyonun zaman cinsinden aralık, gecikme gibi trafik parametrelerinin dikkate alınarak gerçekleştiği, ikinci kalibrasyonda ise trafik çatışmalarının ele alındığı görülmektedir. Genetik algoritmanın en çok kullanılan optimizasyon yöntemi olduğu anlaşılmaktadır.

Çizelge 7.22 VISSIM programının kalibre edildiği çalışmalar.

Yazar	Çalışma alanı	Model	Parametre seçimi	Kalibrasyon ölçütü	Optimizasyon yöntemi
Cunto and Saccomanno, 2008	Işıklı kavşaklar	Wiedemann 99	Plackett-Burman	Kaza potansiyel indisi	Genetik algoritma
Essa and Sayed, 2015	Işıklı kavşaklar	Wiedemann 99	Duyarlılık analizi	Variş türü Arzu edilen hız	Genetik algoritma
Karakises et al., 2017	Yol ağı	Wiedemann 99	Önceki çalışmalardan	Seyahat süresi	Deneme-yanılma
Yu and Fan, 2017	Yol kesimi	Wiedemann 99	-	Hacim Hız	Genetik algoritma Tabu araştırması
Gallelli et al., 2019	Dönel kavşak	Wiedemann 99	Plackett-Burman	Yaklaşım kollarındaki gecikme	Genetik algoritma
Guo et al., 2021	Dört kollu ışıklı kavşak	Wiedemann 99	Duyarlılık analizi	1. Variş türü 2. Çatışmaların uç değer dağılımları	Genetik algoritma
Maheshwary et al., 2020	Kavşak ve yaya geçidi yaklaşımı	Wiedemann 99	Latin hiperküüp örnekleme	Seyahat süresi	Genetik algoritma
Yang et al., 2012	Erişim kontrollü örülme bölgeleri	Wiedemann 74	-	Kapasite	Deneme-yanılma
Siddharth and Ramadurai, 2013	Işıklı kavşak	Wiedemann 74	Latin hiperküüp örnekleme	Hacim	Genetik algoritma
Huang et al., 2013	Işıklı kavşaklar	Wiedemann 74	Duyarlılık analizi	1. Zaman cinsinden aralık 2. Çatışma sayıları	Genetik algoritma
Lu et al., 2016	Işıklı kavşak	Wiedemann 74	Duyarlılık analizi	Doygun takip aralığı	Altın oran arama
Wang et al., 2018	Işıklı kavşaklar	Wiedemann 74	Duyarlılık analizi	1. Zaman cinsinden aralık 2. Çatışma sayıları	Genetik algoritma
Guo et al., 2019	Işıklı kavşaklar	Wiedemann 74	Duyarlılık analizi	1. Gecikme 2. Çatışma sayıları	Genetik algoritma
Bandi and George, 2020	Yol ağı	Wiedemann 74	Önceki çalışmalardan	Hacim	Yapay sinir ağları
Vajeeran and De Silva, 2020	Üç ve dört kollu kavşaklar	Wiedemann 74	-	Hacim Kuyruk uzunluğu	Deneme-yanılma

İncelenen örölme bölgelerinde gözlemlenen ve programdan ölçülen trafik hacimlerini karşılaştırmak için GEH (Geoffrey E. Havers) istatistiği kullanılmıştır. GEH istatistiği formülü Denklem 7.3'te verilmiştir.

$$GEH = \sqrt{\frac{2(M-C)^2}{M+C}} \quad (7.3)$$

M: Benzetim modelinden elde edilen trafik hacmi

C: Sahada gözlemlenen trafik hacmi

VISSIM programında oluşturulan örölme bölgeleri ilk önce programın varsayılan değerleri ile çalıştırılmıştır. Programda 'Veri Toplama Noktası' seçilerek her bir şerit üzerine bu noktalardan yerleştirilmiştir. Program çalıştırıldığında yerleştirilen noktalardan geçen taşıt sayısı elde edilmiştir. Her örölme bölgesinde 10 benzetim yapılmış ve ortalama değerleri dikkate alınmıştır. Çizelge 7.23'te her örölme bölgesi için GEH istatistiği sonuçları verilmiştir. GEH < %5 iki hacim değeri arasında iyi bir uyum olduğunu, %5 < GEH < %10 kabul edilebilir ancak incelenmesi gerekli durumu, GEH > %10 ise iki hacim değeri arasında uyum olmadığını göstermektedir. GEH değerleri incelendiğinde sadece Otogar ve Örnekköy örölme bölgelerinin %5'in altında kaldığı görülmektedir. Kalibrasyon; Atakent, Girne ve Gaziemir örölme bölgeleri için yapılmıştır.

Çizelge 7.23 GEH istatistiği değerleri.

Örölme Bölgesi	Hacim		GEH
	Benzetim programı	Saha gözlemi	
Atakent	1532	2118	13,72
Girne	2044	4107	37,19
Gaziemir	2355	4507	36,74
Otogar	1735	1770	0,84
Örnekköy	4213	4217	0,06

Bu tez çalışmasında VISSIM programında yer alan Wiedemann 99 sürücü davranış parametreleri ile şerit değiştirme için kullanılan parametreler literatürde kullanılan sınır değerler ile programın kendi varsayılan değerleri dikkate alınarak Plackett-Burman deney tasarımında kullanılmıştır.

Bu tez kapsamında kalibrasyon amacıyla kullanılan deęişkenler ile alt ve üst sınır deęerleri Çizelge 7.25'te gösterilmiştir. A-F ile gösterilen Wiedemann 99 parametreleri 7.1 başlığı altında açıklanmıştır. G ile gösterilen minimum uzaklık cinsinden aralık, durma durumunda, şerit deęiştirme için öndeki araçla bulunması gereken minimum mesafedir. H ile gösterilen güvenli mesafe azaltma faktörü orijinal güvenli mesafeye uygulanan katsayıdır. Bu katsayının kullanılma sebebi şerit deęiştiren sürücünün manevra sırasında güvenli mesafeyi azaltmasıdır. J ile gösterilen işbirlikçi fren için maksimum yavaşlama ivmesi, takip durumundaki taşıtın önde giden taşıtın yan şeritten kendi şeridine geçmesine izin vererek ortak frenlemeye başlayıp başlamayacağını ifade etmektedir.

Çizelge 7.25 Başlangıç model girdileri.

Faktör	Parametre	Alt seviye (-1)	Üst seviye (+1)
A	CC0	0,5	3
B	CC1	0,5	1,5
C	CC2	1,5	6
D	CC3	-15	-4
E	CC5	0,1	2
F	CC6	2	20
G	Minimum uzaklık cinsinden aralık	0,45	4
H	Güvenli mesafe azaltma faktörü	0,2	0,8
J	İşbirlikçi fren için maksimum yavaşlama ivmesi	-9	-4

Deney tasarımı, Excel programına eklenti olarak yüklenen SPC (Statistical Process Control) programı ile gerçekleştirilmiştir. Dokuz faktörün yer aldığı Plackett-Burman deney tasarımında 36 tekrar kullanılmıştır. Her bir faktörün anlamlılık düzeyi ANOVA ile belirlenmiştir.

Atakent örülme bölgesi için yapılan Plackett-Burman deney tasarımı sonucunda CCO, minimum mesafe cinsinden aralık ve güvenli mesafe azaltma faktörü %5 anlamlılık düzeyinde bulunmuştur. ANOVA analizi sonuçları Çizelge 7.26'da gösterilmiştir.

Çizelge 7.26 Atakent kavşağı örülme bölgesi ANOVA sonuçları.

Kaynak	Katsayılar	Serbestlik derecesi	Kareler toplamı	Kareler ortalaması	F	p
Sabit	1499.1					
A	-60.13	1	57840	57840	63.944	0.0002
B	-8.88	1	1260.3	1260.3	1.393	0.2825
C	6.25	1	625.0	625.0	0.691	0.4377
D	-16.13	1	4160.3	4160.3	4.599	0.0757
E	-10.88	1	1892.3	1892.3	2.092	0.1982
F	2.75	1	121.0	121.0	0.134	0.7271
G	-70.75	1	80089	80089	88.541	0.0001
H	-20.13	1	6480.3	6480.3	7.164	0.0367
J	-4.50	1	324.0	324.0	0.358	0.5714
Hata		6	5427.3	904.5		

Girne örülme bölgesi için yapılan Plackett-Burman deney tasarımı sonucunda CCO, CC2, minimum mesafe cinsinden aralık, güvenli mesafe azaltma faktörü ve işbirlikçi fren için maksimum yavaşlama ivmesi %5 anlamlılık düzeyinde bulunmuştur. ANOVA analizi sonuçları Çizelge 7.27’de gösterilmiştir.

Çizelge 7.27 Girne kavşağı örülme bölgesi ANOVA sonuçları.

Kaynak	Katsayılar	Serbestlik derecesi	Kareler toplamı	Kareler ortalaması	F	p
Sabit	2160.5					
A	82.38	1	108570	108570	34.556	0.0011
B	-1.75	1	49.00	49.00	0.016	0.9047
C	55.25	1	48841	48841	15.545	0.0076
D	-17.88	1	5112.3	5112.3	1.627	0.2493
E	-22.88	1	8372.3	8372.3	2.665	0.1537
F	1.00	1	16.00	16.00	0.005	0.9454
G	-398.88	1	2545620	2545620	810.234	0.0000
H	-281.75	1	1270129	1270129	404.264	0.0000
J	-235.38	1	886422	886422	282.135	0.0000
Hata		6	18851	3141.8		

Gaziemir örülme bölgesi için yapılan Plackett-Burman deney tasarımı sonucunda CCO, minimum mesafe cinsinden aralık ve güvenli mesafe azaltma faktörü %5 anlamlılık düzeyinde bulunmuştur. ANOVA analizi sonuçları Çizelge 7.28’de gösterilmiştir.

Çizelge 7.28 Gazemir kavşağı örülme bölgesi ANOVA sonuçları.

Kaynak	Katsayılar	Serbestlik derecesi	Kareler toplamı	Kareler ortalaması	F	p
Sabit	2110.8					
A	-83.63	1	111890	111890	33.161	0.0012
B	-23.75	1	9025.0	9025.0	2.675	0.1531
C	-22.25	1	7921.0	7921.0	2.348	0.1764
D	-5.38	1	462.3	462.3	0.137	0.7240
E	-5.13	1	420.3	420.3	0.125	0.7362
F	-18.75	1	5625.0	5625.0	1.667	0.2442
G	-77.38	1	95790	95790	28.389	0.0018
H	-57.25	1	52441	52441	15.542	0.0076
J	-22.38	1	8010.3	8010.3	2.374	0.1743
Hata		6	20245	3374.2		

7.3.2 Genetik algoritma ile en uygun değerlerin bulunması

Genetik algoritma, Holland (1975) tarafından önerilen ve doğal seçim mekanizmasından esinlenen bir eniyileme yöntemidir. Genetik algoritma, seçim, çaprazlama ve mutasyon olmak üzere üç operatöre sahiptir (Mitchell, 1998).

Seçim, hangi kromozomların (aday çözümler) sonraki popülasyonu oluşturacağını belirlemesidir. Çaprazlama, ebeveyn kromozomlarının özelliklerinin birleştirilerek yavrular oluşturulmasıdır. Çaprazlama oranı (p_c), her nesilde oluşan yavru sayısının popülasyon büyüklüğüne (n_{pop}) oranı olarak tanımlanmaktadır. Bu oran, çaprazlama işlemine tabi tutulacak kromozom sayısını belirlemektedir. Mutasyon, çaprazlamadan sonra yavrulara uygulanmakta ve böylece nesildeki kromozomların çeşitliliği artırılmaktadır. Mutasyon oranı (p_m), her genin değiştirilme olasılığını göstermektedir (Gen and Cheng, 1997; Mitchell, 1998).

Genetik algoritmanın çalışma prensibi aşağıda gösterilmiştir:

1. Başlangıç popülasyonunu oluştur
2. Popülasyondaki her bireyin uygunluk değerini hesapla
3. Yeni popülasyon oluşturmak için aşağıdaki adımları uygula

3.1. Üretim için en iyi bireyleri seç

3.2. Yeni yavrular oluşturmak için ebeveynlere çaprazlama uygula

3.3. Yeni çocuklara mutasyon uygula

3.4. Yeni çocukları popülasyona yerleştir

4. Yeni popülasyon ile algoritmayı çalıştır

5. Durma kriteri sağlanana kadar 2 numaralı adıma geri dön.

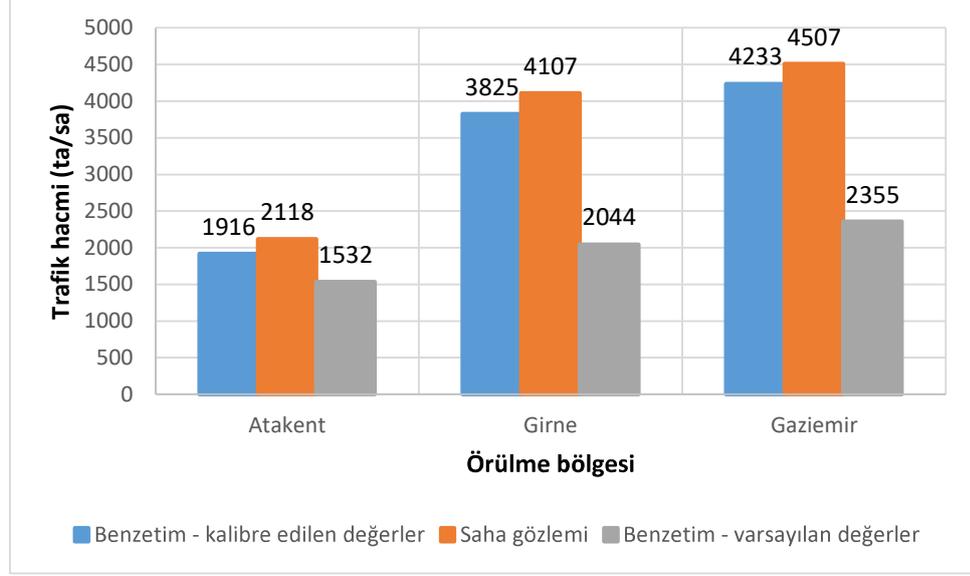
Bu tez kapsamında Plackett-Burman deney tasarımı ile trafik hacmine en çok etkisi olan sürücü davranış parametreleri ile şerit değiştirme parametreleri belirlendikten sonra genetik algoritma ile en uygun değerleri bulunmuştur. Genetik algoritma kullanılarak kalibrasyon yapılan önceki çalışmalar da dikkate alınarak $n_{pop} = 15$, $p_c = 0,8$, $p_m = 0,05$ ve maksimum iterasyon sayısı ise 30 alınmıştır. Uygunluk fonksiyonu için GEH bağıntısı kullanılmış ve en küçük GEH değerini veren çözüm en uygun çözüm olarak kabul edilmiştir.

