



**SÜRÜCÜ DİKKAT DAĞINIKLIĞININ ÇEVRESEL
ETKİLERİNİN İNCELENMESİ VE NESNE TESPİT
ALGORİTMALARI İLE TESPİT EDİLMESİ**

Kadir Diler ALEMDAR

Doktora Tezi

İnşaat Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Muhammed Yasin ÇODUR

2023

Her hakkı saklıdır.



FEN BİLİMLERİ ENSTİTÜSÜ
DOKTORA TEZİ

SÜRÜCÜ DİKKAT DAĞINIKLIĞININ ÇEVRESEL ETKİLERİNİN
İNCELENMESİ VE NESNE TESPİT ALGORİTMALARI İLE TESPİT
EDİLMESİ

Kadir Diler ALEMDAR

Tez Danışmanı: Doç. Dr. Muhammed Yasin ÇODUR

Anabilim Dalı: İnşaat Mühendisliği

Erzurum

2023

Her hakkı saklıdır

ETİK KURALLARA UYGUNLUK BEYANI

Erzurum Teknik Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım bu tez içindeki tüm bilgilerin doğru ve tam olduğunu, bilgilerin üretilmesi aşamasında bilimsel etiğe uygun davrandığımı, yararlandığım bütün kaynakları atıf yaparak belirttiğimi beyan ederim.

17 / 11 / 2023

Kadir Diler ALEMDAR

ÖZET

DOKTORA TEZİ

SÜRÜCÜ DİKKAT DAĞINIKLIĞININ ÇEVRESEL ETKİLERİNİN İNCELENMESİ VE NESNE TESPİT ALGORİTMALARI İLE TESPİT EDİLMESİ

Kadir Diler Alemdar

Erzurum Teknik Üniversitesi

Fen Bilimleri Enstitüsü

İnşaat Mühendisliği Ana Bilim Dalı

Danışman: Doç. Dr. Muhammed Yasin ÇODUR

Gelişmiş ve gelişmekte olan ülkelerde trafik kazaları insan hayatını tehdit eden en önemli konulardan biridir. Trafik kazalarındaki kusur oranları arasında en büyük payın sürücülere ait olduğu görülmektedir. Sürücü kusurlarının sebepleri incelendiğinde sürücü dikkat dağınıklığı ön plana çıkmaktadır. Sürücü dikkat dağınıklığının trafik güvenliğinin yanı sıra çevre kirliliği üzerinde de önemli düzeyde etkisi bulunmaktadır. Bu tez çalışması kapsamında sürücü dikkat dağınıklığının trafik güvenliği ve çevre kirliliğine etkisi ayrı ayrı ele alınmıştır. Erzurum ilinde dikkate alınan 23 kavşakta dikkat dağınıklığı yaşayan sürücülerin en sık sergiledikleri eylem olan cep telefonu kullanımı ve etkileri değerlendirilmiştir. Sürücülerin cep telefonu kullanım durumu incelendiğinde yıllık 291,37 saatlik gecikme, 1,472 kg CO₂, 0,44 kg NO_x emisyonu ve 261,6 litre yakıt tüketimi meydana geldiği görülmektedir. Sürücü dikkat dağınıklığının önlenmesi veya kısmen önüne geçilebilmesi amacıyla tez çalışması kapsamında nesne tespiti algoritmaları kullanılmıştır. Sürücü dikkat dağınıklığının tespiti için YOLO mimarisine ait YOLOv7 ve YOLOv8 modelleri eğitilmiştir ve tespit işlemi gerçekleştirilmiştir. Modelin eğitilmesi amacıyla belirlenen eylem sınıflarının öncelik dereceleri Analitik Hiyerarşi Süreci kullanılarak belirlenmiştir. YOLO modellerinin eğitilmesi için yeni veri seti oluşturulmuş ve farklı sürüş karakteristiklerini yansıtan toplam 39.996 görüntü çalışmaya dahil edilmiştir. mAP 0.5:0.95 ölçüt metriğine göre YOLOv7 modelinde %91,17 ve YOLOv8 modelinde %92,03 doğruluk oranı elde edilerek başarılı performans gösterdikleri sonuçlar ile ortaya konulmuştur. Ayrıca, Akıllı Ulaşım Sistemleri kapsamında gerçek zamanlı sürüşe dayanan tespit ve sürücü ikaz yaklaşımı ele alınarak trafik güvenliği ve çevre kirliliği anlamındaki olumsuzlukların giderilmesi amaçlanmıştır.

2023, 166 sayfa

Anahtar Kelimeler: Sürücü Dikkat Dağınıklığı, Çevre Kirliliği, Trafik Güvenliği, YOLO, Akıllı Ulaşım Sistemleri

ABSTRACT

Ph.D

EXAMINING THE ENVIRONMENTAL EFFECTS OF DRIVER DISTRACTION CAUSED AND DETECTING IT WITH OBJECT DETECTION ALGORITHMS

Kadir Diler ALEMDAR

Erzurum Technical University

Graduate School of Natural and Applied Sciences

Department of Civil Engineering

Supervisor: Assoc. Prof. Dr. Muhammed Yasin ÇODUR

Traffic accidents are one of the most important issues threatening human life in developed and developing countries. It is seen that the largest share of the fault rates in traffic accidents belongs to the drivers. When the causes of driver errors are examined, driver distraction comes to the fore. Driver distraction has a significant impact on environmental pollution as well as traffic safety. Within the scope of this thesis, the effects of driver distraction on traffic safety and environmental pollution are discussed separately. Mobile phone use, which is the most common action exhibited by distracted drivers, and its effects were evaluated at 23 intersections in Erzurum province. When drivers' mobile phone usage status is examined, it is seen that there is an annual delay of 291,37 hours, 1,472 kg CO₂, 0,44 kg NO_x emissions and 261,6 liters of fuel consumption. In order to prevent or partially prevent driver distraction, object detection algorithms were used within the scope of the thesis. To detect driver distraction, YOLOv7 and YOLOv8 models belonging to the YOLO architecture were trained and the detection process was carried out. The priority levels of action classes determined for model training were determined using the Analytic Hierarchy Process. A new data set was created to train YOLO models and a total of 39,996 images reflecting different driving characteristics were included in the study. According to the mAP 0.5:0.95 criterion metric, an accuracy rate of 91.17% for the YOLOv7 model and 92.03% for the YOLOv8 model was obtained, demonstrating successful performance. In addition, within the scope of Intelligent Transportation Systems, it is aimed to eliminate the negativities in terms of traffic safety and environmental pollution by considering the detection and driver warning approach based on real-time driving.

2023, 166 page

Keywords: Driver Distraction, Environmental Pollution, Traffic Safety, YOLO, Intelligent Transportation Systems

TEŞEKKÜR

Akademik hayata ilk adımımı attığım günden itibaren desteğini, bilgi birikimini, tecrübesini ve ilgisini eksik etmeyen, tez çalışması ve tez yazımı süresince desteğini esirgemeyen ve sürekli yol gösteren çok kıymetli danışman hocam Sayın Doç. Dr. Muhammed Yasin ÇODUR’a teşekkür eder, saygılarımı sunarım.

Akademik çalışmalarımın gelişmesi için gerekli yönlendirmelerini ve katkılarını sunarak tezimin hazırlanması ve nihai hale gelmesinde büyük emekleri olan saygıdeğer hocalarım Sayın Prof. Dr. Ahmet TORTUM ve Sayın Doç. Dr. Ahmet ATALAY’a teşekkürlerimi sunarım. Ayrıca, tez sürecine katkıda bulunan ve tez savunma jürime katılan Sayın Doç. Dr. Osman Ünsal BAYRAK ve Sayın Dr. Öğr. Üyesi Muhammed Ali ÇOLAK hocalarıma saygı ve şükranlarımı ifade etmek isterim. Ayrıca, tez çalışması desteğini esirgemeyen Sayın Arş. Gör. Dr. Muhammet YILMAZ’a teşekkür ederim.

Tüm hayatım boyunca istisnasız her konuda arkamda olan ve desteklerini hissetmediğim tek bir an olmayan sevgili aileme, bugünlere gelmem için sürekli çabalayan annem Gönül ALEMDAR’a, desteklerini ve güvenlerini sürekli hissettiğim abim Haktan ALEMDAR’a ve ablam Dilek Nur KOLÇAK’a sevgimi, saygımı ve teşekkürlerimi sunarım.

Gerek akademik anlamda gerek özel hayatımda sevgisini, güvenini ve desteğini esirgemeyen hayatımın her alanına daima olumlu katkıda bulunan sevgili eşim yol arkadaşım Beyza Nur ALEMDAR’a sevgilerimi sunar, teşekkür ederim.

Kadir Diler ALEMDAR
Kasım 2023

İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	i
ABSTRACT	ii
TEŞEKKÜR	iii
İÇİNDEKİLER	iv
SİMGELER VE KISALTMALAR	vi
ŞEKİLLER DİZİNİ	vii
ÇİZELGELER DİZİNİ	x
1. GİRİŞ	1
1.1. Trafik Kazaları	1
1.2. Sürücü Dikkat Dağılıklığı	5
1.3. Cep Telefonu Kullanımı.....	8
2. KAYNAK ÖZETLERİ	14
3. MATERYAL ve YÖNTEM	26
3.1. Çalışma Alanı.....	26
3.1.1. Seçilen kavşakların konumsal özellikleri.....	29
3.2. Yol Kenarı Gözlem Verilerinin Toplanması.....	35
3.3. Entropi Ağırlıklandırma Yöntemi	38
3.4. Coğrafi Bilgi Sistemleri	40
3.5. Analitik Hiyerarşi Süreci.....	41
3.5.1. AHP yönteminin hiyerarşik yapısı	41
3.5.2. İkili karşılaştırma matrisleri	42
3.5.3. İkili karşılaştırma matrislerinin tutarlılığı	43
3.5.4. Öncelik değerlerinin hesaplanması	45
3.6. Sürücü Dikkat Dağılıklığı Tespiti İçin Verilerin Toplanması ve Etiketlenmesi.....	45
3.7. Makine Öğrenimi	49
3.8. Derin Öğrenme.....	51
3.8.1. Yapay sinir ağları	54
3.8.2. Evrişimli sinir ağları.....	56
3.8.3. Bölgesel tabanlı konvolüsyonlu sinir ağı (R-CNN)	64
3.8.4. Hızlı bölgesel tabanlı konvolüsyonlu sinir ağı (Fast R-CNN)	64

3.8.5. Daha hızlı bölgesel tabanlı konvolüsyonlu sinir ağı (Faster R-CNN)	65
3.8.6. Tek atışlı çoklu kutu detektörü (Single shot multibox detector).....	66
3.8.7. Görsel geometri grubu (Visual geometry group)	67
3.8.8. Artık ağı (Residual Network).....	68
3.9. Sadece Bir Kez Bak (You Only Look Once)	70
4. ARAŞTIRMA BULGULARI ve TARTIŞMA.....	76
4.1. Yol Kenarı Gözlem Araştırması ve Sonuçları	76
4.2. Entropi Ağırlıklandırma Sonuçları.....	94
4.3. Eylem Sınıflarının Belirlenmesi ve AHP Yöntemi ile Ağırlıklandırılması	102
4.4. Sürücü Dikkat Dağınıklığı Verilerinin Hazırlanması	115
4.5. Sürücü Dikkat Dağınıklığının Tespit Edilmesi.....	119
5. SONUÇ ve ÖNERİLER.....	145
KAYNAKLAR	151

SİMGELER VE KISALTMALAR DİZİNİ

Simgeler

Açıklama

λ_{max}	Maksimum Öz değer
%	Yüzde

Kısaltmalar

AAA	Amerikan Otomobil Birliği
AHP	Analitik Hiyerarşi Süreci
BMGK	Birleşmiş Milletler Genel Kurulu
CBS	Coğrafi Bilgi Sistemleri
CI	Tutarlılık İndeksi
CNN	Evrişimli Sinir Ağı
CR	Tutarlılık Oranı
ÇKKV	Çok Kriterli Karar Verme
EGM	Emniyet Genel Müdürlüğü
GPU	Grafik İşlem Birimi
HRNN	Hiyerarşik Tekrarlayan Sinir Ağı
IoU	Görüntü Benzeşmesi
mAP	Ortalama Hassasiyet Metriği
NHTSA	Ulusal Karayolu Trafik Güvenliği İdaresi
OECD	Ekonomik İş Birliği ve Kalkınma Örgütü
PCN	Progressive Calibration Networks
ResNet	Residual Network
RI	Rastgele İndeksi
RoI	İlgi Bölgesi
RPN	Bölge Teklif Ağı
SSD	Single Shot Multibox Detector
TÜİK	Türkiye İstatistik Kurumu
VGG	Visual Geometry Group
WHO	Dünya Sağlık Örgütü
YOLO	You Only Look Once

ŞEKİLLER DİZİNİ

Şekil 1.1. OECD üye ülkelerdeki trafik kaza istatistikleri.....	2
Şekil 1.2. Yaş gruplarına göre trafik kazalarında ölüm oranı	3
Şekil 1.3. Ülkelere göre karayolu trafik kazalarındaki 100.000 kişi başına düşen ölüm oranı (2022).	4
Şekil 1.4. 2016-2027 yılları arası için Dünya geneli güncel ve tahmini akıllı telefon kullanıcı sayısı, milyar.....	8
Şekil 3.1. Erzurum ilinin coğrafi konumu ve çalışma alanı.....	27
Şekil 3.2. Gözlem yapılan kavşakların konumları	28
Şekil 3.3. Yol kenarı gözlem araştırması ölçüm stratejisi	36
Şekil 3.4. AHP hiyerarşik yapısı.....	42
Şekil 3.5. Dikkat dağınıklığı tespiti için gerekli olan verilerin toplanması amacıyla kurulan kamera düzeneği.....	46
Şekil 3.6. Kamuya açık olarak yayınlanan veri setinden temsili görüntüler	47
Şekil 3.7. Oluşturulan veri setinden temsili görüntüler	48
Şekil 3.8. Makine öğrenimi algoritma türleri.....	50
Şekil 3.9. Yapay zekâ, makine öğrenimi ve derin öğrenme arasındaki ilişki.....	51
Şekil 3.10. Makine öğrenimi ve derin öğrenme arasındaki işleyiş farkı	53
Şekil 3.11. Beyin ve sinir ağı yapısı temsili görseli.....	54
Şekil 3.12. Yapay sinir ağının yapısı	55
Şekil 3.13. Derin öğrenme sinir ağı yapısı.....	57
Şekil 3.14. Evrişimli sinir ağı mimarisi	57
Şekil 3.15. Konvolüsyon işlemi için temsili örnek.....	59
Şekil 3.16. Ortalama ve maksimum havuzlama yöntemleri	60
Şekil 3.17. Tam bağlantılı katman prosesi.....	61
Şekil 3.18. Seyreltme katmanı uygulanmayan ve uygulanan ağ	62
Şekil 3. 19. Aktivasyon fonksiyonları. (a) Sigmoid fonksiyonu; (b) Tanh fonksiyonu; (c) ReLU fonksiyonu; (d) Leaky ReLU fonksiyonu (e) Softmax fonksiyonu...	63
Şekil 3.20. R-CNN model mimarisi.....	64
Şekil 3.21. Fast R-CNN model mimarisi	65
Şekil 3.22. Faster R-CNN model mimarisi.....	66
Şekil 3.23. SSD model mimarisi.....	67

Şekil 3.24. VGG model mimarisi	68
Şekil 3.25. Farklı katmandaki mimarilerin test ve eğitim hata değerleri.....	69
Şekil 3.26. ResNet-18 mimari modeli	69
Şekil 3.27. YOLOv1 model mimarisi.....	72
Şekil 3.28. Gerçek zamanlı nesne tespiti yapabilen YOLO mimarilerinin karşılaştırılması	73
Şekil 4.1. Çalışma alanında gecikme parametresinin görsel sunumu.....	78
Şekil 4.2. Çalışma alanında toplam sürücü sayısı parametresinin görsel sunumu	80
Şekil 4.3. Çalışma alanında cep telefonu kullanan sürücü sayısının görsel sunumu.....	82
Şekil 4.4. Çalışma alanında ihlal ortalamasının görsel sunumu	84
Şekil 4.5. Çalışma alanında sürücü bazlı gecikme ortalamasının görsel sunumu	86
Şekil 4.6. CO ₂ (g) emisyonunun çalışma alanındaki görseli	89
Şekil 4.7. NO _x (g) emisyonunun çalışma alanındaki görseli.....	91
Şekil 4.8. Yakıt tüketiminin (litre) çalışma alanındaki görseli	93
Şekil 4.9. Ağırlıklı kavşak değerlerinin çalışma alanındaki gösterimi	100
Şekil 4.10. Çalışma kapsamında değerlendirmeye alınan eylem sınıfları	103
Şekil 4.11. Verilerin etiketlenmesinde kullanılan uygulamaların temsili görseli.....	116
Şekil 4.12. Veri setinin kategorize edilmiş durumu.....	116
Şekil 4.13. Veri büyütme teknikleri.....	117
Şekil 4.14. Etiketleme sonucu elde edilen “label” dosyalarının görseli	118
Şekil 4.15. Verilerin dosyalama işlemi için temsili gösterim	119
Şekil 4.16. YOLOv8 modeli süresince GPU kullanımı.....	121
Şekil 4.17. “Epoch” değerinin değişimine göre modelin eğitim durumları.....	123
Şekil 4.18. Veri seti için oluşturulan “data.yaml” dosyası	124
Şekil 4.19. Çalışmada kullanılan veri setine ilişkin sayısal veriler ve görüntülerin genişlik – yükseklik değerlerinin değişimini gösteren grafikler.	125
Şekil 4.20. Eğitim setinde sürücü dikkat dağınıklığının tespit edildiği görüntüler	130
Şekil 4.21. Doğrulama setinde sürücü dikkat dağınıklığının tespit edildiği bazı görüntüler	133
Şekil 4.22. YOLOv7 ve YOLOv8 modelinden elde edilen mAP 0.5 değerleri ve grafiği	134
Şekil 4.23. YOLOv7 ve YOLOv8 modelinden elde edilen mAP 0.5-0.95 değerleri ve grafiği.	135

Şekil 4.24. YOLOv7 ve YOLOv8 modelinden elde edilen kayıp fonksiyonları grafiği	137
Şekil 4.25. YOLOv7 ve YOLOv8 modelinden elde edilen F1 skorunun etiket sınıflarına göre ayrımı.	139
Şekil 4.26. YOLOv7 ve YOLOv8 karışıklık matrisi sonuçları	141
Şekil 4.27. YOLOv7 ve YOLOv8 modellerinin performans çıktılarının karşılaştırılması	142



ÇİZELGELER DİZİNİ

Çizelge 1.1. Emniyet Genel Müdürlüğü istatistiklerine göre sürücü kusurları.....	4
Çizelge 1.2. 2010-2020 yılları arasında ABD’de dikkat dağınıklığı sebebiyle meydana gelen trafik kazaları.	9
Çizelge 1.3. 2019 yılında meydana gelen ölümcül trafik kazalarının yaş gruplarına göre dağılımı.	11
Çizelge 1.4. Seyahat hızına bağlı olarak 2 saniyelik mesafe	12
Çizelge 3.1. Seçilen kavşakların numarası ve isimleri	29
Çizelge 3.2. Emisyon ve yakıt tüketimi hesaplamaları için dikkate alınan referans değerler.	37
Çizelge 3.3. İkili karşılaştırma matrisi örneği.....	42
Çizelge 3.4. Saaty önem derecesi skalası.....	43
Çizelge 3.5. Farklı kriter sayılarına göre Rastgele İndeks değerleri.....	44
Çizelge 3.6. Makine öğrenimi ve derin öğrenme arasındaki temel farklar.....	52
Çizelge 4.1. Yol kenarı gözlem araştırması sonucu elde edilen veriler.....	77
Çizelge 4.2. Kavşakların emisyon ve yakıt tüketimi değerleri	87
Çizelge 4.3. Entropi ağırlıklandırma yöntemi için oluşturulan karar matrisi	94
Çizelge 4.4. Entropi yönteminde kullanılan normalize karar matrisi	95
Çizelge 4.5. Entropi değerler matrisi	97
Çizelge 4.6. Entropi değeri ve bilginin farklılaşma derece değerleri	98
Çizelge 4.7. Parametre ağırlık sonuçları	98
Çizelge 4.8. Kavşakların ağırlıklı değerleri	98
Çizelge 4.9. AHP karar matrisi	104
Çizelge 4.10. Normalize karar matrisi	109
Çizelge 4.11. Eylem sınıflarının ağırlıkları	113
Çizelge 4.12. Eylem sınıflarının ağırlık değerine göre sırası	113
Çizelge 4.13. Gruplandırılan eylem sınıfları ve nesne tespit algoritmasına dahil edilen eylem sınıfları.	114
Çizelge 4.14. YOLOv8 için geliştirilen ağırlık dosyaları	122

1. GİRİŞ

Bu tez çalışması kapsamında giriş bölümünde sürücü dikkat dağınıklığının trafik kazaları üzerindeki etkisi ve çevresel etkileri incelenmiştir. Bu bağlamda, ilk olarak trafik kazaları ile ilgili bilgiler sunulmuştur. Daha sonra, sürücü dikkat dağınıklığının tanımından, türlerinden ve etkilerinden bahsedilmiştir. Sürücü dikkat dağınıklığı kaynaklı trafik kaza istatistikleri sunularak dikkat dağınıklığının çevresel etkileri ifade edilmiştir.


1.1.Trafik Kazaları

Kaza, genellikle doğası gereği ani olan ve yaralanma, maddi manevi kayıplara yol açan beklenmeyen olaylar olarak ifade edilmektedir (Bonilla-Escobar and Gutiérrez 2014). Kazaların yeri, zamanı ve meydana gelme şekli önceden bilinmemektedir. Hiç kuşkusuz, en önemli kaza sınıflarından biri de karayolu trafik kazalarıdır. Karayolu trafik kazası, halka açık bir yol veya caddede bir veya daha fazla kişinin yaralanması veya ölümüne veya maddi kayıplara neden olan ve en az bir aracın hareket halinde olduğu bir olayı ifade etmektedir (Sembajwe et al. 2022). Trafik kazalarındaki ölüm, yaralanma ve maddi manevi kayıplar oldukça yüksek seviyelerde olduğundan dolayı trafik kazası, Dünya Sağlık Örgütü (WHO) tarafından halk sağlığı sorunu olarak kabul edilmektedir. Trafik kazaları, bireylerde maddi ve manevi hasarlara yol açarak, kişilerin sağlığını, yaşam kalitesini ve konforunu olumsuz yönde ciddi bir şekilde etkilemektedir. Ayrıca, trafik kazaları günlük hayatın kaçınılmaz bir parçası olmasına rağmen bireyler veya yakınları trafik kazalarıyla karşılaştınca duyarlılık seviyeleri artmaktadır.

Trafik kazaları insanların hayatlarını olumsuz bir şekilde etkileyip geri dönülemez sonuçlara sebep olabilmektedir. Karayolu trafik kazalarında her yıl yaklaşık 1,3 milyon insan hayatını kaybetmektedir (Anonymous 2022a). Bunun yanı sıra, 50 milyona yakın insan da ruhen veya fiziksel olarak yaralanmaktadır. Ekonomik İş Birliği ve Kalkınma Örgütü (OECD) üyesi olan ülkelerdeki trafik kaza istatistikleri Şekil 1.1’de sunulmuştur (Kim et al. 2021; Anonymous 2023a). Ölüm ve yaralanmaların toplum üzerindeki etkilerinin oldukça önemli olduğu çalışmalarda ortaya konmuştur (Sabigaba et al. 2023). Trafik kazalarında manevi kayıpların yanında maddi kayıplar da oldukça


1. GİRİŞ

önemli bir yer tutmaktadır (Bougueroua and Carnis 2016). Trafik kazaları, trafikteki bireylerin bütününe ve her yönüyle önemli derecede tehdit etmektedir.



Şekil 1.1. OECD üye ülkelerdeki trafik kaza istatistikleri


Trafik kazalarında ölüm ve yaralanmalar hemen hemen tüm yaş gruplarını etkilese de özellikle 15-24 yaş arası genç nüfus üzerindeki etkisi yok sayılamaz. Belirtilen yaş grubunda meydana gelen ölüm ve yaralanmaların en önemli sebeplerinden biri trafik kazalarıdır. Amerika Birleşik Devletleri'nde (ABD) yapılan araştırmada yaş grubuna göre trafik kazalarında ölenlerin sayısına ilişkin görsel Şekil 1.2'de sunulmuştur (Anonymous 2021; Anonymous 1999).



Şekil 1.2. Yaş gruplarına göre trafik kazalarında ölüm oranı

Dünya genelinde ölüm sebepleri incelendiğinde, 2021 yılı itibariyle trafik kazaları ölüm sebepleri arasında 9. sırada yer almaktadır. Mevcut durumun devam etmesi halinde 2030 yılında trafik kazalarının ölüm sebepleri arasında 5. sıraya yükseleceği öngörülmektedir. Bu durumun önüne geçebilmek amacıyla, Birleşmiş Milletler Genel Kurulu (BMGK) 2030 yılına kadar trafik kazalarındaki ölüm ve yaralanma oranlarının yarıya kadar indirmek gibi iddialı bir hedef belirlemiştir (Anonymous 2022b). Şekil 1.3’de Dünya genelindeki trafik kazalarında ülkelere göre ölüm oranları verilmiştir (Anonymous 2022c). Bu oranın hesaplanmasında trafik kazalarında hayatını kaybedenlerin 100.000 kişi başına düşen ölüm oranı kullanılmaktadır. Özellikle, Afrika kıtasındaki ölüm oranlarının yüksek oluşu sosyo-ekonomik gelişmişlik düzeyi ile ilişkisi bulunmaktadır.

1. GİRİŞ



Şekil 1.3. Ülkelere göre karayolu trafik kazalarındaki 100.000 kişi başına düşen ölüm oranı (2022).

Bir trafik kazasının meydana gelebilmesi için bir veya daha fazla faktörün bir araya gelmesi gerekmektedir. Türkiye İstatistik Kurumu’nun (TÜİK) yayınladığı trafik kazası verilerine göre kaza sebepleri dar bir çerçeve ile sınırlandırılmıştır. Örneğin, 2022 yılına ait veriler incelendiğinde şu ifadeler yer almaktadır. “Türkiye’de 2022 yılında ölümlü yaralanmalı trafik kazasına neden olan toplam 224 bin 418 kusura bakıldığında kusurların %86,6’sının sürücü, %9,5’inin yaya, %2,1’inin taşıt, %1,2’nin yolcu ve %0,4’ünün yol kaynaklı olduğu görüldü.” (Anonim 2022a). Ayrıca, Emniyet Genel Müdürlüğü’nün (EGM) kaza istatistik verileri incelendiğinde trafik kazalarına neden olan sürücü kusurları Çizelge 1.1’de verilmiştir (Anonim 2022b).

Çizelge 1.1. Emniyet Genel Müdürlüğü istatistiklerine göre sürücü kusurları

Sürücü Kusurları	
Araç hızını yol, hava ve trafiğin gerektirdiği şartlara uydurmamak	Trafik güvenliği ile ilgili diğer kurallara uymamak
Kavşak, geçit ve kaplamanın dar olduğu yerlerde geçiş önceliğine uymamak	Yaya ve okul geçitlerinde yavaşlamamak, yayalara geçiş hakkı vermemek
Şerit izleme ve değiştirme kurallarına uymamak	Alkollü olarak araç kullanmak
Arkadan Çarpma	Aşırı hızla araç kullanmak
Doğrultu Değiştirme (dönüş) kurallarına uymamak	Geçme yasağı olan yerlerden geçmek
Manevraları düzenleyen genel şartlara uymamak	Hatalı şekilde veya yasak olan yerlere park etmek
Kırmızı ışık veya görevlinin dur işaretinde durmamak	Diğer
Taşıt giremez trafik işareti bulunan yerlere girmek	

1. GİRİŞ

Çizelge 1.1 incelendiğinde sürücü kusurlarının kapsamı sınırlı tutulmuştur. Ayrıca, sürücü kusurlarından ziyade kazanın oluşum sınıfları dikkate alınmıştır. Sürücü ile ilgili genel kusurlar hakkında bilgi verilmiştir. Ancak, WHO'nun raporları incelendiğinde trafik kazalarının sebepleri ve buna bağlı oluşan risk faktörleri oldukça geniş bir yaklaşım ile ele alınmaktadır. Aşırı hızlanma, alkol ve diğer psikoaktif maddelerin etkisi altında araç kullanma, yorgun veya uykulu araç kullanma, dikkat dağınıklığı, güvensiz yol altyapısı, uygun olmayan araçlar, trafik kurallarının yetersiz uygulanması vb. nedenlerden dolayı trafik kazalarının meydana geldiği ifade edilmektedir (Anonymous 2022a).

Türkiye özelinde trafik kazaları incelendiğinde 2022 yılında 1.232.957 trafik kazası meydana gelmiştir. Bu kazalardan 197.261 tanesi ölümlü yaralanmalı kaza sınıfına girmektedir. 2022 yılındaki trafik kazalarında 5.229 ölüm ve 288.696 yaralanma meydana gelmiştir. Bu kazaların %82,5'i yerleşim yeri içinde ve %17,5'i yerleşim yeri dışında gerçekleşmiştir. Ayrıca, Türkiye'de 1.000 taşıt başına düşen ölümlü yaralanmalı trafik kazası oranı 7,4'tür (Anonim 2022a). Türkiye genelinde 100.000 kişi başına düşen ölüm sayısı ise 2019 yılı itibarıyla 7'dir (Anonymous 2019a).

1.2.Sürücü Dikkat Dağınıklığı

Bu tez çalışması kapsamında trafik kaza sebeplerinden biri olan dikkat dağınıklığı incelenmektedir. Dikkat dağınıklığı kaynaklı sürüş davranışlarının çevresel etkileri, meydana gelen kazalara ilişkin bilgiler ve bu tür kazaların önlenmesi amacıyla öneriler sunulacaktır. Dikkat dağınıklığı, sürücüyü güvenli sürüş faaliyetlerinden uzaklaştıracak eylemlerin bütünüdür. Örneğin, cep telefonu ile konuşmak, mesaj yazmak, yeme-içme hali, araçtaki insanlarla konuşmak, multimedya sistemi ile ilgilenmek, makyaj yapmak vb. faaliyetler dikkat dağınıklığına sebep olan eylemlerdir. Trafik kazalarının %80'inden fazlası, cep telefonu kullanmak, mesajlaşmak, yolcularla konuşmak, sigara veya içecek içmekten kaynaklanmaktadır (Yanbin et al. 2017; Aljasim and Kashef 2022). Ancak, mesaj yazmak dikkat dağınıklığını en çok etkileyen eylemlerdendir. Bir mesajı okumak veya yazmak için sürücü dikkatini yoldan 5 saniyeliğine ayırdığında 90 km/sa hızla, bütün bir futbol sahasını gezecek kadar yol almaktadır (Anonymous 2020a). Sürücünün dikkatinin dağılması, insanların güvenliği üzerinde büyük bir etkiye sahiptir ve otonom

1. GİRİŞ

sürüş yardımından sigorta şirketlerine ve soruşturmalara kadar bir dizi uygulama için ilgili bir konudur (Valeriano et al. 2018).

Sürüş esnasında dikkat dağınıklığı gün geçtikçe büyüyen önemli bir risk faktörüdür ve bu konuda karar vericilerin ciddi endişeleri oluşmaktadır. Dikkat dağınıklığı faktörü üzerine yürütülen birçok çalışmanın ilgilendiği nokta, sürüş esnasında cep telefonu ve diğer teknolojik cihazların kullanımının yaygınlaşmasından kaynaklanan dikkat dağınıklığıdır. Ulusal Karayolu Trafik Güvenliği İdaresi (NHTSA) verilerine göre ABD’de 2020 yılında gerçekleşen ölümlü kazaların %8’i ve yaralanmalı kazaların %14’ünün sebebi sürücülerin genellikle cep telefonu kullanımından kaynaklı oluşan dikkat dağınıklığıdır (Anonymous 2022d). Bu alanda birçok çalışma yürütülmesine rağmen teknolojik cihazlarının kullanımından kaynaklanan dikkatsizlik başta olmak üzere, dikkat dağınıklığı sorunu ve bu sorunun trafik kazaları üzerindeki etkisi tam olarak bilinmemektedir. Konunun derinine inmeden önce sürücülerde meydana gelen dikkat dağınıklığı ve çeşitleri aşağıda açıklanmaktadır.

Yapılan tanıma göre, “Dikkat dağınıklığı, dikkatin güvenli sürüş için önem arz eden eylemlerden sürüşü tehlikeye atan eylemlere sapmasıdır.” (Anonymous 2020b). Diğer bir tanıma göre “Dikkatin, güvenli sürüş için kritik olan faaliyetlerden, diğer ikincil bir faaliyete doğru saptırılmasıdır. Bu durum, güvenli sürüş için kritik olan faaliyetlere yetersiz dikkat verilmesine veya hiç dikkat edilmemesine neden olabilir” (Regan et al. 2011). Kısaca ifade etmek gerekirse, sürücünün karar verme yetisi, farkındalığı ve sürüş performansı zayıflar. Sürücü dikkat dağınıklığı dört farklı şekilde meydana gelebilir.

Görsel: Sürüş ile ilişkisi olmayan herhangi bir durum için yoldan gözlerin ayrılmasıdır. Bir sürücü gözlerini yoldan ayırdığı esnada kendisini ve etrafındaki diğer insanları tehlikeye atmaktadır. Çoğu zaman, teknolojik cihazlar nedeniyle sürücülerin görsel dikkati dağılmaktadır. Sürücü, sürüş esnasında bu cihazlardan uzak durmalıdır. Yukarıda da belirtildiği üzere 90 km/sa hızla seyreden bir sürücünün cep telefonuna 5 saniye süresince bakması durumunda bir futbol sahası uzunluğundaki yolu kat ettiği ölçülmüştür.

1. GİRİŞ

Bilişsel: Zihinsel karmaşa yaşanması durumlarını içeren haller: cep telefonu ile konuşurken konu hakkında düşünme gibi eylemlerdir. Kısaca, sürücünün düşüncesini ve odağını sürüş faaliyetlerinden uzaklaştıran her şey bilişsel dikkat dağınıklığı sınıfına girmektedir. Teknolojik cihazların kullanımından daha fazla dikkat dağınıklığına yol açan bir dikkat dağınıklığı türüdür. Çünkü, sürücülerin sürüş esnasındaki odaklarının ölçülmesi mümkün değildir ve sıklıkla odak dağılmaktadır.

Fiziksel: Sürüş için birincil görevleri yerine getirmek yerine, farklı fiziksel eylemlerde bulunmak: cep telefonundan mesajlaşma, bilgi eğlence ekranlarıyla ilgilenme gibi eylemlerdir. Kısaca, bir sürücünün ellerini direksiyon simidinden çekmesi fiziksel dikkat dağınıklığı olarak ifade edilmektedir. Sürücülerin radyo istasyonun ayarlanması, diğer koltuklara erişim, cep telefonu kullanımı gibi durumlar fiziksel dikkat dağınıklığı sınıfına girmektedir.


İşitsel: Sürüş sırasında dış sesleri engelleyecek bir gürültü ortamına maruz kalmak: cep telefonuyla konuşmak, yüksek sesle müzik dinlemek gibi eylemlerdir. Çoğu sürücü araçlarında radyo/müzik sistemlerinin açık olmasına alışık olmasına rağmen; gürültü dikkat dağıtıcı bir durumdur. Yüksek sesle müzik dinlemek veya müziklere eşlik etmek dikkat dağınıklığına neden olmaktadır. Müzik dinlemek ve eşlik etmek sadece işitsel değil bilişsel dikkat dağınıklığı sınıfına da girmektedir. Ayrıca, yüksek ses ile müzik dinlemek araç dışındaki olaylardan haberdar olamamak anlamına gelmektedir.

Sürüş esnasında yukarıda bahsedilen durumlardan biri veya birkaçı aynı anda meydana gelebilir. Buna bağlı olarak sürücü dikkat dağınıklığı oluşmaktadır. Sürücü dikkat dağınıklığı araç içi veya harici dikkat dağınıklığı olarak ikiye ayrılabilir. Harici dikkat dağınıklıklarına örnek olarak, reklam panoları, yol kenarı tabelaları verilebilir. Unutulmaması gereken bir durum vardır ki; her dikkat dağınıklığı trafik kazasına sebebiyet vermese de kaza riskini ciddi oranda artırmaktadır. Ayrıca, sürücünün normal sürüş davranışlarından uzaklaşması ile çevresel etkiler de ön plana çıkmaktadır. Dikkat dağınıklığı yaşayan sürücü nedeniyle gecikmelerin meydana gelmesi ve buna bağlı olarak yakıt tüketimi ve emisyon değerleri gibi çevresel koşulların değişmesi kaçınılmazdır.

1. GİRİŞ

1.3.Cep Telefonu Kullanımı

Teknolojide yaşanan olağanüstü ve hızlı gelişmeler sayesinde yaşam her geçen gün dijitalleşmektedir. Ayrıca, insanoğlu dijitalleşmeye olan bağlılığını sürekli artırmaktadır. Cep telefonu kullanımının, Dünya genelinde 7,26 milyar kullanıcıya çıkması bu bağımlılığı çok net bir şekilde ortaya koymaktadır. Türkiye özelinde bu istatistik incelendiğinde 82 milyonun üzerinde abone sayısı olduğu görülmektedir. Cep telefonu kullanımı akıllı telefon özelinde incelendiğinde, Dünya genelinde 6,64 milyar akıllı telefon kullanıcısının olduğu görülmektedir (Turner 2022). 2025 yılında cep telefonu kullanıcısı sayısının 7,49 milyar, akıllı telefon kullanıcısı sayısının ise 7,33 milyar olacağı tahmin edilmektedir. Bu tahminler doğrultusunda dijitalleşmenin son sürat devam edeceği öngörülmektedir. Şekil 1.4’de akıllı telefon kullanım istatistikleri 2016-2027 yılları arası için sunulmuştur.



Şekil 1.4. 2016-2027 yılları arası için Dünya geneli güncel ve tahmini akıllı telefon kullanıcı sayısı, milyar.