VISSIM grafik ara yüzü kullanım kolaylığı sağlamaktadır. Ancak kullanıcı benzetimde kullanılan parametrelere dinamik olarak erişmek ve onları değiştirmek istediğinde COM (Component Object Model – Bileşen Nesne Modeli) ile kontrolü sağlayabilmektedir (Tettamanti et al., 2015). VISSIM-Python ortamı ile COM programlama kullanılarak gerçekleştirilen kalibrasyon sonuçları Çizelge 7.29’da sunulmuştur. Faktör isimlerinin karşılık geldiği parametreler Çizelge 7.25’te yer almaktadır. En iyi sonuçlar Atakent örülme bölgesi için 10, Girne örülme bölgesi için 17, Gazimir örülme bölgesi için 16 iterasyon sonucunda bulunmuştur.

Çizelge 7.29 Genetik algoritma sonuçları.

Örülme Bölgesi	GA sonuçları					Hacim		GEH
	A	C	G	H	J	Kalibrasyon sonucu	Saha gözlemi	
Atakent	0.500	-	0.451	0.221	-	1916	2118	4,49
Girne	0.500	1.7281	0.450	0.200	-7.554	3825	4107	4,47
Gazimir	0.622	-	0.669	0.229	-	4233	4507	4,14

Her üç bölgenin saha gözlemlerinden elde edilen hacim, programın varsayılan değerleri ile bulunan hacim ve kalibrasyon sonucunda elde edilen hacim değerleri Şekil 7.2’de gösterilmiştir. Kalibre edilen modelin saha verileriyle uyumlu olduğu grafikten anlaşılmaktadır.



Şekil 7.2 Hacim değerlerinin karşılaştırılması.

7.3.3 SSAM programı ile çatışma verilerinin elde edilmesi

Temsili güvenlik ölçütlerini tespit etmede en yaygın kullanılan yaklaşım, bir benzetim modelinden elde edilen veri çıktısı üzerinde bir son işlemci kullanmaktır. FHWA (2008), bu işlem için Temsili Güvenlik Değerlendirme Modeli (Surrogate Safety Assessment Model - SSAM) geliştirmiştir. SSAM çıktı olarak KKS, İSS, yavaşlama ivmesi, maksimum hız ve bağıl hız parametrelerine ait değerler vermektedir (Young et al., 2014).

SSAM, .trj uzantılı yörünge dosyaları üzerinden çalışmaktadır. SSAM, bu dosyalardan çatışma verisi bilgilerini çıkarmak için her bir yörünge dosyasındaki verileri işlemektedir. Yörünge dosyalarının işlenmesi, her dosyanın boyutuna ve analiz edilmesi gereken yörünge dosyalarının sayısına bağlı olarak değişmektedir (FHWA, 2008).

SSAM, çatışmaları dik açılı, arkadan-çarpma, şerit-değiştirme ve diğer olmak üzere dört grupta analiz etmektedir. Çatışma sınıflandırılması açığa bağlı olarak yapılmaktadır (FHWA, 2008):

- Dik açılı: $|\text{çarpışma açısı}| > 85^\circ$
- Arkadan çarpma: $|\text{çarpışma açısı}| < 30^\circ$
- Şerit değiştirme: $30^\circ \leq |\text{çarpışma açısı}| \leq 85^\circ$

- Diğer: Çatışma açısı bilinmiyor.

İki aşamalı kalibrasyon çalışmalarının ikinci aşamasında SSAM programında KKS sınır değeri değiştirilerek çatışma sayıları gerçek değerlere yakınlaştırılmaya çalışılmıştır (Essa and Sayed, 2015; Fan et al., 2013; Zhou and Huang, 2013). Çalışmaların birçoğunda arkadan çarpma tipi çatışmalar dikkate alınmıştır.

Bu tez kapsamında VISSIM programından elde edilen yörünge dosyaları SSAM programında çalıştırılarak çatışma sayıları elde edilmiştir. İncelenen örülme bölgelerinden tespit edilen KKS değerleri göz önünde bulundurularak gerçeğe en yakın çatışma sayılarını veren KKS değeri belirlenmiştir. Benzetimden elde edilen ile sahada gözlemlenen çatışmalar arasındaki farkı ölçmek için ortalama mutlak yüzde hata (OMYH) kullanılmıştır. OMYH, Denklem 7.4 ile hesaplanmaktadır.

$$OMYH = \frac{100}{n} \sum_{i=1}^n \left| \frac{c_m^i - c_f^i}{c_f^i} \right| \quad (7.4)$$

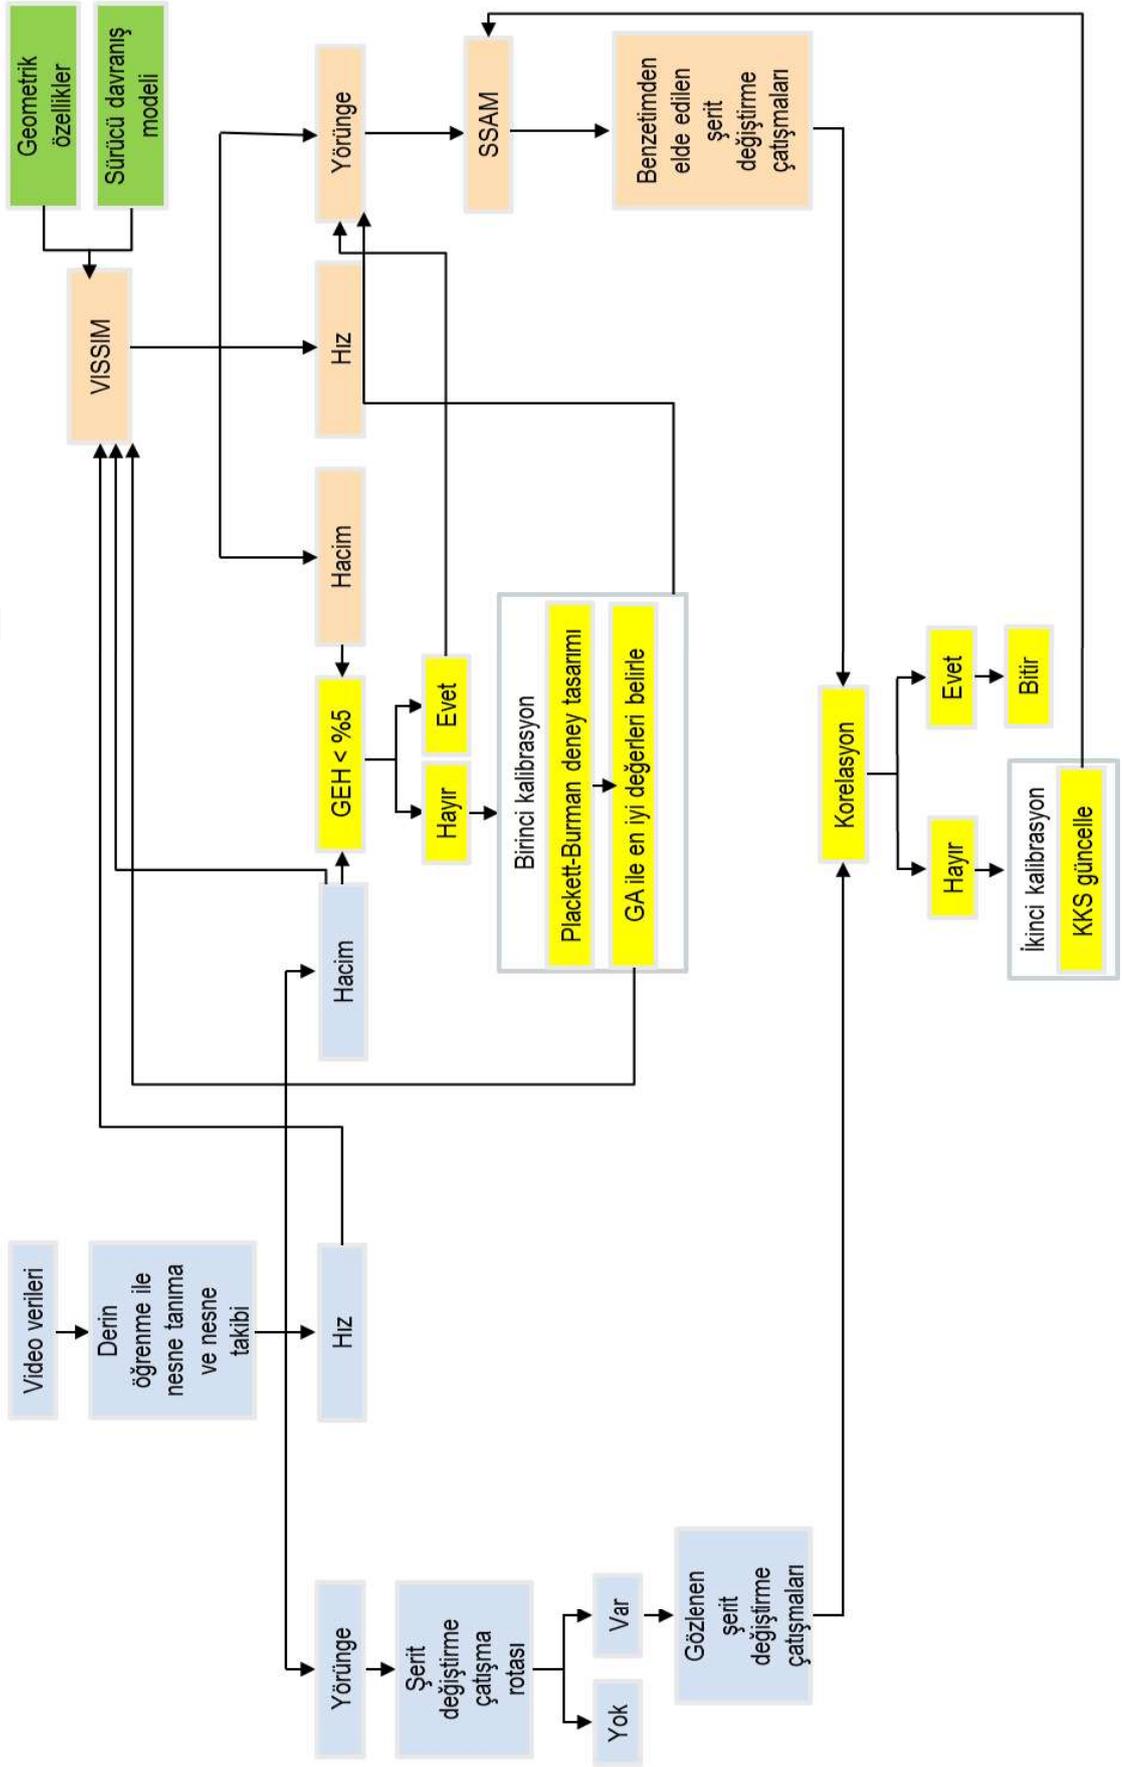
Denklem 7.4'te c_m^i ; i örülme bölgesinde benzetim programından gelen çatışma sayısını, c_f^i ; gözlemlenen çatışma sayısını, n ise örülme bölgesi sayısını ifade etmektedir.

SSAM programı, KKS için 1,5 sn değerini kullanmaktadır. Çizelge 7.30'da gözlemlenen çatışma sayıları, KKS değerinin 1,5 sn kullanıldığı durumda elde edilen çatışma sayıları ve KKS'nin kalibre edilen değeri ile elde edilen çatışma sayıları şerit değiştirme çatışmaları için karşılaştırılmıştır. Denklem 7.4 ile OMYH değeri hesaplandığında %6,96 bulunmuştur.

Çizelge 7.30 Şerit değiştirme çatışmalarının karşılaştırılması.

Örülme bölgesi	Gözlenen	SSAM varsayılan KKS	SSAM kalibre edilmiş
Atakent	169	631	KKS: 0,65 168
Girne	73	650	KKS: 0,50 82
Gaziemir	44	197	KKS: 0,50 52
Örnekköy	54	954	KKS:0,60 56
Otogar	22	26	KKS: 0,76 22

Bu tez çalışmasında iki aşamalı kalibrasyon için oluşturulan akış şeması Şekil 7.3'te sunulmuştur.



Şekil 7.3 İki aşamalı kalibrasyon akış şeması.

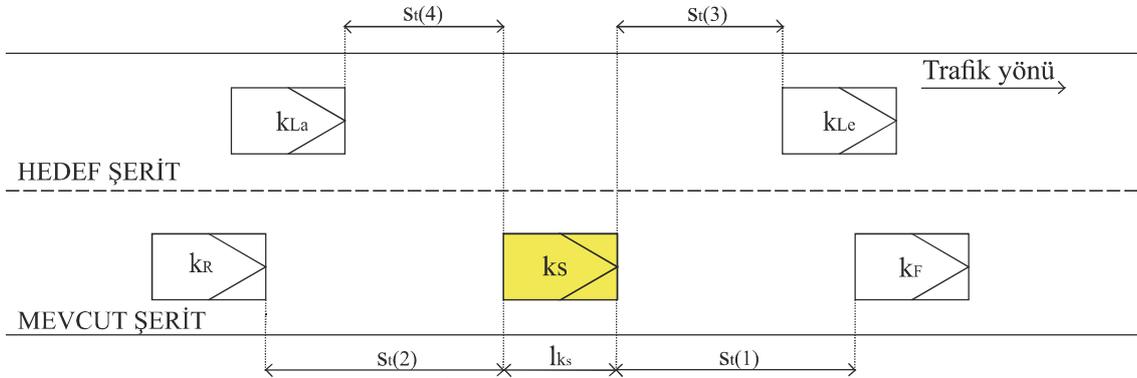
8. YENİ BİR GÜVENLİK ÖLÇÜTÜNÜN ÖNERİLMESİ

Literatürde güvenlik ölçütlerinin genellikle aynı şerit üzerinde birbirini takip eden taşıtlar için kullanıldığı anlaşılmaktadır. Son birkaç yıldır ise şerit değiştirmeye yönelik çalışmaların da yürütülmeye başlandığı görülmektedir. Bu bölümde ilk önce literatürdeki çalışmalara yer verilmiş ve ardından önerilen ölçütler sunulmuştur.

8.1 Şerit Değiştirme Güvenliği ile ilgili Çalışmalar

Şerit değiştirme manevraları; zorunlu şerit değiştirme ve isteğe bağlı şerit değiştirme olmak üzere ikiye ayrılmaktadır. Zorunlu şerit değiştirmeler planlanan varış noktasına gitmek için gerçekleştirilmektedir. Öte yandan isteğe bağlı şerit değiştirmeler daha hızlı sürüş veya daha iyi bir sürüş ortamı sağlamak amacıyla gerçekleştirilmektedir (Zheng, 2014).

Park et al. (2018) çalışmasında şerit değiştirme boyunca şerit değiştiren taşıtın kendi şeridinde ve hedef şeritteki taşıtlarla arasındaki duruş uzunluğu indeksini (DUI) hesaplayarak risk maruziyet seviyesi (RMS) ve risk şiddet seviyesi (RŞS) isimli iki ölçüt oluşturmuştur. Daha sonra bu iki ölçütten faydalanarak şerit değiştirmenin güvenli bir şekilde gerçekleşme olasılığını hata ağacı analizi yöntemi ile belirlemiştir. Şekil 8.1’de k_s ile gösterilen şerit değiştiren taşıt, hem kendi şeridinde önünde (k_F) ve arkasında (k_R) ilerleyen taşıtlarla hem de şerit değiştirmeyi tamamladığında hareket edeceği şeritte (hedef şerit) önünde (k_{Le}) ve arkasında (k_{La}) ilerleyen taşıtlarla etkileşim içindedir. Çalışmada t anında her taşıtın duruş görüş mesafeleri ve şerit değiştiren taşıtın çevresindeki her bir taşıtla arasındaki DUI hesaplanmıştır. Şerit değiştiren taşıt ile çevresindeki taşıtlar arasındaki açıklık $s_t(i)$ ile gösterilmektedir.



Şekil 8.1 Şerit değiştiren taşıt ve çevresindeki taşıtlar (Park et al., 2018).

DUI, Denklem 8.1 ile bulunmaktadır. DUI değerinin sıfırdan büyük olması öndeki taşıt aniden durduğunda arkadaki taşıtın kaza olmadan durabileceği anlamına gelmektedir. Hedef şeritteki taşıtlarla DUI hesaplanırken k_S 'nin mevcut konumunun, hedef şeritte hareket eden taşıtlarla aynı doğrultuda olduğu kabulü yapılmıştır. Denklem 8.1, k_S - k_F taşıtları arasındaki DUI değerinin hesaplanışını göstermektedir.

$$DUI_t(1) = \begin{cases} \text{güvenli} , & \text{eğer } s_t(1) + SSD_t^{k_F} - SSD_t^{k_S} - l_{k_{SF}} > 0 \\ \text{güvenli değil} , & \text{aksi takdirde} \end{cases} \quad (8.1)$$

Yukarıdaki denklemde $l_{k_{SF}}$ öndeki taşıtın uzunluğu, SSD_t ise duruş görüş uzunluğudur. RMS; şerit değiştiren taşıtın şerit değiştirme süresi boyunca teklikeli durumlara ne kadar maruz kaldığını göstermektedir. RŞS ise kaçınma manevrası yapılmadığı takdirde meydana gelebilecek kaza şiddetini belirtmektedir. Bu iki ölçüt hata ağacı analizi ile bir araya getirilerek güvenli şerit değiştirmenin gerçekleşmeme olasılığını gösteren Şerit Değiştirme Risk İndeksi (ŞDRİ) önerilmiştir. Çalışmada otoyol kesimlerinde ve bir çalışma sahasında insansız hava aracı ile yapılan çekimler kullanılarak zorunlu ve isteğe bağlı şerit değiştirmeler incelenmiştir. Şerit değiştiren taşıtın ön tamponunun sol köşesinin şerit çizgisine değdiği an şerit değiştirmenin başlangıcı, arka tamponunun sağ köşesinin şerit çizgisine değdiği an ise şerit değiştirmenin bitişi kabul edilmiştir. RMS, Denklem 8.2 ile bulunmaktadır. Güvenli olmayan şerit değiştirme süresi, DUI'nin sıfırdan küçük olduğu zaman adımlarının toplanmasıyla elde edilmektedir. RMS değerinin artması olası kazalara maruz kalma süresinin arttığını göstermektedir.

$$RMS = \frac{\text{Güvenli olmayan şerit değiştirme süresi}}{\text{Toplam şerit değiştirme süresi}} \quad (8.2)$$

RŞS, Denklem 8.3 ile hesaplanmakta ve gözlemlenen en büyük duruş uzunluğu indeksinin kritik duruş uzunluğu indeksine bölünmesiyle bulunmaktadır. DUI, öndeki ve arkadaki taşıtların duruş görüş mesafelerini karşılaştırarak taşıt takip durumunun güvenli olup olmadığını gösteren bir ölçüttür. DUI_{kritik} , hız değeri 180 km/sa alınarak hesaplanmış ve 565 m bulunmuştur. RŞS değerinin yüksek olması bir kaza meydana gelmesi durumunda beklenen kaza şiddetinin de yüksek olması anlamına gelmektedir.

$$RŞS = \frac{DUI_{gözlenen}^{maksimum}}{DUI_{kritik}} \quad (8.3)$$

Şerit değiştiren taşıtın çevresindeki dört taşıta bağlı olarak güvenli şerit değiştiremememe durumu $\phi(i)$ ile gösterilirse, bu değer Denklem 8.4 ile bulunmaktadır.

$$\varphi(i) = RMS(i) \times R\SS(i) \quad (8.4)$$

ŞDRİ'ye karşılık gelen sistem hatası ise $\Phi(k_S)$ ile gösterilmekte ve Denklem 8.5 ile elde edilmektedir.

$$\Phi(k_S) = 1 - \prod_{i=1}^4 [1 - \varphi(i)] \quad (8.5)$$

Çalışma sonunda 70 adet zorunlu şerit değiştirmenin yapıldığı çalışma sahasındaki risk indeksinin daha yüksek olduğu tespit edilmiştir. Φ için sınır değeri 0,3 olarak seçilmiştir.

Wu et al. (2020) şerit değiştirme kaynaklı riski gerçek zamanlı olarak belirlemek için zaman ve konum esaslı risk tahminini ileri sürmüşlerdir. Çalışmada NGSIM veri seti kullanılmıştır. Taşıtın hareket ettiği şerit numarasının değiştiği andan itibaren 4,5 s öncesi ve 4,5 s sonrası değerlendirilmiştir. Zaman esaslı risk düzeyi (ZRD) Denklem 8.6 ile bulunmaktadır.

$$ZRD_i(t) = e^{-\frac{KKS_i^2}{2\sigma^2}} \quad (8.6)$$

Denklemden KKS; kazadan kaçınma süresini, σ ise reaksiyon süresini göstermektedir ve çalışmada 1,5 sn olarak alınmıştır.

Konum esaslı risk düzeyi (KRD), Park et al. (2018) çalışmasında olduğu gibi DÜİ ile ilişkilidir. Denklem 8.3 ile bulunan risk şiddet seviyesi, konum esaslı risk düzeyi olarak tanımlanmıştır. Ancak bu çalışmada farklı olarak $DÜİ_{kritik}$ sabit bir değer alınmamış, bunun yerine t anındaki en büyük teorik DÜİ, Denklem 8.7 ile gösterildiği gibi hesaplanmıştır.

$$DÜİ_{kritik} = SSD_t^{k_S} + l_{k_{SF}} \quad (8.7)$$

KRD'nin formülü Denklem 8.8 ile gösterilmiştir.

$$KRD_i(t) = \begin{cases} \frac{|KRD_i(t)|}{KRD_i^{kritik}(t)}, & KRD_i(t) < 0 \\ 0, & KRD_i(t) \geq 0 \end{cases} \quad (8.8)$$

Çalışmada çatışma anı KKS değerinin en küçük olduğu an olarak alınmıştır. ZRD ve KRD kullanılarak güvenli şerit değiştirmenin başarısızlık olasılığı hata ağacı analizi ile belirlenmiştir.

8.2 Yeni Güvenlik Ölçütleri

Bu tez çalışması kapsamında konum ve zaman esaslı olmak üzere iki yeni ölçüt önerilmiştir. Bu amaçla şerit değiştiren taşıt ile şerit değiştirmenin başladığı mevcut şerit ve şerit değiştirmenin tamamlandığı hedef şerit üzerinde hareket eden taşıtlar arasındaki etkileşimler ikili olarak incelenmiştir. Bu iki ölçüt hata ağacı analizi ile bir araya getirilerek şerit değiştirmenin güvenli bir şekilde gerçekleşmeme olasılığı hesaplanmıştır.

8.2.1 Konum esaslı risk indeksi

Konum esaslı ölçütün oluşturulmasında duruş uzunluğu indeksi ile en küçük örülme uzunluğunun incelenen örülme bölgesi uzunluğuna oranından faydalanılmıştır. Örülme bölgesinin uzunluğunun da dikkate alındığı bu ölçüte konum esaslı risk indeksi (KERİ) ismi verilmiştir. KERİ bağıntısı Denklem 8.9'da sunulmuştur.

$$KERİ = e^{-\left(\frac{U_{\min_öu}/U_{öu}}{DUİ^{gözlenen}_{maksimum}}\right)} \quad (8.9)$$

$U_{\min_öu}$: Minimum örülme uzunluğu

$U_{öu}$: Gözlemlenen örülme bölgesinin uzunluğu

Örülme bölgeleri zorunlu şerit değiştirmelerin yoğun olarak gerçekleştiği bölgelerdir ve şerit değiştirmenin örülme uzunluğu içinde tamamlanması gerekmektedir. Örülme uzunluğu arttıkça sürücüler şerit değiştirmeyi gerçekleştirmek için daha fazla zaman ve alana sahip olmaktadır. Bu nedenle konum esaslı risk indeksi belirlenirken örülme uzunluğunun etkisi de bağıntıya dâhil edilmiştir.

DUI değeri Denklem 8.1'e göre hesaplanmıştır. Duruş görüş uzunluğu hesaplanırken intikal reaksiyon süresi 1,5 sn alınmıştır. İntikal reaksiyon süresinin önceki çalışmalarda 1 – 2,5 sn arasında alındığı görülmüştür (Park et al., 2018; Shi et al., 2018; Wu et al., 2021). Ancak 1,5 sn değerinin yaygın olarak kullanılması nedeniyle bu çalışmada da intikal reaksiyon süresinin 1,5 sn alınmasına karar verilmiştir (Papaioannou, 2007; Son et al., 2011; Wu et al., 2018; Chen et al., 2021). Şerit değiştirme boyunca DUI değerleri hesaplanmış ve sıfırdan küçük değerlere sahip güvenli olmayan durumlar tespit edilmiştir. En riskli durumun belirlenmesi için DUI değeri gözlemlenen değerlerin en büyüğü olacak şekilde seçilmiştir. Hedef şeritteki taşıtlar ile DUI hesaplanırken 8.1

başlığındaki çalışmalarda kabul edildiği gibi şerit değiştiren taşıtın mevcut konumunun, hedef şeritte hareket eden taşıtlar ile aynı doğrultuda olduğu kabulü yapılmıştır.

8.2.2 Zaman esaslı risk indeksi

Zaman esaslı ölçütün oluşturulmasında kazadan kaçınma süresinden ve fren süresinden yararlanılmıştır. Şerit değiştirme çatışma rotasına sahip iki taşıtın olası kaza noktası belirlenip kazadan kaçınma süresi tespit edilmiş ve ardından kaçınma manevrası olarak aniden frene basıldığı takdirde durma anına kadar geçen süre hesaplanmıştır. Bu ölçüte duruş süresi risk indeksi (DSRİ) ismi verilmiştir. DSRİ bağıntısı Denklem 8.10'da sunulmuştur.

$$DSRİ = e^{-\left(\frac{KKS_{gözlenen}^{minimum}}{F_t}\right)} \quad (8.10)$$

$KKS_{gözlenen}^{minimum}$: DUI değerinin sıfırdan küçük olduğu durumlardaki en küçük KKS.

F_t : Fren süresi, frene basıldığı andan durma anına kadar geçen süre.

Şerit değiştirme boyunca DUI değerinin sıfırdan küçük olduğu güvenli olmayan değerler belirlenmiş ve karşılık gelen KKS değerleri kaydedilmiştir. Bu değerlerden en küçüğü gözlenen minimum KKS değeri olarak alınmıştır. Şerit değiştiren taşıt ile incelenen diğer taşıt arasında çarpaz bir çarpışma rotası varsa kesişme noktasına varma süresi KKS değeri olarak alınmıştır. Taşıt takip durumunda ise Denklem 3.1'de gösterilen geleneksel bağıntı kullanılmıştır.

Fren süresi ise sürücünün aniden frene basması durumunda ne kadar süre sonra duracağını göstermektedir. F_t , Denklem 8.11 ile hesaplanmıştır.

$$F_t = \frac{V}{35,3 \times f} \quad (8.11)$$

V : Taşıt hızı (km/sa)

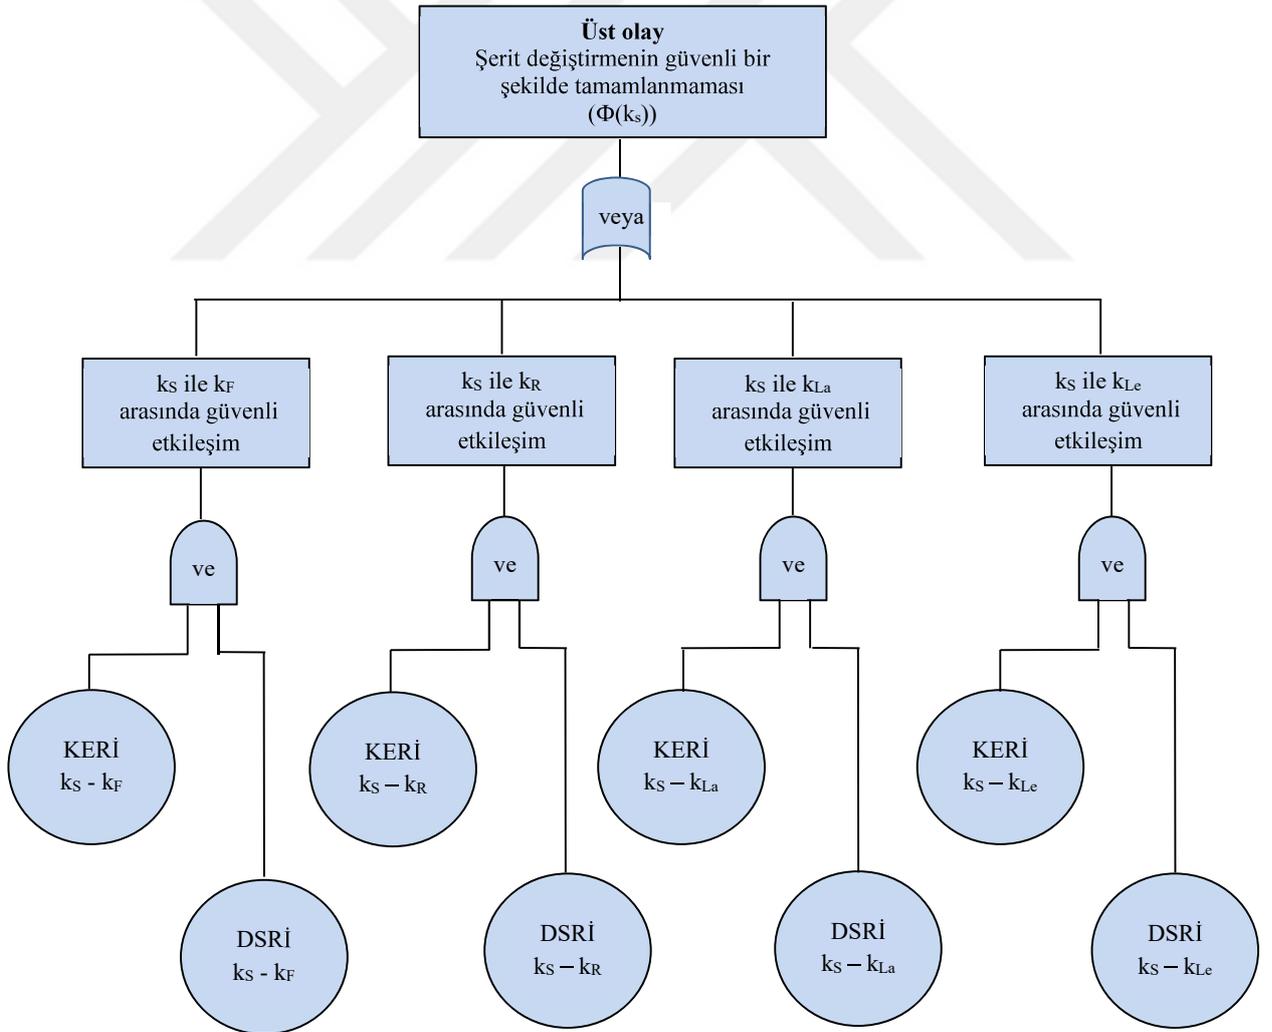
f : Sürtünme katsayısı

Denklem 8.11'deki f değeri kuru ve asfalt yol kaplaması için 0,6 alınmıştır.