Cep telefonları, sadece çağrıyı cevaplamak veya çağrı yapmak için kullanılmamaktadır. Sürekli etkileşim halinde olunan cep telefonları hiç kuşkusuz sürüş esnasında da sıklıkla kullanılmaktadır. Gerek cep telefonları olsun gerek araçların bilgi eğlence sistemleri olsun sürüş esnasında önemli derecede dikkat dağınıklığına neden

1. GİRİŞ

olmaktadır. Cep telefonu kullanımı ve trafik kaza istatistikleri ile ilgili bazı veriler bulunmaktadır. Dünya genelinde, günün herhangi bir saatinde yaklaşık 660.000 sürücü bir otomobilin direksiyonundayken telefonlarını kullanmaya çalışmaktadır. Ulusal Güvenlik Konseyi, araç kullanırken cep telefonu kullanımının her yıl 1,6 milyon kazaya yol açtığını bildirmektedir (Anonymous 2021). Mesajlaşma ve araba kullanmanın neden olduğu kazalarda yılda yaklaşık 390.000 yaralanma meydana gelmektedir (Anonymous 2022e). Tüm ölümcül kazaların yaklaşık %14'ü bir tür cep telefonu kullanımını içermektedir (Anonymous 2022f). Araç kullanırken mesajlaşmak kazaya neden olma olasılığı bakımından alkolü araç kullanmaktan 6 kat daha fazla olduğu görülmüştür. Araç kullanırken mesaj yazmak, gözleri yoldan ayırarak geçirilen süreyi %400 oranında artırmaktadır. Sürücü normal sürüş esnasında yoldan gözlerini 1 saniyeliğine ayırdığı düşünülürse cep telefonu kullanımı durumunda bu süre 5 saniyeye çıkmaktadır. Yol güvenliği uzmanı Brake, direksiyon başında telefon kullanmanın kaza yapma olasılığını dört kat artırdığını ifade etmektedir (Anonymous 2020b). Mesajlaşan sürücülerin bir kazaya karışma olasılığı, mesaj atmayan sürücülerden 23 kat daha fazladır (Anonymous 2020c). ABD’de 2010-2020 yılları arasında dikkat dağınıklığı sebebiyle meydana gelen trafik kazalarına ilişkin veriler Çizelge 1.2’de sunulmuştur (Anonymous 2022g). ABD’de yapılan bir çalışmaya göre New Jersey eyaletindeki kazaların %25’i sürücülerin dikkat dağınıklığı nedeniyle meydana gelmektedir (Hasan 2021). ABD Ulaştırma Bakanlığı tarafından açıklanan verilere göre 2020 yılında dikkati dağılmış sürücü nedeniyle 3.142 kişinin öldüğü tespit edilmiştir (Anonymous 2020d). Bu istatistiklerde belirtilen dikkati dağılmış sürücülerin her birinin cep telefonu ile ilişkisi olduğu düşünülmektedir.

Çizelge 1.2. 2010-2020 yılları arasında ABD’de dikkat dağınıklığı sebebiyle meydana gelen trafik kazaları.

Yıl	2020	2019	2018	2017	2016	2015	2014	2013	2012	2011	2010
Dikkati Dağılmış Sürüş Ölümleri	3.142	2.895	2.645	3.003	3.197	3.242	2.972	2.910	3.098	3.047	2.993

1. GİRİŞ

Çizelge 1.2. (Devam)

Dikkati Dağılımı Sürüş Kazaları (x1.000)	680	986	938	912	905	885	967	904	908	826	900
--	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----

Çizelge 1.2 incelendiğinde pandeminin etkisiyle 2020 yılında trafik kaza sayısında önemli miktarda azalma gözlemlenmektedir. Ancak, ölümler için aynı durum söz konusu değildir. Trafik kazası sayısı azalmasına rağmen ölüm sayısından artış meydana gelmiştir.

Amerikan Otomobil Birliği (AAA) anketine göre, genç sürücülerin %94'ü mesajlaşmanın ve araba kullanmanın tehlikelerini kabul etmesine rağmen, %35'i yine de bunu yaptığını kabul etmektedir (Anonymous 2021). Ölümcül kazalara karışan genç sürücülerin %21'inin dikkati cep telefonları tarafından dağıldığı tespit edilmiştir. 15-29 yaş arası 15.341 sürücü dikkat dağınıklığı veya cep telefonu kullanımı nedeniyle ölümcül kazalara karışmıştır (Anonymous 2021).

İstatistikler, ABD'de her yıl mesajlaşma ve araba kullanma nedeniyle 400 civarında ölüm olduğunu göstermektedir. Ancak, gerçek sayının bu istatistiğin en az 2 katı olduğu düşünülmektedir. ABD'deki her 4 araba kazasından 1'i, mesajlaşırken araba kullanmaktan kaynaklandığı ifade edilmiştir. Ayrıca, ABD'de her 3 gençten 1'i en az bir kez mesaj attığını ve aynı zamanda araba kullandığını itiraf etmektedir (Anonymous 2018a). Ek olarak, yapılan bir diğer çalışmaya göre cep telefonu kullanımının trafik kazaları üzerindeki etkisinin gençler arasında daha fazla olduğu gözlemlenmiştir (Klauer et al. 2014). ABD'de meydana gelen trafik kazaları sonrası yapılan bir ankette sürücülerin cep telefonu kullanım oranları Çizelge 1.3'de sunulmaktadır.

Dikkat dağınıklığı ile ilgili yapılan diğer bir araştırmaya göre, çeşitli dışsal faktörler kontrol edildikten sonra, bir sürücü eller serbest telefon görüşmesi yaptığında zamansal olarak 0,33 s'lik gecikme ve elde telefon görüşmesi için 0,75 s'lik gecikme öngörülmektedir (Saifuzzaman et al. 2015).

1. GİRİŞ

Çizelge 1.3. 2019 yılında meydana gelen ölümcül trafik kazalarının yaş gruplarına göre dağılımı.

Yaş Grubu	Sayı	Cep Telefonu Kullanan Sürücüler
15-20	66	%17
21-24	61	%16
25-34	90	%23
35-44	79	%20
45-54	48	%12
55-64	32	%8
65-74	10	%3
75+	3	%1
Toplam	390	%100

Allianz'ın Yol Güvenliği Araştırma şirketinin Türkiye'deki sürücüler için gerçekleştirmiş olduğu araştırmanın sonuçları şu şekildedir; 1.600 sürücü ile görüşerek son üç yılda kaza yapan sürücülerin %60'nın kaza sırasında cep telefonlarını kullandıkları tespit edildiği vurgulanmaktadır. Kaza yapmayan sürücülerde ise cep telefonu kullanma oranı %37 olduğu ortaya çıkmıştır. Araştırmaya göre, sürücülerin %46'sı, yani yaklaşık her iki sürücüden biri cep telefonu kullanmama kuralını ihlal etmektedir. Sürücülerin %74'ü ise araca entegre teknik cihazların dikkatlerini dağıttığını belirtmektedir. Sürücülerin %15'i trafikteyken cep telefonu ile mesajlaşma eylemini sergilemektedir ve %24'ü akıllı telefonlarını kullanarak mesajlarını okumaktadır. 24 yaş altı katılımcılar arasında bu oranın çok daha yüksek olduğu gözlemlenmiştir. Bu yaş grubundaki katılımcıların %23'ü araba kullanırken mesaj yazarken, %27'si mesajlarını okumaktadır. Araştırma, sürücülerin %52'sinin dikkatinin yolcuların yaptığı telefon konuşmaları nedeniyle dağıldığını ortaya koymaktadır (Anonim 2017; Turan 2017)

Sürücülerin, sürüş esnasında cep telefonlarıyla veya diğer bilgi eğlence sistemleriyle ilgilenmesi ile odak noktası dağılmaktadır. Çizelge 1.4'de sürücünün hızına bağlı olarak 2 saniyede kat ettiği mesafe sunulmuştur. Çizelge 1.4'deki değerler incelendiğinde sürücünün cep telefonu ile 2 saniyelik ilgisinin trafik kazalarında ne kadar önemli olduğu görülmektedir.

Çizelge 1.4. Seyahat hızına bağlı olarak 2 saniyelik mesafe

Seyahat hızı (km/sa)	40	50	60	80	100
2 sn. alınan yol (metre)	22.22	27.78	33.33	44.44	55.56

Cep telefonu ile ilgilenme sürücülerin sadece seyir halinde sergiledikleri eylemlerden değildir. Bunun yanında sürücüler trafik ışıklarında beklerken veya park halindeyken araç içerisinde cep telefonları ile sıklıkla ilgilenmektedir. Park durumundaki araç sürücülerinin trafiği tehlikeye atmaması durumunda herhangi bir dikkat dağınıklığı olmadığı söylenebilir. Çünkü, herhangi bir birincil sürüş faaliyeti göstermemektedir. Ancak, trafik ışıklarında bekleyen sürücülerin kavşaktaki gecikmeleri ve buna bağlı olarak yakıt tüketimi ve emisyon değerlerini etkilediği ifade edilebilir.

Sürücülerin cep telefonu kullanımı nedeniyle trafik kazasına karışma oranları veya ihtimalleri ile ilgili çalışmalar çeşitli kuruluşlar ve araştırmacılar tarafından gerçekleştirilmiştir. Sürücü dikkat dağınıklığının neden olduğu çevresel etkiler özelinde çalışmalar incelendiğinde oldukça kısıtlı bir literatürün var olduğu görülmektedir. Ancak, kısmi yapılan çalışmalar incelendiğinde sürücü dikkat dağınıklığı araç gecikmelerini, yakıt tüketimini ve emisyon değerlerini artırdığı görülmektedir (Calvi et al. 2020; Singh and Kathuria 2021). Trafik kazaları, maruz kalan bireylerin ve yakınlarının hayatını şiddetli bir şekilde etkilemektedir. Ancak, trafiğin çevresel etkileri Dünya üzerinde var olan tüm insanların hayatına doğrudan veya dolaylı yoldan etki etmektedir. Çevresel etkilerin sonuçları anında ortaya çıkmasa da süreç içerisinde trafik kazalarından daha tehlikeli olabilmektedir.

Yapılan tez çalışması kapsamında sürücü dikkat dağınıklığının çevresel etkilerinin incelenmesi, sürücü dikkat dağınıklığının tespit edilmesi ve sürücülerin uyarılması konuları ele alınmıştır. Çalışma, giriş, kaynak özetleri, materyal ve yöntem, araştırma bulguları ve tartışma, sonuçlar ve öneriler başlıkları altında sunulmuştur.

Çalışmanın giriş bölümünde trafik kazaları, sürücü dikkat dağınıklığı ve cep telefonu kullanımı ile ilgili bilgiler sunulmuştur. Kaynak özetleri bölümünde sürücü dikkat dağınıklığının tespiti için yapılan çalışmalar ve sürücü dikkat dağınıklığının

çevresel etkilerini dikkate alan çalışmalardan bahsedilmiştir. Bu tez çalışmasının literatürdeki çalışmalardan farkı ve yeniliği ortaya konulmuştur.

Materyal ve yöntem bölümünde sürücü dikkat dağınıklığının çevresel etkilerinin incelenebilmesi için saha gözlemi yapılan çalışma alanı tanıtılmıştır. Bunun ardından yakıt tüketimi, emisyon ve gecikme değerlerinin kullanıldığı referans çalışmaya yer verilmiştir. Sürücü dikkat dağınıklığının tespiti için kullanılan veriler ve verilerin toplanma şekline ilişkin bilgiler sunulmuştur. Bunun haricinde, çalışma da kullanılan çok kriterli karar verme (ÇKKV) yöntemleri, coğrafi bilgi sistemleri (CBS), derin öğrenme ve görüntü işleme tekniklerden bahsedilmiştir.

Araştırma bulguları ve tartışma bölümünde çalışma kapsamında dikkate alınan problemler incelenmiştir. Mevcut problemlere çözüm için sürücü dikkat dağınıklığının çevresel etkileri, en kritik/yoğun kavşak seçimi ve sonuçları sunulmuştur. Ek olarak, sürücü dikkat dağınıklığının tespit edilmesi ve sürücünün uyarılması ile ilgili bilgiler sunulmuştur.

Sonuçlar ve öneriler bölümünde cep telefonu kaynaklı sürücü dikkat dağınıklığı nedeniyle meydana gelen çevresel etkiler sunulmaktadır. Sürücü dikkat dağınıklığı tespit modeli sonucunda elde edilen performans çıktılarından bahsedilmiştir. Mevcut durumun iyileştirilmesi için çeşitli öneriler ifade edilmiştir.

2. KAYNAK ÖZETLERİ

Sürücülerin dikkat dağınıklığını tespit etmek için literatürde birçok çalışma bulunmaktadır. Bunun yanında, cep telefonu kullanımı kaynaklı dikkat dağınıklığından dolayı meydana gelen çevresel etkiler yeterince incelenmediği görülmektedir. Ayrıca, sürücü dikkat dağınıklığının tespiti için yapılan çalışmaların çoğunda gerçek zamanlı tespit algoritması yürütülmemiştir. Genellikle sahadan elde edilen veriler üzerinden sürücü dikkat dağınıklığı tespiti yapılmıştır. Ayrıca, çalışmaların çoğunluğu cep telefonu kullanım ihlalinin tespiti amacıyla gerçekleştirilmiştir. Herhangi bir ikaz veya uyarı sistemi geliştirilmemiştir. Bu doğrultuda, cep telefonu kullanımından dolayı ortaya çıkan güvenlik etkisi göz önüne alınmadığı söylenebilir. Cep telefonu kullanım ihlallerinin derin öğrenme tabanlı tespiti ile ilgili yapılan çalışmalar aşağıda sunulmaktadır. Bunun yanında, trafik ışıklarında bekleyen sürücülerin yaşadıkları dikkat dağınıklığını ele alan çalışmalarda aşağıda verilmiştir.

AHP yönteminin ve YOLO algoritmasının beraber kullanıldığı tek bir çalışma bulunmaktadır. Asif et al. (2021) tarafından yapılan çalışmada acil durum müdahalesine ilişkin bir afet sınıflandırması önerilmiştir. Acil durum halinde müdahalenin otomatikleştirilmesi için derin öğrenme ve nesne tanıma algoritmaları birlikte kullanılmıştır. Afetle ilgili elde edilen görüntülerin analiz edilmesi ve afet türlerinin sınıflandırılması amacıyla Visual Geometry Group (VGG-16) ve You Only Look Once (YOLO) algoritması tercih edilmiştir. Uygun acil durum müdahalesini belirlemek amacıyla Analitik Hiyerarşi Süreci (AHP) yöntemi kullanılarak sıralama yapılmıştır.

Xing et al. (2019) tarafından yapılan çalışmada sürücü davranışlarını anlamak için çalışmada derin evrimsel sinir ağlarına dayalı bir sürücü aktiviteleri tanıma sistemi tasarlanmıştır. Spesifik olarak, normal sürüş, sağ ayna kontrolü, dikiz ayna kontrolü, sol ayna kontrolü, araç içi multimedya cihazını kullanma, mesajlaşma ve cep telefonuna cevap verme olmak üzere yedi adet sürüş aktivitesi belirlenmiştir. Veri seti için düşük maliyetli kamera kullanılmaktadır ve sadece on adet sürücü çalışmada yer almaktadır. Eğitim maliyetlerini azaltmak ve önceden eğitilmiş Evrimsel Sinir Ağı (CNN) modellerine ince ayar yapmak için transfer öğrenme algoritmalarından AlexNet, GoogLeNet ve ResNet50 modelleri uygulanmıştır. Yedi adet sürüş aktivitesinin tespit

algoritması sonuçlarına göre AlexNet %81,6, GoogLeNet %78,6 ve ResNet50 %74,9 doğruluk oranı elde edilmiştir. Daha sonra dikkat dağınıklığının tespit edilmesi için ikili sınıflandırma derin öğrenme yöntemi kullanılmıştır. Buna göre %91,4 doğruluk ile dikkat dağınıklığı tespit edilmiştir.

Eraqi et al. (2019), dikkat dağınıklığını tespit edebilmek ve tanımlayabilmek için derin öğrenme algoritmalarını kullanmışlardır. ImageNet üzerinde daha önceden eğitilmiş modelleri “transfer learning” mantığıyla tekrar kullanmışlardır. Dikkat dağınıklığını tespit etmek için tam bağlantılı katmanlar (fully connected layers) yeniden eğitilmiştir. Gerçek zamanlı ve genetik olarak ağırlıklı CNN kullanılmıştır. Çalışmada kullanılmak üzere nihai haliyle 44 sürücülük halka açık bir veri seti oluşturulmuştur. Veri seti gerçek hayat koşullarından ziyade sürücü, araç ve dikkat dağınıklığının belirlenmesi amacıyla yapay görüntüler ile elde edilmiştir. Çalışmanın sonuçlarını değerlendirmek ve karşılaştırma yapmak için “StateFarm” veri seti dikkate alınmıştır. Çalışmada, VGG-16, AlexNet, ResNet50 ve Inception V3 modelleri uygulanmıştır. Gerçek zamanlı tespit yapılabilmesi için bağlantı parametrelerinin sayısını azaltan NasNetMobile modeli kullanılmıştır ve %84,64 oranında doğruluk elde edilmiştir.

Alotaibi and Alotaibi (2020), dikkati dağılmış sürücülerin tespit edilmesi için CNN ve HRNN algoritmasından oluşan bir grup model geliştirmişlerdir. Veri seti olarak Kaggle platformunda yayınlanan “StateFarm” ve “AUC” veri seti kullanılmıştır. ResNet, HRNN ve Inception modelinden tek bir grup model olarak faydalanılmıştır. Modelde, Inception modülü ile entegre bir ResNet bloğu ve iki HRNN katmanı bulunmakta ve bunları iki yoğun katman (dense layers) ve softmax sınıflandırıcı takip etmektedir. Önerilen modelin, “StateFarm” ve “AUC” veri seti için sırasıyla %96,23 ve %92,36 oranında doğruluk oranı olduğu gözlemlenmektedir.

Gumaei et al. (2020), yaptıkları çalışmada uç nokta ve bulut bilgi işlem teknolojileri ile derin öğrenme yaklaşımını kullanarak araç sürücülerinin dikkat dağınıklığının gerçek zamanlı tespit edilebilmesi için kamera tabanlı bir yaklaşım önermişlerdir. Önerilen çerçeve, araç ortamında uç cihazlara yerleştirilen dikkat dağınıklığı algılama modülü, bulut ortamına entegre eğitim modülü ve telekomünikasyon ağı ile bağlantılı analiz modülü olmak üzere üç modülden oluşmaktadır. Önerilen yaklaşımda özel CNN ve

VGG-16 derin öğrenme algoritmaları kullanılmıştır. Çalışma sonucunda, veri setinde yapılan iyileştirme sonucunda CNN ve VGG-16 için sırasıyla %99,64 ve %99,73'lük oranda doğruluk oranı elde edilmiştir.

Alkan vd (2019) tarafından derin öğrenme algoritmalarından biri olan Single Shot Multi Box Detector (SSD) kullanılarak sürücünün telefon kullanım ihlali tespitine yönelik yeni bir otomatik teknik önerilmiştir. Bir otoyol üzerine kurulu bir tavan köprüsü üzerine yerleştirilmiş mevcut bir plaka tanıma kamera sisteminden faydalanılarak, gündüz ve gece boyunca gerçek dünya görüntüleri yakalanmaktadır. 5.900'den fazla gerçek dünya görüntüsü kullanarak deneyler gerçekleştirilmiştir ve sürücü cep telefonu kullanım ihlali algılama görevinde genel olarak %90,8'lik bir doğruluk elde edilmiştir.

Xiong et al. (2019), sürücülerin cep telefonu nedeniyle meydana gelen dikkat dağınıklığının tespiti için bir çalışma yürütmüşlerdir. Dikkat dağınıklığının tespit edilmesi için iki adımlı bir yaklaşım önermişlerdir. İlk adımda, yüz bölgesini tespit ve takibini yapan Progressive Calibration Networks (PCN) mimarisi kullanılmıştır. İkinci adımda, belirlenen alanda cep telefonunun tespit edilmesi amacıyla CNN mimarisi tercih edilmiştir. İkili karşılaştırma durumları dikkate alınarak cep telefonunun tespit edilmesi amaçlanmıştır Bunun için, 22.216 adet cep telefonu ile ilgilen sürücü resmi ve 25.464 adet normal sürücü çalışmaya dâhil edilmiştir. Önerilen yaklaşım, %96,56 oranında doğruluk oranına sahip olduğu ifade edilmektedir.

Wagner et al. (2022), sürücülerin cep telefonu kullanımını ve yiyecek tüketme durumunu sürücü pozisyon sınıflandırma yaklaşımı ile tespit etmeyi araştırmışlardır. Dikkat dağınıklığını tespit etmek için farklı derin öğrenme modellerini eğitmişlerdir ve farklı baş açılarının değerlendirilmesi için iki kızılötesi kamera tarafından yakalanan görüntüler ile veri kümesi oluşturulmuştur. Toplam 32.188 adet sürücü resmi veri seti olarak çalışmaya dahil edilmiştir. Sınıflandırmanın doğruluğunu kanıtlamak için sağ ve sol kamera için ayrı ayrı CNN mimarileri eğitilmiş ve değerlendirme yapılmıştır. Çalışmada sürücünün duruşunu sınıflandırmak için dört farklı CNN modeli eğitilmiş ve değerlendirilmiştir. Bunlar, ResNeXt-34, ResNeXt-50, VGG-16 ve VGG-19'dur. Sol ve sağ kamera için sırasıyla %92,88 ve %90,36 oranında bir doğruluk oranı elde edilmiştir.

Omerustaoglu et al. (2020) tarafından yürütülen çalışmada sürücü destek sistemlerinin geliştirilmesi için görüntü tabanlı dikkati dağılmış sürücü algılama modeline sensör verilerinin entegre edilmesi önerilmektedir. Gerçek dünya verilerinden toplanan cep telefonu kullanan sürücü görüntülerini ve sensör verilerini içeren yeni bir veri seti oluşturulmuştur. Dokuz farklı davranış için iki adımlı dikkat dağınıklığı tespit sistemi kullanılmıştır. İlk adım olarak transfer öğrenme ve ince ayar (fine tune) yöntemlerini kullanarak görüntü tabanlı CNN mimarisi oluşturulmuştur. İkinci adımda sensör ve görüntü verileri birlikte kullanılarak LSTM-RNN mimari kurulmuştur. İki farklı teknik ile sistem değerlendirilmiştir ve sensör verilerinin entegre edilmesi ile performansın önemli ölçüde arttığı gözlemlenmiştir.

Rouari et al. (2021), lojistik ulaşımda sürücü kaynaklı trafik kazalarını azaltmak amacıyla sürücü hatalarını inceleyen bir çalışma gerçekleştirmişlerdir. “StateFarm” veri seti kullanılarak sürücünün dikkat dağınıklığına sebep olan sürüş pozisyonları oluşturulan CNN mimarisi sayesinde tespit edilmeye çalışılmıştır. 22.424 adet sürücü resmi dikkate alınarak oluşturulan CNN modeli ile %98,05 oranında bir doğruluk oranı elde edilmiştir. Ayrıca, aynı veri seti için daha önce yapılan çalışmalar incelenmiştir ve AlexNet, Inception V3, VGG-16 ve 3D-CNN gibi modellere göre önerilen modelin daha iyi sonuç verdiği gözlemlenmiştir.

Valeriano et al. (2018), derin öğrenme ve CNN mimarisinden faydalanarak sürücülerin dikkatini dağıtan unsurların tespit edilmesi sorununu ele almaktadırlar. Çalışmada veri seti olarak “StateFarm” kütüphanesi kullanılmıştır. Farklı CNN mimarileri oluşturulmuş ve kıyaslama yapılmıştır.

Kumar et al. (2021) tarafından yürütülen çalışmada sürücü dikkat dağınıklığının tespit edilmesi amacıyla genetik algoritma tabanlı altı farklı algoritma önerilmiştir. Bunlar, AlexNet, VGG16, EfficientNet B0, Vanilla CNN, Modified DenseNet ve InceptionV3 + BiLSTM algoritmalarıdır. Çalışmada iki farklı açık kaynak veri seti kullanılarak karşılaştırma yapılmıştır. Kıyaslama sonucunda %99,75 oranında başarı sağlanmıştır.

Sajid et al. (2021), dikkati dağılmış sürücülerin tespit edilmesi amacıyla “StateFarm” veri setini kullanarak daha güvenilir bir çerçeve sunmak için çalışma yürütmüşlerdir. EfficientDet modeli tespit amacıyla kullanılmıştır ve en iyi sonucu veren model ile daha hızlı bölgesel tabanlı konvolüsyonlu sinir ağı (Faster R-CNN) ve YOLO-V3 kıyaslanmıştır. Kullanılan EfficientDet model mimarisinin doğruluk oranına göre diğer modellerden daha iyi sonuç verdiği gözlemlenmiştir.

Pal et al. (2021), dikkati dağılmış sürücülerin tespiti ve uyarılması için bir çalışma gerçekleştirmişlerdir. Sürücülerin tespit edilmesinde “StateFarm” veri seti kullanılmıştır. MobileNet, ResNet, Inception-v3 ve DenseNet model mimarileri ile sürücülerin tespit edilmesi amaçlanmıştır. Doğruluk oranına göre en iyi sonucun ResNet mimarisi ile oluşturulan modelin elde ettiği görülmektedir. Sürücü uyarıcı sistem ile ilgili herhangi bir öneri sunulmamıştır.

Li et al. (2022), geliştirilmiş derin öğrenme teknikleri kullanarak sürücü dikkat dağınıklığını tespit etmek için bir çalışma yürütmüşlerdir. Çalışmada, açık kaynak olarak yayınlanan üç farklı veri setine AlexNet, VGG-16 ve ResNet-18 algoritmaları uygulanmıştır ve sonuçları karşılaştırılmıştır. Buna göre, sırasıyla %99,92, %100 ve %99,99 oranında başarı oranı sağlanmıştır. ResNet-18 algoritmasının iki veri setinde daha düşük başarı oranı elde ettiği görülmüştür.

Aljasim and Kashef (2022) tarafından yapılan çalışmada sürücünün dikkatini dağıtan eylemlerin seviyesini en aza indirmek ve sürüş güvenliğini artırmak için çeşitli topluluk derin öğrenme (ensemble deep learning) modellerinden oluşan bir çerçeve tasarlanmıştır. Çalışmada, iki veya daha fazla derin öğrenme modelini birleştirmek amacıyla topluluk yöntemlerini kullanan ve ölçeklenebilir model olan The Ensemble-Based Distraction Detection with Recommendations Model (E2DR) mimarisi önerilmektedir. ResNet50 ve VGG16 modellerini içeren E2DR mimarisi “StateFarm” veri setine uygulanmış ve %92 oranında doğruluk oranı elde edilmiştir.

Ezzouhri et al. (2021), sürücülerin dikkat dağınıklığını tespit etmek amacıyla hazır bir veri seti üzerinden çalışma gerçekleştirmişlerdir. Önerilen çözümün temel özelliği, dikkat dağınıklığını tespit etmeden ve sınıflandırmadan önce derin öğrenme tabanlı

segmentasyon uygulayarak sürücünün vücut bölümlerinin çıkarılmasıdır. Segmentasyon yöntemi olarak Mask R-CNN modeli uygulanmıştır. Ayrıca, sınıflandırma yöntemi olarak CNN algoritmalarından VGG-19 ve Inception-v3 tercih edilmiştir. Önerilen yaklaşımda 38.327 adet sürücü görüntü elde edilmiş ve “AUC” veri seti kıyaslama olarak kullanılmıştır. Çalışma sonuçları incelendiğinde, segmentasyon modülünün sınıflandırmadaki performansı ciddi anlamda geliştirdiğini göstermektedir. “AUC” veri seti için %96 oranında doğruluk oranı elde edilmiştir.

Sahoo et al. (2022) tarafından yürütülen çalışmada hafif derin evrişimli sinir ağlar kullanılarak dikkati dağılmış sürücü tespiti yapılmıştır. Sürücü duruşunu sınıflandırmak için transfer öğrenme yöntemlerinden SqueezeNet 1.1’in son katman değişikliğiyle birlikte uygulanmaktadır. Genişletme ve sıkıştırma katmanları sayesinde derin CNN’nin çok sayıda parametresi değiştirilmiştir. Dolayısıyla SqueezeNet mimarisinin parametre boyutu azaltılarak gömülü sistemler için uygun hale getirilmiştir. “StateFarm” veri seti üzerinde yapılan model çalışmasında eğitim performansı açısından %99,93’lük bir doğruluk oranı sağladığı gözlemlenmiştir. Gerçek bir araçta test edebilmek için Raspberry Pi 4B modeli kullanılmıştır.

Balabid et al. (2022) tarafından karayollarındaki araçların konumlarını belirleyen, plaka numaralarını algılayan, ön cam bölgesini tespit eden ve daha önceden tanımlanmış ihlallere göre sınıflandıran bir derin öğrenme yaklaşımı önerilmiştir. Veri seti olarak plaka tanıma sisteminden faydalanılarak yaklaşık 10.000 görüntüden oluşan gerçek dünya verileri kullanılmıştır. Model için Faster R-CNN, Derin CNN, Shallow CNN ve veri setine uygun olarak hazırlanmış bir özel CNN mimarileri uygulanmıştır. Oluşturulan özel CNN mimarileri için VGG-16, VGG-19, ResNet ve Inception v3 algoritmalarına ince ayarlar yapılmıştır. Tüm mimariler için ortalama %80-90 arasında bir doğruluk oranı elde edilmiştir.

Le et al. (2016), bir sürücünün cep telefonu kullanıp kullanmadığını otomatik olarak belirlemenin yanı sıra ellerinin direksiyon simidinde olup olmadığını algılamak için gelişmiş bir derin öğrenme tabanlı yaklaşım önermektedirler. Eller gibi küçük nesneleri sağlam bir şekilde algılamak için, standart bir Bölge Teklif Ağı (RPN) nesli kullanan ve ilgi bölgesini (ROI) havuzu için daha sık evrişim özellik haritalarından, yani conv3 ve

conv4'ten özellik haritalarını birleştiren Çok Ölçekli Daha Hızlı Evrişimsel Sinir Ağları (MS-FRCNN) yaklaşımı önerilmektedir. Sürücü dikkat dağınıklığı algılama çerçevesinde ilk olarak, bir el, bir cep telefonu ve bir direksiyon simidi gibi tek tek nesneleri algılamak için önerilen MS-FRCNN modeli kullanılmaktadır. Ardından, bir cep telefonunun kullanılıp kullanılmadığını veya direksiyonda kaç elin bulunduğunu belirlemek için geometrik bilgiler çıkarılır. Önerilen yaklaşım, Akıllı Araçlar ve Uygulamalar için Vizyon Mücadelesi veri tabanında ve sürücüleri doğal sürüş koşullarında izlemek için elde edilen zorlu Stratejik Otoyol Araştırma Programı yüz görünümü videolarında gösterilmiş ve değerlendirilmiştir. Deneysel sonuçları, yöntemin, benzer test maliyetinde kalırken, her iki el üzerinde direksiyon algılama ve cep telefonu kullanımı algılamada MS-FRCNN'den daha iyi performans sergilediğini göstermektedir.

Masood et al. (2020), yalnızca dikkati dağılan sürücüyü tespit etmek için değil, aynı zamanda aracın içine monte edilmiş kamera modülü kullanılarak elde edilen görüntüleri analiz ederek dikkat dağılmasının nedenini belirlemek için CNN kullanan bir makine öğrenimi modelini sunmuşlardır. Deneysel sonuçlar, dikkat dağınıklığının tanınmasında ortalama %99 doğruluk göstermektedir ve bu nedenle CNN modelinin sürücüler arasındaki dikkat dağınıklığını belirlemek için kullanılabileceğini kuvvetle desteklemektedir.

Hou et al. (2022), sürüş esnasındaki dikkat dağınıklığı problemini çözmek için sürüş sırasında tehlikeli davranışları tespit etme amacıyla akıllı bir izleme sistemi tasarlamışlardır. Sürücünün davranışını belirlemek için SSD ile birleştirilmiş Mobilenet adlı verimli bir derin öğrenme modeli uygulanmıştır. Önerilen sistemin performansını değerlendirmek için 6.796 görüntüden oluşan tehlikeli sürüş veri seti oluşturulmuştur. Deneysel sonuçlar, önerilen sistemin %99 doğruluk elde edebileceğini ve sürücülerin durumunun gerçek zamanlı izlenmesi için kullanılabileceğini göstermektedir.

Hasan (2021) tarafından yürütülen tez çalışmasında sürücülerin dikkatini dağıtan aktivitelerin tespiti için derin öğrenme tabanlı bir analiz süreci önerilmiştir. Sürücülerin dikkat dağınıklığına sebebiyet veren en olumsuz aktivitenin cep telefonu kullanımı olduğunu elde etmiştir.

Dey (2021) tez çalışmasında trafik kazalarında önemli rol oynayan sürücü dikkat dağınıklığının tespit edilmesi için iki aşamalı bir derin öğrenme tabanlı mimarisi önermiştir. İlk adım olarak, toplam 4 güvensiz sürüş eylemi ve 1 adet güvenli sürüş eyleminden oluşan veri seti için ResNet-101 model mimarisini kullanarak sürücünün dikkat dağınıklığına sebep olan eylemi tespit etmeye çalışılmıştır. Daha sonra, 9 adet güvensiz sürüş eylemi ve 1 adet güvenli sürüş eylemini içeren aynı veri seti için tespit çalışması gerçekleştirilmiştir. İlk adım için %75 ve ikinci adım için %94 doğruluk oranı elde edilmiştir.

Huth et al. (2015), trafik ışığı kırmızı olduğunda cep telefonu kullanımını ve sergilenen sürüş eylemini analiz etmek için yol kenarı gözlem çalışması yürütmüşlerdir. Kavşaklarda 124 cep telefonu kullanıcısı ve bir grup normal sürüş faaliyeti sergileyen sürücüler incelenmiştir. Trafik bilincinin bozulduğu durumlarda cep telefonu kullanımı ile gecikme arasındaki ilişki değerlendirilmiştir. Trafik ışığı yeşile döndüğünde sürücüler cep telefonunu kullanmayı bırakma eğilimi gösterse de normal sürüş uygulamalarının gerektiği gibi yapılmadığı gözlemlenmiştir. Ayrıca, cep telefonu kullanımının taşıt gecikmelerini genel olarak artırdığı gözlemlenmiştir.

Catalina Ortega et al. (2021) tarafından yürütülen çalışmada normal sürüş eylemleri ve ikincil sürüş eylemleri sergileyen 39 genç katılımcının trafik davranışları incelenmiştir. Dikkati dağılmış sürücülerin, normal sürüş davranışları sergileyen sürücülere göre araç kontrolü açısından önemli ihlaller yaptıkları belirlenmiştir. Araç kullanırken cep telefonu kullanımının sürücülerin iş yükünü arttırdığı gözlemlenmiştir. Ek olarak hem sürüş halinde hem de trafik ışıklarında beklerken sürücülerin olağan sürüş güzergâhlarını izleyemedikleri görülmüştür.

Gjorgjevski et al. (2021), kırmızı ışıktaki bekleyen ilk iki motorlu taşıt sürücüsünün davranışlarını incelemişlerdir. Üç farklı gözlem parametresi dikkate alınmıştır: demografik özellikler, dikkat dağıtıcı eylemler ve trafik ışıklarından geçerken verilen tepkiler. Genel olarak trafik ışığı kırmızıdan yeşile döndüğünde 2 saniyeden fazla hareketsiz kalan araç gecikmiş olarak değerlendirilmiştir. Araştırmaya dahil edilen 1.008 sürücüden 608'inin trafik ışıklarında dikkat dağınıklığı yaşadığı gözlemlenmiştir. Araç içi dikkat dağılmasının ise %44,8 oranıyla en sık görülen dikkat dağıtma türü olduğu

belirlenmiştir. Cep telefonu kullanımı oranı ise %7,4 olarak tespit edilmiştir. 126 sürücünün gecikmeli davranış sergilediği ve bu sürücülerin %88,1'inin dikkatinin dağıldığı belirlenmiştir.

Sieklicka et al. (2022), yoğun trafik koşulları altında sinyalize kavşakta sürücülerin davranışları üzerine araştırma yapmışlardır. Yoğun trafik koşullarında sürücülerin en az bir kez kırmızı ışıktaki beklemek zorunda kaldığı gözlemlenmiştir. Saha araştırması sonuçları incelendiğinde kırmızı ışığın yanmasından itibaren aracını durduran sürücülerin %60'ının cep telefonu kullandığı görülmüştür. Ayrıca anket sonuçlarına göre sürücülerin %40'ından azı bu davranışı sergilediğini itiraf etmiştir.

Bakhtari Aghdam et al. (2022) tarafından yapılan çalışmada, sürücülerin trafik ışıklarındaki davranışları incelenmiştir. 946 sürücünün katıldığı çalışmada sabah, öğlen ve akşam saatlerindeki davranışlar gözlemlenmiştir. Trafik ışıklarında sürücülerin %13,6'sının cep telefonunu kullandığı tespit edilmiştir. Ayrıca kadın sürücüler arasında cep telefonu kullanım oranının erkek sürücülere göre iki kat daha fazla olduğu belirlenmiştir. 26-40 yaş arası ve 41-50 yaş arası sürücülerin 25 yaş altı sürücülere göre daha az cep telefonu kullandıkları gözlenmiştir.

Sharma et al. (2019), sinyalize kavşaklarda rölantideki yakıt tüketiminin tahmini üzerine bir çalışma yürütmüşlerdir. 341 araç rölanti durumunda yakıt tüketimi açısından test edilmiştir. Çalışmada Delhi'deki yaklaşık 950 kavşak incelenmiştir. Yakıt tüketiminin yanı sıra sera gazı emisyonları da çalışma kapsamında tahmin edilmektedir. Sonuçlar incelendiğinde 9.036 litre benzin, motorin ve LPG tüketiminin olduğu görülmüştür. Bunun yanı sıra, günde yaklaşık 37 ton CO₂ emisyonu elde edilmiştir (Sharma et al. 2019).

Sharma et al. (2022), rölantide yakıt tüketimi ve ilgili emisyonlar hakkında farkındalık oluşturmak amacıyla Delhi'deki 100 sinyalize kavşakta 40 günlük bir çalışma gerçekleştirmişlerdir. Farkındalık çalışması öncesi trafik ışıklarında oluşan emisyon değeri günlük 9.357 ton CO₂ olarak hesaplanmıştır. Farkındalık çalışması sonrasında bu değer 7.976 ton CO₂ seviyelerine kadar gerilemiştir. Ayrıca yakıt tüketiminde de yaklaşık %22'lik bir azalma gözlemlenmiştir.