KKS olası kaza noktasına varma süresi, F_t fren süresinden büyük ise kaza gerçekleşmeyecektir. Bu ölçüt ile fren süresi ile KKS değerlerinin kaza olma olasılığına etkisi tespit edilmektedir.

8.2.3 Şerit değiştirme risk indeksi

Bu tez çalışmasında KERİ ve DSRİ ölçütleri hata ağacı analizi (HAA) yöntemi ile bir araya getirilerek şerit değiştirme risk indeksi (ŞDRİ) belirlenmiştir. HAA kapsamında risk derecesi araştırılan ana istenmeyen olay üst olay, daha ileri bir ayrıştırma olmaksızın üst olayı tetikleyen olay ise esas olay olarak gösterilmektedir. Analizde yer alan “ve” kapısı, sembol altında gösterilen tüm olayların, “veya” kapısı ise sembol altındaki olayların herhangi birinin gerçekleşmesi ile bir üst olayın gerçekleşeceğini ifade etmektedir (Yalçinkaya ve diğ., 2020). Şekil 8.2’de tez kapsamında oluşturulan hata ağacı gösterilmiştir.



Şekil 8.2 Hata ağacı yapısı.

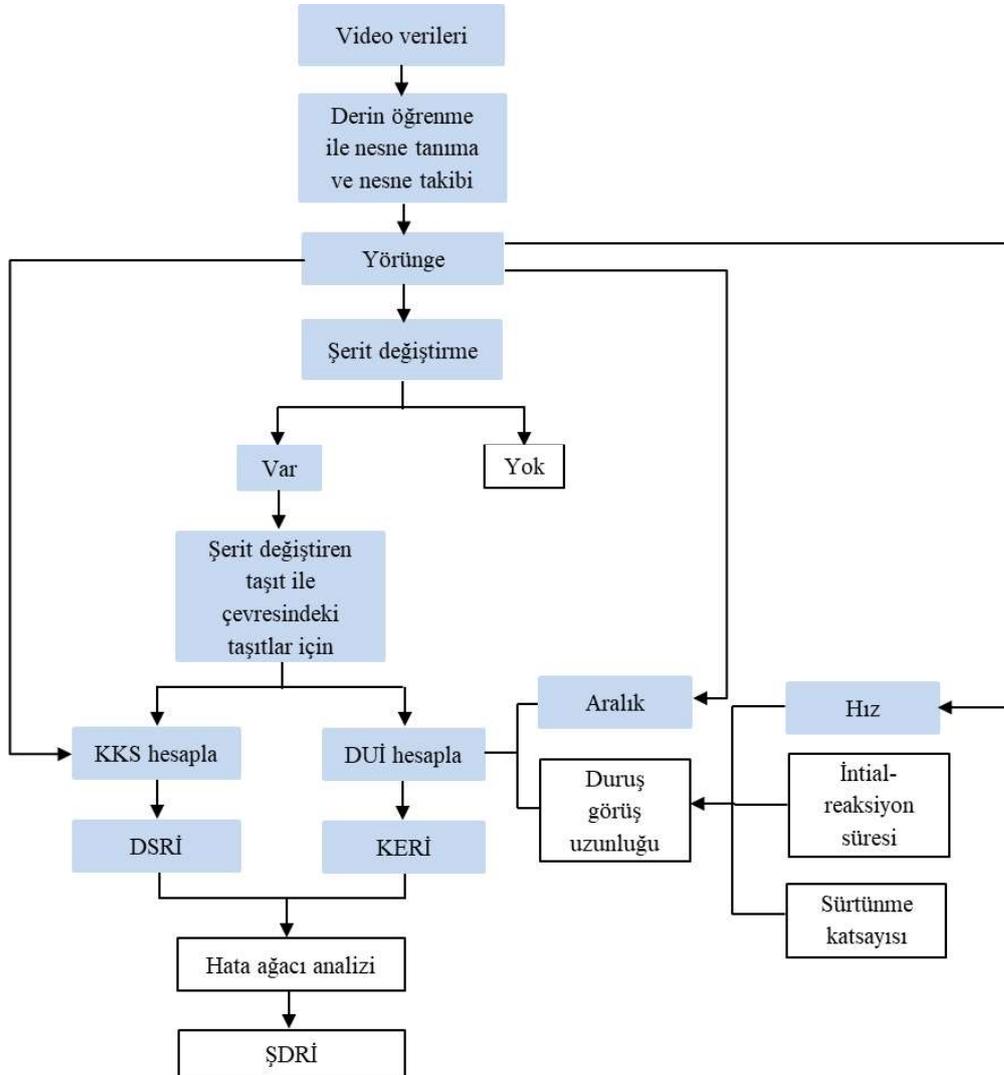
Şerit değiştiren taşıtın (k_S) çevresindeki dört taşıta bağlı olarak (k_F , k_R , k_{La} , ve k_{Le}) güvenli şerit değiştirememeye durumu ($\varphi(i)$) Denklem 8.12 ile hesaplanmaktadır.

$$\varphi(i) = KERİ(i) \times DSRİ(i) \quad (8.12)$$

ŞDRİ ise Denklem 8.13 ile elde edilmektedir.

$$\Phi(k_S) = 1 - \prod_{i=1}^4 [1 - \varphi(i)] \quad (8.13)$$

Bu tez çalışmasında güvenlik ölçütleri için oluşturulan akış şeması Şekil 8.3'te sunulmuştur.



Şekil 8.3 Güvenlik ölçütü akış şeması.

8.3 Örülme Bölgelerinin Güvenlik Analizi

Bu tez kapsamında incelenen örülme bölgeleri önerilen güvenlik ölçütleri ile değerlendirilmiştir. Çizelge 8.1’de her örülme bölgesi için KERİ ve DSRİ ölçütlerinin ortalama, en büyük, en küçük değerleri ile standart sapmaları verilmiştir. Çizelge 8.2’de ise örülme bölgelerinde DUİ değerinin sıfırın altına düştüğü çatışma sayıları, $\varphi(i)$ ve şerit değiştirme risk indeksine karşılık gelen $\Phi(k_s)$ değerlerinin ortalamaları sunulmuştur. Riskli çatışma sayıları incelendiğinde en yüksek değer Atakent örülme bölgesinde, en düşük değer ise Otogar örülme bölgesinde gözlemlenmiştir. Atakent örülme bölgesinde şerit değiştiren taşıt ile çevresindeki taşıtlardan en fazla üç tanesi, Girne, Gazimir, Örnekköy örülme bölgelerinde iki tanesi, Otogar örülme bölgesinde ise sadece bir tanesi sıfırın altında DUİ değerine sahiptir. KERİ ve DSRİ’nin minimum değerleri kıyaslandığında en düşük değerler Atakent örülme bölgesinde tespit edilmiştir. Bu bölgede incelenen çatışma sayısının diğer bölgelere göre fazla olması hesaplanan değerlerin çeşitlilik göstermesine sebep olmuştur. Ortalama ŞDRİ değerleri incelendiğinde en düşük değer Otogar örülme bölgesinde görülmüştür. Şerit değiştiren taşıtın tek bir taşıt ile negatif DUİ değerine sahip olması ŞDRİ değerinin diğer bölgelere göre daha düşük çıkmasının sebeplerinden bir tanesidir.

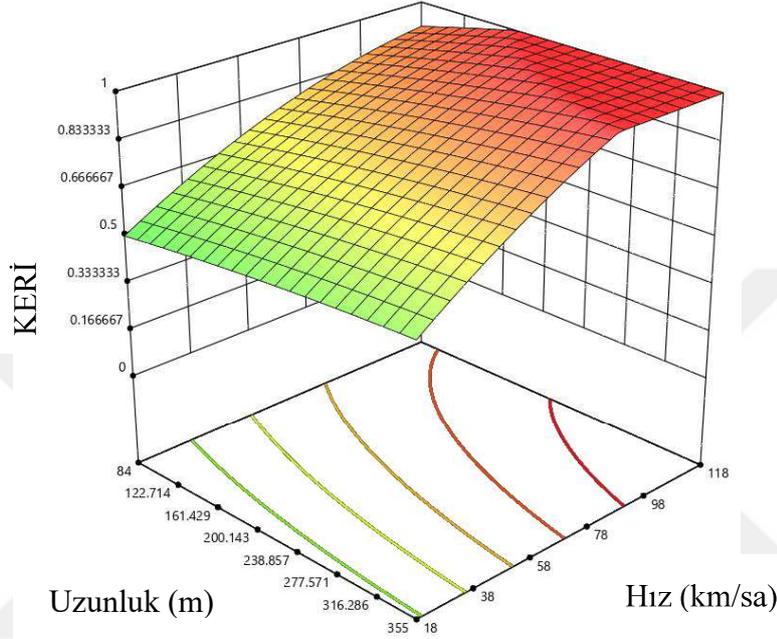
Çizelge 8.1 Örülme bölgelerinde önerilen ölçütler ile elde edilen KERİ ve DSRİ değerleri.

Kaynak	Atakent		Girne		Gazimir		Otogar		Örnekköy	
	KERİ	DSRİ	KERİ	DSRİ	KERİ	DSRİ	KERİ	DSRİ	KERİ	DSRİ
Ortalama	0,763	0,683	0,679	0,669	0,704	0,532	0,898	0,537	0,904	0,668
En büyük	0,971	0,956	0,977	0,867	0,965	0,968	0,995	0,765	0,983	0,927
En küçük	0,000	0,09	0,028	0,270	0,213	0,123	0,714	0,226	0,635	0,243
Standart sapma	0,256	0,189	0,346	0,179	0,278	0,278	0,106	0,219	0,085	0,209

Çizelge 8.2 Çatışma sayıları ve ŞDRİ sonuçları.

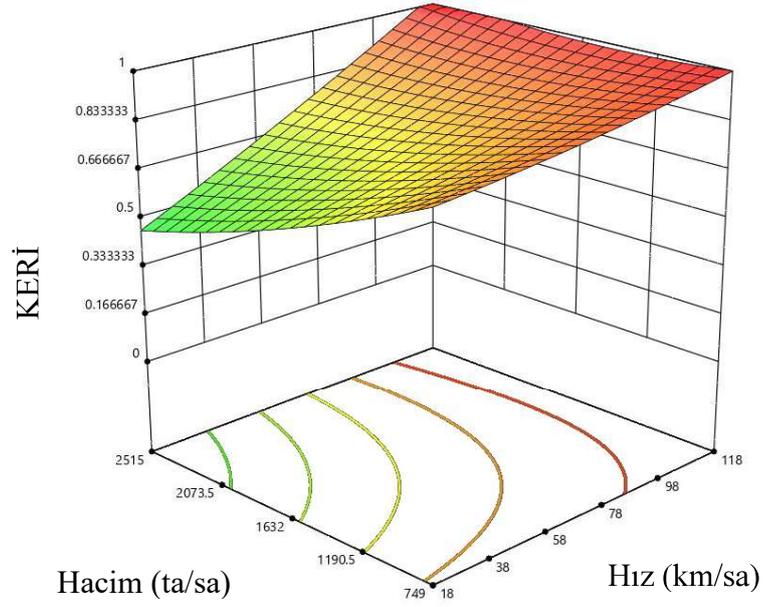
Örülme bölgesi	Çatışma sayısı	$\varphi(1)$	$\varphi(2)$	$\varphi(3)$	$\varphi(4)$	ŞDRİ ($\Phi(k_s)$)
Atakent	88	0,52	0,64	0,61	-	0,60
Girne	19	0,47	0,73	-	-	0,54
Gazimir	26	0,43	0,45	-	-	0,54
Örnekköy	16	0,61	0,65	-	-	0,63
Otogar	8	0,47	-	-	-	0,47

Şekil 8.4'te KERİ-Hız-Örülme uzunluğu ilişkisi gösterilmiştir. Şerit değiştirme rotasına sahip taşıtların hız değeri arttıkça KERİ değerinin önemli ölçüde arttığı tespit edilmiştir. Hız değerinin 98 km/sa ve üstü olduğu durumlarda ise risk seviyesinin en üst seviyede olduğu dikkat çekmektedir. Örülme uzunluğunun KERİ değerine etkisi hız kadar belirgin olmamakla birlikte örülme uzunluğu arttıkça KERİ değerinde de artış olduğu gözlenmiştir.