De Blasiis et al. (2022) tarafından gerçekleştirilen çalışmada sürücü davranışı, kirletici emisyonlar ve trafik akışı arasındaki ilişkiyi anlamak için trafik emisyon modellemesine yönelik yeni bir yaklaşım önerilmiştir. Sonuçlara göre ortalama araç hızı azalsa da sürücülerin ani hızlanma ve yavaşlamalarından dolayı kirletici emisyonlar artmaktadır. Sürücü davranışlarının trafik emisyonları üzerindeki etkisinin oldukça büyük olduğu gösterilmiştir.

Yürütülen bu tez çalışmasında ilk olarak cep telefonu kaynaklı sürücü dikkat dağınıklığının yol kenarı gözlem araştırması yaklaşımıyla tespit edilmesi gerçekleştirilmiştir. Çalışma alanında seçilen kavşaklarda yapılan gözlemler neticesinde sürücü dikkat dağınıklığının neden olduğu gecikmeler hesaplanmıştır. Literatürde var olan referans veriler kullanılarak seçilen kavşaklardaki gecikme ve buna bağlı olarak emisyon ve yakıt tüketimi değerleri incelenmiştir. ÇKKV yöntemleri aracılığıyla dikkate alınan parametrelerin ağırlıklandırılması gerçekleştirilmiştir. Ağırlıklı değerler kullanılarak en yoğun/kritik kavşak seçimi yapılmıştır. Kavşaklardaki değerlerin görsel analiz ve gösterimi kapsamında CBS kullanılmıştır. Çalışmanın devamında, sürücü dikkat dağınıklığının nesne tespit algoritması ile tespit edilmesi için farklı ülke ve şehirlerdeki sürücülerden oluşan veri seti oluşturulmuştur. Veri setindeki eylem sınıflarının ağırlıklandırılması amacıyla ÇKKV yöntemlerinden AHP kullanılmıştır. Literatürdeki çalışmalar / modeller incelenmiştir ve nesne tespiti alanında en iyi sonuç veren algoritma veri setine uygulanmıştır. Oluşturulan model gerçek zamanlı veriler kullanılarak yeniden eğitilmiştir ve sürücü dikkat dağınıklığı tespiti yeniden yapılmıştır. Gerçek zamanlı veriler kullanılarak sürücü dikkat dağınıklığı için sürücünün anlık / gerçek zamanlı uyarılma işlemi gerçekleştirilmiştir.

Tez çalışması kapsamında yürütülen çalışmaların literatürde yer alan çalışmalardan farkları bulunmaktadır. Mevcut çalışmanın literatürden farkı, katkısı ve yeniliği aşağıda sıralanmıştır. Çalışmanın farkları, katkısı ve yeniliği çevresel etkilerinin incelenmesi ve sürücü dikkat dağınıklığının tespit edilmesi olarak iki farklı başlık altında sunulmuştur.

Çevresel etkilerinin incelenmesi:

Cep telefonu kullanımından kaynaklanan gecikme, emisyon, yakıt tüketimi vb. değerlerin incelenmesi ilk defa bu çalışma kapsamında ele alınmıştır.

Dikkati dağılmış sürücülerin çevresel etkilerini analiz etmek için ilk defa ÇKKV ve CBS yaklaşımları birlikte kullanılmıştır.

Cep telefonu kullanımı kaynaklı sürücü dikkat dağınıklığının yol kenarı gözlem yaklaşımıyla tespit edilmesi için kavşak ve araç sayısı bakımından ilk defa bu kadar büyük bir örneklem oluşturulmuştur.

Çevre kirliliğinin yanı sıra trafik güvenliğiyle de doğrudan ilişkili olan sürücü dikkat dağınıklığı kavşak bazlı olarak bu çalışmada incelenmiştir.

Sürücü dikkat dağınıklığının tespit edilmesi:

Gerçek zamanlı sürüş verileri kullanılarak sistem tasarımlarının hiperparametre ayarları uygun şekilde yeniden yapılandırılmıştır. Bu sayede oluşturulan modelin mümkün olan en yüksek doğruluk değerini elde etmesi amaçlanmıştır.

Veri setinin güncel olması bakımından Türkiye'deki sürücüler incelenerek geniş bir veri seti yelpazesi oluşturulmuştur. Farklı karakteristiklere sahip sürücülerin çıktıları için ortak bir görüntü işleme veri tabanının oluşturulması amaçlanmıştır. Mikro ve makro hareketlilik seviyeleri birbirinden tamamen farklı olan kentlerin çalışmaya dâhil edilmesi çalışmanın evrenselliği açısından oldukça önemlidir.

Sürücü dikkat dağınıklığının tespit edilmesi ve dikkati dağılmış sürücüyü uyarmak amacıyla sürücünün uyarılması çalışma kapsamında hedeflenmektedir. Böylece, sürücünün dikkat dağınıklık halini Akıllı Ulaşım Sistemleri'nin bir uygulama alanı olan sürücü destek sistemleri kapsamında mümkün olan en kısa sürede ortadan kaldırmak amaçlanmıştır.

Dikkat dağınıklığına neden olan eylem sınıflarının belirlenmesinde ve çalışmada kullanılması için yürütülecek süreçte ÇKKV Yöntemlerinden AHP kullanılmaktadır. Derin öğrenme algoritmaları ile AHP yönteminin birlikte kullanılması literatürde sıklıkla karşılaşılan bir yöntem birlikteliği değildir. Ancak, AHP yönteminin getirdiği avantajlar göz önüne alındığında derin öğrenme algoritmalarının daha bilimsel ve stratejik bir yaklaşım olması amacıyla bu çalışmada AHP kullanılmıştır. Ayrıca, sürücü dikkat dağınıklığı ile ilgili çalışmalarda ilk defa AHP ve derin öğrenme algoritmaları birlikte uygulanmıştır.




3. MATERYAL ve YÖNTEM

Çalışmanın materyal ve yöntem bölümünde ilk olarak cep telefonu kaynaklı sürücü dikkat dağınıklığı için dikkate alınan çalışma alanı ile ilgili bilgiler sunulmaktadır. Yol kenarı gözlem yaklaşımının uygulama stratejisinden bahsedilmiştir. Çevresel etkilerin analiz edilebilmesi amacıyla kullanılan referans değerler verilmiştir. Yoğun/kritik kavşak seçimi için kullanılan ÇKKV yönteminden bahsedildikten sonra CBS ile ilgili bilgiler sunulmuştur. Bölümün ikinci kısmında, sürücü dikkat dağınıklığının nesne tespiti algoritması ile tespiti için gerekli olan veriler ve veri toplanma yöntemi tanıtılmıştır. Literatürde nesne tespiti için sıklıkla kullanılan yöntemler hakkında bilgiler sunulmuştur.


3.1. Çalışma Alanı

Cep telefonu kaynaklı sürücü dikkat dağınıklığının tespit edilmesi amacıyla Erzurum ilinde 23 adet kavşak değerlendirmeye alınmıştır. Erzurum, 756.052 nüfusa sahip olan ve bölgenin en büyük illerinden biridir. Kent yüz ölçümü bakımından Doğu Anadolu Bölgesinde lider konumdadır. Trafik hareketliliği bakımından kent genelinde kayıtlı motorlu kara taşıtı sayısı 2022 yılı itibariyle 123.460'dır (Anonim 2023). Erzurum ilinin coğrafi konumu Şekil 3.1'de sunulmaktadır.



Şekil 3.1. Erzurum ilinin coğrafi konumu ve çalışma alanı

Çalışma kapsamına dahil edilen kavşakların seçimi için yerel yönetim tarafından hazırlatılan Erzurum Kent İçi Ulaşım Ana Planı, Karayolları Genel Müdürlüğü yetkilileri ve sürücü görüşlerinden faydalanılmıştır. Değerlendirmeye alınan kavşaklar seçilirken kavşak yoğunluğu ve konumsal özellikleri dikkate alınmıştır. Seçilen kavşaklar Şekil 3.2’de sunulmaktadır.



Şekil 3.2. Gözlem yapılan kavşakların konumları

Şekil 3.2 incelendiğinde değerlendirmeye alınan kavşakların geneli Yakutiye ilçe merkezinde bulunmaktadır. Kentin merkez ilçesi olan Yakutiye’de nüfus ve trafik hareketliliği oldukça yüksek seviyelerde seyretmektedir. Bu nedenle objektif bir değerlendirme olması için Kent İçi Ulaşım Ana Planı da dikkate alınarak kavşakların yoğunluğu bu ilçeden seçilmiştir.

3.1.1. Seçilen kavşakların konumsal özellikleri

Değerlendirmeye alınan kavşakların isimlendirilmesi yazar tarafından yapılmıştır. Çizelge 3.1’de kavşak numarası ve isimleri verilmiştir. Şekil 3.2’de yer alan kavşak numaraları ile Çizelge 3.1’de verilen kavşak numaraları uyumludur. Kavşak seçimleri yapılırken Kent İçi Ulaşım Ana Planı, trafik yoğunluğu ve konumsal özellikler göz önüne alınmıştır. Kavşaklara ilişkin özellikler aşağıda sunulmuştur.

Çizelge 3.1. Seçilen kavşakların numarası ve isimleri

Kavşak Numarası	Kavşak Adı
1	MNG AVM Kavşağı
2	Üniversite / Kartal Kavşağı
3	Hastaneler Caddesi / Gez Kavşağı
4	Eski Palandöken Hastanesi / Valilik Kavşağı
5	Havuzbaşı Kavşağı
6	Şehir Hastanesi Kavşağı
7	İhsan Doğramacı Kavşağı
8	Kervansaray Kavşağı
9	Buhara Hastanesi Kavşağı
10	Saraybosna Kavşağı
11	İstasyon Kavşağı
12	Bilgi Evi Kavşağı
13	Sanayi Köprüsü Kavşağı
14	Taş Mağazaları Kavşağı
15	Yenişehir Kavşağı
16	Kayakyolu Kavşağı
17	Tren Garı Kavşağı
18	Gürcükapı Kavşağı
19	Lalapaşa Kavşağı
20	Yoncalık Kavşağı
21	Eğitim Fakültesi Kavşağı
22	Forum AVM Kavşağı
23	Mareşal Hastanesi Kavşağı

MNG AVM Kavşağı

Bölgenin en büyük alışveriş merkezine yakınlığından dolayı nüfus ve trafik hareketliliği oldukça yüksektir. Bunun yanında çevrede bulunan eğitim kurumları ve sosyal alanlardan dolayı bireysel araç kullanımının en yoğun olduğu kavşaklardan biridir. Kavşak bölgesinde yeni açılan yolların olması nedeniyle son yıllarda trafik hareketliliği artmıştır.

Üniversite / Kartal Kavşağı

Bölgenin en büyük devlet üniversitesi olan Atatürk Üniversitesi'nin giriş güzergahında bulunmasından dolayı eğitim ve iş anlamında bu bölgede yüksek hareketlilik bulunmaktadır. Ayrıca, kavşağın sosyal alanlara olan yakınlığı kavşaktaki trafik yoğunluğunu ciddi manada artırmaktadır. Yol kenarı gözlemleri sırasında kavşağı kullanan sürücülerin çoğunluğunun genç sürücüler olduğu gözlemlenmiştir.

Hastaneler Caddesi / Gez Kavşağı

Toplu taşıma araçlarının sıklıkla kullandığı durakların bulunduğu bir konumda yer almaktadır. Ayrıca, kentin farklı bölümlerini birbirine bağlayan en önemli geçiş noktası üzerindedir. Bunun yanında ticaret alanlarına yakınlığı nedeniyle kavşaktaki trafik yoğunluğu yüksek seviyelerdedir. Ulaşım ana aksı üzerinde yer alan kavşağın bütün kollarında günün her saatinde trafik hareketliliği oldukça yüksektir.

Eski Palandöken Hastanesi / Valilik Kavşağı

Kentin en önemli yönetim binalarına yakınlığı ve bölgenin en büyük hastanesi ile kentin diğer bölgelerini birbirine bağlaması nedeniyle trafik yoğunluğu oldukça yüksektir. Özellikle iş giriş ve çıkış saatlerinde çalışanların sıklıkla kullandığı kavşaklardan biridir. Farklı düzey kavşak olmasına rağmen trafiğin tüm akış yönlerinde taşıt yoğunluğu oldukça fazladır.

Havuzbaşı Kavşağı

Kentin en önemli turistik bölgelerinden biri olan Havuzbaşı kavşağı gerek kent sakinleri gerek turistler tarafından sıklıkla kullanılmaktadır. Ayrıca, kamusal binalara ve ticaret bölgesine yakın olması trafik yoğunluğunu artırmaktadır. Ek olarak kentin en önemli sosyal alanlarına yakın olmasından dolayı sürücülerin ve yayaların sıklıkla kullandığı bir kavşaktır.

Şehir Hastanesi Kavşağı

Bölgenin en büyük ve en kapsamlı hastanesine yakın bir konumda yer alan kavşağın trafik hareketliliği oldukça yüksektir. Sağlık için kente gelen bireylerin, kent sakinlerinin ve hastane çalışanlarının sıklıkla kullandığı bir kavşaktır. Bunun yanında farklı yerleşim yerlerini birbirine bağlayan kritik önem seviyesinde bir konumda yer almaktadır. Hastane girişinin kavşak üzerinden yapılması da kavşaktaki trafik yoğunluğunu artırmaktadır.

İhsan Doğramacı Kavşağı

Şehir hastanesi ile yeni yerleşim yerlerini birbirine bağlayan bir konumda yer almaktadır. Ayrıca, şehir merkezi ile güney ilçeleri birbirine bağlayan önemli bir kavşaktır. Hem eğitim hem de sağlık alanlarına yakın olmasından dolayı trafik ve nüfus hareketliliği yüksek seviyelerdedir. Ek olarak yeni yerleşim alanlarının birinin yakınında yer almasıyla birlikte kavşak yoğunluğu her geçen gün artmaktadır.

Kervansaray Kavşağı

Şehir hastanesine ve geniş yerleşim merkezine yakınlığı nedeniyle kavşaktaki trafik yoğunluğu oldukça yüksektir. Toplu taşıma araçlarının sıklıkla kullandığı kavşakta hem bireysel araç hem de toplu taşıma araçları bakımından hareketlilik özellikle iş giriş ve çıkış saatlerinde üst seviyelerdedir.

Buhara Hastanesi Kavşağı

Şehrin tek özel sağlık kuruluşuna yakın olması ve şehirler arası geçişler için kullanılan transit yol üzerinde yer alması nedeniyle kavşaktaki taşıt yoğunluğu oldukça yüksektir. Ayrıca, kavşak büyük yerleşim yerine geçiş için sıklıkla kullanılmaktadır. Kentin en önemli turizmi olan kış sporları için seyahat eden bireylerin Palandöken Dağı'na erişmesi için kullanılması gereken bir kavşak konumundadır.

Saraybosna Kavşağı

Özel firmaların ve işletmelerin bulunduğu cadde üzerinde yer alan kavşakta trafik yoğunluğu yüksektir. Bunun yanında iş giriş ve çıkış saatlerinde şehrin kuzey ve güney bölgelerinin geçiş noktasında bulunmaktadır. Ayrıca, ana aksa alternatif hükmündeki yol üzerinde bulunması sebebiyle de taşıt yoğunluğu sürekli artmaktadır.

İstasyon Kavşağı

Kentin yeni ve büyük bir yerleşim bölgesine ve kamusal binalara bağlantı konumunda yer almaktadır. Bunun yanında üniversite öğrencilerinin konaklama noktalarına yakınlığı nedeniyle kavşaktaki trafik yoğunluğu oldukça yüksektir. Konut yoğunluğunun fazla olduğu bölgede yer almasından dolayı özellikle iş giriş ve çıkış saatlerinde kavşaktaki yoğunluk ve bekleme süreleri oldukça fazladır.

Bilgi Evi Kavşağı

Şehrin ana yerleşim bölgelerinden birine oldukça yakın bir konumda yer almaktadır. Bunun yanında trafik yoğunluğunun azaltılması amacıyla açılan köprülü kavşağın bağlantı noktasında bulunan kavşakta trafik yoğunluğu oldukça yüksektir. İş giriş ve çıkış saatlerinde konut alanlarına ulaşmaya çalışan sürücülerin sıklıkla kullandığı bir kavşaktır.

Sanayi Köprüsü Kavşağı

Kentin ve bölgenin en büyük sanayi yerleşim alanına erişim yolları üzerinde yer alan kavşakta trafik yoğunluğu günün hemen hemen her saatinde oldukça yüksek seviyelerdedir. Bunun yanında çevre yolundan kente bağlanmaya çalışan sürücülerin ve kentin muayene istasyonunun bulunduğu sanayi bölgesinden kent merkezine geçiş yolu üzerinde yer almasından dolayı sürücülerin sıklıkla kullandığı bir kavşaktır.

Taş Mağazaları Kavşağı

Bölgenin en büyük yöresel alışveriş alanına ve turistik bölgelere yakınlığı nedeniyle hem kent sakinlerinin hem de turistlerin sıklıkla kullandığı bir kavşaktır. Günün her saatinde trafik yoğunluğunun yüksek olduğu kavşakta trafik hareketliliği oldukça yüksektir.

Yenişehir Kavşağı

Özel hastane, AVM ve kamusal alanlara yakınlığı nedeniyle sıklıkla kullanılmaktadır. Ayrıca, iki büyük yerleşim yerini birbirinden ayıran ve bu nedenle yoğun şekilde kullanılan bir kavşaktır.

Kayakyolu Kavşağı

Bölgenin en turistik alanlarından biri olan Palandöken Dağı yolu üzerinde bulunan kavşak turistler ve kent sakinleri tarafından sıklıkla kullanılmaktadır. Bunun yanında kentin iki büyük yerleşim merkezinin kesişim noktasında yer almaktadır. Bu nedenlerden dolayı trafik hareketliliği oldukça yüksektir.

Tren Garı Kavşağı

Tren istasyonuna yakınlığı, ticaret ve kamusal alanlara yakınlığı bakımından kavşaktaki trafik yoğunluğu oldukça yüksektir. Ek olarak, toplu taşıma araçlarının

birçoğunun güzergahında yer alan kavşakta, toplu taşıma araç yoğunluğu da yüksek seviyelerdedir.

Gürcükapı Kavşağı

Kentin konut ve ticaret anlamında en eski yerleşim merkezlerine yakınlığı nedeniyle turistler ve kent sakinleri tarafından sıklıkla kullanılır. Buna ek olarak, kamusal alanların çok olması trafik yoğunluğunu artırmaktadır. Kentsel dönüşüm kapsamında yapılan çalışmalar neticesinde bölgedeki trafik hareketliliği sürekli artmaktadır.

Lalapaşa Kavşağı

Kentin en önemli turistik alanlarına ve ticaret bölgelerine yakın olmasından dolayı kentin en önemli ve en yoğun kavşaklarından bir tanesidir. Gerek bireysel araçların gerek toplu taşıma araçlarının sıklıkla kullandığı kavşakta trafik yoğunluğu ciddi derecede yüksektir. Buna ek olarak yaya hareketliliğinin de ciddi derecede yüksek olduğu bir bölgede yer almaktadır.

Yoncalık Kavşağı

Kavşağın yoğun olmasının en büyük sebebi toplu taşıma araçlarının bu kavşağı sıklıkla kullanmasıdır. Bunun yanında turistik bölgelere yakınlığı ve geçiş konumunda olmasından dolayı trafik hareketliliği oldukça yüksektir.

Eğitim Fakültesi Kavşağı

Eğitim kampüsüne, kamusal binalara ve yerleşim alanları arasındaki geçiş bölgelerine yakınlığı dolayısıyla kavşaktaki taşıt yoğunluğu oldukça yüksektir. Ek olarak, şehirlerarası geçiş yolu üzerinde bulunmasından ve yeni açılan bağlantı yolundan dolayı trafik hareketliliği artmaktadır.

Forum AVM


Kentin ilk AVM'sine, geniş yerleşim ve ticaret alanlarına yakın olmasından dolayı kavşaktaki hareketlilik oldukça yüksektir. İki büyük yerleşim merkezinin geçiş noktasında yer alan kavşakta, trafik yoğunluğu her geçen gün artmaktadır.

Mareşal Hastanesi Kavşağı

Önceki dönemlerde askeri hastane olarak kullanılan ve günümüzde kent sakinlerinin sıklıkla kullandığı hastane yakınında yer alan kavşakta hareketlilik oldukça yüksektir. Ayrıca, iki geniş yerleşim merkezinin geçiş noktasında bulunan kavşaktaki trafik yoğunluğu oldukça yüksektir.

3.2. Yol Kenarı Gözlem Verilerinin Toplanması

Cep telefonu kullanımı kaynaklı sürücü dikkat dağınıklığının tespit edilmesi ve buna bağlı olarak yaşanan gecikme, emisyon ve yakıt tüketimi değerlerinin değerlendirilebilmesi için bu çalışma kapsamında seçilen kavşaklarda yol kenarı gözlem araştırması yapılmıştır. Yol kenarı gözlem araştırması için zirve saatlerden biri olarak ifade edilen 17.30-18.30 saatleri seçilmiştir. Bu saatler arasında hafta içi farklı günlerde taşıt yoğunluğu ve sürücülerin cep telefonu kullanım durumu incelenmiştir. Yol kenarı gözlemi için trafik yoğunluğuna göre gözlem ekibi 9 veya 11 kişiden oluşturulmuştur. Gözlem ekibinde sürücü dikkat dağınıklığı üzerine çalışmaları bulunan bir akademisyen ve İnşaat Mühendisliği alanında lisansüstü çalışmalar yapan kişiler de bulunmaktadır. Yol kenarı gözlem araştırmasının uygulama stratejisi Şekil 3.3'de verilmiştir.



Şekil 3.3. Yol kenarı gözlem araştırması ölçüm stratejisi

Yaklaşım kolundaki ölçümler yapılırken zirve saatlerde ölçümler gerçekleştirilmiştir. Kavşaktaki sürücülerin cep telefonu kullanımından kaynaklı dikkat dağınıklığının tespit edilebilmesi amacıyla kavşak kolundaki ilk dört sıradaki araç sürücülerini gözlemlenmiştir. Araç sürücülerini gözlemlenirken gözlem ekibi ve sürücü arasında olabildiğince ilişki veya etkileşim kurulmamaya çalışılmıştır. Çünkü, sürücünün doğal davranışını sergilemeye devam etmesi gözlem çalışması açısından oldukça önemlidir. Gözlem ekibi üyelerinin her biri için hangi bölgedeki aracı gözlemleyeceği ve gözlem sırasında neye dikkat edileceği gözlem araştırması öncesinde anlatılmıştır. İlk dört sıradaki sürücülerin cep telefon kullanımı, kullanıyorsa yeşil ışık yandıktan ne kadar süre sonra cep telefonunu bıraktığı ve buna bağlı olarak gecikmeler ölçülmüştür. Buna ek olarak, trafik ışıklarında bekleyen sürücülerin geçiş süreleri hesaplanmıştır. Bunun için yeşil ışık yanmadan yaklaşım kolunda bekleyen sürücüler dikkate alınmıştır. Araçların ortalama geçiş süreleri ile dikkat dağınıklığı yaşayan sürücülerin gecikme sürelerinin farkları alınarak kavşaklardan ortalama geçiş süresi ve buna istinaden araç sürücülerinin dikkat dağınıklığı yaşayan sürücülerden kaynaklı ne kadar gecikme yaşadıkları hesaplanmıştır. Gözlem yapılırken trafik ve hava koşullarına göre bazı sürücülerin cep telefonu kullanımı tespit edilememiştir. Bunun yanında, araç camlarını filmle kaplatmış sürücüler de gözlemlenememiştir. Tespiti yapılamayan sürücüler herhangi bir cep

telefonu kullanımı yapmadığı varsayılmıştır. Ayrıca, taşıt cinslerinin sayımı için daha fazla gözlem ekibi gerektiğinden dolayı taşıt cinsi sayımı da yapılamamıştır.

Gecikme hesabı yapıldıktan sonra araç sürücülerinin ihlal ortalaması, sürücü bazlı gecikme ortalaması, emisyon, yakıt tüketimi vb. değerlerin hesabı yapılmıştır. Emisyon ve yakıt tüketimi değerlerinin hesaplanabilmesi için araçların emisyon ve yakıt tüketimi değerleri bilinmesi gerekmektedir. Bu bağlamda, trafik ışıklarında bekleyen araçların rölanti halinde beklediği ve Start & Stop sistemine sahip olmadığı varsayılmıştır. Rölanti halindeki araçların yakıt tüketimi ve emisyon değerleri için literatürde çeşitli çalışmalar bulunmaktadır. Rahman et al. (2013) tarafından yapılan araştırmaya göre rölantide çalışan araçların yakıt tüketimi 7 lt/saat'e kadar ulaşabilmektedir. Başka bir çalışmada ise rölantide yakıt tüketim değeri yaklaşık 0,2 ml/saniye olarak hesaplanmıştır (Sharma et al. 2019). Londra'da gerçekleştirilen rapor çalışmasında literatürdeki diğer çalışmalardan farklı olarak araç sınıfı, yakıt türü ve motor hacmi dikkate alınmıştır (Barlow and Cairns 2020). Rapor çalışmasında verilen değerler daha kapsamlı olduğu ve çeşitli araç sınıfı, yakıt türü ve motor hacmi dikkate alındığı için bu tez çalışması kapsamında ilgili referans değerler dikkate alınmıştır. Gerçek trafik koşullarının yansıtılabilmesi için 3 farklı motor cinsi ve araç sınıfı dikkate alınmıştır. Çizelge 3.2'de araç sınıfları, yakıt türü, motor hacmi, emisyon ve yakıt tüketimi değerlerini içeren veriler sunulmuştur.

Çizelge 3.2. Emisyon ve yakıt tüketimi hesaplamaları için dikkate alınan referans değerler.

	CO ₂ (gr/dk.)	CO ₂ (litre/dk.)	NO _x (gr/dk.)	NO _x (litre/dk.)	Yakıt Tüketimi (litre/dk.)
Küçük Araç (1.0 TSI - Benzin)	17,35	9,42	0,01	0,007	0,00835
Aile Aracı / Orta Sınıf (1.6 TDI - Dizel)	16,61	9,02	0,045	0,030	0,0067
Minivan Araç (1.5 - Dizel)	27,77	15,08	0,021	0,014	0,0261

Yakıt tüketimi açısından incelendiğinde en fazla yakıt tüketiminin Minivan Araç da olduğu görülmektedir. Küçük Araç sınıfında ise yakıt tüketimi, Aile Aracı/Orta Sınıfa göre daha fazladır. Bu durum, benzinli aracın rölantide daha fazla yakıt tüketimi gerçekleştirdiğini ortaya koymaktadır. CO₂ emisyonları bakımından Çizelge 3.2 incelendiğinde yakıt tüketimi değerlerine benzer sıralama görülmektedir. Ancak NO_x parametresi incelendiğinde sıralama Aile Aracı/Orta Sınıf – Minivan Araç – Küçük Araç olarak değişmektedir.

3.3. Entropi Ağırlıklandırma Yöntemi

Entropi yaklaşımı ÇKKV problemlerinin çözümünde ağırlıklandırma yöntemi olarak sıklıkla kullanılmaktadır (C. N. Wang et al. 2022; Unal Cilek et al. 2022; Ahsan et al. 2023; Haddadi et al. 2023; Zare Banadkouki 2023). Entropi yaklaşımı, 1865 yılında Rudolp Clausius tarafından ortaya atılan bir problem çözme yöntemidir. Entropi, sistem içindeki belirsizlik düzeyini objektif olarak belirlemektedir (Han et al. 2015). Entropi yöntemi ile karar verme problemlerinde kriterlerin göreceli ağırlıklarını gösteren katsayılar belirlenir. Diğer ağırlıklandırma yöntemlerinden farklı olarak ikili karşılaştırma matrisi içermemesi ve karar vericilerin yargılarına dayanmaması nedeniyle daha objektif olduğu ifade edilmektedir (Durán and Aguilo 2008; Alshehri 2014; Sennaroglu and Varlik Celebi 2018). Entropi yönteminde kriter ağırlıklarının belirlenmesi için karar matrislerinin oluşturulması yeterlidir. Entropi yaklaşımı 5 adımdan oluşmakta olup uygulama adımları aşağıda verilmiştir (Adun 2023).

Adım 1. Karar matrislerinin oluşturulması

Alternatiflerin her bir kriter açısından performans değerlerini ifade eden bir matris tablosudur.

$$A_{ij} = [A_{ij}]_{m \times n} = \begin{bmatrix} a_{11} & \cdots & a_{1n} \\ \vdots & \ddots & \vdots \\ a_{m1} & \cdots & a_{mn} \end{bmatrix} \quad (3.1)$$

Adım 2. Normalizasyon işleminin gerçekleştirilmesi

Normalizasyon işlemi, karar matrisindeki farklı ölçek ve birimlere ait değerlerin aynı ölçek üzerinde homojenleştirilmesini sağlamayı amaçlamaktadır.

$$r_{ij} = \frac{a_{ij}}{\sum_{i=1}^m a_{ij}} \quad (3.2)$$

Adım 3. Her kriter için Entropi değerlerinin hesaplanması

$$e_j = -k \sum_{i=1}^m a_{ij} \ln(a_{ij}) \quad (3.3)$$

$$k = -\frac{1}{\ln(n)} \quad (3.4)$$

$$0 \leq e_j \leq 1 \quad (3.5)$$

Adım 4. Bilginin farklılaşma derecesinin hesaplanması

$$d_j = 1 - e_j \quad (i = 1,2,3, \dots, m \text{ and } j = 1,2,3, \dots, n) \quad (3.6)$$

Her kriter için farklılaşma derecesi hesaplanır. Farklılaşma derecesinin yüksek olması, o kriterin diğer kriterlere göre daha önemli olduğunu gösterir.

Adım 5. Kriter ağırlıklarının hesaplanması

$$w_j = \frac{d_j}{\sum_{i=1}^m d_j} \quad (3.7)$$

$$w_1 + w_2 + \dots + w_n = 1 \quad (3.8)$$

3.4. Coğrafi Bilgi Sistemleri

CBS, tüm veri çeşitleri için veriyi oluşturan, yöneten, analiz eden ve haritalayan bir sistem olarak ifade edilmektedir (Anonymous 2023b). CBS, verileri bir harita ortamına aktararak konum verilerini (ilgilenilen verinin nerede olduğunu) her türlü tanımlayıcı bilgiyle (ilgili verinin konumsal özelliklerini) birleştirir. CBS, araştırmacıların verinin çerçevesini, ilişkileri ve coğrafi özelliklerini anlamlandırmaya yardımcı olur. Faydaları arasında gelişmiş iletişim ve verimliliğin yanı sıra daha iyi yönetim ve karar alma yer almaktadır. CBS, gerek işlem yetenekleri gerekse teknik özellikleri bakımından 1970'li yılların sonlarından itibaren hızla geliştirilmiştir ve artık tüm dünyada birçok alanda farklı amaçlarla yaygın olarak kullanılmaktadır (Alemdar et al. 2020; Puyana-Romero et al. 2020; Yılmaz et al. 2022; Rane et al. 2023) CBS kısaca coğrafi bilgilerin görselleştirilmesini sağlayan bir sistemdir. CBS'nin 4 ana fikri / yaklaşımı şunlardır:

- Coğrafi verilerin oluşturulması,
- Veri tabanı üzerinden yönetilmesi,
- Modelin oluşturulması ve analiz edilmesi,
- İşlenen verilerin harita üzerinde görselleştirilmesi.

CBS, tüm mekânsal bilgi sistemlerini kapsayan ve coğrafi ifadeleri inceleyen bir bilim dalı olarak tanımlanmaktadır. CBS, konum ve model analizine dayalı olarak verilerin sınıflandırılması ve sunulması gibi işlevsel süreçleri de yürütmektedir. CBS sıklıkla farklı türdeki verileri bir harita üzerinde görüntülemek için kullanılır. Literatürde CBS yaklaşımını içeren farklı alanlarda çalışmalar bulunmaktadır. CBS mekânsal analiz, görsel sunum, verilerin toplanması ve saklanması gibi amaçlarla da kullanılmaktadır (Wieczorek and Delmerico 2009).

CBS'nin kullanımı Türkiye için 1980'li yıllardan sonra başlamıştır. Özel sektörün liderliğinde yaygınlaşmaya başlamış olsa bile çeşitli kamu kuruluşlarının da sıklıkla kullandığı bir program olması nedeniyle şu an kamu ve özel sektör tarafından yoğun bir şekilde kullanılmaktadır.

3.5. Analitik Hiyerarşi Süreci


AHP metodu, Thomas L. Saaty tarafından 1970’li yılların sonunda ortaya atılan ve sıklıkla kullanılan bir ÇKKV yöntemidir (Saaty 1977). Alternatifleri değerlendirme ve seçme işlemleri başta olmak üzere çeşitli alanlardaki karar verme problemlerinde kullanılmaktadır. AHP yöntemi ile somut veya somut olmayan durumları içeren kompleks problemler kolaylıkla çözülebilmektedir. AHP tekniği, kullanıcıların sayısallaştırılmamış yargılarla başa çıkmalarını sağlayan bir yöntemdir. Karar vericilerin kişisel yargılarına dayanarak ikili karşılaştırma matrisleri yardımıyla geniş bir karar çerçevesi sağlamaktadır (Saaty 1980).

3.5.1. AHP yönteminin hiyerarşik yapısı

Hiyerarşik tasarımın arkasındaki temel fikir, insan algısının ve yargılarının süreçlerinden kaynaklanmaktadır. İnsan algısının iki aşaması ayrışma ve sentez olarak ifade edilmektedir. İnsan düşünce yapısı dikkate alındığında karmaşık problemlerle karşılaşıldığında önce karmaşıklığı küçük parçalara ayırmak gerekmektedir. Sentez adı verilen ikinci aşamada insan bu küçük parçalar arasındaki ilişkileri fark eder.

Bir hiyerarşinin inşası, karmaşık sistemin küçük parçalara ayrıştırılmasıdır. İyi yapılandırılmış bir hiyerarşiye ulaşmak için problem alanındaki deneyim ve bilgi vazgeçilmezdir. Bu aşamada karar verici, belirli bir sorunla ilgili önemli faktörleri belirlemelidir.

Hiyerarşik model birkaç aşamadan oluşan seviyeler bütünüdür. Elde edilmek istenen sonuç en üste yerleştirilir. Kriterler ve alt kriterler alt seviyelere doğru sıralanır ve sonraki seviyeleri oluşturur. Her seviyedeki kriterlerin veya alternatiflerin sadece bir üst seviyedekileri etkileyebileceğini ve birbirlerinden bağımsız olmaları gerektiği unutulmamalıdır. AHP’nin hiyerarşik yapısını gösteren görsel Şekil 3.4’de verilmiştir (Saaty 2008)



Şekil 3.4. AHP hiyerarşik yapısı

3.5.2. İkili karşılaştırma matrisleri

İkili karşılaştırma matrisleri sayesinde karar vericilerin aynı zaman diliminde iki farklı nesneye / alternatife / kritere odaklanması sağlanarak karar vericilerin kişisel yargıları ve düşüncüleri ölçülmektedir. İkili karşılaştırma matrislerinin oluşturulması, düşünce yapısındaki sentez aşamasıdır. Bu aşamada karar vericiler, iki kriteri alternatife göre karşılaştırmaktadır. İkili karşılaştırma matrisleri alternatiflere göre kriterlerin tek tek karşılaştırılması ile oluşturulmaktadır (Elagözlü 2022).

Çizelge 3.3’de üç farklı kriterin belirli bir alternatife göre karşılaştırmasına ait ikili karşılaştırma matrisi verilmiştir. C_1 , C_2 ve C_3 kriter isimlerini ifade ederken a_{ij} terimi, kriterlerin birbirine göre önem derecelerini göstermektedir.

Çizelge 3.3. İkili karşılaştırma matrisi örneği

Kriter	C_1	C_2	C_3
C_1	1	a_{12}	a_{13}
C_2	a_{21}	1	a_{23}
C_3	a_{31}	a_{32}	1

Örneğin a_{12} , C_1 kriterinin C_2 kriterine göre önemini temsil etmektedir. Matrisin köşegeni 1'lerden oluşmaktadır. Bunun nedeni her kriter kendisiyle karşılaştırıldığında eşit derecede öneme sahip olmasıdır. C_1 kriterinin ağırlığını / önemini W_1 olarak ve C_2

kriterinin ağırlığını / önemini W_2 olarak belirtirsek, a_{12} de W_1/ W_2 olarak yazılabilir. Thomas L. Saaty, kriterlerin göreceli önem derecelerini belirlemek için [1-9] skalası önermektedir. Saaty [1-9] skalası Çizelge 3.4’de verilmiştir (Saaty 1980).

Çizelge 3.4. Saaty önem derecesi skalası

Skala	Açıklama
1	Eşit Önem Derecesi
3	Zayıf Önem Derecesi
5	Güçlü Önem Derecesi
7	Çok Güçlü Önem Derecesi
9	Kesinlik Önem Derecesi

Saaty [1-9] skalasında ara değerler olan 2, 4, 6 ve 8 önem dereceleri belirtilmemiştir. Bunlar orta önem derecelerini ifade etmektedir. Karşılaştırma matrisleri oluşturulurken bu değerler nadiren kullanılmaktadır.

3.5.3. İkili karşılaştırma matrislerinin tutarlılığı

Ölçüm sürecinde tutarlılık her zaman sağlanamamaktadır. Ölçme araçlarını kullandığımızda dahi hatalar gözlenebilmekte ve bu hatalar çoğu zaman tutarsızlığa yol açmaktadır. Tutarsızlık olduğunda A kriterinin B kriterinden, B kriterinin C kriterinden daha önemli olduğunu ancak C kriterinin A kriterinden daha önemli olduğu gözlemlenebilmektedir. Bu sonuç geçişlilik ilkesinin ihlal edildiğini ortaya koymaktadır (Alshehri 2014).