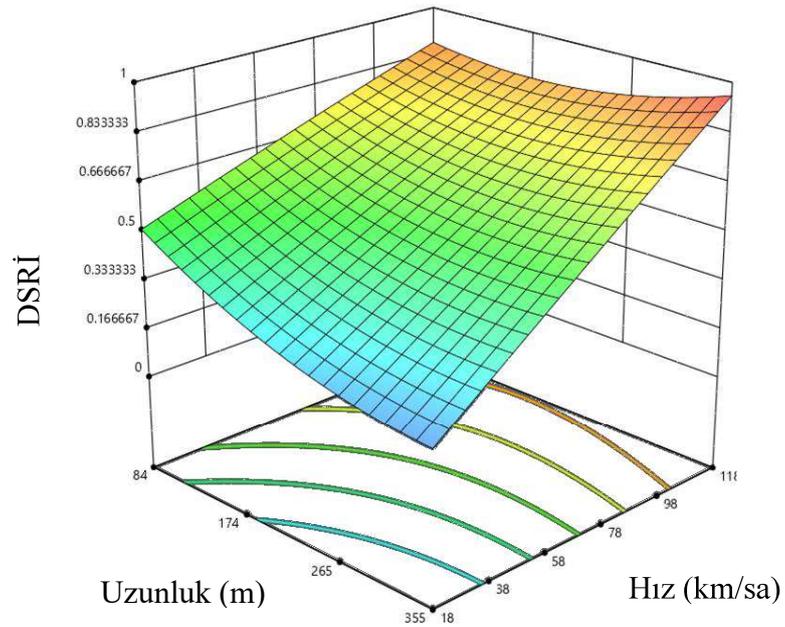
Şekil 8.4 KERİ-Hız-Örülme uzunluğu ilişkisi.

Şekil 8.5'te ise KERİ-Hız-Hacim ilişkisi gösterilmiştir. Hacim azaldıkça KERİ değerinde artış gözlenmiştir. Bu tez çalışması kapsamında zorunlu şerit değiştirmeler dikkate alınmıştır. Bu tip şerit değiştirmeler yoğun olarak örülme şeridi ile yanındaki şeritte gözlenmektedir. Bu sebeple hacim değerinin belirlenmesinde örülme şeridi ile yanındaki şerit dikkate alınmıştır. Trafik hacminin en düşük gözlemlendiği bölge Otogar kavşağı üzerinde yer alan örülme bölgesidir. Trafik hacmine bağlı olarak yaşanan çatışma sayısı da diğer örülme bölgelerine kıyasla daha düşük sayıda tespit edilmiştir. Ancak hesaplanan KERİ değerleri 0,70 ve üzerinde bulunmuştur.

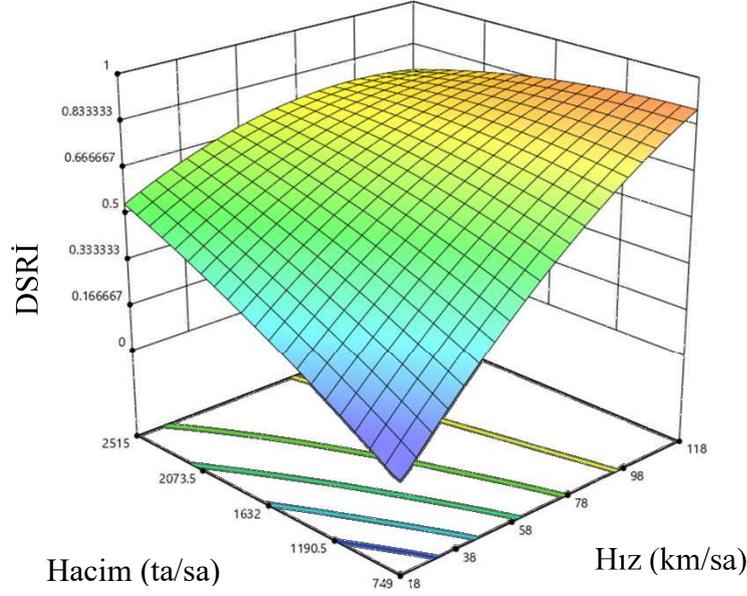


Şekil 8.5 KERİ-Hız-Hacim ilişkisi.

Şekil 8.6’da DSRİ-Hız-Örülme uzunluğu ilişkisi gösterilmiştir. Hız arttıkça DSRİ değerinin arttığı gözlenmiştir. Taşıt hızı arttıkça taşıtın durması için gereken süre de artmaktadır. Fren süresinin KKS değerinden büyük olması durumunda kaza riski artmakta dolayısıyla DSRİ de daha yüksek değerlere sahip olmaktadır. DSRİ değerinin örülme uzunluğu arttıkça azaldığı tespit edilmiştir. Şekil 8.7’de ise DSRİ-Hız-Hacim ilişkisi gösterilmiştir. Hacim azaldıkça DSRİ değerinde azalma gözlenmiştir.

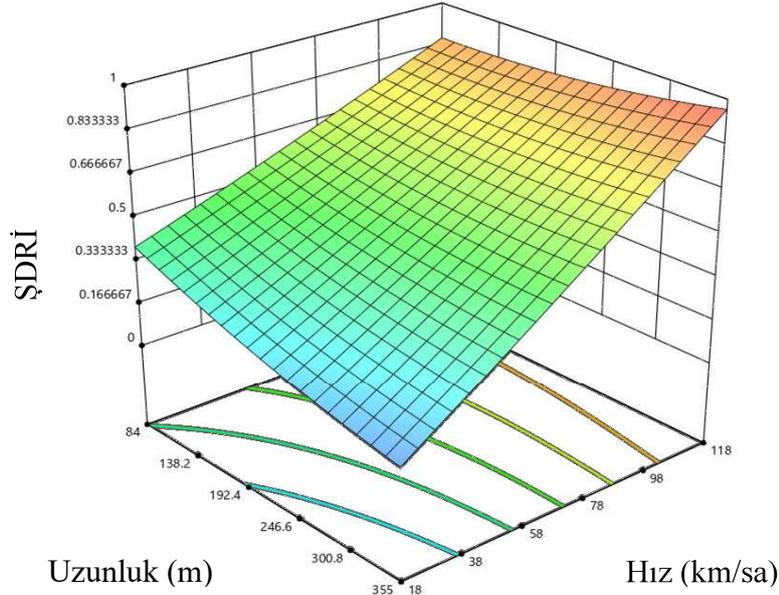


Şekil 8.6 DSRİ-Hız-Örülme uzunluğu ilişkisi.

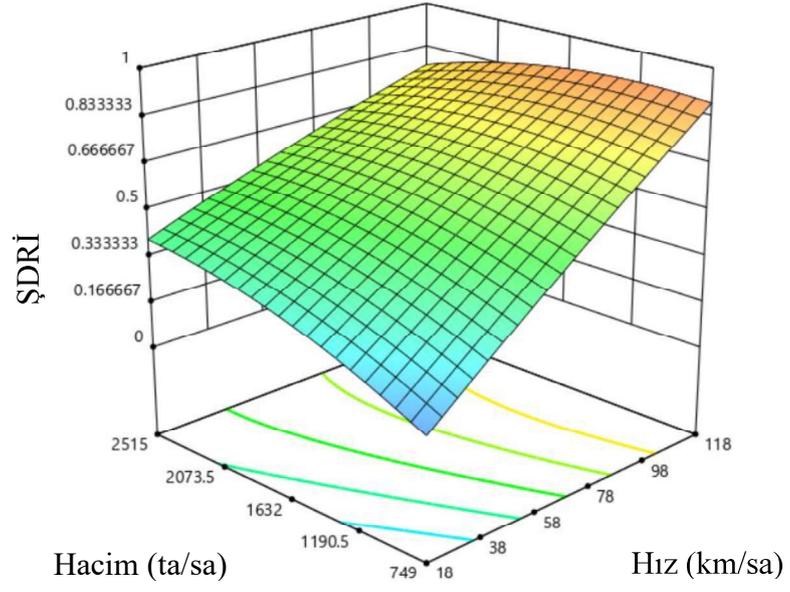


Şekil 8.7 DSRİ-Hız-Hacim ilişkisi.

Şekil 8.8’de ŞDRİ-Hız-Örülme uzunluğu ilişkisi gösterilmiştir. ŞDRİ değeri, KERİ ve DSRİ ölçütlerinin hata ağacı analizine tabi tutulması ile bulunmaktadır. Her iki ölçüt de hız ile birlikte artış göstermiştir. Dolayısıyla ŞDRİ değerinin de hız arttıkça daha yüksek değerlere sahip olduğu görülmüştür. Hız değeri arttıkça ŞDRİ değerinin arttığı gözlenmiştir. Örülme uzunluğu etkisi incelendiğinde ŞDRİ’nin örülme uzunluğu arttıkça azaldığı gözlenmiştir. Şekil 8.9’da ise ŞDRİ-Hız-Hacim ilişkisi gösterilmiştir. Hacim azaldıkça ŞDRİ değerinde azalma gözlenmiştir.



Şekil 8.8 ŞDRİ-Hız-Örülme uzunluğu ilişkisi.



Şekil 8.9 ŞDRİ-Hız-Hacim ilişkisi.

9. SONUÇLAR VE DEĞERLENDİRMELER

Bu tez çalışması kapsamında şerit değiştirme davranışı için iki yeni güvenlik ölçütü önerilmiştir. Güvenlik ölçütleri bir bölgede kaza meydana gelmesini beklemeden güvenlik değerlendirmesi yapılmasına olanak sağlamaktadır. Güvenlik ölçütleri kullanılırken kaza oluşumuna sebep olabilecek çatışmalar dikkate alınmaktadır. Literatürde yer alan çalışmalar incelendiğinde araştırmacıların genellikle arkadan çarpma tipi çatışmalara odaklandığı anlaşılmaktadır. Ancak örülme bölgeleri gibi şerit değiştirmelerin yoğun olarak gerçekleştiği bölgelerde şerit değiştirme çatışmalarının dikkatle değerlendirilmesi gerekmektedir.

Örülme bölgeleri bir katılım kesimini bir ayrılma kesiminin takip ettiği ve birbirleriyle bir yardımcı şerit aracılığıyla bağlandığı bölgelerdir. Örülme bölgelerinin uzunlukları birbirinden farklı olmakla birlikte çok kısa olduğu takdirde şerit değiştirmelerin gerçekleşmesi zorlaşmaktadır. Trafik hacminin yüksek olduğu durumlarda ise sürücüler şerit değiştirebilmek için küçük aralıkları kabul etmek zorunda kalmaktadırlar. Örülme uzunluğunun artması ise sürücülere şerit değiştirebilmeleri için daha fazla zaman ve alan sağlamaktadır. Tez kapsamında incelenen örülme bölgelerinden Atakent örülme bölgesinin uzunluğu, HCM 2016 tarafından önerilen minimum değer olan 91 m'nin (300 ft) altında kalan tek örülme bölgesidir ve en yüksek çatışma sayısı bu örülme bölgesinde tespit edilmiştir. Örülme uzunluğu arttıkça gözlemlenen çatışma sayıları da azalmıştır.

Temsili güvenlik ölçütleri zaman, konum ve ivme esaslı olmak üzere üç başlık altında değerlendirilmektedir. Güvenlik değerlendirmesi çalışmalarında zaman esaslı ölçütlerin sıklıkla tercih edildiği görülmüştür. KKS zaman esaslı ölçütlerden bir tanesi olup sonradan ileri sürülen birçok ölçüte de ilham kaynağı olmuştur. Kazadan kaçınma süresi öndeki taşıtın arkadaki taşıttan daha düşük hızda hareket ettiği taşıt takip durumu için kullanılmaya başlamıştır. Belirtilen durumda kazanın ne kadar süre sonra gerçekleşeceği hesaplanmıştır. Bu ölçüt zaman içinde farklı kabuller altında geliştirilerek günümüzde de geçerliliğini sürdüren bir ölçüt olarak karşımıza çıkmaktadır.

Şerit değiştirme durumunda KKS hesabının yapılabilmesi için farklı bir yöntem kullanılmıştır. Şerit değiştirme çatışma rotasına sahip iki taşıtın olası çarpışma noktası belirlenerek taşıtların o noktaya varış süreleri hesaplanmıştır. Ardından olası kaza tipine göre kritik KKS değerleri tespit edilmiştir. KKS değerleri şerit değiştirme boyunca sürekli olarak kaydedilmiştir.

Tez kapsamında şerit deęiřtirme davranıřından kaynaklı yandan çarpma tipi kazalar için kritik KKS deęerinin belirlenmesi hedeflenmiřtir. Bu deęerin yandan çarpma türü kazalar için geliştirilecek uyarı sistemlerinde kullanılabileceęi düşünölmektedir. Bu amaçla kaydedilen KKS deęerlerinden en küçükleri dikkate alınmıř ve en sık görölen deęer kritik KKS olarak seçilmiřtir. Örölme bölgelerinde hesaplanan kritik KKS deęerlerinin 0,53 – 0,76 sn arasında deęiřtięi tespit edilmiřtir. Gözlemlenen deęerler birlikte analiz edildięinde ise 0,74 sn deęeri kritik KKS deęeri olarak önerilmiřtir.

Bu tez çalıřmasında sahada gözlenen çatıřmaların benzetim modeli ile elde edilen çatıřma sayıları ile uyum saęlaması amacıyla iki ařamalı kalibrasyon yöntemi uygulanmıřtır. ABD Federal Karayolu İdaresi tarafından geliştirilen SSAM programı ile VISSIM programlarından faydalanılarak çatıřma sayıları belirlenmiřtir. Üç adet örölme bölgesinde iki ařamalı kalibrasyona, iki adet örölme bölgesinde ise tek ařamalı kalibrasyona ihtiyaç duyulmuřtur. Benzetim programları güvenlik deęerlendirmesinde tercih edilen yöntemlerden bir tanesidir. Ancak gerçekçi sonuçlar elde etmek için kalibrasyon çalıřmasının yapılması gerekmektedir.

Bir tařıt şerit deęiřtirirken çevresindeki tařıtlarla etkileřim içindedir. Bu tařıtlar kendi şeridinde önünde ve arkasında hareket eden tařıtlar ve hedef şeritte önünde ve arkasında hareket eden tařıtlar olmak üzere en fazla dört adettir. Bu tez çalıřmasında zaman esaslı (DSRİ) ve konum esaslı (KERİ) olmak üzere iki yeni güvenlik ölçütü önerilmiřtir. Önerilen güvenlik ölçütleri şerit deęiřtiren tařıtın çevresindeki tařıtlarla ikili etkileřimleri ele alınarak hesaplanmaktadır. DSRİ ölçütünün oluřturulmasında kazadan kaçınma süresinden ve fren süresinden; KERİ ölçütünün oluřturulmasında ise duruř uzunluęu indeksi ile en küçük örölme uzunluęunun incelenen örölme bölgesi uzunluęuna oranından yararlanılmıřtır.

DSRİ, KKS ile fren süresinin birbirine yakınlıęının kaza oluřumu riskine etkisini gösteren bir ölçüttür. Fren süresinin KKS deęerinden küçük olması tařıtın olası çarpıřma noktasına gelmeden durabileceęi anlamına gelmektedir. KKS arttıkça ve fren süresi azaldıkça kaza riski de azalacaktır. KERİ ise kazanın řiddeti hakkında bilgi veren bir ölçüttür. DÜİ deęerinin sıfırın altına düřtüęü durumlarda KERİ deęeri hesaplanmaktadır. DÜİ deęeri büyödükçe kazanın řiddetinin de artması beklenmektedir. Bu iki ölçüt hata ağacı analizi ile bir araya getirilerek şerit deęiřtirmenin güvenli bir řekilde gerçekteşmeme olasılıęına karřılık gelen řDRİ hesaplanmıřtır. řDRİ deęerinin bire yaklařması şerit deęiřtirmeden kaynaklı kaza meydana gelme riskinin arttıęı anlamına gelmektedir.

Önerilen her iki ölçütün hız arttıkça bire yaklaştığı görülmüştür. Bu sonuç hız arttıkça kaza gerçekleşme olasılığının ve şiddetinin arttığını göstermektedir. Örülme uzunluğunun etkisi değerlendirildiğinde KERİ değerinde önemli bir etki yaratmamakla birlikte DSRİ ve ŞDRİ için örülme uzunluğu arttıkça daha küçük değerler tespit edilmiştir. Trafik hacminin etkisi incelendiğinde ise hızın 80 km/sa altında olduğu durumlarda hacim azaldıkça DSRİ ve ŞDRİ değerlerinin belirgin olarak azaldığı ancak 80 km/sa üstündeki hız değerlerinde her iki ölçütte de artışın görüldüğü tespit edilmiştir. ŞDRİ değerinin hız ile birlikte artış göstermesi çevre yolları gibi hız sınırının yüksek olduğu yollarda kaza riskinin ve şiddetinin de yüksek olduğunu göstermektedir.

Sonuç olarak, tez çalışmasında şerit değiştirme uyarı sistemlerinde kullanılabilecek kritik KKS değeri belirlenmiş, iki aşamalı kalibrasyon uygulanarak gerçeğe uygun çatışma sayıları elde edilmiş ve şerit değiştirmeler için kullanılabilecek iki yeni ölçüt ve bir risk indeksi önerilmiştir.

Bu çalışmada incelenen çatışmalar örülme bölgelerinde gerçekleşen zorunlu şerit değiştirmelerdir. Bundan sonraki çalışmalarda farklı trafik tesislerinde gerçekleşen zorunlu ve isteğe bağlı şerit değiştirmelerin incelenmesi önerilmektedir.

Örülme bölgelerinde gerçekleşen çatışma sayılarının uzunluk kısaltıldıkça artması tasarım esnasında göz önünde bulundurulması gereken bir kıstastır. Atakent örülme bölgesinin örülme uzunluğu 84 m ve gözlemlenen çatışma sayısı 169 iken 100 m örülme uzunluğuna sahip Girne kavşağında %43,2 daha az çatışma tespit edilmiştir. Örülme bölgelerinde güvenli bir şekilde şerit değiştirebilmek için örülme uzunluğunun belirlenmesinde çatışma sayılarının azaltılması da hedeflenmelidir.

İncelenen örülme bölgelerinde yapılan çekimlerin tamamı açık ve güneşli hava koşullarında gerçekleştirilmiştir. Yağmurlu ve sisli hava koşullarında sürüş davranışı farklılık göstereceğinden kazadan kaçınma süresi ve şerit değiştirme risk indeksi değerlerinde de farklılıklar olması beklenmektedir. Bundan sonraki çalışmalarda değişik hava koşullarında gözlem yapılması önerilmektedir.

İncelenen bölgelerdeki kaza verileri kullanılarak kazaların hangi ŞDRİ değerlerinde meydana geldiğinin belirlenmesi, ŞDRİ için bir eşik değerin tespit edilmesinde kullanılabilir. Böylelikle kazaya sebep olacak tehlikeli durumların ayırt edilmesi sağlanabilir.

Bu tez çalışmasında duruş görüş uzunluğunun belirlenmesinde intikal-reaksiyon süresi 1,5 sn alınmıştır. Sürücüsüz taşıtlarda ise bu süre 0,1 – 0,2 sn mertebelerindedir. Dolayısıyla tamamen insanların kullandığı taşıtların oluşturduğu trafik ile sürücüsüz taşıtların da yer aldığı karışık trafik durumunda ŞDRİ değerinin belirlenmesinde farklı intikal-reaksiyon sürelerinin kullanılması gerekli olacaktır. ŞDRİ değerinin belirlenmesine yönelik çalışmaların sürücüsüz taşıtlar da dikkate alınarak yapılması önerilmektedir.



KAYNAKLAR DİZİNİ

- Agren, S.**, 2017, Object tracking methods and their areas of application: A meta-analysis: A thorough review and summary of commonly used object tracking methods, *Computer Science*.
- Albawi, S., Mohammed, T.A. and Al-Zawi, S.**, 2017, Understanding a convolutional neural network, *International Conference on Engineering and Technology (ICET)*, Antalya, Türkiye.
- Allen, B.L. and Shin, B.T.**, 1978, Analysis of Traffic Conflicts and Collisions, Report No. TRR 667, 67-74pp.
- Amundsen, F.H. and Hydén, C.**, 1977, Proceedings: First workshop on Traffic Conflicts, Eds. F.H. Amundsen and C. Hyden, Oslo, Norway.
- Amundsen, F.H. and Larsen, O.E.**, 1977, Traffic conflicts technique – status in Norway, *Proceedings of the 1st Workshop on Traffic Conflicts*, Oslo, Norway.
- Archer, J.**, 2005, Indicators for Traffic Safety Assessment and Prediction and their Application in Micro-Simulation Modelling: A Study of Urban and Suburban Intersections, PhD Thesis, Royal Institute of Technology.
- Arun, A., Haque, M.M., Bhaskar, A., Washington, S. and Sayed, T.**, 2021, A systematic mapping review of surrogate safety assessment using traffic conflict techniques, *Accident Analysis and Prevention*, 153:106016.
- Astarita, V., Giofré, V., Guido, G. and Vitale, A.**, 2021, A Review of the use of traffic simulation for the evaluation of traffic safety levels: can we use simulation to predict crashes?, *Transportation Research Procedia*, 52:244-251 pp.
- Athanesious, J., and Suresh, P.**, 2012, Systematic survey on object tracking methods in video, *International Journal of Advanced Research in Computer Engineering and Technology*, 1(8):242-247 pp.
- Avidan, S.**, 2004, Support vector tracking, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 26(8):1064-1072 pp.
- Bandi, M.M. and George, V.**, 2019, Microsimulation modelling in vissim on short-term and long-term improvements for mangalore city road network, *World Conference on Transport Research – WCTR*, 48:2725-2743 pp.

KAYNAKLAR DİZİNİ (devam)

- Bewley, A., Ge, Z., Ott, L., Ramos, F. and Upcroft, B.**, 2016, Simple online and realtime tracking, *IEEE International Conference on Image Processing*, 3464-3468pp.
- Bochkovskiy, A., Wang, C.Y. and Liao, H.Y.M.**, 2020, YOLOv4: optimal speed and accuracy of object detection, *arXiv:2004.10934*, 1-17 pp.
- Box, G.E.P., Hunter, J.S. and Hunter, W.G.**, 2005, *Statistics for Experimenters, Design, Innovation, and Discovery*, New York, Wiley.
- Brackstone, M. and McDonald, M.**, 1999, Car-following: a historical review, *Transportation Research Part F*, 2:181-196 pp.
- Bradski, G.**, 1998, Real time face and object tracking as a component of a perceptual user interface, *Fourth IEEE Workshop on Applications of Computer Vision WACV'98*, 214-219 pp.
- Brown, T.L.**, 2005, Adjusted minimum time-to-collision (TTC): A robust approach to evaluating crash scenarios, *Proceedings of the Driving Simulation Conference North America*, 40:40-48 pp.
- Buduma, N. and Locascio, N.**, 2017, *Fundamentals of Deep Learning: Designing Next-Generation Machine Intelligence Algorithms*, O'Reilly Media, Inc.
- Cai, Z. and Vasconcelos, N.**, 2018, Cascade r-cnn: delving into high quality object detection, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 6154-6162 pp.
- Chen, Z.**, 2003, Bayesian filtering: from kalman filters to particle filters, and beyond, *Statistics: A Journal of Theoretical and Applied Statistics*, 1-69 pp.
- Chen, Q., Huang, H., Li, Y., Lee, J., Long, K., Gu, R. and Zhai, X.**, 2021, Modeling accident risks in different lane-changing behavioral patterns, *Analytic Methods in Accident Research*, 30:100159 pp.
- Chin, H.C. and Quek, S.T.**, 1997, Measurement of traffic conflicts, *Safety Science*, 26(3):169-185 pp.
- Cooper, P.J.**, 1977, State-of-the-art. report on traffic conflicts research in Canada, *Proceedings of the 1st Workshop on Traffic Conflicts*, Oslo, Norway.
- Cooper, P.J.**, 1984, Experience with traffic conflicts in Canada with emphasis on “post encroachment time” techniques, *International calibration study of traffic conflict techniques*, Springer, Berlin, Heidelberg, 75-96 pp.

KAYNAKLAR DİZİNİ (devam)

- Cooper, D.F. and Ferguson, N.**, 1976, Traffic studies at T-junctions—a conflict simulation model. *Traffic Engineering and Control*, 17:306-309 pp.
- Cunto, F.J.C.**, 2008, Assessing Safety Performance of Transportation Systems using Microscopic Simulation, PhD Thesis, University of Waterloo, Canada, 190p.
- Cunto, F. and Saccomanno, F.F.**, 2008, Calibration and validation of simulated vehicle safety performance at signalized intersections, *Accident Analysis and Prevention*, 40:1171-1179 pp.
- Dai, J., Qi, H., Xiong, Y., Li, Y., Zhang, G., Hu, H. and Wei, Y.**, 2017, Deformable convolutional networks, *Proceedings of the IEEE International Conference on Computer Vision*, 764–773 pp.
- Dahl, J., de Campos, G.R., Olsson, C. and Fredriksson, J.**, 2018, Collision avoidance: A literature review on threat-assessment techniques, *IEEE Transactions on Intelligent Vehicles*, 4(1):101-113 pp.
- Dalal, N. and Triggs, B.**, 2005, Histograms of oriented for human detection, *International Conference on Computer Vision and Pattern Recognition (CVPR '05)*, San Diego, United States, 886-893 pp.
- Darzentas, J., Cooper, D., Storr, P. and McDowell, M.**, 1980, Simulation of road traffic conflicts at T-intersections, *Simulation*, 34:155-164 pp.
- Di, W., Bhardwaj, A. and Wei, J.**, 2018, Deep Learning Essentials, Packt Publishing Ltd., Birmingham, United Kingdom.
- Dingus, T. A., Klauer, S.G., Neale, V. L., Petersen, A., Lee, S. E., Sudweeks, J., Perez, M. A., Hankey, J., Ramsey, D., Gupta, S., Bucher, C., Doerzaph, Z. R., Jermeland, J., and Knippling, R.R.**, 2006, The 100-Car Naturalistic Driving Study, Phase II – Results of the 100-Car Field Experiment, No. DOT-HS-810-593. United States. Department of Transportation. National Highway Traffic Safety Administration.
- Duan, K., Bai, S., Xie, L., Qi, H., Huang, Q. and Tian, Q.**, 2019, Centernet: Keypoint triplets for object detection, *Proceedings of the IEEE International Conference on Computer Vision*, 6569-6578 pp.
- Essa, M. and Sayed, T.**, 2015, Transferability of calibrated microsimulation model parameters for safety assessment using simulated conflicts, *Accident Analysis and Prevention*, 84:41-53 pp.

KAYNAKLAR DİZİNİ (devam)

- Eurostat**, 2021, “Passenger Cars per 1000 Inhabitants”, https://ec.europa.eu/eurostat/databrowser/view/road_eqs_carhab/default/table?lang=en (Erişim tarihi: 24.12.2021).
- Evans, L. and Rothery, R.**, 1973, Experimental measurement of perceptual thresholds in car following, *Highway Research Record*, 64:13-29 pp.
- Everingham, M., Van Gool, L., Williams, C.K.I., Winn, J. and Zisserman, A.**, 2010, The pascal visual object classes (voc) challenge, *International Journal of Computer Vision*, 88(2):303-338 pp.
- Fan, R., Yu, H., Liu, P. and Wang, W.**, 2013, Using vissim simulation model and surrogate safety assessment model for estimating field measured traffic conflicts at freeway merge areas, *IET Intelligent Transport Systems*, 7(1):68-77 pp.
- Felzenszwalb, P., McAllester, D. and Ramanan, D.**, 2008, A discriminatively trained, multiscale, deformable part model, *IEEE conference on computer vision and pattern recognition*, 1-8 pp.
- FHWA**, 2008, Surrogate Safety Assessment Model (SSAM) - Software User Manual, Federal Highway Administration.
- Forbes, T.W.**, 1957, Analysis of “Near Accident” Reports, Bulletin 152, Highway Research Board, Washington, D.C.
- Gallelli, V., Iuele, T., Vaiana, R. and Vitale, A.**, 2017, Investigating the transferability of calibrated microsimulation parameters for operational performance analysis in roundabouts, *Journal of Advanced Transportation*.
- Gallelli, V., Guido, G., Vitale, A. and Vaiana, R.**, 2019, Effects of calibration process on the simulation of rear-end conflicts at roundabouts, *Journal of traffic and transportation engineering (English edition)*, 6(2):175-184 pp.
- Gen, M. and Cheng, R.**, 1997, Genetic Algorithms and Engineering Design, John Wiley & Sons, Inc.
- Ghiasi, G., Lin, T.Y. and Le, Q.V.**, 2019, Nas-fpn: Learning scalable feature pyramid architecture for object detection, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 7036-7045 pp.
- Girshick, R.**, 2014, Fast r-cnn, *Proceedings of the IEEE International Conference on Computer Vision*, 1440-1448 pp.