Tutarlılıkla ilgili bir diğer ilke orantılılıktır. Örneğin, A nesnesi B nesnesinden iki kat ve B nesnesi C nesnesinden üç kat daha ağırsa, A nesnesi C nesnesinden altı kat daha ağır olmalıdır. Ölçüm sürecindeki tutarsızlık her zaman orantılılık ilkesinin ihlalinin bir sonucudur. Ayrıca hem orantılılık hem de geçişlilik ilkelerinin ihlalinin bir sonucu olabilmektedir (Alshehri 2014; Toepfer 2019).

Karar vericilerin kişisel yargıları, ölçüm sürecinde çok iyi bir tutarlılık elde edilmesinin önündeki en büyük engeldir. Saaty, tutarlılık oranının hesaplanması için çeşitli formülasyonlar sunmuştur (Saaty 1977). Maksimum özdeğer (λ_{max}) olarak ifade edilen yaklaşım tutarlılıktan ne kadar ayrıştığına ilişkin kullanılan bir göstergedir. Çok iyi bir

tutarlılık elde edilmesi için bir pozitif karşılıklı matrisin λ_{max} ilgili matrisin kriter sayısına (n) eşit olması gerekmektedir. Tutarsızlık, λ_{max} ifadesinin değeri n'den uzaklaştıkça artar (Zahedi 1986; Vargas 1990). λ_{max} değeri aşağıdaki adımlar takip edilerek bulunur:

1. İki karşılaştırma matrisi çözüm vektörü ile çarpılmaktadır. Hesaplama sonunda farklı bir vektör elde edilmektedir.
2. Elde edilen vektörün ilk bileşeni çözüm vektörünün ilk bileşenine bölünmektedir. Vektörün ikinci bileşeni çözüm vektörünün ikinci vektörüne bölünmektedir. Bu süreç tüm bileşenler tamamlana kadar devam ettirilir.
3. Vektörün bileşenlerinin toplamı bileşen sayısına bölünür.

λ_{max} değeri kullanılarak Tutarlılık İndeksi (CI) hesaplanır. Tutarlılık İndeksine ilişkin formülasyon Denklem 3.9'da verilmektedir.

$$CI = \frac{\lambda_{max} - n}{n - 1} \quad (3.9)$$

Tutarlılık ifadesinin başka bir temsili Tutarlılık Oranıdır (CR). Bu oran, tutarlılık indeksinin aynı dereceden bir matrisin Rastgele İndeksine (RI) bölünmesiyle hesaplanır. Tutarlılık Oranına ilişkin formülasyon Denklem 3.10'da verilmektedir.

$$CR = \frac{CI}{RI} \quad (3.10)$$

RI, tutarlılık oranı iyi bir şekilde elde edilmiş ve buna bağlı olarak elde edilen karşılaştırma matrislerine ait tutarlılık indeksidir. Farklı kriter sayılarına karşılık gelen RI değerleri Çizelge 3.5'de verilmiştir. Bu değerler Oak Ridge Ulusal Laboratuvarı ve Wharton School tarafından belirlenmiştir (Saaty 1977).

Çizelge 3.5. Farklı kriter sayılarına göre RI değerleri

n	1	2	3	4	5	6	7	8
RI	0,00	0,00	0,58	0,90	1,12	1,24	1,32	1,41
n	9	10	11	12	13	14	15	
RI	1,45	1,49	1,51	1,48	1,56	1,57	1,59	

0,10 veya daha düşük bir CR değeri Saaty tarafından kabul edilebilir olarak belirlenir. Bu oran 0,10'u aştığında, ikili karşılaştırma matrislerinin yeniden karar vericiler tarafından oluşturulması gerekmektedir (Webb 2018).

3.5.4.Öncelik değerlerinin hesaplanması

Kriterlerin öncelik değerleri, en büyük öz değere sahip ikili karşılaştırma matrisinin öz vektörü hesaplanarak elde edilir.

İkili karşılaştırma matrislerinin öz vektörünü hesaplamak için çeşitli yaklaşımlar önerilmektedir (Saaty 1977). Yaklaşımlar sayesinde sonuçlar normalleştirilir, bu sayede öncelik değerleri 0-1 arasında sıralanır. Genel olarak Vektör Normalizasyon, Doğrusal Normalizasyon ve Monoton Olmayan Normalizasyon sıklıkla kullanılmaktadır (Özdağoğlu 2013).

3.6. Sürücü Dikkat Dağılıklığı Tespiti İçin Verilerin Toplanması ve Etiketlenmesi


Verilerin toplanma aşaması için çeşitli sürücülerin farklı iklim, hava ve trafik koşullarını içeren sürüş görüntüleri toplanmıştır. Görüntülerin toplanması için iki aşamalı bir yaklaşım uygulanmaktadır. İlk olarak literatürdeki çalışmalarda yer alan ve kamuya açık olarak yayınlanan sürücü dikkat dağılıklığı verileri toplanmıştır. İkinci olarak çalışmanın kapsamının genişletilmesi ve farklı sürücü karakteristiklerinin ortaya konulabilmesi için yazar tarafından veri toplama süreci yürütülmüştür. Bunun için, araç içerisinde yer alan ve iki farklı konumdan görüntü alabilen 1920 x 1080p (piksel) çözünürlüğe sahip iki farklı kamera kullanılmıştır. Kullanılan kameranın lens uzaklığı 3.6MM ve manuel odaklanabilir lens kullanılmıştır. Bunun haricinde araç içerisine uygun olması açısından en iyi görüntü aralığı 1m ~ 3,5m olan model tercih edilmiştir. Kullanılan görüntü cihazı 60FPS'e kadar kare hızını desteklemektedir. Kameranın görüntü çözünürlüğü ve maksimum kare hızı elde edilen verilerin kalitesi açısından oldukça önemlidir. Şekil 3.5'de verilerin toplanması için kurulan düzeneğin görseli sunulmuştur.



Şekil 3.5. Dikkat dağınıklığı tespiti için gerekli olan verilerin toplanması amacıyla kurulan kamera düzeneği.

3. MATERYAL ve YÖNTEM

Kamuya açık olarak yayınlanan veya daha önceden hazırlanan veri setleri tez çalışması kapsamında kullanılmıştır. Çalışmada StateFarm, AUC ve Amal Ezzouhri veri setlerinden faydalanılmıştır (Abouelnaga et al. 2017; Eraqi et al. 2019; Ezzouhri et al. 2021). Kamuya açık olarak yayınlanan veri setlerinin kullanılması ile Mısır, Hindistan, ABD ve Fas ülkelerinden geniş bir veri seti çalışmaya dahil edilmiştir. Kullanılan veri setlerine ilişkin temsili görseller Şekil 3.6’da sunulmuştur.



Şekil 3.6. Kamuya açık olarak yayınlanan veri setinden temsili görüntüler

3. MATERYAL ve YÖNTEM

Ayrıca, kamuya açık olarak yayınlanan veri setine ek olarak yeni bir veri seti Türkiye içerisinde farklı sürücüler kullanılarak çalışmaya dahil edilmiştir. Türkiye özelinde oluşturulan veri setine ilişkin temsili görseller Şekil 3.7’de sunulmuştur.



Şekil 3.7. Oluşturulan veri setinden temsili görüntüler

Böylece, 5 ülkeden farklı sürücüler çalışmaya dahil edilmiştir. Geniş bir veri setinin kullanılması ile farklı sürücü karakteristiklerinin çalışmaya yansıtılması amaçlanmıştır. Bunun yanında trafiğe açık alanda yapılan sürüşler sırasında sürücülerin video kayıtları da alınmıştır. Modelin doğrulaması ve nesnelerin tespiti için bu video kaydı kullanılmıştır. Veri setinin güvenilir olabilmesi açısından tüm veri seti genelinde ön işleme çalışması yapılarak modele uygun olmayan veriler, veri setinden çıkarılmıştır.


Oluşturulan veri setinin eğitim yapılacak modele uygun olması açısından resimlerin teker teker etiketlenme işleminin gerçekleştirilmesi gerekmektedir. Etiketleme işlemi için çevrimiçi veya çevrimdışı hizmet sunan MakeSense.ai., Roboflow.com ve

LabelImg uygulamaları kullanılmıştır. ÇKKV tekniği sonucunda değerlendirmeye alınan sürücü dikkat dağınıklığı sınıfları için etiketleme işlemi yapılmıştır. Etiketleme işlemi sonucunda her bir resim dosyası için bir “label” dosyası oluşturulmuştur. Bu dosyada belirtilen eylem sınıfının numarası ve etiketlenen alanın koordinatları yer almaktadır.

3.7. Makine Öğrenimi

Makine öğrenimi, verileri sınıflandırmamıza ve muhtemel çıktıları tahmin etmemize olanak sağlayan yapay zekânın bir alt dalı olarak ifade edilmektedir (Ren et al. 2022; Zhong et al. 2022). Makine öğreniminin amacı, kullanılan makinelerin mevcut verilere nasıl ulaşacakları ve bunları bir amaç için nasıl kullanacakları konusunda rehberlik eden mimariler oluşturmaktır (Bhardwaj et al. 2019). Bilgi işlem kapasitesi ve devasa miktarda veri nedeniyle, çeşitli karmaşık görevleri yüksek tahmin doğruluğuyla tamamlayabilmek için makine öğrenmesi yöntemlerinden gün geçtikçe daha fazla yararlanılmaktadır (Ran and Hu 2017; Sidey-Gibbons and Sidey-Gibbons 2019).

Genellikle makine öğrenimi 4 adımdan oluşmaktadır: veri işleme, öğrenme, değerlendirme ve tahmin etme aşamalarıdır (Zhou et al. 2017). Temel olarak iki farklı makine öğrenimi tekniği bulunmaktadır. Bunlar Denetimli Makine Öğrenimi ve Denetimsiz Makine Öğrenimidir. Bunların haricinde çok yaygın olmayan Yarı Denetimli Öğrenme ve Takviyeli Öğrenme sınıfları da bulunmaktadır. Şekil 3.8’de Makine Öğrenmesi algoritmalarının ve tekniklerinin görseli sunulmuştur (Zhou et al. 2017; Mohtasham Moein et al. 2023).



Şekil 3.8. Makine öğrenimi algoritma türleri

Makine öğrenimi algoritma sınıflarında temel olarak farklılıklar bulunmaktadır. Denetimli öğrenme mimarileri etiketlenmiş veriler, denetimsiz öğrenme mimarileri ise etiketlenmemiş veriler üzerinden çalışmaktadır. Yarı denetimli öğrenme mimarileri ise her iki tür veri ile çalışabilmektedir. Denetimli öğrenmenin temel amacı girdi ve çıktı parametrelerine göre bir formülasyon oluşturmaktır. Denetimsiz öğrenmede ise girdi ve çıktı parametreleri arasında bir bağlantı aranmaktadır (Liu and Wu 2012; El Bouchefry and de Souza 2020).

3.8. Derin Öğrenme

Derin öğrenme, sinir ağlarına dayalı makine öğrenimi yöntemlerinin / tekniklerinin bir alt kümesi olarak ifade edilmektedir. Birden fazla gizli katmana sahip çok katmanlı bir algılayıcı mimari, derin öğrenme yapısı olarak ifade edilmektedir (Peng et al. 2022). Bu tez çalışması kapsamında Derin öğrenme kavramı ve yöntemleri kullanılmaktadır. Derin öğrenme genel olarak insan beynini taklit etmek için sinir ağlarını kullanmaktadır. Derin öğrenme ve makine öğrenme algoritmaları farklı veri setlerine hizmet etmek amacıyla geliştirilmiştir. Derin öğrenme ve makine öğrenimi arasındaki ilişki Şekil 3.9’da verilmiştir (Anonymous 2020e).




Şekil 3.9. Yapay zekâ, makine öğrenimi ve derin öğrenme arasındaki ilişki

Şekil 3.9'dan anlaşılabacağı üzere derin öğrenme, makine öğreniminin alt dalı olarak ifade edilebilir. Tüm derin öğrenme algoritmaları aslında bir makine öğrenme algoritmasıdır. Ancak, ikisi arasında çeşitli farklar bulunmaktadır. Çizelge 3.6'da makine öğrenimi ve derin öğrenme arasındaki temel farkları ifade eden bilgiler sunulmaktadır (Khan et al. 2021).

Çizelge 3.6. Makine öğrenimi ve derin öğrenme arasındaki temel farklar

Makine Öğrenimi	Derin Öğrenme
Yapay Zekânın alt dalı	Makine Öğreniminin alt dalı
Küçük veri setlerini eğitebilir.	Büyük veri setlerine ihtiyaç duyar.
Düzeltilme ve öğrenme için daha fazla insan müdahalesi gerektirir.	Mimariden ve geçmiş hatalardan kendi kendine beslenir ve öğrenir.
Daha kısa eğitim süresi ve daha düşük doğruluk oranı	Daha uzun eğitim süresi ve daha yüksek doğruluk oranı
Basit, doğrusal korelasyon yapar.	Doğrusal korelasyon yerine kompleks korelasyonlar kurar.
CPU ile eğitilebilir.	GPU desteğine ihtiyaç duyar.

Çizelge 3.6'dan anlaşılabacağı üzere farklı veri setleri ve farklı ihtiyaçlar durumunda kullanım teknikleri ve yöntemleri değişkenlik gösterebilmektedir. Ayrıca, makine öğrenimi ile derin öğrenme arasında işleyiş ve süreç açısından da çeşitli farklılıklar bulunmaktadır. Şekil 3.10'da işleyiş açısından farklılıkları ortaya koyan görsel sunulmaktadır (Khan et al. 2021; Muhammad et al. 2022; Tien et al. 2022).




Şekil 3.10. Makine öğrenimi ve derin öğrenme arasındaki işleyiş farkı

Makine öğrenimi ve derin öğrenme arasındaki temel fark, sınıflandırıcının üzerinde çalıştığı özellikleri veya karakteristikleri çıkarma yöntemidir. Derin öğrenmenin birkaç doğrusal olmayan gizli katmanından çıkarılan özellikleri veya karakteristikleri sayesinde sınıflandırma sürecini, makine öğrenimine göre çok daha performanslı hale getirmektedir (Khan et al. 2021). Makine öğrenimi algoritmaları iki veya daha az sayıda katmandan oluşmaktadır. Bu nedenle elde edilen bilgiler daha sığ olmaktadır. Derin öğrenme algoritmalarında fazla sayıda katman kullanımı mümkün olduğu için daha derin ve nitelikli bilgilerin elde edilmesi mümkündür (Chollet 2017). Sinir ağı olarak ifade edilen ve aralarında ilişki kurulan katmanlar ile oluşturulan model mimarisi ile öğrenme gerçekleştirildikten sonra katmanların her birinde veri seti işlenerek daha temiz ve saf bir bilgi elde edilir. Derin öğrenme algoritmaları, Derin Sinir Ağı (DNN) ve Evrimsel Sinir Ağı (CNN) gibi birçok katmanı içermektedir (Cao et al. 2020; Seghior et al. 2023). Derin öğrenme mimarileri incelenmeden önce sinir ağları ve geçmişte sıklıkla kullanılan Yapay Sinir Ağları (YSA), derin öğrenme başlığı altında incelenmektedir.


3.8.1. Yapay sinir ağı

YSA mimarisi, makine öğrenimi yaklaşımının bir alt dalıdır ve derin öğrenme mimarilerinin dayandığı en temel yapılardandır (Şenalp 2022). Bu mimarinin yapısı oluşturulurken, beyindeki nöronların bilgiyi elde etmek için birbiriyle sürekli etkileşim içerisinde olmasını taklit eden beyin yapısından ilham alınmıştır. Sinir ağlarının karakteristiği nöronlardan oluşmaktadır ve her bilgi işlendikten ve analiz edildikten sonra çıktıya dönüşmektedir (Agatonovic-Kustrin and Beresford 2000). Şekil 3.11’de beyin yapısı ve sinir ağı mimarisi sunulmuştur.



Şekil 3.11. Beyin ve sinir ağı yapısı temsili görseli

Beyin yapısı düşünüldüğünde dendritler girdi parametreleri olarak düşünülebilir. Girdi parametreleri dendritler aracılığıyla toplanır ve aksonlara gönderilir. Akson kanalıyla aktarılan girdi parametreleri her nöron için farklı bir girdi parametresi olarak kullanılabilir. Alınan girdi parametrelerinin kullanılmasında nöronlar arasındaki bağlantının güçlü veya zayıf olması aktif rol oynamaktadır. Ağırlık ile belirlenmiş girdi parametreleri için yeni nöronlar ortaya çıkabilir veya var olan nöronlar ortadan kalkabilir. Temel olarak sinir ağı yapıları da bu mantıkla ilerlemektedir. Beyin sinir yapısını taklit ederek nöronlar arasındaki iletişime hem şekilsel hem de işlevsel olarak benzerlik gösteren YSA, birbirleriyle bağlantılı olan yapay sinir noktalarının oluşturduğu bir mimari ile insan beyni gibi karar verebilen ve değerlendiren akıllı yapılardır. YSA’nın yapısı incelendiğinde ise bir giriş katmanı, bir veya daha fazla gizli katman ve son olarak bir çıkış katmanından oluştuğu görülmektedir (Han et al. 2013; Abdipour et al. 2019). YSA’nın genel yapısına ilişkin görsel Şekil 3.12’de sunulmuştur.



Şekil 3.12. Yapay sinir ağının yapısı

Şekilde belirtilen bu yapıya ayrıca “çok katmanlı algılayıcılar” ismi de verilmektedir. Girdi/Giriş katmanı, sayıları, görüntü pikselleri, ses dosyaları, metinler vb. formattaki giriş parametrelerini içeren katmandır. İkinci katman olarak ifade edilen gizli katmanlar, giriş parametreleri üzerinde çeşitli hesaplamalar gerçekleştirmektedir. Gizli katman olarak ifade edilen bu katmanların sayısını kullanıcı belirlemektedir. Kullanıcının belirlediği gizli katman sayısının en optimum sayıda olması ile en iyi sonuç elde edilebilir (Özkan 2021). Çıkış katmanı olan son katmanda ise, gizli katmanda yapılan hesaplamaların bir sonucu olarak çıktı elde edilmektedir. Katmanlardaki her bir düğüm, giriş parametreleri, ağırlıklar, sapma değeri ve çıktıdan oluşan doğrusal regresyon modeli olarak düşünülebilir. YSA’nın formülasyonu Denklem 3.11’de verilmiştir (Tortum 2003; Çodur 2012; Abidoye et al. 2018; Pratama et al. 2022).


$$\sum_m^i w_i x_i + b = w_1 x_1 + w_2 x_2 + \dots + w_m x_m + b \quad (3.11)$$

Denklemdeki ifadelerden w , ağırlıkları, x girdi parametrelerini ve b bias değerini göstermektedir. Sapma olarak da ifade edilen bias, oluşan düğümün çıktı değerini hesaplarken, girdi parametrelerinin ağırlıklarla çarpıldığı ve sonuç kısmına bir sapma değerinin eklenmesi anlamına gelmektedir. Bias, verilere daha uygun bir model elde edilebilmesi açısından modeldeki etkinleştirme işlevlerinin sola veya sağa kaymasına olanak sağlamaktadır.

Bir giriş katmanı oluşturulduktan sonra ağırlık ataması yapılmaktadır. Ağırlıklar, rastgele bir değişkenin önem derecesini belirlemek için kullanılmaktadır. Ağırlık değeri daha büyük olan girdiler diğer girdilere göre çıktı değeri üzerinde daha etkin rol oynamaktadır. Daha sonra, tüm girdi parametreleri ilişkili ağırlıklarla çarpılır ve toplama işlemi yapılır. Çıktı değeri, çıktı parametresini değerlendiren bir aktivasyon fonksiyonu aracılığıyla elde edilir. Çıktı değeri kullanıcı veya sistem tarafından belirlenen değeri geçerse, katmandaki bir sonraki noktaya iletilerek düğüm noktası etkinleştirilir. Bu durumda, bir düğüm noktasının çıkış parametresi başka bir düğüm noktasının giriş parametresine eşit olması anlamına gelmektedir. Dikkate alınan veri setindeki değerlerin bir katmandan diğer bir katmana aktarılma süreci devam ederse, bu sinir ağı ileri beslemeli bir mimari olarak ifade edilmektedir. Nihai olarak, çıktı katmanına aktarılan girdi parametrelerinden faydalanılarak hata değeri hesaplanır ve geri yayılım algoritması kullanılıp önceki katmanlarda elde edilen ağırlıkların güncellenme işlemi yapılır. Bu durum hedeflenen başarı değerine kadar sürekli bir şekilde devam etmektedir (Abidoye et al. 2018).


3.8.2. Evrişimli sinir ağları

Geleneksel YSA'lar, nesneler ve görüntüler ile ilişkili özellik çıkarım işlemlerini manuel olarak yapmaktadır. Bunun için ise elde edilen veri setinin tüm karakteristik yapısının bilinmesi gerekmektedir. Özellik çıkarım işini daha hızlı ve doğru bir şekilde yapabilmek amacıyla özellik çıkarımını otomatik gerçekleştirebilen ızgara modeline sahip verilere işleyebilen derin öğrenme modeli olan CNN geliştirilmiştir (Hubel and Wiesel 1968; Fukushima 1980). Bu ağlar, görüntülerden belirli öznitelikleri ayırt edebilen, kategorizasyonunu yapabilen ve görüntüleri ve nesneleri etkili bir şekilde analiz etmek için sıklıkla kullanılan DNN olarak ifade edilmektedir (Yamashita et al. 2018). Şekil 3.13'de daha önce YSA için verilen görsele benzer olarak DNN'nin yapısı sunulmuştur.



Şekil 3.13. Derin öğrenme sinir ağı yapısı

CNN'deki “evrişim” ifadesi, var olan fonksiyonun diğer bir fonksiyon tarafından nasıl değiştirildiğini ifade eden bir matematiksel işlemdir. Üçüncü fonksiyonu elde etmek için iki fonksiyonun çarpıldığı doğrusal işlem aşamaya evrişim (konvolüsyon) denmektedir. CNN'ler tipik olarak üç katmandan oluşan matematiksel bir yapıdır. Bunlar, evrişim yani konvolüsyon katmanı, havuzlama katmanı ve tam bağlantılı katmandır. Ayrıca, bu katmanlara ilave olarak aktivasyon fonksiyonu ve seyreltme katmanı da bulunmaktadır. Şekil 3.14'de CNN mimarisi sunulmaktadır.




Şekil 3.14. Evrişimli sinir ağı mimarisi

Konvolüsyon katmanı, öznitelik çıkarma süreci için giriş parametresi olarak verilen görüntülerin farklı özelliklerini ayırt ederek analiz etme işlevini üstlenmektedir. Tam bağlantılı katman ise konvolüsyon sürecinde elde edilen çıktıyı ve diğer aşamalardaki özelliklere göre görüntünün sınıflandırmasını yapma işlevini yürütmektedir (Alzubaidi et al. 2021).

CNN, günümüzde görüntü işleme, sınıflandırma, nesne tespiti, nesne takibi vb. alanlarda sıklıkla kullanılmaktadır. İlerleyen bölümlerde bahsedilecek olan diğer derin öğrenme mimarilerinin altyapısını oluşturan CNN'deki katmanlardan ve işleyiş sürecinden aşağıdaki bölümlerde kısaca bahsedilmiştir.

Evrişim (Konvolüsyon katmanı):

Konvolüsyon veya Evrişim katmanı olarak da bilinen bu katman, CNN'nin temelini oluşturan en önemli katman olarak tanımlanmaktadır (Alzubaidi et al. 2021). Bu katman, evrişimli filtre koleksiyonundan (çekirdek) oluşmaktadır. Yani, belirlenen filtrenin (çekirdek) görüntü üzerinde dolaştırılması ile özellik çıkarımı yapılır ve özellik çıkarımının yapıldığı ilk katman evrişim katmanıdır. Görüntü tespit etme uygulamalarında ne kadar çok filtre kullanılırsa görüntüye ait o kadar fazla özelliğin elde edilmesi mümkündür. Bu filtreler sayesinde görüntüde var olan köşe ve kenar noktalarının özellik haritasında ortaya koyulma işlemi yapılmaktadır. Buna bağlı olarak, evrişim katmanında görüntünün genel hatlarını çıkarmak amacıyla büyük boyutlu ve az sayıda filtre kullanılırken, daha ileri aşamalarda küçük boyutlu ve çok sayıda filtre kullanılmaktadır. Böylece, görüntüye ait tüm detayların öğrenilmesi mümkün hale gelmektedir (İnik ve Ülker 2017). Şekil 3.15'de Evrişim katmanında filtrenin nasıl çalıştığı ile ilgili temsili bir görsel sunulmuştur.




Şekil 3.15. Konvolüsyon işlemi için temsili örnek

Şekil 3.15 incelendiğinde, özellik haritası olarak ifade edilen çıktı değerlerinin girdi değerlerine direk bağlı olmadığı ve sadece filtrenin uygulanmış olduğu 3x3 boyutundaki filtre alanına bağlı olduğu görülmektedir. Çıktı değerlerinin her bir giriş değeri ile doğrudan örtüşmesi gerekli olmadığından, evrişim katmanına “kısmen bağlı” katman yapıları da denmektedir (Dargan et al. 2020).

Havuzlama katmanı:

CNN mimarisinde evrişim katmanını genellikle bir havuzlama katmanı veya diğer adıyla ortalama katmanı takip etmektedir. Havuzlama katmanının genel amacı, hesaplama gücünü artırmak, hesaplama yükünü ve maliyetlerini azaltmak için veri boyutunu azaltmaktır. Havuzlama katmanı için genel olarak kullanılan iki farklı havuzlama yöntemi bulunmaktadır. Bunlar, maksimum havuzlama ve ortalama havuzlama olarak ifade edilmektedir. Şekil 3.16’da iki tip havuzlama yönteminin işleyişi için bir görsel sunulmuştur (Liang 2020). Modele uygun havuzlama yöntemi seçilerek katmanların oluşturulmasına ve mimarinin işletilmesine devam edilir.




Şekil 3.16. Ortalama ve maksimum havuzlama yöntemleri

Maksimum havuzlama yönteminde yapılan işlem filtrenin kapsadığı alandaki piksel değerlerinden maksimum değerini elde etmektir. Ortalama havuzlama yönteminde ise filtrenin kapsadığı alandaki piksel değerlerinin tamamı dikkate alınarak ortalama bir değer elde etmek amaçlanmaktadır (Anonymous 2016). Havuzlama yönteminde çok sayıda veri kaybolmasına karşın CNN işleyişi açısından birçok avantajı bulunmaktadır. Havuzlama katmanları ile karışıklığın azaltılması, aşırı öğrenmenin önüne geçilmesi ve verimliliğin artırılması konularında ciddi iyileştirmeler elde edilebilmektedir (Dong et al. 2016).

Tam bağlantılı katman:

CNN’de art arda gelen evrişim ve havuzlama katmanlarından sonra tam bağlantılı katman gelmektedir. Genel olarak, bu katmanlar her CNN mimarisinin sonunda bulunmaktadır. Bu katmanın içinde, her nöron bir önceki katmanda bulunan tüm nöronlara bağlantılıdır ve bu duruma Tam Bağlı (Fully Connected) yaklaşımı denmektedir. Bu yaklaşım, CNN’nin sınıflandırıcı kısmını oluşturmaktadır (Devi et al. 2021). Tam bağlı katmanının giriş parametrelerini son havuzlama veya evrişim katmanı oluşturmaktadır. Giriş parametreleri, düzleştirme işleminden sonra özellik haritalarından faydalanılarak oluşturulan bir vektör biçimindedir. Tam bağlantı katmanının çıktısı, CNN

mimarisinin nihai çıktısını temsil etmektedir (Alzubaidi et al. 2021). Tam bağlantı katmanının görseli Şekil 3.17’de sunulmaktadır.




Şekil 3.17. Tam bağlantılı katman prosesi

Tam bağlantı katmanları, nöronlar ile birlikte yanlılık/sapma (bias) ve ağırlıktan (weight) oluşmaktadır. Nöronlar iki farklı katman arasındaki bağlantıyı kurmak için kullanılır. Daha önceki katmanlardan ve çeşitli filtrelerden elde edilen özelliklere göre sınıflandırma işlemi gerçekleştirilmektedir. Konvolüsyon ve havuzlama katmanlarında genel olarak ReLu aktivasyon fonksiyonu kullanılırken, tam bağlantılı katmanda Softmax aktivasyonu kullanılır. Softmax aktivasyonu sınıflandırma özelliklerinin tayini için 0-1 aralığında ihtimaller üretmektedir (Şenalp 2022).

Seyreltme katmanı:

Tam bağlantı katmanında tüm özelliklerin aktarılması ve büyük veriler ile eğitim yapılması durumunda, modelde aşırı öğrenme yani ezberleme (overfitting) meydana gelebilmektedir. Bu problemin üstesinden gelebilmek için tam bağlantı katmanında belirli oranlarda düzeltme yapılabilir. Yani, sinir ağı mimarisinden belirli sayıdaki

nöronların çıkarılması ve modelin küçültülmesi işlemi gerçekleştirilmektedir. Bazı özelliklerin kaybolmasına yol açan bu işlem tıpkı havuzlama katmanındaki gibi mimarinin performansını ve işlem hızını artırmaktadır (Srivastava et al. 2014). Seyreltme katmanı ile ilgili görsel Şekil 3.18’de sunulmaktadır.




Şekil 3.18. Seyreltme katmanı uygulanmayan ve uygulanan ağ

Seyreltme katmanı ile gizli katman olarak adlandırılan katmandaki bağlantıların rastgele yok edilmesi ile birlikte tam bağlantılı katmana aktarılan bilgiler de yok olacaktır. Bu dezavantaja karşın yukarıda bahsedilen avantajlarından dolayı hemen hemen tüm evrişimli sinir ağı modellerinde seyreltme katmanı kullanılmaktadır.

Aktivasyon fonksiyonları:

Sinir ağlarındaki aktivasyon fonksiyonları, girdi parametrelerinin ağırlıkları toplamını ağ mimarisindeki düğüm noktalarından bir çıktıya nasıl dönüştürüleceğini tanımlayan en önemli CNN parametrelerindendir. Aktivasyon fonksiyonunun sinir ağında kullanılmaması durumunda, ağ katmanındaki girdi parametreleri basit işlemler ile yürütülecek ve görüntü işleme sürecinin sağlıklı bir şekilde elde edilmesi mümkün olmayacaktır. Aktivasyon fonksiyonları, ağ mimarisindeki parametreler arasındaki ilişkiyi öğrenmek ve tahmin etmek amacıyla kullanılmaktadır. Diğer bir ifadeyle, model mimarisindeki hangi bilginin bir sonraki katmana aktarılacağı ve hangilerinin ağ mimarisini etkilemeyeceğine karar vermektedir. Bu fonksiyonlar, modelin performansı ve kapasitesi üzerinde önemli bir etkiye sahiptir. Ayrıca, modelin farklı katmanlarında farklı aktivasyon fonksiyonları kullanılabilir. ReLU, LeakyReLU, sigmoid, tanh ve

softmax fonksiyonları en sık kullanılan aktivasyon fonksiyonlarıdır. Bu fonksiyonların bazılarına ait grafiksel gösterimler Şekil 3.19’da sunulmaktadır (Yang and Yang 2018).




Şekil 3. 19. Aktivasyon fonksiyonları. (a) Sigmoid fonksiyonu; (b) Tanh fonksiyonu; (c) ReLU fonksiyonu; (d) Leaky ReLU fonksiyonu (e) Softmax fonksiyonu.

Şekil 3.19 incelendiğinde fonksiyonların aldığı değerler hakkında fikir sahibi olunabilir. Sigmoid fonksiyonu girdi parametreleri $[0-1]$ aralığında değerler almaktadır. Sigmoid fonksiyonunda x değerlerindeki değişime oranla y değerlerindeki değişim oldukça kısıtlıdır. Bu nedenle öğrenme sürecinin performansı olumsuz etkilenmektedir. Tanh fonksiyonu $[-1-1]$ aralığında değerler alabilmektedir. Sigmoid fonksiyonuna göre tanımlı olduğu aralığın daha geniş olmasıdır. ReLU fonksiyonu $[0 - +\infty)$ aralığında değer almaktadır. Hesaplama yükü bakımından önceden bahsedilen iki fonksiyonu göre daha avantajlıdır. x değerlerinin negatif olması halinde 0 değerini alması bunun en büyük sebebidir ve bu nedenle sıklıkla tercih edilen bir fonksiyondur. Ancak, sıfır değerini aldığı bölgede türevinin de sıfır değerini alması olumsuzluk teşkil etmektedir. Bu nedenle, Leaky ReLU fonksiyonu geliştirilmiştir ve negatif bölgede sıfıra çok yakın değerler almaktadır (Liu et al. 2019).

3.8.3. Bölgesel tabanlı konvolüsyonlu sinir ağı (R-CNN)

Görüntülerde var olan bölgesel seçme sorunlarını aşmak amacıyla görüntüden sadece 2.000 bölge çıkararak nesne tespiti yapabilen ve bölge önerilerinde bulunabilen Bölgesel tabanlı konvolüsyonlu sinir ağı (R-CNN) yöntemi geliştirilmiştir. R-CNN mimarisi, bir görüntüdeki nesnelerin tespit edilmesi için kullanılmaktadır. R-CNN ile çok sayıdaki bölge içerisinde nesne tespiti yapmak yerine 2.000 bölge arasında nesne tespiti yapılabilir (Girshick et al. 2014). R-CNN mimarisinin oluşturulmuş temsili görseli Şekil 3.20’de verilmiştir (Girshick et al. 2016).




Şekil 3.20. R-CNN model mimarisi

Genel olarak, bölge seçici algoritması sırayla şu şekilde çalışmaktadır: Alt segmentasyon oluşturularak, birçok aday bölge elde edilmektedir. Benzer bölgeleri yinelemeli olarak daha büyük bölgelerle birleştirerek bölge sayısında azaltmaya gidilmektedir. Nihai aday bölge önerileni kullanmak için oluşturulan bölgeler dikkate alınır (Uijlings et al. 2013).

3.8.4. Hızlı bölgesel tabanlı konvolüsyonlu sinir ağı (Fast R-CNN)

R-CNN geliştiricisi tarafından nesne tespiti algoritmaları için R-CNN mimarisinden performans ve hız anlamında daha iyi olan hızlı bölgesel tabanlı konvolüsyonlu sinir ağı (Fast R-CNN) geliştirilmiştir. R-CNN model mimarisine oldukça benzeyen bu algorithmada giriş resmini bölgesel ayırmak yerine görüntü tek bir girdi olarak CNN ile işlenmektedir (Girshick 2015). Önerilen sinir ağı mimarisi bütün görüntüyü evrişim katmanıyla işledikten sonra bir özellik haritası üretmektedir. Daha sonra elde edilen haritalar maksimum havuzlama katmanı yardımıyla boyutları düşürülür.


Maksimum havuzlama katmanı, RoI olarak ifade edilmektedir. Elde edilen özellik haritaları vektör halinde tek düzen haline getirilir. R-CNN mimarisinden farklı bir yanı da sınıflandırıcı aşamasında Softmax fonksiyonunun kullanılmasıdır. Fast R-CNN mimarisinin temel karakteristiği Şekil 3.21’de verilmiştir (Girshick 2015). Fast R-CNN görüntüleri test aşamasında R-CNN mimarisine göre yaklaşık 45 kat, eğitim aşamasında 9 kat daha hızlı analiz eder ve çıktıları verir.



Şekil 3.21. Fast R-CNN model mimarisi

3.8.5. Daha hızlı bölgesel tabanlı konvolüsyonlu sinir ağı (Faster R-CNN)

Fast R-CNN mimarisinde var olan bölge önerisi sorununu çözmek için yine aynı geliştirici tarafından RPN algoritması önerilmiştir. Daha hızlı bölgesel tabanlı konvolüsyonlu sinir ağı (Faster R-CNN) mimarisinde ilk aşama olarak girdi görüntüsü CNN üzerinden geçirilerek özellik haritası elde edilir. Fast R-CNN mimarisinde kullanılan yavaş Seçici Arama (Selective Search) algoritması yerine RPN öğrenimini sağlayan sinir ağı algoritmaları kullanılmaktadır (Nguyen and Abdel Wahab 2023). RPN algoritması bütünüyle CNN mimarisine benzemektedir. Bu algoritmanın temel amacı, nesneleri anlamlandırmak için algılama ve tespit etme önerileri oluşturmaktır. RPN algoritması ile sınıf skorları tayin edilir ve Softmax fonksiyonu kullanılarak bölgedeki objelere ait sınıflar ve sınırlayıcı kutuların belirlenmesi sağlanmaktadır. Faster R-CNN mimarisine ait süreç görseli Şekil 3.22’de verilmektedir (Anonymous 2019b).




Şekil 3.22. Faster R-CNN model mimarisi

Faster R-CNN mimarisi, diğer nesne tespit algoritmalarından farklı olarak girdi görüntülerinin sınıflandırma süreci boyunca yalnız bir defa hesaplama yapmaktadır. Tespit edilmesi istenen bölgelerin bulunduklarında alandaki sınırlayıcı kutuların kenarları ve konumlarını düzeltir (İnik ve Ülker 2017).

3.8.6. Tek atışlı çoklu kutu detektörü (Single shot multibox detector)

Liu et al. 2016 yılında tek atışlı ve ileri beslemeli evrişimli sinir ağlarına bağlı çok kategorili bir nesne tespit algoritması geliştirmişlerdir (Liu et al. 2016). Single shot multibox detector (SSD) algoritması, CNN üzerinden birden fazla özellik haritasına bağlı olarak çok ölçekli sınırlayıcı kutu çıktıları kullanmaktadır. Kıyaslama yapmak gerekirse, Faster R-CNN sınırlayıcı kutularını oluşturmak için RPN kullanır ve sınırlayıcı kutuları nesnelerin tespiti ve sınıflandırmasında kullanır. Böylece, 2 aşamalı bir süreç ilerletilmektedir. SSD algoritmasında ise tek aşamalı olarak nesne tespiti ve sınıflandırma

yapılabilmektedir. SSD algoritmasına ait görsel Şekil 3.23’de sunulmuştur (Liu et al. 2016).




Şekil 3.23. SSD model mimarisi

SSD mimarisinde ilk olarak girdi görüntüsü eklenmekte ve görüntü evrişimli sınır ağı mimarisinden geçirilmektedir. Bu sayede çeşitli boyutlarda bulunan özellik haritaları elde edilmektedir. Özellik haritalarının tamamında ilgili alan için kısıtlayıcı dikdörtgen kutular çıkarılır. Elde edilen dikdörtgen alanları için sınırlar ve sınıflandırmalar tespit edilir. SSD mimarisinde her sınırlayıcı kutu için ayrı ayrı işlem yapmak yerine bir seferde CNN üzerinden geçilir (Tang et al. 2022).

3.8.7. Görsel geometri grubu (Visual geometry group)

Visual Geometry Group (VGG) mimarisi ilk olarak 2014 yılında geliştirilen bir derin öğrenme algoritmasıdır (Anonymous 2015). VGG mimarisi, ImageNet yarışmasında elde ettiği başarılı sonuçların ardından sıklıkla kullanılır hale gelmiştir. VGG mimarisinde 3x3 evrişimli katmanların ardından havuzlama katmanı gelmekte olup ve evrişim katmanlarıyla birlikte 16-19 farklı konfigürasyon derinliği elde edilmektedir. Bu algoritmalarda hacimsel boyuttan tasarruf sağlamak amacıyla maksimum havuzlama tekniği kullanılmaktadır. Mimarinin son adımlarında ise iki bağlantı katmanı (her biri 4.096 düğüm) ve bir softmax fonksiyonu ile sınıflandırma yapılmaktadır. Genel olarak VGG mimarisi CNN’de derinliği artırarak performansı iyileştirmeleri sağlamıştır (Huang et al. 2021). VGG-16 ve VGG-19 olarak isimlendirilen iki farklı versiyonu geliştirici tarafından önerilmiştir. Birbirlerinden farkı ise kullanılan evrişim katmanı sayısı ve ağ

derinliğidir. Genel olarak ifade etmek gerekirse, VGG mimarisi SSD mimarisinde kullanılan bir CNN yapısıdır. VGG model mimarisine ilişkin görsel Şekil 3.24’de sunulmaktadır (Liu et al. 2016).




Şekil 3.24. VGG model mimarisi

VGG mimarisinde ilk evrişim katmanına aktarılan girdi görüntüleri 224×224 boyutunda sabit ve renkli görüntülerden oluşmaktadır. Daha sonra evrişim katmanları ve maksimum havuzlamadan geçirildikten sonra özellik haritaları daha net bir şekilde elde edilmektedir. Bu işlemlerin yapılması ile VGG-16 mimarisinde 138 milyon ile 144 milyon arasında parametre bulunmaktadır (Hamwi and Almustafa 2022). Ayrıca, 1 milyonun üzerinde görüntü ve 1.000 sınıf ile yapılan eğitimler neticesinde VGG-19 mimarisinin VGG-16 mimarisine göre %0,2 daha başarılı olduğu sonucu elde edilmiştir.

3.8.8. Artık ağ (Residual network)


Residual Network (ResNet) mimarisi, derin öğrenme çalışmalarında en sık kullanılan ağlardan biridir. He et al. (2016) tarafından geliştirilen mimari ImageNet 2015 sınıflandırma yarışmasında birincilik almıştır. ResNet ağ modeli ile sinir ağlarındaki derinlik arttıkça kaynak gereksiniminin arttığı ve başarımların düştüğü tespit edilmiştir. Katman sayısına bağlı olarak yapılan işlemler sonucundan test ve eğitim hatalarındaki değişiklikler Şekil 3.25’de sunulmuştur.



Şekil 3.25. Farklı katmandaki mimarilerin test ve eğitim hata değerleri

Şekil 3.25’den de anlaşılacağı üzere modele katman ekleyerek başarı oranını artırmak mümkün değildir. Hatta bunun aksine 20 ve 56 katmanlı modeller karşılaştırıldığında hem test hem de eğitim hatalarında 20 katmanlı modelin başarı sağladığı görülmektedir. Bunun yanı sıra katman sayısındaki artış hesaplama yüküne de etki etmektedir ve bu durum eğitim ve test sürelerinin uzamasına neden olmaktadır.

Bu tür problemlerin üstesinden gelmek için artık (Residual) ağ denilen bloklar kullanılmaktadır. Artık bloklar kullanılarak geliştirilen sinir ağlarının genişletilmesi yerine derinleştirilmesi mümkün hale gelmektedir. Ayrıca, ResNet mimarisi ile hesaplama yükü üzerinde önemli etkisi bulunan parametre sayısının da azaltılması sağlanmıştır. ResNet mimarisi, 18, 34, 50, 101, 110, 152 ve 164 katmandan oluşan versiyonlara sahiptir. ResNet mimarisi ile ilgili görsel Şekil 3.26’da sunulmaktadır (Ramzan et al. 2019).



Şekil 3.26. ResNet-18 mimari modeli

ResNet mimarisinin ön plana çıkan özelliği artık öğrenme bloklarının aktif bir şekilde kullanılmasıdır. Artık bloklarda atlama bağlantıları olarak adlandırılan bir yaklaşım önerilmiştir. Atlama bağlantısı, devam eden eğitimde birkaç adım (katman) atlayarak doğrudan çıktıya ulaşmaktır. ResNet-50 ve daha fazla katmanı bulunan mimarilerde 3 katmanlı artık bloklar bulunurken, daha az sayıda katman bulunan mimarilerde 2 artık katman bulunmaktadır.

Bu bölümde sunulan CNN mimarilerinin anlatılmasının sebebi CNN yapısının işleyişi ve uygulama farklılıklarının ortaya konmasıdır. CNN mimarisi kullanılarak sürekli modellemeler geliştirilmektedir. Bu tez çalışmasının yürütüldüğü süreç zarfında CNN mimarisine ait en son geliştirilen ve başarılı performans sergileyen model YOLO algoritmasıdır. Bu nedenle bu çalışma kapsamında nesne tespiti için YOLO algoritması kullanılmıştır. Diğer yöntemlerin eksikliklerinden ve neden YOLO algoritmasının tercih edildiğinden ilerideki bölümlerde bahsedilmektedir.


3.9. Sadece Bir Kez Bak (You Only Look Once)

YOLO algoritması, ilk olarak 2015 yılında Redmon et al. (2016) tarafından geliştirilen ve CNN mimarisine ait bir derin öğrenme yaklaşımıdır. YOLO algoritmasının temel yapı taşlarını CNN yapıları oluşturmaktadır. YOLO algoritması, bölgesel öneriler sağlayan CNN mimarilerinden farklı olarak girdi görüntüsünü tamamen CNN'den bir kez geçirmektedir. Bu yaklaşım sayesinde, YOLO algoritması diğer modellere göre daha hızlıdır ve gerçek zamanlı olarak çalışabilmektedir (Ouyang and Wang 2019).

YOLO mimarisi, 24 evrişimli katman, iki tamamen bağlı katman ve bir son tespit katmanı ile 27 CNN katmanından oluşmak üzere tasarlanmıştır. Çıktı YOLO ağı, $N * N * (5B+C)$ vektörü olacaktır; burada B, sınırlayıcı kutuları tahmin eden her ızgara hücresidir ve her kutunun bir kutu güven puanı vardır ve C, içindeki tüm sınırlayıcı kutular için bir sınıf puanları kümesidir. Her sınırlayıcı kutu beş öge içerir: (x,y,δ,w,h). Güven puanı, her bir sınırlayıcı kutunun nasıl bir nesne içerdiğini ve sınırlayıcı kutunun ne kadar doğru olduğunu yansıtır. YOLO, tamamen bağlantılı iki katman kullanarak doğrusal bir regresyon gerçekleştirir ve yüksek bir güven puanına sahip sınır kutularını korumak için son bir katman kullanarak tahminde bulunur.

YOLO, her ızgara hücresi için birden fazla sınırlayıcı kutu tahmin ettiğinden, tespit edilmesi gereken nesneyi tahmin etmek için bir sorumlu kayıp fonksiyonu hesaplanmaktadır. YOLO modeli, üç kayıp hesaplama işlevi kullanmaktadır: sınıflandırma kaybı, yerelleştirme (konum) kaybı ve güven kaybı. Bir kayıp fonksiyonu olarak kullanılabilir olanı seçmek için görüntü benzeşmesi (IoU) hesaplanır ve ardından en yüksek değere sahip olan IoU seçilir. YOLO modeli, tahminler ve gerçek nesneler arasındaki hata kaybını hesaplamak için hata kareleri toplamı tekniğini kullanmaktadır. Sınıflandırma kaybı, sınıf olasılığının hata karesidir. Yerelleştirme kaybı, sınır kutusu konumlarındaki ve boyutlarındaki hataları ölçer. Güven kaybı, kutudaki nesnelerin olma olasılığının ölçülmesindeki hata ölçütüdür. YOLO kaybının nihai kaybı, tüm kayıp fonksiyonlarının toplamıdır (kayıp=sınıflandırma kaybı + konum kaybı + güven kaybı).

YOLOv1 olarak adlandırılan algoritma 45 FPS ile çalışır ve aynı anda birden fazla nesneyi algılayabilmektedir. Geliştirilen diğer YOLO versiyonlarında FPS değeri açısından ciddi bir iyileşme elde edilmiştir. YOLO algoritmasının ikinci versiyonu veya YOLO9000 olarak adlandırılan versiyonu 2016 yılının Aralık ayında Anonymous (2018b) tarafından önerilmiştir. Geliştirildiğinde araştırmacılar için oldukça popüler olan YOLOv3 ise 2018 yılında yine Redmond and Farhadi (2018) tarafından öne sürülmüştür. 2020 yılında ise farklı bir araştırma grubu tarafından YOLOv4 algoritması geliştirilmiştir (Bochkovskiy et al. 2020). YOLOv5 algoritması ise yine 2020 yılında Ultralytics'in kurucusu olan Anonymous (2020f) tarafından Github'da yayınlanmaya başlamıştır. 2022 yılında Meituan Görsel Zeka Departmanı tarafından YOLOv6 isimli yeni bir çerçeve sunulmuştur. Bu modelin asıl amacı, endüstriyel uygulamalarda karşılaşılan sorunları çözmektir (Anonymous 2022h). Yine 2022 yılında Wang et al. (2022) tarafından YOLOv7 geliştirilmiştir. YOLOv8 ise 2023 yılında Ultralytics tarafından geliştirilmiştir. YOLO algoritmalarının ilki olan YOLOv1'e ait mimari Şekil 3.27'de sunulmaktadır.



Şekil 3.28. Gerçek zamanlı nesne tespiti yapabilen YOLO mimarilerinin karşılaştırılması

Şekil 3.28 incelendiğinde YOLOv8 performansı, önceki YOLO sürümlerine ve temel olarak YOLOR algoritmasına göre değerlendirilmiştir. Belirtilen modeller aynı

ayarlar ve veri seti ile eğitilmiştir. YOLOv8 modeli son teknoloji nesne tespit algoritmalarına kıyasla en iyi hız ve doğruluk dengesini elde etmiştir. Genel olarak YOLOv8, 5 FPS'den 160 FPS'ye kadar değişen hız ve doğruluk açısından diğer nesne tespit algoritmalarını geride bırakmıştır.

YOLO algoritmalarının performanslarını ölçmek için çeşitli çıktı ölçüm parametreleri bulunmaktadır. “Precision”, “Recall”, “F1-Score”, “mAP” değerleri ile algoritmanın performansı ölçülebilir. İlgili ölçüm parametrelerine ait formülasyonlar Denklem 3.12., 3.13., 3.14., 3.15. ve 3.16.’da verilmiştir.

$$Precision = \frac{Doğru\ Pozitif}{Doğru\ Pozitif + Yanlış\ Pozitif} \quad (3.12)$$

$$Recall = \frac{Doğru\ Pozitif}{Doğru\ Pozitif + Yanlış\ Negatif} \quad (3.13)$$

$$AP = \sum_{i=0}^{n-1} [(Recall(i)) - (Recall(i + 1))] * Precision(i) \quad (3.14)$$

$$mAP = \frac{1}{n} \sum_{i=0}^n AP_i \quad (3.15)$$

$$F_1 = 2 * \frac{precision * recall}{precision + recall} \quad (3.16)$$

Denklem 3.12’de formülasyonu verilen “Precision” (Kesinlik), pozitif olarak tahmin edilen girdilerin ne kadarının gerçekten pozitif olduğunu göstermektedir. Kesinlik değeri özellikle yanlış pozitif tahmin durumlarında oldukça önem arz etmektedir. Yanlış yapılan tahmin ile modelin performansı düşeceğinden dolayı Kesinlik parametresi değeri model seçiminde etkili bir kriter olarak değerlendirilmektedir.

Denklem 3.13’deki formülasyon ile ifade edilen “Recall” (Duyarlılık) pozitif değer olarak tahmin edilmesi gereken girdilerin kaç tanesinin pozitif olarak tahmin edildiğini gösteren bir ölçüm parametresidir. Yanlış pozitif olarak tahmin edilen durumlar için “Recall” değeri bize yardımcı olacaktır. Kesinlik değerinde olduğu gibi Duyarlılık değeri de yüksek olmalıdır.

Kesinlik ve Duyarlılık değerlerinin harmonik ortalaması alınarak F1 skor değeri elde edilmektedir. Harmonik ortalamanın seçilmesinin nedeni uç durumlardaki girdilerin de ölçüm parametresinde dikkate alınma gerekliliğidir. Genel olarak Doğruluk parametresi yerine F1 skor değeri dikkate alınmaktadır. Bunun nedeni homojen olmayan veri seti nedeniyle hatalı bir model seçiminin önüne geçmektedir.



4. ARAŞTIRMA BULGULARI ve TARTIŞMA

Çalışmanın bu bölümünde ilk olarak Erzurum ilinde seçilen kavşakların yol kenarı gözlem sonuçları incelenecektir. Yol kenarı gözlem sırasında elde edilen verilerin sunulması ve yorumlanması bu bölümde yapılmaktadır. Referans değer olarak kabul edilen yakıt tüketimi ve emisyon değerleri dikkate alınarak seçilen kavşaklardaki yakıt tüketimi, emisyon ve gecikme değerleri incelenecektir. Dikkate alınan kavşaklar arasında en yoğun / kritik kavşağın seçilmesi için Entropi ağırlıklandırma yöntemi ile belirlenen parametrelerin ağırlıklandırılması ve sonuçları sunulmaktadır. Parametre değerlerinin CBS ortamında gösterimi ve analizi yapıldıktan sonra en yoğun / kritik kavşağın da gösterimi CBS ortamında verilmiştir.

Bu bölümün ikinci kısmında sürücü dikkat dağınıklığı için hangi eylem sınıfının kullanılacağını belirlemek için ağırlıklandırma yöntemi olarak AHP yöntemi uygulanmıştır ve sonuçları sunulmuştur. En yüksek önem derecesine sahip eylem sınıflarını dikkate alarak sürücü dikkat dağınıklığı tespiti için oluşturulan veri setinde etiketleme işlemi gerçekleştirilmiştir. Eylem sınıflarının ön işleme süreci tamamlandıktan sonra görüntü işleme algoritması ile sürücü dikkat dağınıklığı tespiti yapılmıştır ve model sonuçları detaylı bir şekilde sunulmuştur.


4.1. Yol Kenarı Gözlem Araştırması ve Sonuçları

Yol kenarı gözlem araştırması esnasında Şekil 3.3’de belirtilen strateji uygulanmıştır. Gözlem ekibinin sayısı trafik yoğunluğuna göre değişiklik göstermektedir. Cep telefonu kaynaklı sürücü dikkat dağınıklığının analiz edilmesinde iki önemli parametre dikkate alınmıştır. Gözlem yapılan sürücü cep telefonu kullanımı ve yeşil ışık yandıktan sonra ne kadar sürede cep telefonu kullanımını bırakma durumudur. Bu sayede hem trafik ışıklarında bekleyen sürücülerin cep telefon kullanım alışkanlıklarının analiz edilmesi hem de cep telefonu kullanımından kaynaklanan gecikmelerin hesaplanması mümkün hale gelmiştir. Kavşak bazlı yapılan gözlem araştırmasında elde edilen sonuçlar Çizelge 4.1’de sunulmaktadır.

Çizelge 4.1. Yol kenarı gözlem araştırması sonucu elde edilen veriler

Kavşak Numarası	Gecikme (s)	Toplam Sürücü Sayısı	Cep Telefonu Kullanan Sürücü Sayısı	İhlal ortalaması (%)	Sürücü Bazlı Gecikme Ortalaması	Gecikme (dk.)
1	443,50	692	119	17,197	0,641	7,392
2	352,42	684	123	17,982	0,515	5,874
3	478,49	984	195	19,817	0,486	7,975
4	320,78	723	108	14,938	0,444	5,346
5	347,52	806	124	15,385	0,431	5,792
6	170,57	555	72	12,973	0,307	2,843
7	89,25	310	47	15,161	0,288	1,488
8	75,11	245	43	17,551	0,307	1,252
9	167,29	614	80	13,029	0,272	2,788
10	99,68	370	49	13,243	0,269	1,661
11	122,48	385	51	13,247	0,318	2,041
12	117,94	380	52	13,684	0,310	1,966
13	120,78	367	48	13,079	0,329	2,013
14	94,28	298	46	15,436	0,316	1,571
15	107,09	466	62	13,305	0,230	1,785
16	131,09	345	56	16,232	0,380	2,185
17	151,49	435	71	16,322	0,348	2,525
18	120,64	385	61	15,844	0,313	2,011
19	201,13	646	111	17,183	0,311	3,352
20	100,80	338	45	13,314	0,298	1,680
21	113,93	436	58	13,303	0,261	1,899
22	114,19	421	57	13,539	0,271	1,903
23	106,08	356	52	14,607	0,298	1,768

Çizelge 4.1 gecikme parametresi bakımından incelendiğinde en fazla gecikmenin olduğu kavşağın 3 numaralı kavşak (Hastaneler Caddesi / Gez Kavşağı) olduğu görülmektedir. Bu kavşağı 1 numaralı kavşak (MNG AVM Kavşağı) takip etmektedir. En az gecikmenin olduğu kavşağın 8 numaralı kavşak (Kervansaray Kavşağı) olduğu görülmektedir. Şekil 4.1’de gecikme parametresinin çalışma alanındaki görsel analizi ve gösterimi verilmiştir.



Şekil 4.1. Çalışma alanında gecikme parametresinin görsel sunumu

Gözlem araştırması sonuçları toplam sürücü sayısı bakımından incelendiğinde yine en yoğun kavşağın 3 numaralı kavşak olduğu görülmektedir. Bu kavşağı 5 numaralı kavşak (Havuzbaşı Kavşağı) izlemektedir. Trafik yoğunluğunun en düşük olduğu kavşak ise 8 numaralı kavşaktır. Şekil 4.2’de toplam sürücü sayısı parametresinin çalışma alanındaki görsel analizi ve gösterimi verilmiştir.






Şekil 4.2. Çalışma alanında toplam sürücü sayısı parametresinin görsel sunumu

Cep telefonu kullanan sürücü sayısı açısından Çizelge 4.1 incelendiğinde yine en fazla cep telefonu kullanımının 3 numaralı kavşakta yapıldığı görülmektedir. 5 numaralı kavşak ise ilgili parametre açısından bu kavşağı takip etmektedir. Ek olarak, 2 numaralı kavşağın (Üniversite / Kartal Kavşağı) parametre değerleri ile 5 numaralı kavşağın değerleri oldukça yakındır. Cep telefonu kullanımının en az olduğu kavşak ise 8 numaralı kavşaktır. Şekil 4.3’de cep telefonu kullanan sürücü sayısının çalışma alanındaki görsel analizi ve gösterimi verilmiştir.






Şekil 4.3. Çalışma alanında cep telefonu kullanan sürücü sayısının görsel sunumu

İhlal ortalaması açısından bakıldığında ilk üç kavşak sırasıyla 3 – 2 – 8'dir. 8 numaralı kavşakta, toplam sürücü sayısı ve cep telefonu kullanan sürücülerin sayısı az olmasına rağmen ihlal ortalamasında 3. sırada bulunmaktadır. En düşük ortalama sahip kavşak ise 6 numaralı (Şehir Hastanesi Kavşağı) kavşaktır. Şekil 4.4'de ihlal ortalamasının çalışma alanındaki görsel analizi ve gösterimi verilmiştir.






Şekil 4.4. Çalışma alanında ihlal ortalamasının görsel sunumu

Kavşaklardaki gecikmenin daha iyi anlaşılması için toplam gecikmeden ziyade sürücülerin bireysel olarak ne kadar gecikme yaşadığına bakılmalıdır. Sürücü bazlı gecikme ortalaması açısından incelendiğinde ilk üç kavşak sırasıyla 1-2-3'dür. Sürücü bazında en az gecikmenin yaşandığı kavşak ise 15 numaralı (Yenişehir Kavşağı) kavşaktır. Şekil 4.5'de sürücü bazlı gecikme ortalamasının çalışma alanındaki görsel analizi ve gösterimi verilmiştir.





Şekil 4.5. Çalışma alanında sürücü bazlı gecikme ortalamasının görsel sunumu

Emisyon ve yakıt tüketimi hesaplamaları için referans olarak alınan değerler (Çizelge 3.2) ve Çizelge 4.1'deki değerler kullanılarak kavşak bazlı yakıt tüketimi ve emisyon değerleri hesaplanmıştır. Tezin önceki bölümlerinde de bahsedildiği gibi taşıt cinsi sayımları yol kenarı gözlem araştırmasında gerçekleştirilememiştir. Bu nedenle hesaplamalar yapılırken trafik kombinasyonu varsayımı üzerinden yapılmıştır. Trafik kombinasyonunun belirlenmesi için Erzurum özelinde motorlu kara taşıtları istatistiklerinden ve gözlem ekibinin yargılarından faydalanılmıştır. TÜİK'in 2023 motorlu kara taşıtları istatistikleri il bazlı olarak incelendiğinde haziran ayı itibariyle Erzurum genelinde toplam 128.389 motorlu kara taşıtı bulunmaktadır ve bunların 64.447 adedi otomobil sınıfı olarak değerlendirilmektedir (Anonim 2023b). Bu bilgiler doğrultusunda gözlem ekibinin de katkılarıyla Küçük Araç, Aile Aracı / Orta Sınıf ve Minivan Araç için sırasıyla %30, %30 ve %40 oranları esas alınmıştır. Yol kenarı gözlemlerine göre Küçük Araç ile Aile Aracı / Orta Sınıf araç türlerinin yoğunluklarının birbirine yakın olduğu belirtilmiştir. Bunun yanında, toplu taşıma araçları dikkate alınarak Minivan Araç kombinasyonu %40 olarak değerlendirilmiştir. Bu tez çalışması kapsamında TÜİK'in istatistikleri ve gözlem ekibinin yargıları da göz önüne alınarak otomobil sınıfının kompozisyonu %60 olarak dikkate alınmıştır. Bunun sebebi, otomobilden daha küçük hacimli motorlu kara taşıtları da bu sınıfa dahil edilmiştir. Bu değerlendirmelere göre kavşakların emisyon ve yakıt tüketimi değerleri Çizelge 4.2 de verilmiştir.


Çizelge 4.2. Kavşakların emisyon ve yakıt tüketimi değerleri

Kavşak Numarası	CO ₂ (g)	CO ₂ (litre)	NO _x (g)	NO _x (litre)	Yakıt Tüketimi (litre)
1	157,41	85,48	0,18	0,12	0,11
2	125,09	67,92	0,15	0,10	0,09
3	169,83	92,22	0,20	0,13	0,12
4	113,86	61,82	0,13	0,09	0,08
5	123,35	66,98	0,14	0,10	0,09
6	46,53	25,27	0,05	0,04	0,03
7	53,77	29,20	0,06	0,04	0,04
8	42,87	23,28	0,05	0,03	0,03
9	43,47	23,61	0,05	0,03	0,03

Çizelge 4.2. (Devam)

10	33,46	18,17	0,04	0,03	0,02
11	42,82	23,25	0,05	0,03	0,03
12	71,39	38,76	0,08	0,06	0,05
13	41,86	22,73	0,05	0,03	0,03
14	60,54	32,87	0,07	0,05	0,04
15	26,66	14,48	0,03	0,02	0,02
16	35,78	19,43	0,04	0,03	0,03
17	37,65	20,45	0,04	0,03	0,03
18	31,68	17,20	0,04	0,02	0,02
19	59,38	32,24	0,07	0,05	0,04
20	40,53	22,01	0,05	0,03	0,03
21	35,38	19,21	0,04	0,03	0,02
22	40,44	21,96	0,05	0,03	0,03
23	38,01	20,64	0,04	0,03	0,03


Çizelge 4.2 incelendiğinde CO₂ (g) emisyonu bakımından en yüksek değerler sırasıyla 3 – 1 ve 2 numaralı kavşaklarda gözlemlenmektedir. Bunun yanında CO₂ (g) emisyon değerinin en düşük olduğu kavşak ise 15 numaralı kavşaktır. CO₂ (g) emisyonunun çalışma alanındaki görsel analizi ve sunumu Şekil 4.6’da verilmiştir.



Şekil 4.6. CO₂ (g) emisyonunun çalışma alanındaki görseli

Çizelge 4.2 NO_x (g) parametresi açısından incelendiğinde CO₂ (g) emisyonu sonuçlarına çok benzer sıralamalar ortaya çıkmaktadır. CO₂ (g) emisyonunda olduğu gibi en yüksek değere sahip kavşaklar 3 – 1 ve 2 olurken en düşük değere sahip kavşak ise 15 numaralı kavşaktır. Buna göre NO_x parametresinin çalışma alanındaki görseli Şekil 4.7’de sunulmaktadır.






Şekil 4.7. NOx (g) emisyonunun çalışma alanındaki görseli

Çizelge 4.2 yakıt tüketimi (litre) parametresi açısından incelendiğinde CO₂ (g) ve NO_x (g) emisyonu sonuçlarına çok benzer sıralamalar ortaya çıkmaktadır. CO₂ (g) ve NO_x (g) emisyonunda olduğu gibi en yüksek değere sahip kavşaklar 3 – 1 ve 2 olurken en düşük değere sahip kavşak ise 15 numaralı kavşaktır. Belirtilen üç parametre değerlerinin de birbiriyle ilişkili olmasının nedeni tüm değerlerin gecikme parametresiyle bağlantılı olmasıdır. Yakıt tüketimi değerlerinin çalışma alanındaki görseli Şekil 4.8’de sunulmaktadır.





Şekil 4.8. Yakıt tüketiminin (litre) çalışma alanındaki görseli

Çizelge 4.1 ve Çizelge 4.2’de yer alan değerler incelendiğinde parametrelerin çoğunluğu için 3 numaralı kavşağın ön planda olduğu görülmektedir. Ancak, en yoğun / kritik kavşağın belirlenebilmesi amacıyla bilimsel ve stratejik bir yaklaşım uygulanması gerekmektedir. Bu amaç doğrultusunda ilgili parametrelerin ağırlıklandırılması için Entropi ağırlıklandırma yöntemi kullanılmıştır.

4.2. Entropi Ağırlıklandırma Sonuçları

Entropi ağırlıklandırma yönteminin uygulanması için öncelikle Denklem 3.1.’de belirtilen karar matrisinin oluşturulması gerekmektedir. Entropi yönteminin diğer ağırlıklandırma yöntemlerinden farkı kişisel yargılara ihtiyaç duymadan ağırlıklandırma yapabilmesidir. Kişisel yargı gerektiren ağırlıklandırma yöntemlerinde karar verme takımı yeterli kapasitede ve sayıda değilse objektif bir değerlendirme yapamamaktadır. Bu nedenle, çalışmanın bu bölümünde parametrelerin ağırlıklandırılması amacıyla Entropi yöntemi tercih edilmiştir. Yöntem kapsamında oluşturulan karar matrisi Çizelge 4.3’de sunulmaktadır.

Çizelge 4.3. Entropi ağırlıklandırma yöntemi için oluşturulan karar matrisi

Kavşak No/Kriter	Gecikme (s)	Toplam Sürücü Sayısı	Cep Telefonu Kullanan Sürücü Sayısı	İhlal Ortalaması (%)	Sürücü Bazlı Gecikme Ortalaması	CO ₂ (g)	NO _x (g)	Yakıt Tüketimi (litre)
1	443,50	692,00	119	17,197	0,641	157,413	0,184	0,111
2	352,42	684,00	123	17,982	0,515	125,086	0,146	0,088
3	478,49	984,00	195	19,817	0,486	169,832	0,199	0,119
4	320,78	723,00	108	14,938	0,444	113,856	0,133	0,080
5	347,52	806,00	124	15,385	0,431	123,346	0,144	0,087
6	170,57	555,00	72	12,973	0,307	60,541	0,071	0,043
7	89,25	310,00	47	15,161	0,288	31,678	0,037	0,022
8	75,11	245,00	43	17,551	0,307	26,659	0,031	0,019
9	167,29	614,00	80	13,029	0,272	59,377	0,069	0,042
10	99,68	370,00	49	13,243	0,269	35,380	0,041	0,025
11	122,48	385,00	51	13,247	0,318	43,472	0,051	0,031

Çizelge 4.3. (Devam)

12	117,94	380,00	52	13,684	0,310	41,861	0,049	0,029
13	120,78	367,00	48	13,079	0,329	42,869	0,050	0,030
14	94,28	298,00	46	15,436	0,316	33,463	0,039	0,023
15	107,09	466,00	62	13,305	0,230	38,010	0,044	0,027
16	131,09	345,00	56	16,232	0,380	46,528	0,054	0,033
17	151,49	435,00	71	16,322	0,348	53,769	0,063	0,038
18	120,64	385,00	61	15,844	0,313	42,819	0,050	0,030
19	201,13	646,00	111	17,183	0,311	71,388	0,083	0,050
20	100,80	338,00	45	13,314	0,298	35,777	0,042	0,025
21	113,93	436,00	58	13,303	0,261	40,438	0,047	0,028
22	114,19	421,00	57	13,539	0,271	40,530	0,047	0,028
23	106,08	356,00	52	14,607	0,298	37,651	0,044	0,026

Entropi yönteminde karar matrisi oluşturulduktan sonra bütün değerlerin aynı ölçekte olmasını sağlamak amacıyla normalizasyon işlemi gerçekleştirilmektedir. Normalizasyon işlemi Denklem 3.2.'de verilen formülasyona göre uygulanmaktadır. Normalize karar matrisi Çizelge 4.4'de sunulmaktadır.

Çizelge 4.4. Entropi yönteminde kullanılan normalize karar matrisi

Kavşak No/Kriter	Gecikme (s)	Toplam Sürücü Sayısı	Cep Telefonu Kullanan Sürücü Sayısı	İhlal Ortalaması (%)	Sürücü Bazlı Gecikme Ortalaması	CO ₂ (g)	NO _x (g)	Yakıt Tüketimi (litre)
1	0,107	0,062	0,069	0,050	0,081	0,107	0,107	0,107
2	0,085	0,061	0,071	0,052	0,065	0,085	0,085	0,085
3	0,115	0,088	0,113	0,057	0,061	0,115	0,115	0,115
4	0,077	0,064	0,062	0,043	0,056	0,077	0,077	0,077
5	0,084	0,072	0,072	0,044	0,054	0,084	0,084	0,084
6	0,041	0,049	0,042	0,037	0,039	0,041	0,041	0,041
7	0,022	0,028	0,027	0,044	0,036	0,022	0,022	0,022
8	0,018	0,022	0,025	0,051	0,039	0,018	0,018	0,018
9	0,040	0,055	0,046	0,038	0,034	0,040	0,040	0,040
10	0,024	0,033	0,028	0,038	0,034	0,024	0,024	0,024

Çizelge 4.4. (Devam)

11	0,030	0,034	0,029	0,038	0,040	0,030	0,030	0,030
12	0,028	0,034	0,030	0,040	0,039	0,028	0,028	0,028
13	0,029	0,033	0,028	0,038	0,041	0,029	0,029	0,029
14	0,023	0,027	0,027	0,045	0,040	0,023	0,023	0,023
15	0,026	0,041	0,036	0,038	0,029	0,026	0,026	0,026
16	0,032	0,031	0,032	0,047	0,048	0,032	0,032	0,032
17	0,037	0,039	0,041	0,047	0,044	0,037	0,037	0,037
18	0,029	0,034	0,035	0,046	0,039	0,029	0,029	0,029
19	0,049	0,057	0,064	0,050	0,039	0,049	0,049	0,049
20	0,024	0,030	0,026	0,038	0,038	0,024	0,024	0,024
21	0,027	0,039	0,034	0,038	0,033	0,027	0,027	0,027
22	0,028	0,037	0,033	0,039	0,034	0,028	0,028	0,028
23	0,026	0,032	0,030	0,042	0,037	0,026	0,026	0,026

Normalize karar matrisi oluşturulduktan sonra Entropi değerlerinin hesaplanması amacıyla Denklem 3.3.'deki formülasyon kullanılmaktadır. Çizelge 4.5'de hesaplanan Entropi değerleri verilmiştir.

Çizelge 4.5. Entropi değerler matrisi

Kavşak No/Kriter	Gecikme (s)	Toplam Sürücü Sayısı	Cep Telefonu Kullanan Sürücü Sayısı	İhlal Ortalaması (%)	Sürücü Bazlı Gecikme Ortalaması	CO ₂ (g)	NO _x (g)	Yakıt Tüketimi (litre)
1	-0,239	-0,172	-0,184	-0,149	-0,203	-0,239	-0,239	-0,239
2	-0,210	-0,170	-0,188	-0,154	-0,177	-0,210	-0,210	-0,210
3	-0,249	-0,213	-0,246	-0,164	-0,171	-0,249	-0,249	-0,249
4	-0,198	-0,176	-0,173	-0,136	-0,161	-0,198	-0,198	-0,198
5	-0,208	-0,189	-0,189	-0,138	-0,158	-0,208	-0,208	-0,208
6	-0,131	-0,149	-0,132	-0,123	-0,126	-0,131	-0,131	-0,131
7	-0,083	-0,099	-0,098	-0,137	-0,120	-0,083	-0,083	-0,083
8	-0,073	-0,083	-0,092	-0,151	-0,126	-0,073	-0,073	-0,073
9	-0,130	-0,159	-0,142	-0,123	-0,116	-0,130	-0,130	-0,130
10	-0,090	-0,112	-0,101	-0,125	-0,115	-0,090	-0,090	-0,090
11	-0,104	-0,116	-0,104	-0,125	-0,129	-0,104	-0,104	-0,104
12	-0,101	-0,115	-0,105	-0,128	-0,127	-0,101	-0,101	-0,101
13	-0,103	-0,112	-0,099	-0,124	-0,132	-0,103	-0,103	-0,103
14	-0,086	-0,096	-0,096	-0,139	-0,128	-0,086	-0,086	-0,086
15	-0,094	-0,132	-0,119	-0,125	-0,102	-0,094	-0,094	-0,094
16	-0,109	-0,107	-0,111	-0,143	-0,145	-0,109	-0,109	-0,109
17	-0,121	-0,126	-0,131	-0,144	-0,137	-0,121	-0,121	-0,121
18	-0,103	-0,116	-0,118	-0,141	-0,127	-0,103	-0,103	-0,103
19	-0,147	-0,164	-0,176	-0,149	-0,127	-0,147	-0,147	-0,147
20	-0,090	-0,105	-0,095	-0,125	-0,123	-0,090	-0,090	-0,090
21	-0,099	-0,126	-0,114	-0,125	-0,112	-0,099	-0,099	-0,099
22	-0,099	-0,123	-0,112	-0,127	-0,115	-0,099	-0,099	-0,099
23	-0,094	-0,109	-0,105	-0,134	-0,123	-0,094	-0,094	-0,094

Denklem 3.4.'de yer alan katsayının hesaplanması için dikkate alınan alternatif sayısı kullanılmaktadır. Buna göre, $k = 0,3189$ olarak hesaplanmıştır. Katsayı ve entropi değerleri hesaplandıktan sonra bilginin farklılaşma derecesi hesaplanmaktadır. Parametre bazında entropi değerleri ve bilginin farklılaşma derecesi Çizelge 4.6'da verilmiştir.

Çizelge 4.6. Entropi değeri ve bilginin farklılaşma derece değerleri

	Gecikme (s)	Toplam Sürücü Sayısı	Cep Telefonu Kullanan Sürücü Sayısı	İhlal Ortalaması (%)	Sürücü Bazlı Gecikme Ortalaması	CO ₂ (g)	NO _x (g)	Yakıt Tüketimi (litre)
e _i	0,944	0,979	0,967	0,998	0,989	0,944	0,944	0,944
d _j	0,056	0,021	0,033	0,002	0,011	0,056	0,056	0,056

Entropi değerleri ve bilginin farklılaşma derecesi hesaplandıktan sonra son aşama olarak Denklem 3.7.'de verilen formülasyon kullanılarak parametre bazlı ağırlıklar elde edilmektedir. Çizelge 4.7'de parametre ağırlıkları verilmiştir.

Çizelge 4.7. Parametre ağırlık sonuçları

	Gecikme (s)	Toplam Sürücü Sayısı	Cep Telefonu Kullanan Sürücü Sayısı	İhlal Ortalaması (%)	Sürücü Bazlı Gecikme Ortalaması	CO ₂ (g)	NO _x (g)	Yakıt Tüketimi (litre)
w _i	0,192	0,073	0,112	0,008	0,037	0,192	0,192	0,192

Çizelge 4.7 incelendiğinde ağırlığı en yüksek olan parametreler Gecikme, CO₂, NO_x ve Yakıt Tüketimi olarak ön plana çıkmaktadır. Değerlerin birbiriyle aynı olmasının sebebi karar matrisindeki değerler oluşturulurken CO₂, NO_x ve Yakıt Tüketimi parametre değerlerinin Gecikme değerine bağımlı olmasıdır. Bu doğrultuda Entropi yönteminin karar matrisi değerleri üzerinden ağırlıklandırma yaptığı ve yargılardan bağımsız objektif bir şekilde işlem yaptığı da ispat edilmiştir. Ağırlık değerleri ve parametre değerleri kullanılarak kavşaklar için yeni ağırlıklı değer hesaplanmıştır. Buna göre en kritik / yoğun kavşak belirlenmiştir. Çizelge 4.8'de ağırlıklı değerler sunulmaktadır.