KAYNAKLAR DİZİNİ (devam)

- Girshick, R., Donahue, J., Darrell, T. and Malik, J.**, 2014, Rich feature hierarchies for accurate object detection and semantic segmentation, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 580-587 pp.
- Glauz, W.D., and Migletz, D.J.**, 1980, Application of Traffic Conflict Analysis at Intersections, National Cooperative Highway Research Program Report, Washington, D.C.
- Grayson, G. and Hakkert, A.**, 1987, Accident analysis and conflict behaviour. Road Users and traffic safety, *Van Gorcum and Comp BV*, 27-59 pp.
- Grayson, G.B., Hydén, C., Kraay, J.H., Muhlrud, N. and Oppe, S.**, 1984, The Malmö Study: A Calibration of Traffic Conflict Techniques, Institute for Road Safety Research SWOV, Leidschendam.
- Greenshields, B.D., Schapiro, D., and Eriksen, E.L.**, 1947, Traffic Performance at Urban Street Intersections, Technical Report No.1, Yale Bureau of Highway Traffic, Yale University.
- Guo, Y., Essa, M., Sayed, T., Haque, M. and Washington, S.**, 2019, A comparison between simulated and field-measured conflicts for safety assessment of signalized intersections in Australia, *Transportation Research Part C*, 101:96-110 pp.
- Guo, Y., Sayed, T., Zheng, L. and Essa, M.**, 2021, An extreme value theory based approach for calibration of microsimulation models for safety analysis, *Simulation Modelling Practice and Theory*, 106:102172p.
- Hagan, M., Demuth, H., Beale, M. and De Jesus, O.**, 1996, Neural Network Design, PWS Publishing, Boston, MA.
- Hakkert, A.S. and Gitelman, V.**, 2014, Thinking about the history of road safety research: Past achievements and future challenges, *Transportation Research Part F*, 25:137-149 pp.
- Hamuda, E., Mc Ginley, B., Glavin, M., and Jones, E.**, 2018, Improved image processing-based crop detection using Kalman filtering and the Hungarian algorithm, *Computers and Electronics in Agriculture*, 148:37-44 pp.
- Hanbay, K. ve Üzen, H.**, 2017, Nesne tespit ve takip metotları: kapsamlı bir derleme, *Türk Doğa ve Fen Dergisi*, 6(2):40-49 pp.

KAYNAKLAR DİZİNİ (devam)

- Hansson, A.**, 1975, Studies in Driver Behaviour, with Applications in Traffic Design and Planning, Two Examples, Lund Institute of Technology, Department of Traffic Planning and Engineering, University of Lund, Bulletin 11.
- Hauer, E.**, 1979, Methodological assessment of the techniques, *Proceedings of the 2nd International Traffic Conflicts Technique Workshop*, Paris, France.
- Hauer, E.**, 1982, Traffic conflicts and exposure, *Accident Analysis and Prevention*, 14(5):359-364 pp.
- Hauer, E. and Garder, P.**, 1986, Research into the validity of the traffic conflicts technique, *Accident Analysis and Prevention*, 18(6):471-481 pp.
- Haykin, S.**, 1999, Neural Networks A Comprehensive Foundation, Prentice Hall, Second Edition, New Jersey, 842p.
- Haykin, S.**, 2009, Neural Networks and Learning Machines, Prentice Hall, Third Edition, New Jersey, 938p.
- Hayward, J.C.**, 1972, Near-miss determination through use of a scale of danger, *Highway Research Record*, 384:24-34 pp.
- He, K., Gkioxari, G., Dollár, P. and Girshick, R.**, 2017, Mask r-cnn, *Proceedings of the IEEE International Conference on Computer Vision*, 2961-2969 pp.
- He, K., Zhang, X., Ren, S. and Sun, J.**, 2015, Spatial pyramid pooling in deep convolutional networks for visual recognition, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 37(9):1904-1916 pp.
- He, K., Zhang, X., Ren, S. and Sun, J.**, 2016, Deep residual learning for image recognition, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 770-778 pp.
- Hebb, D.O.**, 1949, The Organization of Behavior A Neuropsychological Theory, John Wiley and Sons, Inc., New York, 365p.
- Highway Capacity Manual (HCM).**, 2016, Transportation Research Board of the National Academies, Washington, DC.
- Hinton, G.E., Srivastava, N., Krizhevsky, A., Sutskever, I. and Salakhutdinov, R.R.**, 2012, Improving neural networks by preventing co-adaptation of feature detectors, *arXiv:1207.0580*, 1-18pp.

KAYNAKLAR DİZİNİ (devam)

- Hoeser, T. and Kuenzer, C.**, 2020, Object detection and image segmentation with deep learning on earth observation data: a review-part i: evolution and recent trends, *Remote Sensing*, 12(10):1667.
- Homberger, W.S.**, 1951, The behaviour of drivers at uncontrolled intersections, *Traffic Engineering*, 22(3):105-108 pp.
- Hou, J., List, G.F. and Guo, X.**, 2014, New algorithms for computing the time-to-collision in freeway traffic simulation models, *Computational Intelligence and Neuroscience*, 1-8 pp.
- Howard, A.G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M. and Adam, H.**, 2017, MobileNets:efficient convolutional neural networks for mobile vision applications, *arXiv:1704.04861*, 1-9 pp.
- Hu, J., Shen, L., Albanie, S., Sun, G. and Wu, E.**, 2017, Squeeze-and-excitation networks, *arXiv:1709.01507*.
- Huang, F., Liu, P., Yu, H. and Wang, W.**, 2013, Identifying if VISSIM simulation model and SSAM provide reasonable estimates for field measured traffic conflicts at signalized intersections, *Accident Analysis and Prevention*, 50:1014-1024 pp.
- Huang, G., Lu, Z., Van Der Maaten, L. and Weinberger, K.Q.**, 2018, Densely connected convolutional network, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 4700–4708 pp.
- Hydén, C.**, 1987, The Development of a Method for Traffic Safety Evaluation: The Swedish Traffic Conflicts Technique, Lund Department of Traffic Planning and Engineering.
- Hydén, C.**, 1996, Traffic Conflicts Technique – State of the Art, Lund Department of Traffic Planning and Engineering.
- Ioffe, S. and Szegedy, C.**, 2015, Batch normalization: accelerating deep network training by reducing internal covariate shift, *Proceedings of the 32nd International Conference on Machine Learning, PMLR*, 37:448-456 pp.
- Jimenez, F., Naranjo, J.E. and Garcia, F.**, 2013, An improved method to calculate the time-to-collision of two vehicles, *International Journal of Intelligent Transportation Systems Research*, 11(1):34-42 pp.
- Joshi, P., Godoy, V., and Escriva, D.**, 2016, *OpenCV by Example*, Packt Publishing.

KAYNAKLAR DİZİNİ (devam)

- Kalman, R.E.**, 1960, A new approach to linear filtering and prediction problems, *Journal of Basic Engineering*, 82(1):35-45 pp.
- Karakises, I., Spangler, M. and Margreiter, M.**, 2017, Designing a Vissim-Model for a motorway network with systematic calibration on the basis of travel time measurements, *3rd Conference on Sustainable Urban Mobility*, Volos, Greece.
- Karayolları Genel Müdürlüğü**, 2021, Trafik Kazaları Özeti 2020, Trafik Güvenliği Dairesi Başkanlığı.
- Katrakazas, C., Quddus, M. And Chen, W.H.**, 2019, A new integrated collision risk assessment methodology for autonomous vehicles, *Accident Analysis and Prevention*, 127:61-79 pp.
- Kiefer, R.J., LeBlanc, D.J. and Flannagan, C.A.**, 2005, Developing an inverse time-to-collision crash alert timing approach based on drivers' last-second braking and steering judgments, *Accident Analysis and Prevention*, 37:295-303 pp.
- Klebsberg, D.**, 1964, Derzeitiger Stand der Verhaltensanalyse des Kraftfahrens, *Arbeit und Leistung, Abt. Arbeitswissenschaft Soziale Betriebspraxis*, 18:33-37 pp.
- Köksal Babacan, E., Özbek, L., ve Biçer, C.**, 2011, Uyarlı kokusuz kalman filtresi, *BAÜ Fen Bilimleri Enstitüsü Dergisi*, 13(1):59-67 pp.
- Krizhevsky, A., Sutskever, I. and Hinton, G.E.**, 2012, Imagenet classification with deep convolutional neural networks, *Advances in Neural Information Processing Systems*, 25:1097-1105 pp.
- Kuang, Y., Qu, X. and Wang, S.**, 2015, A tree-structured crash surrogate measure for freeways, *Accident Analysis and Prevention*, 77:137-148 pp.
- Kusano, K.D., Chen, R., Montgomery, J. And Gabler, H.C.**, 2015, Population distributions of time to collision at brake application during car following from naturalistic driving data, *Journal of Safety Research*, 54:95-104 pp.
- Laureshyn, A., Svensson, Å. and Hydén, C.**, 2010, Evaluation of traffic safety, based on micro-level behavioural data: Theoretical framework and first implementation, *Accident Analysis and Prevention*, 42:1637-1646 pp.

KAYNAKLAR DİZİNİ (devam)

- Law, H. and Deng, J.**, 2018, Cornernet: Detecting objects as paired keypoints, *Proceedings of the European Conference on Computer Vision (ECCV)*, 734-750 pp.
- Lazebnik, S., Schmid, C. and Ponce, J.**, 2006, Beyond bags of features: spatial pyramid matching for recognizing natural scene categories, *IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'06)*, 2169-2178 pp.
- Leichter, I., Lindenbaum, M., and Rivlin, E.**, 2010, Mean shift tracking with multiple reference color histograms, *Computer Vision and Image Understanding*, 114:400-408 pp.
- Lightburn, A.**, 1984, The development of the Traffic Conflicts Technique: An Approach to the Study of Road Accidents, PhD Thesis, University of Nottingham.
- Lin, T.Y., Maire, M., Belongie, S., Bourdev, L., Girshick, R., Hays, J., Perona, P., Ramanan, D., Zitnick, C.L. and Dollár, P.**, 2014, Microsoft coco: common objects in context, *European Conference on Computer Vision*, 740-75 pp.
- Liu, S., Qi, L., Qin, H., Shi J. and Jia, J.**, 2018, Path aggregation network for instance segmentation, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 8759-8768 pp.
- Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C.Y. and Berg, A.C.**, 2016, SSD: single shot multibox detector, *European conference on computer vision*, 21-37 pp.
- Lowe, D.G.**, 1999, Object recognition from local scale-invariant features, *Proceedings of the Seventh IEEE International Conference on Computer Vision*, 2:1150-1157 pp.
- Lu, Z., Fu, T., Fu, L., Shiravi, S. and Jiang, C.**, 2016, A video-based approach to calibrating car-following parameters in VISSIM for urban traffic, *International Journal of Transportation Science and Technology*, 5:1-9 pp.
- Lucas, B. and Kanade, T.**, 1981, An iterative image registration technique with an application to stereo vision, *7th International Joint Conference on Artificial Intelligence*.

KAYNAKLAR DİZİNİ (devam)

- Ma, J., Dong, H. and Zhang, H. M.**, 2007, Calibration of microsimulation with heuristic optimization methods. *Transportation Research Record*, 1:208-217 pp.
- Maheshwary, P., Bhattacharyya, K., Maitra, B. and Boltze, M.**, 2020, A methodology for calibration of traffic micro-simulator for urban heterogeneous traffic operations, *Journal of Traffic and Transportation Engineering (English Edition)*, 7(4):507-519 pp.
- McCulloch, W.S. and Pitts, W.H.**, 1943, A logical calculus of the ideas immanent in nervous activity, *Bulletin of Mathematical Biophysics*, 5:115-133 pp.
- Michaels, R.M.**, 1963, Perceptual factors in car following, *Proceedings of the Second International Symposium on the Theory of Road Traffic Flow*, 44-59 pp.
- Milam, R. T. and Choa, F.**, 2002, Recommended guidelines for the calibration and validation of traffic simulation models, *Eighth TRB Conference on the Application of Transportation Planning Methods Transportation Research Board*, Texas Department of Transportation, Corpus Christi Metropolitan Planning Organization, Federal Highway Administration, and Federal Transit Administration.
- Minderhoud, M.M. and Bovy, P.H.L.**, 2001, Extended time-to-collision measures for road traffic safety assessment, *Accident Analysis and Prevention*, 33:89-97 pp.
- Mitchell, M.**, 1998, *An Introduction to Genetic Algorithms*, MIT Press.
- N-Yo, S.A.K.**, 2018, Development of a Real-Time Face Recognition System Using Deep Learning Techniques, Yüksek Lisans Tezi, Gaziantep Üniversitesi Fen Bilimleri Enstitüsü, 58s.
- OECD**, 1997, *Road Safety, Continuing Policy And Research Challenge*, Organisation for Economic Co-operation and Development, Paris.
- OECD**, 2008, *Towards Zero - Ambitious Road Safety Targets And The Safe System Approach*, Organization for Economic Co-operation and Development/International Transport Forum, Paris.
- Oh, C. and Kim, T.**, 2010, Estimation of rear-end crash potential using vehicle trajectory data, *Accident Analysis and Prevention*, 42:1888-1893 pp.

KAYNAKLAR DİZİNİ (devam)

- Older, S.J. and Shippey, J.**, 1977, Traffic conflict studies in the United Kingdom, *Proceedings of the 1st Workshop on Traffic Conflicts*, Oslo.
- Olstam, J.J. and Tapani, A.**, 2004, Comparison of Car Following Models, Swedish National Road and Transport Research Institute, 45p.
- OpenCV.**, 2019, OpenCV Tutorials. Meanshift and Camshift: https://docs.opencv.org/master/d7/d00/tutorial_meanshift.html adresinden alındı
- Oppe, S.**, 1986, Evaluation of traffic conflict techniques, *Proceedings, Workshop on Traffic Conflicts and other Intertmediate Measures in Safety Eualuation*, Budapest.
- O'Shea, K. and Nash, R.**, 2015, An introduction to convolutional neural networks, *arXiv:1511.08458*, 1-11 pp.
- Ozbay, K., Yang, H., Bartin, B. and Mudigonda, S.**, 2008, Derivation and validation of a new simulation-based surrogate safety measure, *Transportation Research Record, Journal of Transportation Research Board*, 2083(1):105-113 pp.
- Öztürk, K. ve Şahin, M.E.**, 2018, Yapay sinir ağları ve yapay zekaya genel bir bakış, *Takvim-i Vekayi*, 6(2):25-36s.
- Panwai, S. and Dia, H.**, 2005, Comparative evaluation of microscopic car-following behavior, *IEEE Transactions on Intelligent Transportation Systems*, 6(3):314-325 pp.
- Papaoannou, P.**, 2007, Driver behaviour, dilemma zone and safety effects at urban signalised intersections in Greece, *Accident Analysis and Prevention*, 39(1):147-158 pp.
- Parekh, H.S., Thakore, D.G. and Jaliya, U.K.**, 2014, A survey on object detection and tracking methods, *International Journal of Innovative Research in Computer and Coomunication Engineering*, 2(2):2970-2978 pp.
- Park, H., Oh, C., Moon, J. and Kim, S.**, 2018, Development of a lane change risk index using vehicle trajectory data, *Accident Analysis and Prevention*, 110:1-8pp.
- Pathan, S., Al-Hamadi, A. and Michaelis, B.**, 2009, Intelligent feature-guided multi-object tracking using Kalman filter, *2nd International Conference on Computer, Control and Communication* 1-6 pp.