Çizelge 4.8. Kavşakların ağırlıklı değerleri

Kavşak Numarası	Ağırlık Değerler	Kavşak Numarası	Ağırlık Değerler
1	179,503	13	63,705
2	155,631	14	51,572
3	218,431	15	68,912
4	148,506	16	65,720
5	163,317	17	79,272

Çizelge 4.8. (Devam)

6	93,058	18	66,463
7	51,243	19	112,067
8	42,399	20	56,050
9	97,395	21	68,063
10	58,535	22	66,930
11	65,796	23	59,535
12	64,365		

Ağırlıklı değerler incelendiğinde dikkate alınan parametreler bakımından en yoğun / kritik kavşak 3 numaralı kavşak olarak ön plana çıkmaktadır. 3 numaralı kavşağı sırasıyla 1 – 2 – 5 ve 4 numaralı kavşak izlemektedir. Ağırlıklı değerler bakımından en düşük değere sahip kavşak ise 8 numaralı kavşaktır. Bu kavşağı sırasıyla 7 – 14 – 10 numaralı kavşaklar takip etmektedir. Şekil 4.9’da ağırlıklı değerler ile oluşturulmuş çalışma alanı haritası yer almaktadır.



Şekil 4.9. Ağırlıklı kavşak değerlerinin çalışma alanındaki gösterimi

Ağırlıklı değerler sonucunda 3 numaralı kavşak en yoğun / kritik kavşak olarak belirlenmiştir. Dikkate alınan hemen hemen tüm parametrelerde 3 numaralı kavşak ön plana çıkmaktadır. Bunun nedeni, kavşaktaki taşıt yoğunluğunun fazla olmasının yanında kavşaktaki sürücülerin cep telefonu kullanım eğiliminin de yüksek olmasıdır. Bu durum, kavşaktaki gecikmeyi artırdığı için en kritik / yoğun kavşak olarak 3 numaralı kavşak bulunmuştur. Ağırlıklı değerler hesaplanırken entropi ağırlıklandırma yönteminde elde edilen ağırlıklardaki bazı değerlerin birbiriyle aynı olduğu görülmektedir. Bunun nedeni, entropi herhangi bir kişisel yargıya dayanmamakla birlikte objektif değerlendirme yapmaktadır. Kişisel yargıların parametre bazında önceliklendirme yapmamasından dolayı birbirine bağlı parametre değerleri için aynı ağırlık değerlerin bulunması olağan bir durumdur. Ek olarak, bu değerlerin aynı çıkması Entropi yönteminin objektif bir ağırlıklandırma yöntemi olduğunu ortaya koymaktadır. Çoğu parametre değerlendirmesinde ön plana çıkan 3 numaralı kavşak ağırlıklı değerlerde de ilk sırayı almıştır.

Bunun haricinde tüm kavşaklardaki parametre değerleri incelendiğinde saatlik / günlük / yıllık olarak gecikme değerinin ne derecede önemli olduğu görülmektedir. Buna göre saatlik olarak sadece dikkate alınan kavşaklar için geçerli olan gecikme süresi 4.146,53 saniyedir. Bu da saatte toplam 69,1 dakika değerine denk gelmektedir. Bu da demek oluyor ki kavşakları kullanan sürücülerin toplamı, belirtilen süre zarfında 69,1 dakika gecikme yaşamaktadır. Bu değerın Erzurum’da dikkate alınan 23 kavşakta hesaplandığı unutulmamalıdır. Kavşakları kullanan toplam sürücü sayısı 11.241 olarak ölçülmüştür. Bunun yanında cep telefonu kullanımı kaynaklı dikkat dağınıklığı yaşayan sürücülerin sayısı ise 1.730’dur. Tüm kavşaklar düşünüldüğünde cep telefonu kullanım ihlalinin ortalaması %15,39 olarak hesaplanmıştır. Değerlendirmeye alınan kavşaklarda ölçümler hafta içi zirve saatlerde gerçekleştirilmiştir. Yıl boyunca resmî tatiller hariç tutulduğunda iş günü sayısı olarak bakıldığında 2023 yılı içerisinde 253 iş günü bulunmaktadır. Yıl boyunca belirtilen süre dilimi aralığında aynı şekilde gecikmelerin gerçekleştiği düşünüldüğünde yıllık 291,37 saatin cep telefonu kullanımı kaynaklı gecikme nedeniyle efektif kullanılmadığı görülmektedir.

Ek olarak, ilgili değerler emisyon ve yakıt tüketimi açısından incelendiğinde saatlik olarak 1.471,74 (g) CO₂ emisyonu gerçekleşmektedir. Bu değerın sadece dikkate

alınan kavşaklarda geçerli olduğu unutulmamalıdır. Saatlik olarak 1,472 (kg) CO₂ emisyonu açığa çıkmaktadır. İş günü sayısı olarak düşünüldüğünde yıl boyunca 372,42 (kg) CO₂ emisyonu gerçekleşmektedir. Araştırmalara göre bir ağaç yıllık olarak 25 kg CO₂ absorbe edebilmektedir. Bu oran dikkate alındığında, değerlendirmeye alınan kavşaklarda cep telefonu kullanımı nedeniyle yaşanan gecikmeden kaynaklı CO₂ emisyonunu bir yılda yaklaşık 15 ağaç absorbe edebildiğini göstermektedir (Anonymous 2023c). Bunun yanında saatlik olarak 1,721 (g) NO_x emisyonu gerçekleşmektedir. Yıllık olarak düşünüldüğünde 0,44 (kg) NO_x emisyonu ortaya çıkmaktadır. Yakıt tüketimi incelendiğinde saatlik olarak 1,034 litre cep telefonu kaynaklı gereksiz yakıt tüketimi meydana gelmektedir. İş günü sayısı düşünüldüğünde 2023 yılında yaklaşık 261,6 litre gereksiz yakıt tüketimi gerçekleştiği söylenebilir.

Sürücülerin cep telefonu kullanımı kaynaklı yaşadıkları gecikme değerlerinin oldukça ciddi değerlerde olduğu görülmektedir. Unutulmamalıdır ki bu çalışmada Erzurum ilinde yer alan 23 kavşak için belirlenen saat diliminde ilgili değerler hesaplanmıştır. Gecikmeye bağlı olarak ortaya çıkan emisyon değerleri ve gereksiz yakıt tüketimi azımsanmayacak derecededir. Bunun yanında günün farklı saatlerinde ilgili parametre değerlerinin 0 olmadığı açıktır. Yani, cep telefonu kaynaklı sürücü dikkat dağınıklığından dolayı çevresel ve ekonomik olarak ciddi sorunlar bulunmaktadır. Sürücü dikkat dağınıklığının tespit edilmesi ve kısmi olarak engellenmesi bu değerler de iyileştirmeler sağlayacaktır. Sürücü dikkat dağınıklığının tespit edilmesi ve sürücülerin uyarılması ile çevre kirliliğinin ve fosil yakıt kullanımının azaltılması hedeflenmektedir. Tez çalışması kapsamında derin öğrenme yaklaşımının nesne tespit algoritmaları kullanılarak sürücü dikkat dağınıklığının tespit edilmesi ve sürücünün uyarılması amaçlanmaktadır.

4.3. Eylem Sınıflarının Belirlenmesi ve AHP Yöntemi ile Ağırlıklandırılması

Sürücü dikkat dağınıklığının tespit edilebilmesi amacıyla sürücülerin sergiledikleri eylem sınıflarının belirlenmesi gerekmektedir. Belirlenen sınıflara göre nesne tespiti algoritmaları eğitilecektir ve modelleme sonuçları elde edilecektir. Bu nedenle, sınıfların belirlenmesi model sonuçlarını doğrudan etkileyen bir işlem adıdır. Eylem sınıflarının belirlenmesi için literatürdeki çalışmalar incelenmiştir (Atchley et al.

2011; Huth et al. 2015; Zhang et al. 2019; Zhou et al. 2020; Bakhtari Aghdam et al. 2022; Hou et al. 2022; Buchholz et al. 2023; Cummings and Bauchwitz 2023; Hollósi et al. 2023; Shajari et al. 2023). Bunun yanında, günlük hayatta sıklıkla araç kullanan sürücülerden de görüşler alınmıştır. Bu doğrultuda çalışma kapsamında değerlendirilen eylem sınıfları Şekil 4.10'da sunulmuştur.



Şekil 4.10. Çalışma kapsamında değerlendirmeye alınan eylem sınıfları

Şekil 4.10 incelendiğinde çalışma kapsamında 23 adet eylem sınıfı dikkate alınmıştır. Literatürdeki çalışmalardan ve sürücülerden faydalanılarak oluşturulan bu eylem sınıflarının bazıları birbirini tekrarlayan niteliktedir. Ek olarak, 23 eylem sınıfının nesne tespit algoritmaları ile tespit edilebilmesi büyük bir zorluktur. Bu nedenle önemli eylem sınıflarının tespit edilebilmesi hedeflenmektedir. Eylem sınıflarının önem derecesinin belirlenmesi amacıyla ÇKKV yöntemlerinden AHP tekniği bu çalışmada kullanılmıştır.

AHP yönteminde dikkate alınan eylem sınıfları / parametrelerin performans değerleri mevcut olmadığı için kişisel yargılara ihtiyaç duyulmaktadır. AHP yönteminin uygulanması için ilk olarak karar matrisinin oluşturulması gerekmektedir. Bu amaç doğrultusunda karar verme takımı oluşturulmuştur. Karar matrisinde 2 akademisyen ve 4 sürücü yer almaktadır. Karar verme takımı üyelerinin oluşturduğu karar matrislerinin tutarlı olanlarının ortalaması alınarak AHP'nin diğer işlem adımlarına geçilmiştir. Temsili örnek olarak karar verme takımından bir üyenin oluşturduğu karar matrisi Çizelge 4.9'da sunulmaktadır.

Çizelge 4.9. AHP karar matrisi

Eylem Sınıfı	ES1	ES2	ES3	ES4	ES5	ES6	ES7	ES8	ES9	ES10	ES11	ES12
	Hava şartları	Yol Kusurları	Araç Kusurları	Diğer Araçlar	Yol Kenarı İşaretleri	Kaza Durumları	Klima Sistemi Ayanı	Yayalar	İçecek İçmek	Yemek Yemek	Sigara İçmek	Müzik Dinlemek
ES1	1,00	3,00	5,00	5,00	7,00	5,00	9,00	1,00	0,33	0,33	0,33	3,00
ES2	0,33	1,00	1,00	1,00	3,00	1,00	7,00	1,00	0,33	0,33	0,33	3,00
ES3	0,20	1,00	1,00	1,00	1,00	1,00	9,00	0,33	0,11	0,14	0,14	1,00
ES4	0,20	1,00	1,00	1,00	1,00	1,00	9,00	0,33	0,20	0,14	0,14	1,00
ES5	0,14	0,33	1,00	1,00	1,00	1,00	9,00	0,33	0,14	0,11	0,11	1,00
ES6	0,20	1,00	1,00	1,00	1,00	1,00	9,00	0,33	0,20	0,14	0,14	1,00
ES7	0,11	0,14	0,11	0,11	0,11	0,11	1,00	0,11	0,11	0,11	0,11	0,14
ES8	1,00	1,00	3,00	3,00	3,00	3,00	9,00	1,00	0,33	0,33	0,33	3,00
ES9	3,00	3,00	9,00	5,00	7,00	5,00	9,00	3,00	1,00	1,00	1,00	7,00
ES10	3,00	3,00	7,00	7,00	9,00	7,00	9,00	3,00	1,00	1,00	1,00	7,00
ES11	3,00	3,00	7,00	7,00	9,00	7,00	9,00	3,00	1,00	1,00	1,00	7,00
ES12	0,33	0,33	1,00	1,00	1,00	1,00	7,00	0,33	0,14	0,14	0,14	1,00

Çizelge 4.9. (Devam)

Eylem Sınıfı	ES12	ES13	ES14	ES15	ES16	ES17	ES18	ES19	ES20	ES21	ES22	ES23
	Müzik Dinlemek	Görünüş ile İlgilenme	Makyaj Yapmak	Telefon ile Konuşmak	Telefon ile Mesajlaşmak	Sosyal Medya Kullanımı	Resim Çekmek	Multi Medya ile İlgilenmek	Yolcularla Konuşmak	Yayalarla Konuşmak	Diğer Sürücülerle Konuşmak	Aracın Farklı Bölümlerine Erişim
ES1	3,00	0,33	0,33	0,14	0,11	0,11	0,11	0,14	0,33	3,00	3,00	0,14
ES2	3,00	0,33	0,33	0,11	0,11	0,11	0,11	0,14	0,20	3,00	3,00	0,11
ES3	1,00	0,20	0,20	0,11	0,11	0,11	0,11	0,14	0,20	1,00	1,00	0,11
ES4	1,00	0,20	0,33	0,11	0,11	0,11	0,11	0,14	0,20	1,00	1,00	0,11
ES5	1,00	0,14	0,20	0,11	0,11	0,11	0,11	0,11	0,14	1,00	1,00	0,11
ES6	1,00	0,20	0,33	0,11	0,11	0,11	0,11	0,14	0,20	1,00	1,00	0,11
ES7	0,14	0,11	0,11	0,11	0,11	0,11	0,11	0,11	0,11	0,11	0,14	0,11
ES8	3,00	0,33	0,33	0,14	0,11	0,14	0,14	0,20	0,33	3,00	3,00	0,14
ES9	7,00	1,00	3,00	0,33	0,33	0,33	0,33	1,00	1,00	5,00	7,00	0,33
ES10	7,00	1,00	3,00	1,00	0,33	0,33	0,33	1,00	1,00	7,00	9,00	0,33
ES11	7,00	1,00	3,00	1,00	0,33	0,33	0,33	1,00	1,00	7,00	9,00	0,33
ES12	1,00	0,14	0,20	0,11	0,11	0,11	0,11	0,14	0,20	1,00	1,00	0,11

Çizelge 4.9. (Devam)

Eylem Sınıfı	ES1	ES2	ES3	ES4	ES5	ES6	ES7	ES8	ES9	ES10	ES11	ES12
	Hava şartları	Yol Kusurları	Araç Kusurları	Diğer Araçlar	Yol Kenarı İşaretleri	Kaza Durumları	Klima Sistemi Ayarı	Yayalar	İçecek İçmek	Yemek Yemek	Sigara İçmek	Müzik Dinlemek
ES13	3,00	3,00	5,00	5,00	7,00	5,00	9,00	3,00	1,00	1,00	1,00	7,00
ES14	3,00	3,00	5,00	3,00	5,00	3,00	9,00	3,00	0,33	0,33	0,33	5,00
ES15	7,00	9,00	9,00	9,00	9,00	9,00	9,00	7,00	3,00	1,00	1,00	9,00
ES16	9,00	9,00	9,00	9,00	9,00	9,00	9,00	9,00	3,00	3,00	3,00	9,00
ES17	9,00	9,00	9,00	9,00	9,00	9,00	9,00	7,00	3,00	3,00	3,00	9,00
ES18	9,00	9,00	9,00	9,00	9,00	9,00	9,00	7,00	3,00	3,00	3,00	9,00
ES19	7,00	7,00	7,00	7,00	9,00	7,00	9,00	5,00	1,00	1,00	1,00	7,00
ES20	3,00	5,00	5,00	5,00	7,00	5,00	0,11	3,00	1,00	1,00	1,00	5,00
ES21	0,33	0,33	1,00	1,00	1,00	1,00	9,00	0,33	0,20	0,14	0,14	1,00
ES22	0,33	0,33	1,00	1,00	1,00	1,00	7,00	0,33	0,14	0,11	0,11	1,00
ES23	7,00	9,00	9,00	9,00	9,00	9,00	9,00	7,00	3,00	3,00	3,00	9,00

Çizelge 4.9. (Devam)

Eylem Sınıfı	ES13	ES14	ES15	ES16	ES17	ES18	ES19	ES20	ES21	ES22	ES23
	Görünüş ile İlgilenme	Makyaj Yapmak	Telefon ile Konuşmak	Telefon ile Mesajlaşmak	Sosyal Medya Kullanım	Resim Çekmek	Multi Medya ile İlgilenmek	Yolcularla Konuşmak	Yayalarla Konuşmak	Diğer Sürücülerle Konuşmak	Aracın Farklı Bölümlerine Erişim
ES13	1,00	1,00	0,33	0,33	0,33	0,33	1,00	1,00	7,00	9,00	0,33
ES14	1,00	1,00	0,33	0,20	0,33	0,33	0,33	0,33	5,00	5,00	0,33
ES15	3,00	3,00	1,00	0,33	1,00	1,00	1,00	3,00	9,00	9,00	1,00
ES16	3,00	5,00	3,00	1,00	1,00	1,00	3,00	3,00	9,00	9,00	3,00
ES17	3,00	3,00	1,00	1,00	1,00	1,00	1,00	3,00	9,00	9,00	1,00
ES18	3,00	3,00	1,00	1,00	1,00	1,00	1,00	3,00	9,00	9,00	1,00
ES19	1,00	3,00	1,00	0,33	1,00	1,00	1,00	1,00	7,00	9,00	1,00
ES20	1,00	3,00	0,33	0,33	0,33	0,33	1,00	1,00	7,00	9,00	0,33
ES21	0,14	0,20	0,11	0,11	0,11	0,11	0,14	0,14	1,00	1,00	0,11
ES22	0,11	0,20	0,11	0,11	0,11	0,11	0,11	0,11	1,00	1,00	0,11
ES23	3,00	3,00	1,00	0,33	1,00	1,00	1,00	3,00	9,00	9,00	1,00

Karar verme takımı tarafından oluşturulan karar matrislerinin tutarlılık oranlarının incelenmesi amacıyla Denklem 3.9. ve 3.10. kullanılmıştır. Denklem 3.10.'da belirtilen RI değerinin hesaplaması için Saaty'nin önerdiği skala kullanılmaktadır. Ancak, Saaty'nin önerdiği skalada değerlendirmeye alınan alternatif sayısı 15 ile sınırlandırılmıştır. Bu tez çalışmasında 23 adet eylem sınıfının değerlendirilmesi için literatürde kullanılan ve Denklem 4.1.'de verilen ifade kullanılmaktadır (Alonso and Lamata 2006).

$$RI(n) = 0,00149n^3 - 0,05121n^2 + 0,59150n - 0,79124 \quad (4.1)$$

Denklem 4.1.'de yer alan n parametresi, değerlendirmeye alınan eylem sınıflarının sayısını belirtmektedir. Karar matrisinin geçerli olması için CR değerinin 0,1'den küçük olması gerekmektedir. Bu doğrultuda, tüm karar matrislerinin CR değerleri hesaplanmıştır. CR değeri 0,1'den küçük olan karar matrisleri değerlendirmeye alınmıştır ve matris indislerinin ortalaması alınarak nihai karar matrisi oluşturulmuştur. Dikkate alınan karar matrislerinin tutarlılık oranının ortalaması 0,084 olarak hesaplanmıştır. AHP yönteminde karar matrisi oluşturulduktan sonra normalizasyon işlemi gerçekleştirilmektedir. Normalizasyon işlemi için doğrusal normalizasyon yaklaşımı tercih edilmiştir. Çizelge 4.10'da temsili normalize karar matrisi verilmektedir.

Çizelge 4.10. Normalize karar matrisi

	ES1	ES2	ES3	ES4	ES5	ES6	ES7	ES8	ES9	ES10	ES11	ES12
Eylem Sınıfı	Hava şartları	Yol Kusurları	Araç Kusurları	Diğer Araçlar	Yol Kenarı İşaretleri	Kaza Durumları	Klima Sistemi Ayarı	Yayalar	İçecek İçmek	Yemek Yemek	Sigara İçmek	Müzik Dinlemek
ES1	0,014	0,037	0,047	0,050	0,059	0,050	0,049	0,015	0,014	0,016	0,016	0,028
ES2	0,005	0,012	0,009	0,010	0,025	0,010	0,038	0,015	0,014	0,016	0,016	0,028
ES3	0,003	0,012	0,009	0,010	0,008	0,010	0,049	0,005	0,005	0,007	0,007	0,009
ES4	0,003	0,012	0,009	0,010	0,008	0,010	0,049	0,005	0,008	0,007	0,007	0,009
ES5	0,002	0,004	0,009	0,010	0,008	0,010	0,049	0,005	0,006	0,005	0,005	0,009
ES6	0,003	0,012	0,009	0,010	0,008	0,010	0,049	0,005	0,008	0,007	0,007	0,009
ES7	0,002	0,002	0,001	0,001	0,001	0,001	0,005	0,002	0,005	0,005	0,005	0,001
ES8	0,014	0,012	0,028	0,030	0,025	0,030	0,049	0,015	0,014	0,016	0,016	0,028
ES9	0,043	0,037	0,085	0,050	0,059	0,050	0,049	0,046	0,042	0,047	0,047	0,066
ES10	0,043	0,037	0,066	0,070	0,076	0,070	0,049	0,046	0,042	0,047	0,047	0,066
ES11	0,043	0,037	0,066	0,070	0,076	0,070	0,049	0,046	0,042	0,047	0,047	0,066
ES12	0,005	0,004	0,009	0,010	0,008	0,010	0,038	0,005	0,006	0,007	0,007	0,009

Çizelge 4.10. (Devam)

Eylem Sınıfı	ES12	ES13	ES14	ES15	ES16	ES17	ES18	ES19	ES20	ES21	ES22	ES23
	Müzik Dinlemek	Görünüş ile İlgilenme	Makyaj Yapmak	Telefon ile Konuşmak	Telefon ile Mesajlaşmak	Sosyal Medya Kullanımı	Resim Çekmek	Multi Medya ile İlgilenmek	Yolcularla Konuşmak	Yayalarla Konuşmak	Diğer Sürücülerle Konuşmak	Aracın Farklı Bölümlerine Erişim
ES1	0,028	0,014	0,009	0,011	0,016	0,012	0,012	0,010	0,010	0,028	0,025	0,013
ES2	0,028	0,014	0,009	0,009	0,016	0,012	0,012	0,010	0,006	0,028	0,025	0,010
ES3	0,009	0,008	0,005	0,009	0,016	0,012	0,012	0,010	0,006	0,009	0,008	0,010
ES4	0,009	0,008	0,009	0,009	0,016	0,012	0,012	0,010	0,006	0,009	0,008	0,010
ES5	0,009	0,006	0,005	0,009	0,016	0,012	0,012	0,007	0,004	0,009	0,008	0,010
ES6	0,009	0,008	0,009	0,009	0,016	0,012	0,012	0,010	0,006	0,009	0,008	0,010
ES7	0,001	0,005	0,003	0,009	0,016	0,012	0,012	0,007	0,278	0,001	0,001	0,010
ES8	0,028	0,014	0,009	0,011	0,016	0,015	0,015	0,013	0,010	0,028	0,025	0,013
ES9	0,066	0,041	0,082	0,026	0,047	0,036	0,036	0,067	0,031	0,047	0,059	0,030
ES10	0,066	0,041	0,082	0,079	0,047	0,036	0,036	0,067	0,031	0,066	0,076	0,030
ES11	0,066	0,041	0,082	0,079	0,047	0,036	0,036	0,067	0,031	0,066	0,076	0,030
ES12	0,009	0,006	0,005	0,009	0,016	0,012	0,012	0,010	0,006	0,009	0,008	0,010

Çizelge 4.10. (Devam)

Eylem Sınıfı	ES1	ES2	ES3	ES4	ES5	ES6	ES7	ES8	ES9	ES10	ES11	ES12
	Hava Şartları	Yol Kusurları	Araç Kusurları	Diğer Araçlar	Yol Kenarı İşaretleri	Kaza Durumları ¹	Klima Sistemi Ayarı	Yayalar	İçecek İçmek	Yemek Yemek	Sigara İçmek	Müzik Dinlemek
ES12	0,005	0,004	0,009	0,010	0,008	0,010	0,038	0,005	0,006	0,007	0,007	0,009
ES13	0,043	0,037	0,047	0,050	0,059	0,050	0,049	0,046	0,042	0,047	0,047	0,066
ES14	0,043	0,037	0,047	0,030	0,042	0,030	0,049	0,046	0,014	0,016	0,016	0,047
ES15	0,100	0,110	0,085	0,090	0,076	0,090	0,049	0,107	0,127	0,047	0,047	0,085
ES16	0,128	0,110	0,085	0,090	0,076	0,090	0,049	0,138	0,127	0,140	0,140	0,085
ES17	0,128	0,110	0,085	0,090	0,076	0,090	0,049	0,107	0,127	0,140	0,140	0,085
ES18	0,128	0,110	0,085	0,090	0,076	0,090	0,049	0,107	0,127	0,140	0,140	0,085
ES19	0,100	0,086	0,066	0,070	0,076	0,070	0,049	0,076	0,042	0,047	0,047	0,066
ES20	0,043	0,061	0,047	0,050	0,059	0,050	0,001	0,046	0,042	0,047	0,047	0,047
ES21	0,005	0,004	0,009	0,010	0,008	0,010	0,049	0,005	0,008	0,007	0,007	0,009
ES22	0,005	0,004	0,009	0,010	0,008	0,010	0,038	0,005	0,006	0,005	0,005	0,009
ES23	0,100	0,110	0,085	0,090	0,076	0,090	0,049	0,107	0,127	0,140	0,140	0,085

Çizelge 4.10. (Devam)

Eylem Sınıfı	ES12	ES13	ES14	ES15	ES16	ES17	ES18	ES19	ES20	ES21	ES22	ES23
	Müzik Dinlemek	Görüntü ile ilgilenme	Makyaj Yapmak	Telefon ile Konuşmak	Telefon ile Mesajlaşmak	Sosyal Medya Kullanımı	Resim Çekmek	Multi Medya ile ilgilenmek	Yolcularla Konuşmak	Yayalarla Konuşmak	Diğer Sürücülerle Konuşmak	Aracın Farklı Bölümlerine Erişim
ES12	0,009	0,006	0,005	0,009	0,016	0,012	0,012	0,010	0,006	0,009	0,008	0,010
ES13	0,066	0,041	0,027	0,026	0,047	0,036	0,036	0,067	0,031	0,066	0,076	0,030
ES14	0,047	0,041	0,027	0,026	0,028	0,036	0,036	0,022	0,010	0,047	0,042	0,030
ES15	0,085	0,124	0,082	0,079	0,047	0,108	0,108	0,067	0,093	0,085	0,076	0,089
ES16	0,085	0,124	0,136	0,238	0,141	0,108	0,108	0,202	0,093	0,085	0,076	0,266
ES17	0,085	0,124	0,082	0,079	0,141	0,108	0,108	0,067	0,093	0,085	0,076	0,089
ES18	0,085	0,124	0,082	0,079	0,141	0,108	0,108	0,067	0,093	0,085	0,076	0,089
ES19	0,066	0,041	0,082	0,079	0,047	0,108	0,108	0,067	0,031	0,066	0,076	0,089
ES20	0,047	0,041	0,082	0,026	0,047	0,036	0,036	0,067	0,031	0,066	0,076	0,030
ES21	0,009	0,006	0,005	0,009	0,016	0,012	0,012	0,010	0,004	0,009	0,008	0,010
ES22	0,009	0,005	0,005	0,009	0,016	0,012	0,012	0,007	0,003	0,009	0,008	0,010
ES23	0,085	0,124	0,082	0,079	0,047	0,108	0,108	0,067	0,093	0,085	0,076	0,089

Normalize karar matrisleri oluşturulduktan sonra eylem sınıflarının öncelik değerlerinin tespit edilmesi gerekmektedir. Denklem 4.2. formülasyonu kullanılarak eylem sınıflarının ağırlıkları hesaplanmıştır. Hesaplanan ağırlık değerleri Çizelge 4.11’de verilmiştir.

$$w_i = \left(\frac{1}{n}\right) \sum_{j=1}^n a'_{ij} \quad i, j = 1, 2, \dots, n \quad (4.2.)$$

Çizelge 4.11. Eylem sınıflarının ağırlıkları

Eylem Sınıfı	ES1	ES2	ES3	ES4	ES5	ES6	ES7	ES8
Ağırlık Değeri	0,0182	0,0115	0,0096	0,0106	0,0086	0,0106	0,0010	0,0163
Eylem Sınıfı	ES9	ES10	ES11	ES12	ES13	ES14	ES15	ES16
Ağırlık Değeri	0,0585	0,0605	0,0681	0,0086	0,0576	0,0393	0,0873	0,1142
Eylem Sınıfı	ES17	ES18	ES19	ES20	ES21	ES22	ES23	
Ağırlık Değeri	0,0979	0,0969	0,0701	0,0557	0,0096	0,0086	0,0806	

Çizelge 4.11 incelendiğinde en yüksek eylem sınıfı ağırlığı ES16 olduğu görülmektedir. Eylem sınıfı ağırlıklarının büyükten küçüğe doğru incelenmesi açısından Çizelge 4.12 sunulmuştur.

Çizelge 4.12. Eylem sınıflarının ağırlık değerine göre sırası

Eylem Sınıfı	ES16	ES17	ES18	ES15	ES23	ES19	ES11	ES10
Ağırlık Değeri	0,1142	0,0979	0,0969	0,0873	0,0806	0,0701	0,0681	0,0605
Eylem Sınıfı	ES9	ES13	ES20	ES14	ES1	ES8	ES2	ES4
Ağırlık Değeri	0,0585	0,0576	0,0557	0,0393	0,0182	0,0163	0,0115	0,0106
Eylem Sınıfı	ES6	ES3	ES21	ES5	ES12	ES22	ES7	
Ağırlık Değeri	0,0106	0,0096	0,0096	0,0086	0,0086	0,0086	0,001	

Çizelge 4.12 incelendiğinde eylem sınıfı ağırlık değerlerinde farklılıklar bulunmaktadır. Örneğin ES14, ES1’e göre iki kattan daha fazla önemlidir. ES14 ile ES20 arasında da önemli bir fark bulunmaktadır. Ağırlık değerleri arasında önemli farklar bulunan eylem sınıfları değerlendirmeye alınmamıştır. Daha az önemli olan eylem sınıflarının değerlendirme kapsamına alınmaması, oluşturulan modellerde hem hız hem

de doğruluk açısından olumlu katkı sağlamaktadır. Çizelge 4.12 yer alan ES16, ES17, ES18, ES15, ES23, ES19, ES11, ES10, ES9, ES13, ES20 ve ES14 çalışma kapsamında değerlendirmeye alınmıştır. Değerlendirmeye alınan eylem sınıflarının içeriği incelendiğinde bazılarının benzer fiziksel eylemlere dayandığı görülmektedir. Örnek vermek gerekirse ES9, ES10 ve ES11 eylem sınıfları çok benzer fiziksel eylemleri içermektedir. Ek olarak, ES16 ve ES17 cep telefonu kullanımında aynı fiziksel eylemlere sahiptir. Bu nedenlerden dolayı benzer sınıfların birleştirilmesi nesne tespit algoritmalarının işleyiş süreci açısından faydalı olmaktadır.

Yukarıda bahsedilen nedenlerden dolayı ilk olarak ES16, ES17 ve ES18 tek bir eylem sınıfı olarak değerlendirilmiştir. ES11, ES10 ve ES9 eylem sınıfları da tek bir eylem grubu olarak düşünülmüştür. ES13 ve ES14 eylem sınıfları da tek bir eylem sınıfı olarak ele alınmıştır. Tüm bu anlatılanlara ek olarak nesne tespit algoritmalarının kişilerin hareketlerini ve tespit edilen durumun farklılığını ortaya koyabilmek amacıyla fiziksel eylem çeşitliliği de ortaya konmuştur. Bu duruma örnek vermek gerekirse, ES15 – Telefon ile Konuşmak eylem sınıfı için sürücünün sağ veya sol eli ile bu eylemi gerçekleştirmesi tez kapsamında değerlendirmeye alınmıştır. Çizelge 4.13’de çalışma kapsamında nesne tespit algoritmalarında değerlendirilen eylem sınıfları sunulmuştur.

Çizelge 4.13. Gruplandırılan eylem sınıfları ve nesne tespit algoritmasına dahil edilen eylem sınıfları.


Tez Çalışması Kapsamında Değerlendirilen Sürücü Dikkat Dağılımlığı Eylem Sınıfları	Nesne Tespit Algoritması İçin Dikkate Alınan Sürücü Dikkat Dağılımlığı Eylem Sınıfı
-	Normal Sürüş
Telefon ile Mesajlaşmak	Sağ El- Telefon ile Mesajlaşmak / İlgilenmek Sol El- Telefon ile Mesajlaşmak / İlgilenmek
Sosyal Medya Kullanımı	
Resim Çekmek	
Telefon ile Konuşmak	Sağ El- Telefon ile Konuşmak
	Sol El- Telefon ile Konuşmak
Multi Medya ile İlgilenmek	Multi Medya ile İlgilenmek
İçecek İçmek	İçmek / Yemek
Yemek Yemek	
Sigara İçmek	
Görünüş ile İlgilenme	Görünüş ile İlgilenme
Aracın Farklı Bölümlerine Erişim	Aracın Farklı Bölümlerine Erişim
Yolcularla Konuşmak	Yolcularla Konuşmak

Çizelge 4.13 incelendiğinde sürücü dikkat dağınıklığının tespiti için nesne tespit algoritmalarına dahil edilmek üzere 10 eylem sınıfı belirlenmiştir. Eylem sınıfları belirlenirken önem dereceleri ve fiziksel eylem hareketliliğinin çeşitliliği dikkate alınmıştır.

4.4. Sürücü Dikkat Dağınıklığı Verilerinin Hazırlanması


Sürücü dikkat dağınıklığının tespit edilmesi amacıyla 5 farklı ülkeden onlarca sürücü görüntüleri kullanılarak veri seti oluşturulmuştur. Veri seti oluşturulurken farklı kamera açılarını içeren sürücü görüntülerinin çalışmaya dahil edilmesine dikkat edilmiştir. Farklı ülkelere sürücü görüntülerinin çalışmaya dahil edilmesi ile sürücü dikkat dağınıklığı tespiti için oluşturulan modelin farklı sürüş karakteristiklerine uyumlu hale gelmesi amaçlanmaktadır. Dikkat dağınıklığının tespit edilmesi için ilk olarak veri setindeki görüntülerin düzenleme işleminin yapılması gerekmektedir. Bu doğrultuda görüntüler içinde eylem sınıflarının belirsiz olması, görüntü piksel bozuklukları, verimsiz kamera açısı vb. sebeplerden dolayı kalitesiz ve yetersiz olarak değerlendirilen veriler veri setinden çıkarılmıştır. Sürücü dikkat dağınıklığı tespiti için kullanılacak modele girdi görüntüleri 640 x 640 boyutunda olacağı için tüm görüntüler bu boyuta çevrilmiştir.

Nihai durumda elde edilen veri setindeki görüntülerin belirlenen eylem sınıflarına göre etiketleme işlemlerinin yürütülmesi gerekmektedir. Bunun için çevrimiçi ve çevrimdışı hizmet sunan uygulamalar kullanılmıştır. Tez çalışması kapsamında MakeSense.ai, Roboflow.com ve LabelImg uygulamalarından faydalanılmıştır. Etiketleme işleminin amacı görüntü içerisinde yer alan eylem sınıfının koordinatlarının ve hangi eylem sınıfına ait olduğunu belirlemektir. Etiketleme işlemi sonrasında ilgili görüntüye ait bir adet “label” dosyası oluşturulmaktadır ve bu dosyaya etiketlenen alanın koordinatları ve eylem sınıfının numarası yazılmaktadır. Şekil 4.11’de çevrimiçi ve çevrimdışı programlarda yapılan etiketleme işlemine ait temsili bir görsel sunulmuştur.



Şekil 4.11. Verilerin etiketlenmesinde kullanılan uygulamaların temsili görseli


Şekil 4.11’de verilen temsili görsel benzerliğinde veri setindeki tüm verilere aynı işlem teker teker yapılmıştır. Bu tez çalışması kapsamında 13.332 görüntü kullanılmıştır ve bu görüntüler yukarıda da belirtildiği gibi tek tek etiketlenmiştir. Şekil 4.12’de veri setinin eğitim, doğrulama ve test dosyalarına ayrılmış halinin gösterimi bulunmaktadır.




Şekil 4.12. Veri setinin kategorize edilmiş durumu

Bu kadar geniş veri setinin kullanılmasının amacı oluşturulan modelin farklı sürücü karakteristikleri ve fiziksel eylemler açısından duyarlı olmasını sağlamaktır. Bu sayede, modelin homojenliğinin sağlanması ve gerek duyulması halinde ince ayarların ve hassasiyetinin ayarlanması mümkün hale gelmiştir. Ayrıca, farklı kamera açıları kullanılmış olmasına rağmen veri setindeki çeşitliliğin artırılması amacıyla veri büyütme işlemi yapılmıştır. Şekil 4.13’de verilere uygulanabilecek veri büyütme teknikleri sunulmuştur.

Görüntü Seviyesini Büyütme Teknikleri



Sınırlayıcı Kutu Büyütme Teknikleri




Şekil 4.13. Veri büyütme teknikleri

Şekil 4.13 belirtilen veri büyütme yöntemlerinden “Rotation” – Döndürme, “Shear” – Kayma ve “Noise” – Gürültü teknikleri tez çalışması kapsamında uygulanmıştır. Böylece, veri seti genişletilerek yukarıda bahsedildiği üzere modelin homojenliği ve duyarlılığı artırılmıştır. Veri etiketleme ve veri büyütme işlemleri uygulandıktan sonra görüntülere ilişkin “label” dosyaları elde edilmiştir ve temsili örnek görseli Şekil 4.14’de verilmiştir.

```
0 0.5050198397999504 0.4687672460456673 0.9896875357603634 0.9375344920913345
1 0.5030542373569571 0.4623030345818206 0.9905872501476584 0.9246060691636412
2 0.4785327759324648 0.5109673587695932 0.9192410685760425 0.9765925113574951
3 0.4671872191876947 0.4991468256718264 0.933974744852421 0.9982936513436528
4 0.49294076804868014 0.4988149292648213 0.9580665260229869 0.9280872094604942
5 0.5198539338694632 0.49951976931455294 0.9602921322610735 0.9685442723174834
6 0.5024814038559405 0.5000858622284844 0.9950371922881189 0.999473078032542
7 0.5278710800721181 0.52265625 0.9442578398557637 0.9546875
8 0.5040423615075627 0.5064330135441526 0.983466279492157 0.9871339729116947
9 0.5046668724067594 0.49975468883275004 0.9906662551864811 0.9995093776655001
```

Şekil 4.14. Etiketleme sonucu elde edilen “label” dosyalarının görseli

Görüntüler ve etiket dosyaları hazırlandıktan sonra bunların klasöre aktarılma / dosyalama işlemi yürütülmektedir. Uygulanılan modele göre klasör / dosyalama süreçleri farklı olabilmektedir. Eğitim, doğrulama ve test için farklı klasörler oluşturularak modelin verileri sırasıyla çekmesi sağlanmaktadır. Bu tez çalışmasında oluşturulan modellerden birine ait dosyalama düzeni Şekil 4.15’de yer almaktadır.



Şekil 4.15. Verilerin dosyalama işlemi için temsili gösterim

4.5. Sürücü Dikkat Dağınıklığının Tespit Edilmesi

Sürücü dikkat dağınıklığının tespit edilmesi için tüm veriler, etiketleme ve dosyalar hazırlandıktan sonra modelin eğitilmesi adımları gerçekleştirilmektedir. Literatürde en çok kullanılan algoritma olarak YOLOv5 ön plana çıkmaktadır. Ancak, karelerin yakalanması, hızın homojen bir şekilde devam etmemesi ve geliştirilen diğer YOLO modellerine göre oldukça yavaş kalmasından dolayı YOLOv5 algoritması artık geçerliliğini kaybetmek üzeredir. Bu nedenle artık YOLOv5 algoritmasının farklı yaklaşımlar kullanılarak çeşitli varyasyonları geliştirilmiştir (Guo and Zhang 2022; Sun et al. 2022; Liu et al. 2023). Bunun yanında literatürde yine sıklıkla kullanılan Faster R-CNN algoritması için yakındaki nesnelerden ziyade uzaktaki görüntülerin tespitinde kullanılması literatürdeki çalışmalarda tavsiye edilmiştir. Ayrıca, yakalanan görüntü sayısı ile hata hesaplama yöntemleri arasında tutarsızlıktan dolayı sürdürülebilir bir algoritma olmadığı çalışmalarda ifade edilmektedir. Ancak, uzaktaki nesnelerin

tespitinde halen daha kullanılmaktadır (Huang et al. 2023; Li et al. 2023; Weihong et al. 2023). YOLOv7 algoritması geliştirildiğinde hız açısından tüm nesne tespit yöntemleri arasında en hızlı algoritma olarak tanıtılmıştır. Hız açısından oldukça iddialı olan algoritmanın doğruluk, karelerin yakalanması ve yanlış tahminlerde bulunması nedeniyle algoritmanın incelendiği çalışmalarda tutarlı ve sürdürülebilir olmadığı ifade edilmiştir. Ancak, YOLOv7, daha eski YOLO versiyonlarına göre daha etkili sonuç sağladığı görülmektedir (Patel et al. 2022; Wu et al. 2022; Zhou et al. 2023). YOLOv8, YOLO mimarisinin en yeni üyesi olarak geliştirilmiştir. Yapılan çalışmalarda gerek hız gerek doğruluk anlamında diğer nesne tespit yöntemlerinden iyi olduğu ispatlanmıştır. Bunun yanında karelerin yakalanması ve tahminlerdeki yüksek doğruluk ile mevcut durumda literatürde sıklıkla kullanılmaktadır (Karna et al. 2023; Sharma et al. 2023; Soylu and Soylu 2023). Bu tez çalışması kapsamında YOLOv7 ve YOLOv8 algoritmaları kullanılmıştır. Böylece hem algoritmaların karşılaştırılması yapılmıştır hem de veri seti iki farklı ve en son geliştirilen algoritma ile eğitilmiştir. Bunun için Google sunucusunun sunduğu Colab uygulaması kullanılmaktadır. Google Colab uygulamasında kullanıcılara belirli sınırlar dahilinde Grafik İşlem Birimi (GPU) ücretli veya ücretsiz şekilde sunulmaktadır. Google Colab'da çalışma zamanı türü Python 3 tercih edilmektedir. Modelin eğitilmesi için öncelikle çalışma zamanı ve kullanılacak GPU tipi seçilmektedir. Ücretli veya ücretsiz olarak sunulan GPU destek ünitelerinden Tesla T4 GPU bu tez çalışması kapsamında kullanılmıştır. Şekil 4.16'da çalışma kapsamında GPU bellek kullanımı ve GPU kullanım oranı verilmiştir.



Şekil 4.16. YOLOv8 modeli süresince GPU kullanımı

Kullanılacak GPU tipi ve çalışma ortamı seçildikten sonra çalışma dosyalarının yer aldığı Google Drive bağlantısı modele tanıtılmaktadır. Böylece, Google Drive uygulamasına aktarılan tüm veriler artık modele aktarılabilir. Google Drive uygulama bağlantısının tanıtılması için aşağıdaki kod birimi yazılmaktadır.

```
from google.colab import drive
drive.mount('/content/drive')
```

Uygulama bağlantısı yapıldıktan sonra kullanılacak modelin Colab ortamına aktarılması gerekmektedir. YOLOv8 modelinin Colab ortamına aktarılması, gerekli eksikliklerin ve düzenlemelerin yapılması için aşağıda yer alan kod birimi yazılmaktadır.

```
%pip install ultralytics
import ultralytics
ultralytics.checks()
!git clone https://github.com/ultralytics/ultralytics.git
!pip install -r requirements.txt
```

Kod biriminin Google Colab uygulamasında yazılmasının ardından modelin eğitim başlangıcında kullanılan ağırlık değerleri modele tanıtılmıştır. YOLOv7 ve YOLOv8 için geliştiriciler tarafından birçok ağırlık parametre dosyası oluşturulmuştur. Test edilen ağırlık parametre dosyaları boyut, doğruluk oranı, hız, parametre sayısı, saniyedeki kayan nokta işlemleri (FLOPs) sayısı açısından değerlendirilmektedir. Çizelge 4.14’de YOLOv8 için geliştirilen ağırlık dosyalarının karşılaştırılması sunulmaktadır.

Çizelge 4.14. YOLOv8 için geliştirilen ağırlık dosyaları

Model	Boyut (Piksel)	Doğruluk (mAP) 50-95	Hız CPU ONNX (ms)	Hız A100 TensorRT (ms)	Parametre Sayısı (M)	FLOPs (B)
YOLOv8n	640	37,3	80,4	0,99	3,2	8,7
YOLOv8s	640	44,9	128,4	1,20	11,2	28,6
YOLOv8m	640	50,2	234,7	1,83	25,9	78,9
YOLOv8l	640	52,9	375,2	2,39	43,7	165,2
YOLOv8x	640	53,9	479,1	3,53	68,2	257,8


Bu tez çalışması kapsamında veri setine uygun olması nedeniyle YOLOv8n ağırlık dosyası kullanılmıştır. Veri setinin geniş olması nedeniyle daha yavaş olan ağırlık dosyaları tercih edilmemiştir. Doğruluk oranındaki dezavantaj veri setinde yer alan görüntülerin fazlalığıyla giderilmiştir. Ağırlık dosyası belirlendikten sonra modelin eğitim aşamasına geçilmektedir. Aşağıda yer alan kod birimi aracılığıyla eğitim başlatılmaktadır.

```
!yolo train model=yolov8n.pt
data=/content/drive/MyDrive/Tez_Son/data.yaml epochs=200 imgsz=640
```

Model eğitilirken modele tanıtılan iki önemli değer bulunmaktadır. Bunlar “batch size” ve “epoch” olarak nitelendirilmektedir. Parti büyüklüğü olarak ifade edilen “batch size”, dahili model parametrelerini güncellemeden önce üzerinde çalışılan örnek sayısını tanımlayan bir hiperparametredir. Bir gruba, bir veya daha fazla örnek üzerinde yinelenen ve tahminler yapan bir döngü olarak düşünülebilir. Diğer bir ifade ile tek bir grupta mevcut olan eğitim örneklerinin toplam sayısı olarak ifade edilebilir. Tüm veri setinin

modele aktarılması mevcut algoritmalarda imkansızdır. “Batch size” yaklaşımı ile veri seti belirli gruplara bölünerek modele aktarılabilmektedir. “Batch size” için genellikle tercih edilen değerler 4, 8, 16, 32, 64 ve 128’dir. Bu değerlerin model eğitimi yapılacak veri sayısına uyumlu olması gerekmektedir. Bu çalışmada “batch size” değeri 16 alınmıştır.

Döngü sayısı olarak ifade edilen “epoch” değeri, öğrenme algoritmasının eğitim veri kümesi boyunca kaç kez çalışacağını tanımlayan bir hiperparametredir. “Epoch” değerinin 1 olması, bütün veri kümesinin model üzerinden yalnızca bir kez ileri ve geri ilerlemesidir. Model eğitimi tek bir döngüde tamamlanamayacağından “epoch” değeri 50, 100, 200, 400 veya daha fazla alınmaktadır. “Epoch” değerinin optimum değerlerde tutulmaması nedeniyle yetersiz uyum (underfitting) veya aşırı uyum (overfitting) durumları ortaya çıkmaktadır. Şekil 4.17’de bu durumları gösteren görsel sunulmaktadır.



Şekil 4.17. “Epoch” değerinin değişimine göre modelin eğitim durumları

Veri setinde yetersiz uyum ve aşırı uyum durumlarından kaçınmak amacıyla model farklı “epoch” değerleriyle çok defa eğitilmiştir. Bu eğitimlerin bazılarında aşırı uyum veya yetersiz uyum durumları meydana gelmiştir. Denemeler neticesinde veri setine en uygun “epoch” değerinin 200 olduğuna karar verilmiştir. Bu yüzden eğitimler 200 değeri üzerinden yapılmıştır.

Modelin eğitilmesi için yapılması gereken bir adım ise veri dosyalarının ve etiketleri içeren dosyanın düzenlenmesidir. “data.yaml” olarak ifade edilen dosyanın içerisindeki görüntülerin dosya adresi eğitim, doğrulama ve test olarak ayrı ayrı verilmesi gerekmektedir. Bunun haricinde, veri setindeki eylem sınıf sayısının ve sıralamasının

verilmesi gerekmektedir. Tez çalışmasında oluşturulan “data.yaml.” dosyası Şekil 4.18’de verilmiştir.


```
train: /content/drive/MyDrive/Doktora_Tez/YOLOv8/images/train
val: /content/drive/MyDrive/Doktora_Tez/YOLOv8/images/val
test: /content/drive/MyDrive/Doktora_Tez/YOLOv8/images/test

nc: 10
names: ['Drinking', 'HairandMakeup', 'LeftHandTalking', 'LeftHandText', 'NormalDriving', 'OperatingMedia', 'ReachingBehind', 'RightHandTalking', 'RightHandText', 'TalkingPassenger']
```

Şekil 4.18. Veri seti için oluşturulan “data.yaml” dosyası


Model eğitilirken eğitim yapılan veri setinin doğru bir şekilde belirtilmesi oldukça önemlidir. Aksi takdirde, model eğitime başlayamaz veya yanlış veri seti kullanarak eğitime başlamaktadır. Bunun yanında, etiketlenen dosyaların etiket sınıfının doğru olması modelin performans çıktılarını doğrudan etkilemektedir. Çünkü, yanlış bir etiket sınıfı ile etiketlenen görüntü, model için tutarsızlık oluşturmaktadır. Bunun önüne geçmek için görüntü etiketleme işlem süreçlerini adım adım yürütmek gerekmektedir. Etiket işlemi yapılırken ilk etiket sınıfının değerinin “0” olması gerektiğine de dikkat edilmelidir.

Yukarıda bahsedilen işlem adımları yapıldıktan sonra artık modelin eğitim aşamasına geçilmektedir. Modelin eğitilmesi için YOLOv7’de “train.py” dosyası çalıştırılırken YOLOv8’de “setup.py” dosyası çalıştırılmaktadır. Bu tez çalışması kapsamında modelin eğitilmesi için geçen süre YOLOv7 için yaklaşık 10 saat iken YOLOv8 için 7 saattir. Bu süre zarfında modelde oluşabilecek hatalardan sakınmak için modelin hesapladığı son ağırlık değerleri sürekli kaydedilmiştir. Çalışmada kullanılan veri setine ilişkin YOLOv7 ve YOLOv8 çıktı sonuçları Şekil 4.18’de sunulmaktadır.



Şekil 4.19. Çalışmada kullanılan veri setine ilişkin sayısal veriler ve görüntülerin genişlik yükseklik değerlerinin değişimini gösteren grafikler.


Şekil 4.19 incelendiğinde a) grafiğinde çalışmada dikkate alınan her bir sınıf için kaç adet görselin bulunduğu yer almaktadır. Grafik incelendiğinde dikkate alınan etiket sınıflarının dağılımının homojen olup olmadığı gösterilmektedir. Grafik b) ve c) incelendiğinde veri setinde bulunan görsellerin boyutlarına ilişkin bilgiler yer almaktadır. Modelin eğitimi için dikkate alınan verilerin dağılımlarının ve boyutlarının modelin çalıştırılması için uygun olduğu gözlemlenmiştir Verilerin uygunluğu sağlandıktan sonra modelin eğitim aşamasında tespiti yapılan görüntülere ilişkin görseller Şekil 4.20’de sunulmaktadır.



Şekil 4.20. (Devam)




Şekil 4.20. (Devam)




Şekil 4.20. (Devam)


Şekil 4.20’de yer alan görsellerde etiketlenen dosyaların model tarafından tespit edilmesi gerçekleştirilmiştir. Şekil 4.20’de verilen görsellerdeki görüntüler kamuya açık olan veriler ve çalışma kapsamında oluşturulan verilerin eğitim tespit sonuçlarıdır. Modelin doğrulama aşamasında ise doğrulama veri seti için model tahmin işlemini gerçekleştirerek sürücü dikkat dağınıklığının tespiti yapılmıştır. Şekil 4.21’de veri setleri kullanılarak oluşturulan doğrulama veri seti için tahmini ve tespiti yapılan görseller sunulmaktadır. Ayrıca, net bir görüntü sunulabilmesi amacıyla modelin verdiği doğruluk oranları kullanılarak Şekil 4.21’deki son görsel örnek teşkil etmesi hasebiyle oluşturulmuştur.



Şekil 4.21. Doğrulama setinde sürücü dikkat dağınıklığının tespit edildiği bazı görüntüler




Şekil 4.21. (Devam)




Şekil 4.21. (Devam)

Modelin eğitilmesi ve doğrulanması işlemlerinden sonra Şekil 4.19 ve Şekil 4.20 deki görseller elde edilmiştir. Belirtilen görseller modelin yaptığı tespit için sunduğu temsili görüntüleri içermektedir. Model sonuçlarının incelenmesi için mAP (ortalama hassasiyet metriği), F1 skoru, Precision, Recall, Karışıklık Matrisi ve Kayıp Fonksiyonlarına bakılması daha sağlık olacaktır. Şekil 4.22 ve Şekil 4.23’de modelin mAP ölçüt çıktı grafikleri verilmiştir. Daha net gözükmesi amacıyla grafikler tek tek verilmiştir.




Şekil 4.22. YOLOv7 ve YOLOv8 modelinden elde edilen mAP 0.5 değerleri ve grafiği




Şekil 4.23. YOLOv7 ve YOLOv8 modelinden elde edilen mAP 0.5-0.95 değerleri ve grafiği.

mAP, nesne tespiti algoritmalarında kullanılan ve modelin performansını değerlendiren bir ölçüttür. Bu ölçüt sayesinde modelin doğruluğu hakkında fikir sahibi olunabilir. mAP ölçütü, eğitilen modelin çeşitli nesnelerin tespitindeki yeteneğini ile ilgili kullanıcıya bilgi sunmaktadır. mAP ölçütünün literatürde sıklıkla kullanılan iki farklı varyasyonu bulunmaktadır. Bunlar mAP 0.5 ve mAP 0.5-0.95'dir. Bu varyasyonlar modelin kullandığı eşik değerlerine göre değişmektedir. Nesne tespitinin geçerli sonuç verdiğini ispatlamak için görüntüde yer alan minimum IoU değerini dikkate alan farklı eşik değerleri bulunmaktadır. Dikkate alınan eşik değerlerine göre mAP ölçütü

değişmektedir. mAP 0.5 olarak ifade edilen ölçüt için IoU değeri 0.5 olarak alınmaktadır. Yani, görüntülerdeki benzeşmenin 0,5'den büyük olması halinde model görüntüyü doğru tahmin ettiğini varsaymaktadır. mAP 0.95 ölçütünde ise IoU değeri 0.5-0.95 olarak alınmaktadır. mAP ölçüt değeri ne kadar yüksek ise modelin doğruluğu o kadar yüksektir. Ayrıca, mAP ölçütleri için oluşturulan grafiklerin birbirlerine benzerlikleri modelin doğru tahminler yaptığını ortaya koymaktadır. mAP ölçütünün yanı sıra kayıp fonksiyon grafikleri model performansı hakkında önemli bilgiler sunmaktadır. Şekil 4.24'de kayıp fonksiyon grafikleri verilmiştir



Şekil 4.24. YOLOv7 ve YOLOv8 modelinden elde edilen kayıp fonksiyonları grafiği




Şekil 4.24. (Devam)

YOLO algoritması, görüntü başına birden fazla sınırlayıcı kutu öngörmektedir. Gerçek pozitifin kaybını hesaplamak için nesneden yalnızca birinin sorumlu olması gerekmektedir. Bu amaçla temel gerçekte en yüksek IoU değerine sahip olan seçilmektedir. Bu strateji sınırlayıcı kutu tahminleri arasında uzmanlaşmaya yol açmaktadır. Her tahmin, belirli boyutları ve en boy oranlarını tahmin etmede daha iyi hale gelmektedir. YOLO, kaybı hesaplamak için tahminler ile temel gerçek arasındaki hataların toplamının karesini kullanmaktadır. Kayıp fonksiyonu aşağıdaki sınıflardan oluşmaktadır.

Sınıflandırma kaybı (Classification), bir nesne tespit edilirse, her hücredeki sınıflandırma kaybı, her sınıf için sınıf koşullu olasılıklarının kare hatası olarak hesaplanmaktadır. Konum / Yerleşim kaybı (Box), konumsal kaybı, tahmin edilen sınır kutusu konumları ve boyutlarındaki hataları ölçmektedir. Yalnızca nesneyi tespit

etmekten sorumlu olan kutu dikkate alınır. Güven kaybı (Objectness), nesnenin tespit edilip edilmemesiyle ilgili hatayı hesaplayan kayıp fonksiyonudur.


Algoritma sonuçlarının performansını anlamlandırmak için bir diğer ölçüt ise precision ve recall değerleridir. Precision ölçütü, gerçekte doğru olan ve tahmin edilen pozitiflerin oranını ölçmektedir. Diğer bir ifadeyle, gerçek pozitiflerin sayısının toplamının pozitif tahmin sayısına oranı olarak tanımlanmıştır. Yani, precision değeri ne kadar yüksek ise modelin pozitifleri o kadar yüksek oranda tespit ettiği ifade edilebilir. Recall, pozitif olarak doğru bir şekilde sınıflandırılan pozitif numune sayısının toplam pozitif numune sayısına oranı olarak ifade edilmektedir. Recall modelin pozitif örnekleri tespit etme yeteneğini ölçmektedir. Recall ne kadar yüksek olursa, o kadar fazla pozitif örnek tespit edildiğini göstermektedir. Recall, yalnızca pozitif örneklerin nasıl sınıflandırıldığıyla ilgilenmektedir. Recall ve precision değerleri kullanılarak modelin performansını ölçen ve ciddi bir gösterge olan F1 skoru hesaplanmaktadır. Şekil 4.25’de oluşturulan modellerin F1 skoru verilmiştir.



Şekil 4.25. YOLOv7 ve YOLOv8 modelinden elde edilen F1 skorunun etiket sınıflarına göre ayrımı.

F1 skoru, modelin doğruluğunu ölçen bir makine öğrenimi değerlendirme ölçütüdür. Modelin precision ve recall değerleri kullanılarak oluşturulan F1 skoru modelin performansı hakkında önemli düzeyde bilgi vermektedir. Doğruluk ölçütü, bir modelin tüm veri kümesinde kaç kez doğru tahmin yaptığını hesaplar. Bu yalnızca veri

kümesinin dengeli olması durumunda güvenilir bir ölçüm olabilir; yani veri kümesinin her sınıfı aynı veya benzer sayıda örneğe sahip olmalıdır. Bununla birlikte, gerçek dünyadaki veri kümeleri büyük ölçüde sınıf dengesizliğine sahiptir ve bu da çoğu zaman bu ölçümü geçersiz kılmaktadır. Örneğin, ikili sınıf veri kümesinin A sınıfı ve B sınıfı sırasıyla 90 ve 10 örneğe sahipse, örnekten bağımsız olarak yalnızca A sınıfını tahmin eden bir model yine de %90 doğruluk oranına sahip olacaktır. Bu nedenle F1 skoru kullanılmaktadır. F1 skoru, precision ve recall değerlerinin harmonik ortalaması kullanılarak hesaplanmaktadır. F1 skorunun en üst düzeye çıkarılması hem precision hem de recall değerinin aynı anda en optimum düzeye çıkarılması anlamına gelmektedir. Modelin sınıflara bağımlı olarak tahmin veya tespit doğruluğu, F1 skoru değeri ile birebir ilişkilidir. Modelin performansının ölçülmesi için kullanılan diğer bir metrik ise karışıklık matrisidir. Modellere ait karışıklık matrisleri Şekil 4.26'da sunulmaktadır.




Şekil 4.26. YOLOv7 ve YOLOv8 karışıklık matrisi sonuçları



Şekil 4.26. (Devam)

Karışıklık matrisi, bir sınıflandırma algoritmasının performansını özetlemek için kullanılan bir tekniktir. Her etiketi sınıfında eşit olmayan sayıda gözlem bulunuyorsa veya veri kümesinde ikiden fazla sınıf varsa, sınıflandırma doğruluğu tek başına yanıltıcı olabilmektedir. Karışıklık matrisinin hesaplanması, eğitilen modelin neyi doğru yaptığı ve ne tür hatalar yaptığı konusunda kullanıcıya fikir sunmaktadır. Eğitilen modelin yaptığı hataların yanında yapılan hata türü hakkında bilgi sağlamaktadır.

YOLOv7 ve YOLOv8 modellerinin performans çıktıları yukarıda verilmiştir. Modellerin karşılaştırılmasında önemli olan performans parametreleri mAP değerleri, F1 skoru ve karışıklık matrisidir. Şekil 4.27’de YOLOv7 ve YOLOv8 modellerinin performans çıktılarının özet şeklinde karşılaştırması yer almaktadır.



Şekil 4.27. YOLOv7 ve YOLOv8 modellerinin performans çıktılarının karşılaştırılması

Şekil 4.27 incelendiğinde YOLOv7 modellemesi için mAP 0.5 değeri %99,53, mAP 0.5-0.95 değeri %91,17 ve F1 skor değeri 0,789 olduğu görülmektedir. YOLOv7 modellemesinin tek başına yapıldığı varsayıldığında elde edilen performans değerlerinin yeterli ve kabul edilebilir olduğu söylenebilir. Özellikle F1 skor değerinin 0,5’den büyük olması durumunda modelin başarılı olduğu varsayılmaktadır. Bunun yanında YOLOv8 modelinde mAP 0.5 değeri %97,21, mAP 0.5-0.95 %92,03 ve F1 skor değerinin 0,859 olduğu görülmektedir. YOLOv7 modellemesinde olduğu gibi bu değerlerin tek başına yeterli ve kabul edilebilir olduğu söylenebilir. YOLOv7 ve YOLOv8 modelleri incelendiğinde mAP 0.5 performans parametresi için YOLOv7 modellemesinin daha iyi sonuç verdiği görülmektedir. Modelin performansı sadece bu performans ölçütüne göre değerlendirilmiş olsaydı YOLOv7 modelinin YOLOv8 modelinden daha iyi sonuç verdiği söylenecektir. Ancak, mAP 0.5-0.95 metriği ve daha önemlisi F1 skoru incelendiğinde YOLOv8 modelinin YOLOv7 modeline göre daha iyi performans sergilediği söylenebilir. Tek bir performans parametresine bağlı kalmaksızın çok ölçütlü değerlendirme yapılmasının önemi bir kez daha ortaya konmuştur. mAP 0.5 değerinin YOLOv7 modelinde daha iyi sonuç vermesinin nedeni YOLOv7 modelinin YOLOv8 modeline göre sınırlayıcı kutu kaybında daha kötü performans sergilemesi olarak söylenebilir. Bunun haricinde kayıp fonksiyonlar sonuçları incelendiğinde her iki modelin de geçerli performans sergilediği söylenebilir. Sınıflandırma kaybı, güven kaybı ve konum kaybı değerlerinin 0,1’den küçük olması halinde modelin kayıp

fonksiyonlarının kabul edilebilir seviyede olduğu ifade edilmektedir. Ek olarak, YOLOv8 modelinde hesaplanan ve etiket sınıflarının dengesi konusunda fikir veren ve 1,0 değerine yakın olması gereken diğer bir kayıp fonksiyonu ise dağıtımsal odak kaybı (dfl_loss) fonksiyonudur. Bu değerde, YOLOv8 modelinde 1,0 oldukça yakındır ve sınıfların dağılımının homojen olduğu söylenebilir.

Her iki modelin performans değerleri ve çıktıları incelendiğinde modellerin sürücü dikkat dağınıklığının tespit edilmesi konusunda iyi sonuçlar verdiği söylenebilir. Hız ve performans çıktıları açısından YOLOv8 modelinin nispeten daha iyi performansa sahip olduğu görülmektedir. YOLOv8, YOLO mimarisinin geliştirilen son modeli olarak ön plana çıkmaktadır. Eski sürümlerine göre sınırlayıcı kutu kaybı, tespit ve tahmin ölçütlerinde literatürdeki diğer çalışmalarda da daha iyi sonuç verdiği gözlemlenmektedir ve bu çalışma ile de bu sonuç ortaya konulmuştur.

Sürücü dikkat dağınıklığının veri setleri üzerinden tespit ve tahmin edilmesi literatüre oldukça önemli bir farkındalık ve katkı sunmaktadır. Ancak, gerçek zamanlı trafik akışında sürücü dikkat dağınıklığının tespit edilmesi ve sürücülerin dikkat dağınıklığı yaşadıkları esnada uyarılması trafik güvenliğinin artırılması için çok önemli bir gelişme olacaktır. Bunun yanında yol kenarı gözlem araştırması sonucunda elde edilen veriler ışığında gereksiz gecikmelerden kaynaklı çevre kirliliği ve yakıt tüketimi olumsuz bir şekilde etkilenmektedir. Bu tür olumsuzlukların önüne geçilebilmesi amacıyla bu tez çalışması kapsamında önceden eğitilen YOLOv8 modeli kullanılarak sürücülerin anlık dikkat dağınıklığının tespiti yapılmış ve sürücülerin uyarılması için modellerin entegrasyonu sağlanmıştır. Sürücü dikkat dağınıklığının tespiti YOLOv8 modeli ile yapılırken sürücülerin uyarılması için kamuya açık olarak yayınlanan ve YOLO mimarisi ile uyumlu algoritma kullanılmıştır (Anonymous 2022i). Anlık ikaz sisteminin çalışma sürecine ilişkin video kaydı alınmıştı ve “<https://youtu.be/07rMliKoaGQ>” bağlantısında sunulmaktadır.

Sürücülerin anlık dikkat dağınıklıkları tespit edilmiş ve sürücüler uyarılmıştır. Sürücülerin uyarılmasının ve sürücünün birincil sürüş faaliyetlerine geri dönmesi ile trafik kazalarının nispeten azaltılması hedeflenmektedir. Bunun yanında, çevre kirliliği düşünüldüğünde özellikle bekleme esnasında sürücülerin gereksiz gecikmelerden

kaçınacağı ve böylece daha sağlıklı ve sürdürülebilir bir trafik akışının sağlanması mümkün hale gelmektedir. Böylece, akıllı ulaşım sistemlerinin en önemli amaçlarından olan trafik güvenliği ve sürdürülebilir ulaşım alanlarına katkı yapılmış olacaktır.



5. SONUÇ ve ÖNERİLER

Yapılan bu tez çalışması kapsamında sürücü dikkat dağınıklığı nedeniyle meydana gelen olumsuz durumlar ele alınmıştır. Tez çalışmasında öncelikle sürücü dikkat dağınıklığının en önemli eylem sınıfı olan Cep Telefonu Kullanımı incelenmiştir. Cep telefonu kullanımının her geçen gün yaygınlaşması ile hiç şüphesiz trafikteki sürücülerin cep telefonu kullanım oranı artmaktadır. Seyir halinde cep telefonu kullanan sürücülerin diğer sürücülerin ve trafik unsurlarının hayatını ve sağlığını olumsuz bir şekilde etkilediği açık bir şekilde ifade edilebilir. Cep telefonu kullanımı kaynaklı sürücü dikkat dağınıklığı sadece trafik güvenliği anlamında değil aynı zamanda çevresel etkiler açısından da önemli bir tehdit unsuru olarak ön plana çıkmaktadır.

Cep telefonu kullanımının çevresel etkilerinin incelenmesi için bu tez çalışması kapsamında yol kenarı gözlem araştırması gerçekleştirilmiştir. Çalışma alanı olan Erzurum ilinde trafik ve nüfus hareketliliği yüksek olan Yakutiye ve Palandöken ilçelerinde seçilen yoğun kavşaklarda zirve saat olarak ifade edilen 17.30-18.30 saat diliminde ölçümler yapılmıştır. Ölçümler yapılırken trafik ışıklarında bekleyen ilk dört sıradaki sürücüler dikkate alınmıştır. Kavşak kolundaki tüm araçların gözlemlenebilmesi için çok geniş bir gözlem ekibinin oluşturulması gerekmektedir. Ancak, sürücülerin gözlem ekibinin varlığından veya çalışma yapıldığından haberdar olması sürücülerin doğal davranışlarını sergilememesine yol açabilir. Bu nedenle tez çalışması kapsamında kavşak kolundaki sürücülerin tamamı ve kavşaktaki taşıt cinsi sayımları gerçekleştirilmemiştir. Yol kenarı gözlem araştırmasında kavşağı kullanan taşıt sayısı, cep telefonu kullanan sürücü sayısı, cep telefonu kullanım durumu ve cep telefonu kullanan sürücülerin yeşil ışık yandıktan ne kadar süre sonra cep telefonunu bıraktığı gibi parametreler ölçülmüştür. Dikkate alınan kavşaklarda 11.241 sürücü gözlemlenmiştir ve bu sürücülerin yaklaşık %15'inin birincil sürüş faaliyetlerini tamamen bırakıp cep telefonu kullanımı yaptığı ve bu nedenle kavşakta gecikmelere neden olduğu tespit edilmiştir. Dikkat dağınıklığı yaşayan sürücülerden kaynaklı gecikmeler tüm kavşakta hatta makro düzeyde bakıldığında kentin tüm trafik akışında olumsuz durumlar oluşturmaktadır. Dikkate alınan kavşaklar ve saat dilimi dikkat alındığında cep telefonu kullanımı kaynaklı sürücü dikkat dağınıklığı nedeniyle yaklaşık 69,1 dakikalık gecikme meydana gelmektedir. Bu değerin ilgili saat aralığında ve 23 kavşak için

hesaplanmaktadır. Ayrıca, dikkate alınan kavşaklar arasında ilgili parametreler ışığında en kritik önem seviyesine sahip kavşağın belirlenebilmesi amacıyla çalışmada ÇKKV yöntemlerinden Entropi ve CBS kullanılmıştır. Buna göre, ilgili parametrelerde de kötü performans sergileyen 3 numaralı kavşağın cep telefonu kullanımı kaynaklı sürücü dikkat dağınıklığı açısından en kritik kavşak olduğu tez çalışmasında belirlenmiştir. Kent geneli bakıldığında ilgili saatlerde tüm kavşaklarda daha fazla gecikmelerin meydana geleceği kaçınılmaz bir gerçektir.

Yol kenarı gözlem araştırması sonucu elde edilen veriler ve referans değerler kullanılarak dikkate alınan kavşaklarda belirli zaman dilimindeki emisyon ve yakıt tüketimi hesaplamaları gerçekleştirilmiştir. Saatlik olarak bazı değerler önemsiz olarak görünse de yıllık olarak ve tüm kent genelindeki kavşaklar düşünüldüğünde hem emisyon hem de yakıt tüketimi değerlerinin oldukça ciddi seviyelerde olduğunu söylenebilmektedir. Yıllık olarak değerlerin incelenmesi için ilgili saat diliminde 2023 yılı iş günlerinde aynı gecikmelerin gerçekleştiği varsayılmaktadır. Buna göre, yıllık 291,37 saat cep telefonu kullanımı nedeniyle gereksiz gecikme oluşmaktadır. Buna bağlı olarak 372,42 kg CO₂, 0,44 (kg) NO_x ve 261,6 litre yakıt tüketimi meydana gelmektedir. Ortaya çıkan sonuçların dikkate alınan kavşaklarda dahi azımsanmayacak derecede önemli olduğu görülmektedir. Bu tür olumsuzlukların ortadan kaldırılması için bazı öneriler sürücüler ve kuruluşlar tarafından resmi olmayan yöntemlerle sunulmuştur. Bunlardan bazıları,

- Trafik ışıklarında cep telefonu kullanımının önlenmesi için sinyal kesici sistemlerin devreye alınması,
- Kavşak bölgelerine görsel uyarıların konulması,
- Sürücülerin belirli aralıklarla radyo frekansları aracılığıyla uyarılmasıdır.

Ancak, ortaya atılan önerilerin sürdürülebilir olmadığı ve sürücülerin dikkat dağınıklığına olumlu katkı sunmasında ziyaden olumsuz etkileyebileceği düşünülmektedir. Sinyal kesicilerin uygulanması ile acil durumlarda cep telefonu görüşmesi yapmak isteyen kullanıcıların iletişim probleminin meydana gelmesi, görsel uyarılar ve radyo frekansları ile sürücülerin uyarılması ile hem görsel hem de işitsel olarak sürücü dikkat dağınıklığının daha fazla artmasına yol açabilmesi muhtemeldir. Bunlar

yerine, sürücülerin dikkat dağınıklığına neden olan tüm eylem sınıflarının tespit edilip sürücülerin bireysel olarak uyarılması hem dikkat dağınıklığı hem de diğer sürücülerin güvenliği için en uygun yöntem olacağı düşünülmektedir. Ayrıca, kavşaklarda meydana gelen gecikmelerde nispeten azalacağı için çevresel açıdan da olumlu katkılar sağlanacaktır. Bu bağlamda, tez çalışması kapsamında sürücü dikkat dağınıklığının tespiti ve sürücülerin uyarılması işlemleri gerçekleştirilmiştir.

Sürücü dikkat dağınıklığının tespit edilebilmesi amacıyla nesne tespiti için kullanılan derin öğrenme algoritmalarından faydalanılmıştır. Literatürde yer alan sürücü dikkat dağınıklığı eylem sınıfları incelenmiştir. Ek olarak, sürücü görüşlerinden faydalanılarak dikkat dağınıklığını en çok etkileyen eylem sınıfları çalışmaya dahil edilmiştir. Ancak, her eylem sınıfının aynı sıklıkla sergilenmediği ve aynı önem derecesinde olmadığı çalışmalarda ifade edilmektedir. Bu nedenle, tez çalışmasında bu alanda ilk olarak uygulanan AHP yöntemi ile sürücü dikkat dağınıklığı eylem sınıflarının önem dereceleri hesaplanmıştır. Literatürde de ifade edildiği gibi cep telefonu ile mesajlaşmak en önemli eylem sınıfı olarak belirlenmiştir. Önem derecelerine göre değerlendirilen eylem sınıflarının fiziksel eylemlere göre ayrımı da bu çalışma kapsamında gerçekleştirilmiştir. Çalışma kapsamında dikkate alınan sürücü dikkat dağınıklığı eylem sınıflarına uygun olan kamuya açık olarak yayınlanan ve sürücü dikkat dağınıklığının tespiti için daha önce kullanılan veri setleri toparlanmıştır. Bunun yanında, farklı sürüş karakteristiklerini yansıtmaları, veri setinin evrenselliği ve güncelliğinin sağlanması amacıyla farklı sürücülerin yer aldığı yeni bir veri seti de oluşturulmuştur. Böylece, sürücü dikkat dağınıklığının tespit edilmesi için geniş bir veri seti elde edilmiştir. Ek olarak, veri setinin farklı görüntü özelliklerini duyarlı olması açısından veri büyütme teknikleri kullanılarak nihai veri seti elde edilmiştir.

Tespit edilecek eylem sınıflarına uygunluğu ve veri setindeki görüntülerin tespiti açısından nesne tespit modelleri incelenmiştir ve YOLO mimarisinin uygun olduğuna karar verilmiştir. YOLO mimarisinde yer alan algoritmaların diğer derin öğrenme algoritmalarına göre üstünlükleri nedeniyle YOLO mimarisi tercih edilmiştir. Bu amaç doğrultusunda YOLOv7 ve YOLOv8 tez çalışması kapsamında nesne tespit ve tahmin yöntemi olarak kullanılmıştır. YOLOv7 ve YOLOv8 algoritmalarının her ikisinin de kullanılması ile YOLO mimarileri arasında kıyaslama imkânı da sağlanmış olacaktır.

Eğitilen modeller sonucunda sürücü dikkat dağınıklığının başarılı bir şekilde tespit edildiği ve tahminlerinin sağlıklı bir şekilde yapıldığı sonuçlar ile ortaya konulmuştur. Buna göre, mAP 0.5 ölçütüne göre YOLOv7 algoritmasında %99,53 ve YOLOv8 algoritmasında %97,21 doğruluk oranı elde edilmiştir. YOLOv7 algoritmasının daha başarılı performans göstermesinin nedeni yakalanan görüntü karelerinde var olan hata hesaplamasından kaynaklanmaktadır. Bu nedenle çalışmada diğer performans çıktıları da incelenmiştir. mAP 0.5-0.95 ölçütüne göre YOLOv7 algoritmasında %91,17 ve YOLOv8 algoritmasında %92,03 doğruluk oranı elde edilmiştir. mAP ölçüm parametreleri veri setinin homojen olduğu durumlarda kullanıcıya doğru sonuçları sunabilir. Ancak, veri setinin homojen olmadığı durumlarda analiz edilmesi için F1 skor değeri incelenmelidir. Bu bağlamda, YOLOv7 algoritmasında 0,789 ve YOLOv8 algoritmasında 0,859 F1 skor değeri elde edilmiştir. Tüm ölçüm parametreleri incelendiğinde her iki algoritmanın da başarılı sonuçlar sergilediği görülmektedir. Ancak, YOLOv8 algoritmasının hem hız hem de ölçüm parametreleri bakımından daha başarılı performans sergilediği söylenebilir. Literatürde sürücü dikkat dağınıklığı tespiti yapılan çalışmalarda kullanılan yöntemlerin yetersizliği ve uygulanan metodolojinin verimsizliği nedeniyle bu tez çalışması ön plana çıkmaktadır.