KAYNAKLAR DİZİNİ (devam)

- Peng, Y., Abdel-Aty, M., Shi, Q. and Yu, R.,** 2017, Assessing the impact of reduced visibility on traffic crash risk using microscopic data and surrogate safety measures, *Transportation Research Part C*, 74:295-305 pp.
- Perkins, S. and Harris, J.,** 1967, Criteria for Traffic Conflict Characteristics: Accident Potential at Intersections, Research Publication GMR-718, General Motors Corporation, Warren, Michigan.
- Perronnin, F., Sánchez, J. and Mensink, T.,** 2010, Improving the fisher kernel for large-scale image classification, In *European Conference on Computer Vision*, 143-156 pp.
- Pirdavani, A., Brijs, T., Bellemans, T. and Wets, G.,** 2010, Evaluation of traffic safety at un-signalized intersections using microsimulation: a utilization of proximal safety indicators, *Advances in Transportation Studies*, 22:43-50 pp.
- Pourabdollah, M., Bjarkvik, E., Fürer, F., Lindenberg, B. and Burgdorf, K.,** 2017, Calibration and evaluation of car following models using real-world driving data, *IEEE 20th International Conference on Intelligent Transportation Systems*.
- Plackett, R.L. and Burman, J.P.,** 1946, The design of optimum multifactorial experiments, *Biometrika*, 33(4):305-325 pp.
- Planung Transport Verkehr AG (PTV),** 2014, VISSIM User Manual Version 11.0, PTV, Karlsruhe.
- Redmon, J., Divvala, S., Girshick, R. and Farhadi, A.,** 2016, You only look once: unified, real-time object detection, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 779-788 pp.
- Redmon, J. and Farhadi, A.,** 2017, YOLO9000: better, faster, stronger, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 7263-7271 pp.
- Redmon, J. and Farhadi, A.,** 2018, YOLOv3: an incremental improvement, *arXiv:1804.02767*, 1-6 pp.
- Ren, S., He, K., Girshick, R. and Sun, J.,** 2016, Faster r-cnn: towards real-time object detection with region proposal networks, *arXiv:1506.01497*, 1-14 pp.
- Rosenblatt, F.,** 1958, The design of an intelligent automaton, *Research Trends, Cornell Aeronaut Lab.*, 6(2):5-13 pp.

KAYNAKLAR DİZİNİ (devam)

- Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Sean, M., Huang, Z., Karpathy, A., Khosla, A., Bernstein, M., Berg, A.C., and Fei-Fei, L.,** 2015, ImageNet large scale visual recognition challenge, *International Journal of Computer Vision*, 115(3):211-252 pp.
- Saffarzadeh, M., Nadimi, N., Naseralavi, S. and Mamdoohi, A.R.,** 2013, A general formulation for time-to-collision safety indicator, *Proceedings of the Institution of Civil Engineers-Transport*, 166(5):294-304 pp.
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A. and Chen, L.C.,** 2018, Mobile net v2: inverted residuals and linear bottlenecks, *arXiv:1801.04381*, 1-14 pp.
- Sermanet, P., Eigen, D., Zhang, X., Mathieu, M., Fergus, R. and LeCun, Y.,** 2013, Overfeat: Integrated recognition, localization and detection using convolutional networks, *arXiv:1312.6229*.
- Sharma, S., Sharma, S. and Athaiya, A.,** 2020, Activation functions in neural networks, *International Journal of Engineering Applied Sciences and Technology*, 4(12):310-316 pp.
- Sharma, V. and Mir, R.N.,** 2020, A comprehensive and systematic look up into deep learning based object detection techniques: a review, *Computer Science Review*, 38:1-29 pp.
- Shi, J. and Tomasi, C.,** 1994, Good features to track, *IEEE Conference on Computer Vision and Pattern Recognition*, 593-600 pp.
- Shi, X., Wong, Y.D., Li, M.Z.F. and Chai, C.,** 2018, Key risk indicators for accident assessment conditioned on pre-crash vehicle trajectory, *Accident Analysis and Prevention*, 117:346-356 pp.
- Siddharth, S.M.P. and Ramadurai, G.,** 2013, Calibration of vissim for indian heterogeneous traffic conditions, *2nd Conference of Transportation Research Group of India (2nd CTRG)*, 104:380-389 pp.
- Simonyan, K. and Zisserman, A.,** 2015, Very deep convolutional networks for large-scale image recognition, *3rd International Conference on Learning Representation (ICLR)*, San Diego, USA.
- Sivic, J. and Zisserman, A.,** 2003, Video google: a text retrieval approach to object matching in videos, *Proceedings of the 9th IEEE International Conference on Computer Vision (ICCV'03)*, 1470-1477 pp.

KAYNAKLAR DİZİNİ (devam)

- Son, D., Kweon, Y.J. and Park, B.**, 2011, Development of crash prediction models with individual vehicular data, *Transportation Research Part C*, 19(6):1353-1363 pp.
- Stanford**, 2018, “Convolutional Neural Networks for Visual Recognition”, <https://cs231n.github.io/convolutional-networks/>, (Erişim tarihi: 15 Aralık 2018).
- St-Aubin, P., Miranda-Moreno, L. and Saunier, N.**, 2013, An automated surrogate safety analysis at protected highway ramps using cross-sectional and before–after video data, *Transportation Research Part C*, 36:284-295 pp.
- Subramanian, J. and Simon, R.**, 2013, Overfitting in prediction models – is it a problem only in high dimensions?, *Contemporary Clinical Trials*, 36:636-641 pp.
- Svensson, A.**, 1998, A Method for Analysing the Traffic Process in a Safety Perspective, Lund: Lund Institute of Technology.
- Svensson, A. and Hydén, C.**, 2006, Estimating the severity of safety related behaviour, *Accident Analysis and Prevention*, 38:379-385 pp.
- SweRoad**, 2001, İlerleme Raporu. İsveç Trafik Çatışması (Conflict) Tekniğinin Türkiye’de Kullanılması (Pursaklar’da Ön- ve Sonrası Çalışmaları ve Çankırı’da bir Pilot Çalışma’yı içermektedir), Ankara.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V. and Rabinovich, A.**, 2015, Going deeper with convolutions, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 1-9 pp.
- Tao, H., Sawhney, H. and Kumar, R.**, 2002, Object tracking with bayesian estimation of dynamic layer representations, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 75–89 pp.
- Tak, S., Kim, S. and Yeo, H.**, 2015, Development of a deceleration-based surrogate safety measure for rear-end collision risk, *IEEE Transactions on Intelligent Transportation Systems*, 16(5):2435-2445 pp.
- Tan, M., Chen, B., Pang, R., Vasudevan, V., Sandler, M., Howard, A. and Le, Q.V.**, 2019, MnasNet: platform-aware neural architecture search for mobile, *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2820-2828 pp.

KAYNAKLAR DİZİNİ (devam)

- Tan, M. and Le, Q.V.**, 2019, Efficientnet: rethinking model scaling for convolutional neural networks, *arXiv:1905.11946*, 1-10 pp.
- Tettamanti, T., Csikós, A., Varga, I. and Eleöd, A.**, 2015, Iterative calibration of VISSIM simulator based on genetic algorithm, *Acta Technica Jaurinensis*, 8(2):145-152 pp.
- Türk Standartları Enstitüsü, TS 6407**, 2013, Şehir İçi Ulaşım Hesaplamalarında Araç Tiplerine Göre Kullanılacak Oto Birim Katsayıları, Ankara.
- Vajeeran, A. and de Silva, G.L.D.I.**, 2020, Identification of effective intersection control strategies during peak hours, *Transportation Research Procedia*, 48:687-697 pp.
- van de Sande, K.E.A, Uijlings, J.R.R., Gevers, T and Smeulders, A.W.M.**, 2011, Segmentation as selective search for object recognition, *IEEE International Conference on Computer Vision*, 1879-1886 pp.
- van der Horst, R. and Hogema, J.**, 1994, Time-to-collision and collision avoidance systems, *Proceedings of the 6th ICTCT Workshop*, Salzburg.
- Viola, P. and Jones, M.**, 2001, Rapid object detection using a boosted cascade of simple features, *Proceedings of the 2001 IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 1:1-9 pp.
- Vogel, K.**, 2003, A comparison of headway and time to collision as safety indicators, *Accident Analysis and Prevention*, 35:427-433 pp.
- Wang, S.C.**, 2003, *Interdisciplinary Computing in Java Programming*, The Springer International Series in Engineering and Computer Science, Boston, 266p.
- Wang, C., Xu, C., Xia, J., Qian, Z. and Lu, L.**, 2018, A combined use of microscopic traffic simulation and extreme value methods for traffic safety evaluation, *Transportation Research Part C*, 90:281-291 pp.
- Wang, C.Y., Liao, H.Y.M., Wu, Y.H., Chen, P.Y., Hsieh, J.W. and Yeh, I.H.**, 2020, CSPNet: a new backbone that can enhance learning capability of cnn, *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR) Workshops*, 390-391 pp.
- Wang, C. and Stamatiadis, N.**, 2014, Evaluation of a simulation-based surrogate safety metric, *Accident Analysis and Prevention*, 71:82-92 pp.

KAYNAKLAR DİZİNİ (devam)

- Ward, J.R., Agamennoni, G., Worrall, S., Bender, A. and Nebot, E.,** 2015, Extending time to collision for probabilistic reasoning in general traffic scenarios, *Transportation Research Part C*, 51:66-82 pp.
- Wegman, F., Johnston, I., Kroj, G. and Pain, R.,** 2007, Road Traffic Safety Research and Education in Israel, Ramat Hasharon: The Ran Naor Foundation For The Advancement Of Road Safety Project.
- Wojke, N., Bewley, A. and Paulus, D.,** 2017, Simple online and realtime tracking with a deep association metric, *IEEE International Conference on Image Processing*, 3645-3649 pp.
- Wu, K.F. and Jovanis, P.P.,** 2012, Crashes and crash-surrogate events: Exploratory modeling with naturalistic driving data, *Accident Analysis and Prevention*, 45:507-516 pp.
- Wu, J., Wen, H. and Qi, W.,** 2020, A new method of temporal and spatial risk estimation for lane change considering conventional recognition defects, *Accident Analysis and Prevention*, 146: 105796 pp.
- Wu, Y., Abdel-Aty, M., Cai, Q., Lee, J. and Park, J.,** 2018, Developing an algorithm to assess the rear-end collision risk under fog conditions using real-time data, *Transportation Research Part C*, 87:11-25 pp.
- Xie, S., Girshich, R., Dollár, P., Tu, Z. and He, K.,** 2017, Aggregated residual transformations for deep neural network, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 1492-1500 pp.
- Yalçinkaya, N.M., Demirel, E. ve Say, N.,** 2020, Tehlikeli maddelerin karayolu ile taşınması sürecinde ortaya çıkan çevresel risklerin hata ağacı analizi (haa) ile değerlendirilmesi, *Mühendislik Bilimleri ve Tasarım Dergisi*, 8(4):973-984 pp.
- Yamashita, R., Nishio, M., Do, R.K.G., and Togashi, K.,** 2018, Convolutional neural networks: an overview and application in radiology, *Insights into Imaging*, 9(4):611-629 pp.
- Yang, C., Shao, C. and Liu, L.,** 2012, Study on capacity of urban expressway weaving segments, *Procedia - Social and Behavioral Sciences*, 43:148-156 pp.
- Yılmaz, A., Javed, O. and Shah, M.,** 2006, Object tracking: a survey, *ACM Computing Surveys*, 38(4):13-58 pp.

KAYNAKLAR DİZİNİ (devam)

- Young, W., Sobhani, A., Lenné, M. and Sarvi, M.**, 2014, Simulation of safety: a review of the state of the art in road safety simulation modelling, *Accident Analysis and Prevention*, 38:89-103 pp.
- Yu, M. and Fan, W.**, 2017, Calibration of microscopic traffic simulation models using metaheuristic algorithms, *International Journal of Transportation Science and Technology*, 6:63-77 pp.
- Zheng, Z.**, 2014, Recent developments and research needs in modeling lane changing, *Transportation Research Part B*, 60:16-32 pp.
- Zheng, L., Ismail, K. and Meng, X.**, 2014, Traffic conflict techniques for road safety analysis: open questions and some insights. *Canadian Journal of Civil Engineering*, 41(7):633-641 pp.
- Zhou, H. and Huang, F.**, 2013, Development of traffic safety evaluation method based on simulated conflicts at signalized intersections, *13th COTA International Conference of Transportation Professionals (CICTP 2013)*, 96:881-885 pp.
- Zoph, B. and Le, Q.V.**, 2017, Neural architecture search with reinforcement learning, *arXiv:1611.01578*, 1-16 pp.
- Zoph, B., Vasudevan, V., Shlens, J. and Le, Q.V.**, 2018, Learning transferable architectures for scalable image recognition, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 8697-8710 pp.

TEŞEKKÜR

Doktora eğitimim boyunca bilgi ve tecrübesinden faydalandığım ve desteğini her zaman hissettiğim danışman hocam Doç. Dr. Yalçın ALVER'e teşekkürü bir borç bilirim.

Tez izleme komitemde yer alan ve değerli görüşleri ile önemli katkılarda bulunan Prof. Dr. Perviz AHMEDZADE ve Prof. Dr. Serhan TANYEL'e teşekkürlerimi sunarım.

Manevi destekleri için aileme ve hep yanımda olan arkadaşlarım Arş. Gör. Dr. Cihat YÜKSEL, Arş. Gör. Dr. Mehmet Metin MUTLU, Arş. Gör. Mervegül UYSAL ve İnş. Yük. Müh. Elia ODABAŞI'na sonsuz teşekkür ederim.

Pelin ÖNELÇİN

İzmir, 2022

ÖZGEÇMİŞ

Pelin ÖNELÇİN, 2003 yılında girdiği Ege Üniversitesi Mühendislik Fakültesi İnşaat Mühendisliği Bölümü'nden 2008 yılında mezun oldu. 2008 yılında Politecnico di Milano Üniversitesi İnşaat Mühendisliği Bölümü'nde başladığı yüksek lisansını 2010 yılında bitirdi. 2012 yılında Ege Üniversitesi Fen Bilimleri Enstitüsü İnşaat Mühendisliği Anabilim Dalı'nda Ulaştırma programında yüksek lisansa başladı. 2014 yılında yüksek lisans eğitimini tamamlayıp aynı sene içinde doktora eğitimine başladı. Aynı zamanda, 2012 yılından beri Ege Üniversitesi İnşaat Mühendisliği Bölümü'nde araştırma görevlisi olarak çalışmaktadır.