Sürücü dikkat dağınıklığının tespit edilmesi ile trafik ışıklarında bekleyen sürücülerin dikkat dağınıklıkları tespit edilebilir ve ilgili birimler tarafından caydırıcı önlemler alınabilir. Buna ek olarak, sürücülerin sadece belirli bölgelerde tespitinin yapılmasının yeterli olmayacağı düşünüldüğünden anlık gerçek zamanlı sürücü dikkat dağınıklığının yapılması tez çalışması kapsamında gerçekleştirilmiştir. Bu amaç doğrultusunda daha önceden eğitilen ve başarılı sonuçlar sunan YOLOv8 algoritması ve uyarıcı / ikaz sistemi için geliştirilen algoritma sayesinde sürücülerin dikkat dağınıklığının tespit edilmesi ve sürücülerin bireysel olarak uyarılması gerçekleştirilmiştir. Sürücü uyarı sistem tasarımı için tüm eylem sınıflarının tespiti anlık olarak gerçekleştirilmiş olup dikkat dağınıklığı eylem sınıfını sergileyen sürücülerin uyarılması için var olan uyarı sisteminin transpozu alınarak ihlal sınıflarında sürücülerin uyarılması işlemi yapılmıştır. Tüm eylem sınıfları dikkate alındığında anlık tespit ve uyarı sisteminin %90'nın üzerinde doğruluk oranı ile çalıştığı belirlenmiştir. Sürücü dikkat dağınıklığının tespit edilmesi ve sürücünün uyarılması süreçleri bilgisayar ortamında gerçekleştirilmiştir.

Yapılan tez çalışması değerlendirildiğinde sürücü dikkat dağınıklığının trafik güvenliğine ve çevre kirliliğine etkisi ortaya konulmaktadır. Trafikte yer alan diğer sürücülerin yanında dikkati dağılan araç sürücüsünün de sürüş güvenliğinin gerçek zamanlı sağlanması mümkün hale gelmektedir. Trafik güvenliğinin sağlanması ve çevresel etkilerin azaltılması için dikkat edilmesi gereken konular şunlardır:

Sürücü dikkat dağınıklığının önlenmesi veya azaltılabilmesi için sürücülere yönelik belirli aralıklarla ilgili birim ve kuruluşlar tarafından farkındalık eğitimlerinin gerçekleştirilmesi gerekmektedir. Ek olarak, kent genelinde sürücü adayları içinde yapılacak farkındalık çalışmaları ile toplumsal farkındalık sağlanarak trafik güvenliğine ve çevre kirliliğinin azaltılmasına olumlu yönde katkı yapılması sağlanabilir.

Özellikle cep telefonu kaynaklı dikkat dağınıklığının ve dolayısıyla olumsuz çevre ve trafik koşulların önüne geçebilmek için caydırıcı yaptırımların daha etkin bir şekilde uygulanması gerekmektedir. Bunun için cep telefonu kullanan sürücülerin sürekli veya bölgesel olarak tespit edilmesi gerçekleştirilmelidir. Bu amaç doğrultusunda geliştirilen dikkat dağınıklığı tespit yöntemi ile cep telefonu kullanan sürücüler tespit edilebilir ve ilgili idare tarafından caydırıcı yaptırımlar uygulanabilir. Kritik ve yoğun kavşaklarda kullanılacak trafik yönetim sistem bileşenlerine entegre edilecek sürücü dikkat dağınıklığı tespit sistemi sayesinde otonom bir şekilde cep telefonu kullanımı tespit edilebilir ve sürücüye caydırıcı yaptırımlar sistem tarafından uygulanabilir.

Sürücü dikkat dağınıklığının sadece trafik ışıklarında beklerken meydana gelmediği bilinen bir gerçektir. Sürüş esnasında sürücünün isteyerek veya istemeden dikkatinin dağılmasının önüne geçebilmek için sürücülerin anlık ve gerçek zamanlı uyarılması gerekmektedir. Böylece, trafik güvenliğine son derecede önemli katkıların sunulması mümkün hale gelecektir. Tez çalışması kapsamında gerçekleştirilen uyarıcı sistemin araçlara entegre edilmesi ile daha fazla sürücünün güvenliği sağlanabilir. Araçlara entegre edilen sistem sayesinde sürücülere yönelik yaptırımların ve uyarılarında ilgili idare tarafından uzaktan yürütülmesi mümkün hale gelmektedir. Böylece, trafik güvenliği ve çevre kirliliği konusunda hassasiyet artırılabilir.

Trafik koşulları dikkate alındığında ilgili idarenin sadece cep telefonu kullanımı için caydırıcı bir yaptırımının olduğu görülmektedir. Diğer sürücü dikkat dağınıklığı sınıflarının herhangi bir yaptırıma tabii olmadığı ve bu nedenle herhangi bir caydırıcı unsurun uygulanmadığı bilinmektedir. Tez çalışmasında dikkate alınan eylem sınıflarının ilgili idare tarafından çalışma kapsamına alınması ile dikkat dağınıklığı yaşayan sürücülerin trafik güvenliğini tehlikeye atması önenebilir.

Yerel yönetim veya ilgili idareler tarafından trafik ışıklarında dikkati dağılan sürücülerin neden olduğu çevresel etkilerin araştırılması gerekmektedir. Bu doğrultuda araçların rölanti durumundaki yakıt tüketimi ve emisyon değerleri Karbon Ayak İzi Hesaplama yönergesine göre değerlendirilerek kentlerin sürdürülebilir ulaşım ana planlarının oluşturulması da şekillendirilebilir. Ayrıca, sadece çevresel etkiler değil sürücülerin yaşadığı gecikmeler de göz önüne alınarak kent genelinde etkin bir şekilde kullanılamayan kavşakların tespit edilmesi mümkün hale gelecektir. Yerel yönetim tarafından kritik kavşaklarda yapılacak uygulamalar sayesinde gecikmeler ve dolayısıyla çevresel etkilerde iyileştirmeler sağlanabilir.

KAYNAKLAR

- Abdipour, M., Younessi-Hmazekhanlu, M., Ramazani, S. and Omid, A. 2019. Artificial neural networks and multiple linear regression as potential methods for modeling seed yield of safflower (*Carthamus tinctorius* L.). *Industrial Crops and Products*, 127, 185–194. <https://doi.org/10.1016/j.indcrop.2018.10.050>.
- Abidoye, L., Mahdi, F., Idris, O., Alabi, O. and Wahab, A. 2018. ANN-derived equation and ITS application in the prediction of dielectric properties of pure and impure CO₂. *Journal of Cleaner Production*, 175, 123–132. <https://doi.org/10.1016/j.jclepro.2017.12.013>.
- Abouelnaga, Y. Eraqi, H. and Moustafa, M. 2017. Real-time Distracted Driver Posture Classification. In: 32nd Conference on Neural Information Processing Systems. 3-8 December, Book of Proceedings, 8, Montreal, Canada, <http://arxiv.org/abs/1706.09498>.
- Adun, H. 2023. Sustainability energy security: 20 years assessment of the West African Nations using a comprehensive entropy-TOPSIS analysis. *Environmental Science and Pollution Research*, 30(33), 81093–81112. <https://doi.org/10.1007/s11356-023-28116-5>.
- Agatonovic-Kustrin, S. and Beresford, R. 2000. Basic concepts of artificial neural network (ANN) modeling and its application in pharmaceutical research. *Journal of Pharmaceutical and Biomedical Analysis*, 22(5), 717–727. [https://doi.org/10.1016/S0731-7085\(99\)00272-1](https://doi.org/10.1016/S0731-7085(99)00272-1).
- Ahsan, M., Sarwar, M., Lone, S., Almutlak, S. and Anwer, S. 2023. Optimizing new technology implementation through fuzzy hypersoft set: a framework incorporating Entropy, similarity measure, and TOPSIS techniques. *IEEE Access*, 11, 80680–80691. <https://doi.org/10.1109/ACCESS.2023.3299861>.
- Alemdar, K., Kaya, Ö. and Çodur, M. 2020. A GIS and microsimulation-based MCDA approach for evaluation of pedestrian crossings. *Accident Analysis and Prevention*, 148. <https://doi.org/10.1016/j.aap.2020.105771>.
- Aljasim, M. and Kashef, R. 2022. E2DR: a deep learning ensemble-based driver distraction detection with recommendations model. *Sensors*, 22(5). <https://doi.org/10.3390/s22051858>.
- Alkan, B., Balci, B., Elihos, A. and Artan, Y. 2019. Driver cell phone usage violation detection using license plate recognition camera images. In: 5th International Conference on Vehicle Technology and Intelligent Transport Systems, 3-5 May, Book of Proceedings, 468–474, Crete, Greece. <https://doi.org/10.5220/0007725804680474>.
- Alonso, J. and Lamata, M. 2006. Consistency in the Analytic hierarchy process: a new approach. *International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems*, 14, 445–459. <https://doi.org/10.1142/S0218488506004114>.

- Alotaibi, M. and Alotaibi, B. 2020. Distracted driver classification using deep learning. *Signal, Image and Video Processing*, 14(3), 617–624. <https://doi.org/10.1007/s11760-019-01589-z>.
- Alshehri, J. 2014. AHP-based methodology for a complex decision support in extreme programming. Ph.D Thesis, University of Regina, Faculty of Graduate Studies and Research, Engineering, 359, Saskatchewan.
- Alzubaidi, L., Zhang, J., Humaidi, A., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Santamaría, J., Fadhel, M., Al-Amidie, M. and Farhan, L. 2021. Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data*, 8(1), 53. <https://doi.org/10.1186/s40537-021-00444-8>.
- Anonim, 2017. Web Sitesi: <https://www.aa.com.tr/tr/sirkethaberleri/finans/trafik-kazalarinin-yuzde-60i-cep-telefonu-kullanimindan-kaynaklaniyor/635846>, Erişim Tarihi: 13.12.2022.
- Anonim, 2022a. Web Sitesi: <https://data.tuik.gov.tr/Bulten/Index?p=Karayolu-Trafik-Kaza-Istatistikleri-2022-49513>, Erişim Tarihi: 03.05.2023.
- Anonim, 2022b. Web Sitesi: <https://trafik.gov.tr/kurumlar/trafik.gov.tr/04-Istatistik/Aylik/ocak23.pdf>, Erişim Tarihi: 21.02.2023.
- Anonim, 2023a. Web Sitesi: <https://data.tuik.gov.tr/Bulten/Index?p=Adrese-Dayali-Nufus-Kayit-Sistemi-Sonuclari-2022-49685>, Erişim Tarihi: 04.05.2023.
- Anonim, 2023b. Web Sitesi: <https://data.tuik.gov.tr/Bulten/Index?p=Motorlu-Kara-Tasitlari-Haziran-2023-49427>, Erişim Tarihi: 04.05.2023.
- Anonymous, 1999. Web Sitesi: <https://www.cdc.gov/-nchs/products/index.htm>, Erişim Tarihi: 17.10.2022.
- Anonymous, 2015. Web Sitesi: <https://arxiv.org/abs/1409.1556>, Erişim Tarihi: 10.02.2022.
- Anonymous, 2016. Web Sitesi: <https://arxiv.org/abs/1603.07285>, Erişim Tarihi: 10.09.2022.
- Anonymous, 2018a. Web Sitesi: <https://www.reuters.com/article/us-health-teens-driving/one-in-three-us-teens-text-while-driving-survey-shows-idUSKCN1LQ22K>, Erişim Tarihi: 04.11.2022.
- Anonymous, 2018b. Web Sitesi: <https://arxiv.org/abs/1804.02767>, Erişim Tarihi: 13.11.2022.
- Anonymous, 2019a. Web Sitesi: <https://data.worldbank.org/indicator/SH.STA.TRAF.P5?end=2019&start=2019&type=shaded&view=map>, Erişim Tarihi: 24.02.2023.

- Anonymous, 2019b. Web Sitesi: <https://towardsdatascience.com/fast-r-cnn-for-object-detection-a-technical-summary-a0ff94faa022>, Erişim Tarihi: 13.01.2023.
- Anonymous, 2020a. Web Sitesi: <https://www.nhtsa.gov/risky-driving/distracted-driving>, Erişim Tarihi: 14.01.2023.
- Anonymous, 2020b. Web Sitesi: <https://www.theguardian.com/technology/2020/oct/17/uk-bans-any-use-of-mobile-phones-while-driving>, Erişim Tarihi: 10.01.2023.
- Anonymous, 2020c. Web Sitesi: <https://www.stewartlawoffices.net/blog/is-texting-while-driving-as-dangerous-as-drunk-driving>, Erişim Tarihi: 17.10.2022.
- Anonymous, 2020d. Web Sitesi: <https://www.nhtsa.gov/-risky-driving/distracted-driving>, Erişim Tarihi: 18.10.2022.
- Anonymous, 2020e. Web Sitesi: <https://medium.com/swlh/artificial-intelligence-machine-learning-and-deep-learning-whats-the-real-difference-94fe7e528097>, Erişim Tarihi: 03.07.2023.
- Anonymous, 2020f. Web Sitesi: <https://github.com/ultralytics/yolov5>, Erişim Tarihi: 10.09.2022.
- Anonymous, 2021. Web Sitesi: <https://www.edgarsnyder.com/car-accident/cause-of-accident/cell-phone/cell-phone-statistics.html#:~:text=The National Safety Council reports,caused by texting and driving>, Erişim Tarihi: 12.09.2022.
- Anonymous, 2022a. Web Sitesi: <https://www.who.int/news-room/fact-sheets/detail/road-traffic-injuries>, Erişim Tarihi: 03.03.2023.
- Anonymous, 2022b. Web Sitesi: <https://www.who.int/news-room/fact-sheets/detail/road-traffic-injuries>, Erişim Tarihi: 03.03.2023.
- Anonymous, 2022c. Web Sitesi: https://en.wikipedia.org/wiki/List_of_countries_by_traffic-related_death_rate, Erişim Tarihi: 20.12.2022.
- Anonymous, 2022d. Web Sitesi: <https://crashstats.nhtsa.dot.gov/Api/Public/ViewPublication/813309>, Erişim Tarihi: 14.01.2023.
- Anonymous, 2022e. Web Sitesi: <https://www.iii.org/fact-statistic/facts-statistics-distracted-driving>, Erişim Tarihi: 07.11.2023
- Anonymous, 2022f. Web Sitesi: <https://www.thezebra.com/resources/research/texting-and-driving-statistics/>, Erişim Tarihi: 14.11.2022
- Anonymous, 2022g. Web Sitesi: <https://www.bankrate.com/insurance/car/distracted-driving-statistics/>, Erişim Tarihi: 14.11.2022.

- Anonymous, 2022h. Web Sitesi: <https://medium.com/@ANAI-DemocratizingAI/yolov6-explained-in-simple-terms-c46a0248bddd>, Erişim Tarihi: 03.01.2023.
- Anonymous, 2022i. Web Sitesi: https://github.com/manirajanvn/yolox_custom_training, Erişim Tarihi: 16.06.2023.
- Anonymous, 2023a. Web Sitesi: <https://data.oecd.org/transport/road-accidents.htm>, Erişim Tarihi: 10.07.2023.
- Anonymous, 2023b. Web Sitesi: <https://www.esri.com/en-us/what-is-gis/overview>, Erişim Tarihi: 12.03.2023.
- Anonymous, 2023c. Web Sitesi: <https://ecotree.green/en/how-much-co2-does-a-tree-absorb>, Erişim Tarihi: 13.05.2023.
- Asif, A., Khatoon, S., Hasan, M., Alshamari, M., Abdou, S., Elsayed, K. and Rashwan, M. 2021. Automatic analysis of social media images to identify disaster type and infer appropriate emergency response. *Journal of Big Data*, 8(1), 83. <https://doi.org/10.1186/s40537-021-00471-5>.
- Atchley, P., Atwood, S. and Boulton, A. 2011. The choice to text and drive in younger drivers: behavior may shape attitude. *Accident Analysis and Prevention*, 43(1), 134–142. <https://doi.org/10.1016/J.AAP.2010.08.003>.
- Bakhtari Aghdam, F., Shaheian, K., Sadeghi-Bazargani, H., Kousha, A., Ponnet, K., Abbasalizad Farhangi, M. and Jahangiry, L. 2022. Drivers' unsafe behaviors in Iran: an investigation in West Azerbaijan. *Frontiers in Public Health*, 10. <https://doi.org/10.3389/fpubh.2022.815380>.
- Balabid, A., Altaban, A., Albsisi, M. and Alhothali, A. 2022. Cell phone usage detection in roadway images: from plate recognition to violation classification. *Neural Computing and Applications*. 35, 4667-4682. <https://doi.org/10.1007/s00521-022-07943-6>
- Barlow, T. and Cairns, O. 2020. Web Sitesi: <https://trl.co.uk/uploads/trl/documents/PPR987-TRL-Idling-Analysis-Summary.pdf>, Erişim Tarihi: 05.05.2023
- Bhardwaj, K., Banyal, S. and Sharma, D. 2019. Artificial intelligence based diagnostics, therapeutics and applications in biomedical engineering and bioinformatics, In: *Internet of Things in Biomedical Engineering*. Balas, V.E., Son, L.H., Jha, S., Khari, M. and Kumar, B. E. (eds), Academic Press, 161–187, <https://doi.org/10.1016/B978-0-12-817356-5.00009-7>.
- Bochkovskiy, A., Wang, C. Y., and Liao, H. Y. M. 2020. Yolov4: Optimal speed and accuracy of object detection. *arXiv preprint arXiv:2004.10934*.
- Bonilla-Escobar, F. and Gutiérrez, M. 2014. Injuries are not accidents: towards a culture of prevention. *Colombia Médica*, 45(3), 132-135.

- Bougueroua, M., and Carnis, L. 2016. Economic development, mobility and traffic accidents in Algeria. *Accident Analysis and Prevention*, 92, 168–174, <https://doi.org/10.1016/j.aap.2016.03.016>.
- Buchholz, M., Wögerbauer, E. and Brandenburg, S. 2023. Comparison of the box task combined with a tactile detection response task and the occlusion method as measures of secondary task demand. *Transportation Research Part F: Traffic Psychology and Behaviour*, 97, 328–346, <https://doi.org/10.1016/j.trf.2023.07.019>.
- Calvi, A., D’Amico, F., Ferrante, C. and Bianchini Ciampoli, L. 2020. A driving simulator study to assess driver performance during a car-following maneuver after switching from automated control to manual control. *Transportation Research Part F: Traffic Psychology and Behaviour*, 70, 58–67, <https://doi.org/10.1016/j.trf.2020.02.014>.
- Cao, Y., Dong, Y., Cao, Y., Yang, J. and Yang, M. 2020. Two-stream convolutional neural network for non-destructive subsurface defect detection via similarity comparison of lock-in thermography signals. *NDT & E International*, 112, 102246, <https://doi.org/10.1016/j.ndteint.2020.102246>.
- Catalina Ortega, C., Mariscal, M., Boulagouas, W., Herrera, S., Espinosa, J. and García-Herrero, S. 2021. Effects of mobile phone use on driving performance: an experimental study of workload and traffic violations. *International Journal of Environmental Research and Public Health*, 18(13), <https://doi.org/10.3390/ijerph18137101>.
- Chollet, F. 2017. *Deep learning with python*. Manning, 504, New York.
- Cummings, M. and Bauchwitz, B. 2023. Driver alerting in ADAS-equipped cars: a field study, 2023 IEEE International Conference on Assured Autonomy (2023 ICAA), 6-8 June, Johns Hopkins University, Book of Proceedings 29–33, <https://doi.org/10.1109/ICAA58325.2023.00012>.
- Çodur, M.Y. 2012. Trafik kaza tahmin modelleri: Erzurum ili çevre karayolları için uygulamalar. Doktora Tezi, Atatürk Üniversitesi, Fen Bilimleri Enstitüsü, İnşaat Mühendisliği Ana Bilim Dalı, 141, Erzurum.
- Dargan, S., Kumar, M., Ayyagari, M. and Kumar, G. 2020. A survey of deep Learning and its applications: a new paradigm to machine learning. *Archives of Computational Methods in Engineering*, 27(4), 1071–1092. <https://doi.org/10.1007/s11831-019-09344-w>.
- De Blasiis, M., Ferrante, C., Palmieri, F. and Veraldi, V. 2022. Coupling virtual reality simulator with instantaneous emission model: a new method for estimating road traffic emissions. *Sustainability*, 14(11), 1–13, <https://doi.org/10.3390/su14116793>.

- Devi, D., Sophia, S. and Boselin Prabhu, S. R. 2021. Deep learning-based cognitive state prediction analysis using brain wave signal, In: Cognitive Data Science in Sustainable Computing. Mittali M., Shah, R. and Roy, H. (eds.), Academic Press, 69–84, <https://doi.org/10.1016/B978-0-323-85769-7.00017-3>.
- Dey, A. 2021. Design, Deployment, and validation of computer vision techniques for societal scale applications. Ph.D Thesis, University of South Florida, Computer Science and Engineering, 93, Florida, United States.
- Dong, C., Loy, C., He, K. and Tang, X. 2016. Image super-resolution using deep convolutional networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 38(2), 295–307, <https://doi.org/10.1109/TPAMI.2015.2439281>.
- Durán, O. and Aguilo, J. 2008. Computer-aided machine-tool selection based on a fuzzy-AHP approach. *Expert Systems with Applications*, 34(3), 1787–1794, <https://doi.org/10.1016/j.eswa.2007.01.046>.
- El Bouchefry, K. and de Souza, R. 2020. Learning in big data: introduction to machine learning, In: Knowledge Discovery in Big Data from Astronomy and Earth Observation. Škoda, P. and Adam, E. O. (eds), Elsevier, 225–249, <https://doi.org/https://doi.org/10.1016/B978-0-12-819154-5.00023-0>.
- Elagözlü, P. 2022. Socially sustainable supplier selection using AHP: an industrial application. Yüksek Lisans Tezi, Marmara Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Ana Bilim Dalı, 119, İstanbul.
- Eraqi, H., Abouelnaga, Y., Saad, M. and Moustafa, M. 2019. Driver distraction identification with an ensemble of convolutional neural networks. *Journal of Advanced Transportation*, 4125865, <https://doi.org/10.1155/2019/4125865>.
- Ezzouhri, A., Charouh, Z., Ghogho, M. and Guennoun, Z. 2021. Robust deep learning-based driver distraction detection and classification. *IEEE Access*, 9, 168080–168092, <https://doi.org/10.1109/ACCESS.2021.3133797>.
- Fukushima, K. 1980. Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. *Biological Cybernetics*, 36(4), 193–202, <https://doi.org/10.1007/BF00344251>.
- Girshick, R. 2015. Fast R-CNN. 2015 IEEE International Conference on Computer Vision (ICCV), 07-13 December, Book of Proceedings, 1440-1448, Santiago Chile, <https://doi.org/10.1109/ICCV.2015.169>.
- Girshick, R., Donahue, J., Darrell, T. and Malik, J. 2014. Rich Feature Hierarchies for Accurate Object Detection and Semantic Segmentation. 2014 IEEE Conference on Computer Vision and Pattern Recognition, 23-28 June, Book of Proceedings, 580–587, Columbus, USA, <https://doi.org/10.1109/CVPR.2014.81>.
- Girshick, R., Donahue, J., Darrell, T. and Malik, J. 2016. Region-based Bonvolutional Networks for Accurate Object Detection and Segmentation. *IEEE Transactions*

- on Pattern Analysis and Machine Intelligence, 38(1), 142–158, <https://doi.org/10.1109/TPAMI.2015.2437384>.
- Gjorgjievska, M., Khanna, V., Petrisor, B., Li, C. and Ristevski, B. 2021. Roadside evaluation of distracted driving – driver limitations in recognizing traffic light transitions (REDD – LIGHT). *Journal of Transport and Health*, 21, 101059, <https://doi.org/10.1016/j.jth.2021.101059>.
- Gumaei, A., Al-Rakhami, M., Hassan, M., Alamri, A., Alhussein, M., Razzaque, M., and Fortino, G. 2020. A deep learning-based driver distraction identification framework over edge cloud. *Neural Computing and Applications*, 1-16, <https://doi.org/10.1007/s00521-020-05328-1>.
- Guo, G. and Zhang, Z. 2022. Road damage detection algorithm for improved YOLOv5. *Scientific Reports*, 12(1), 15523, <https://doi.org/10.1038/s41598-022-19674-8>.
- Haddadi, A., Nikoo, M., Nematollahi, B., Al-Rawas, G., Al-Wardy, M., Toloo, M. and Gandomi, A. 2023. Entropy-based air quality monitoring network optimization using NINP and Bayesian maximum entropy. *Environmental Science and Pollution Research*, 30, 84110-84125, <https://doi.org/10.1007/s11356-023-28270-w>.
- Hamwi, W. and Almustafa, M. 2022. Development and integration of VGG and dense transfer-learning systems supported with diverse lung images for discovery of the Coronavirus identity. *Informatics in Medicine Unlocked*, 32, 101004, <https://doi.org/10.1016/j.imu.2022.101004>.
- Han, B., Liu, H. and Wang, R. 2015. Urban ecological security assessment for cities in the Beijing-Tianjin-Hebei metropolitan region based on fuzzy and entropy methods. *Ecological Modelling*, 318, 217–225, <https://doi.org/10.1016/j.ecolmodel.2014.12.015>.
- Han, H., Wang, L. and Qiao, J. 2013. Efficient self-organizing multilayer neural network for nonlinear system modeling. *Neural Networks*, 43, 22–32, <https://doi.org/10.1016/j.neunet.2013.01.015>.
- Hasan, A. 2021. Investigation of distracted driving events in New Jersey. Master Thesis, Rowan University, Civil and Environmental Engineering, 140, New Jersey, United States.
- He, K., Zhang, X., Ren, S. and Sun, J. 2016. Deep residual learning for image recognition. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 27-30 June, Book of Proceedings, 770–778, <https://doi.org/10.1109/CVPR.2016.90>.
- Hollósi, J., Ballagi, Á., Kovács, G., Fischer, S. and Nagy, V. 2023. Face detection using a capsule network for driver monitoring application. *Computers*, 12(8), 161, <https://doi.org/10.3390/computers12080161>.
- Hou, J., Xie, X., Cai, Q., Deng, Z., Yang, H., Huang, H., Wang, X., Feng, L. and Wang, Y. 2022. Early warning system for drivers' phone usage with deep learning

- network. *EURASIP Journal on Wireless Communications and Networking*, 42, <https://doi.org/10.1186/s13638-022-02121-7>.
- Huang, B., Liu, J., Zhang, Q., Liu, K., Liu, X. and Wang, J. 2023. Improved Faster R-CNN network for liquid bag foreign body detection. *Processes*, 11(8), <https://doi.org/10.3390/pr11082364>.
- Huang, X., Zhu, D., Zhang, F., Liu, T., Li, X. and Zou, L. 2021. Sensing population distribution from satellite imagery via deep learning: Model selection, neighboring effects, and systematic biases. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14, 5137–5151, <https://doi.org/10.1109/JSTARS.2021.3076630>.
- Hubel, D. and Wiesel, T. 1968. Receptive fields and functional architecture of monkey striate cortex. *The Journal of Physiology*, 195(1), 215–243, <https://doi.org/10.1113/jphysiol.1968.sp008455>.
- Huth, V., Sanchez, Y. and Brusque, C. 2015. Drivers' phone use at red traffic lights: a roadside observation study comparing calls and visual-manual interactions. *Accident Analysis and Prevention*, 74, 42–48, <https://doi.org/10.1016/j.aap.2014.10.008>.
- İnik, Ö. ve Ülker, E. 2017. Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri. *Gaziosmanpasa Journal of Scientific Research*, 6(3), 85–104.
- Karna, N., Putra, M., Rachmawati, S., Abisado, M. and Sampedro, G. 2023. Toward accurate fused deposition modeling 3D printer fault detection using improved YOLOv8 with hyperparameter optimization. *IEEE Access*, 11, 74251–74262, <https://doi.org/10.1109/ACCESS.2023.3293056>.
- Khan, P., Kader, M., Islam, S., Rahman, A., Kamal, M., Toha, M., and Kwak, K. 2021. Machine learning and deep learning approaches for brain disease diagnosis: principles and recent advances. *IEEE Access*, 9, 37622–37655, <https://doi.org/10.1109/ACCESS.2021.3062484>.
- Kim, Y., Back, J. and Kim, J. 2021. A tamper-resistant algorithm using blockchain for the digital tachograph. *Electronics*, 10(5), 1–19, <https://doi.org/10.3390/electronics10050581>.
- Klauer, S. G., Guo, F., Simons-Morton, B. G., Ouimet, M. C., Lee, S. E. and Dingus, T. A. 2014. Distracted driving and risk of road crashes among novice and experienced drivers. *New England Journal of Medicine*, 370(1), 54–59, <https://doi.org/10.1056/nejmsa1204142>.
- Kumar, A., Sangwan, K. S. and Dhiraj. 2021. A computer vision based approach for driver distraction recognition using deep learning and genetic algorithm based ensemble. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 12855, 44–56, https://doi.org/10.1007/978-3-030-87897-9_5.

- Le, T. H. N., Zheng, Y., Zhu, C., Luu, K., and Savvides, M. 2016. Multiple Scale Faster-RCNN Approach to Driver's Cell-Phone Usage and Hands on Steering Wheel Detection. 2016 IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), 26 June – 1 July, Book of Proceedings, 46–53, Las Vegas, Nevada, USA, <https://doi.org/10.1109/CVPRW.2016.13>.
- Li, G., Liu, Q. and Guo, Z. 2022. Driver distraction detection using advanced deep learning technologies based on images. *IEEE Journal of Radio Frequency Identification*, 6, 825–831, <https://doi.org/10.1109/JRFID.2022.3209237>.
- Li, W., Li, Z., Wei, Y., Gong, C., Zhang, M. and Chen, L. 2023. Square ancient sites detection in typical regions of the Mongolian plateau using improved faster R-CNN from Google Earth high-resolution images. *International Journal of Remote Sensing*, 44(17), 5207–5227. <https://doi.org/10.1080/01431161.2023.2244641>.
- Liang, X. 2020. Theoretical basis, In: *Ascend AI Processor Architecture and Programming*. Liang, P. (eds), Elsevier, 1-40, Amsterdam, <https://doi.org/https://doi.org/10.1016/B978-0-12-823488-4.00001-1>.
- Liu, Q., and Wu, Y. 2012. Supervised learning, in: *Encyclopedia of the sciences of learning*. Seel, N.M. (eds), Springer, 3243–3245, New York, https://doi.org/10.1007/978-1-4419-1428-6_451.
- Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C. Y. and Berg, A. C. 2016. SSD: Single Shot MultiBox Detector, In: *Computer Vision – ECCV 2016*, Leibe, B., Matas, J., Sebe, N. and Welling, M. (eds), Springer, 21–37, New York.
- Liu, Y., Wang, X., Wang, L. and Liu, D. 2019. A modified leaky ReLU scheme (MLRS) for topology optimization with multiple materials. *Applied Mathematics and Computation*, 352, 188–204, <https://doi.org/10.1016/j.amc.2019.01.038>.
- Liu, Z., Wang, L., Liu, Z., Wang, X., Hu, C. and Xing, J. 2023. Detection of cotton seed damage based on improved YOLOv5. *Processes*, 11(9), 2682, <https://doi.org/10.3390/pr11092682>.
- Masood, S., Rai, A., Aggarwal, A., Doja, M. N. and Ahmad, M. 2020. Detecting distraction of drivers using convolutional neural network. *Pattern Recognition Letters*, 139, 79–85, <https://doi.org/10.1016/j.patrec.2017.12.023>.
- Mohtasham Moein, M., Saradar, A., Rahmati, K., Ghasemzadeh Mousavinejad, S. H., Bristow, J., Aramali, V. and Karakouzian, M. 2023. Predictive models for concrete properties using machine learning and deep learning approaches: a review. *Journal of Building Engineering*, 63, 105444, <https://doi.org/10.1016/j.jobbe.2022.105444>.
- Muhammad, Kennedy, J., and Lim, C. W. 2022. Machine learning and deep learning in phononic crystals and metamaterials – A review. *Materials Today Communications*, 33, 104606, <https://doi.org/10.1016/j.mtcomm.2022.104606>.

- Nguyen, D. H. And Abdel Wahab, M. 2023. Damage detection in slab structures based on two-dimensional curvature mode shape method and Faster R-CNN. *Advances in Engineering Software*, 176, 103371, <https://doi.org/10.1016/j.advengsoft.2022.103371>.
- Omerustaoglu, F., Sakar, C. O. and Kar, G. 2020. Distracted driver detection by combining in-vehicle and image data using deep learning. *Applied Soft Computing*, 96, 106657, <https://doi.org/10.1016/j.asoc.2020.106657>.
- Ouyang, L. and Wang, H. 2019. Vehicle target detection in complex scenes based on YOLOv3 algorithm. *IOP Conference Series: Materials Science and Engineering*, 569(5), <https://doi.org/10.1088/1757-899X/569/5/052018>.
- Özdağoğlu, A. 2013. Farklı normalizasyon yöntemlerinin TOPSIS'te karar verme sürecine etkisi. *Ege Akademik Bakış*, 13(2), 245–257.
- Özkan, Y. 2021. Uygulamalı Derin Öğrenme. *Papatya Bilim*, 256, İstanbul.
- Pal, A., Kar, S. and Bharti, M. 2021. Algorithm for distracted driver detection and alert using deep learning. *Optical Memory and Neural Networks*, 30(3), 257–265, <https://doi.org/10.3103/S1060992X21030103>.
- Patel, K., Bhatt, C. and Mazzeo, P. L. 2022. Improved ship detection algorithm from satellite images using YOLOv7 and graph neural network. *Algorithms*, 15(12), <https://doi.org/10.3390/a15120473>.
- Peng, J., Han, H., Yi, Y., Huang, H. and Xie, L. 2022. Machine learning and deep learning modeling and simulation for predicting PM2.5 concentrations. *Chemosphere*, 308, 136353, <https://doi.org/10.1016/j.chemosphere.2022.136353>.
- Pratama A. D., Bakar, M., Ismail, N. B. and Mashuri, M. 2022. ANN-based methods for solving partial differential equations: a survey. *Arab Journal of Basic and Applied Sciences*, 29(1), 233–248, <https://doi.org/10.1080/25765299.2022.2104224>.
- Puyana-Romero, V., Cueto, J. L. And Gey, R. 2020. A 3D GIS tool for the detection of noise hot-spots from major roads. *Transportation Research Part D: Transport and Environment*, 84, <https://doi.org/10.1016/j.trd.2020.102376>.
- Rahman, S. M. A., Masjuki, H. H., Kalam, M. A., Abedin, M. J., Sanjid, A. and Sajjad, H. 2013. Impact of idling on fuel consumption and exhaust emissions and available idle-reduction technologies for diesel vehicles- a review. *Energy Conversion and Management*, 74, 171–182, <https://doi.org/10.1016/j.enconman.2013.05.019>
- Ramzan, F., Khan, M. U. G., Rehmat, A., Iqbal, S., Saba, T., Rehman, A. and Mehmood, Z. 2019. A deep learning approach for automated diagnosis and multi-class classification of alzheimer's disease stages using resting-state fMRI and residual neural networks. *Journal of Medical Systems*, 44(2), 37, <https://doi.org/10.1007/s10916-019-1475-2>.

- Ran, Z.Y. and Hu, B.G. 2017. Parameter identifiability in statistical machine learning: a review. *Neural Computation*, 29(5), 1151–1203. https://doi.org/10.1162/NECO_a_00947
- Rane, N. L., Achari, A., Saha, A., Poddar, I., Rane, J., Pande, C. B. and Roy, R. 2023. An integrated GIS, MIF, and TOPSIS approach for appraising electric vehicle charging station suitability zones in Mumbai, India. *Sustainable Cities and Society*, 97, <https://doi.org/10.1016/j.scs.2023.104717>.
- Redmon, J. and Farhadi, A. 2017. YOLO9000: Better, Faster, Stronger. 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 21-26 July, Book of Proceedings, 6517–6525, Honolulu, USA, <https://doi.org/10.1109/CVPR.2017.690>.
- Redmon, J., Divvala, S., Girshick, R. and Farhadi, A. 2016. You Only Look Once: Unified, Real-Time Object Detection, 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 27-30 June, Book of Proceedings, 779–788, New York, USA, <https://doi.org/10.1109/CVPR.2016.91>.
- Regan, M. A., Hallett, C. and Gordon, C. P. 2011. Driver distraction and driver inattention: definition, relationship and taxonomy. *Accident Analysis and Prevention*, 43(5), 1771–1781, <https://doi.org/10.1016/j.aap.2011.04.008>.
- Ren, Y.S., Ma, C.Q., Kong, X.L., Baltas, K. and Zureigat, Q. 2022. Past, present, and future of the application of machine learning in cryptocurrency research. *Research in International Business and Finance*, 63, 101799, <https://doi.org/10.1016/j.ribaf.2022.101799>.
- Rouari, A., Moussaoui, A., Chahir, Y., Rauf, H. T. and Kadry, S. 2021. Deep CNN-based autonomous system for safety measures in logistics transportation. *Soft Computing*, 25(18), 12357–12370, <https://doi.org/10.1007/s00500-021-05949-1>.
- Saaty, T. 2008. Decision making with the Analytic hierarchy process. *International Journal of Services Sciences*, 1(1), 83–98, <https://doi.org/10.1504/IJSSCI.20-08.017590>.
- Saaty, T. L. (1977). A scaling method for priorities in hierarchical structures. *Journal of Mathematical Psychology*, 15(3), 234–281, [https://doi.org/10.1016/0022-2496\(77\)90033-5](https://doi.org/10.1016/0022-2496(77)90033-5).
- Saaty, T. L. 1980. *The Analytic Hierarchy Process*, McGraw-Hill International Book Company, 287, New York.
- Sabigaba, M., Jing, L., Mbanjumucyo, G., Mumporeze, L., Beeman, A. and Martin, K. D. 2023. Epidemiology and outcomes of geriatric trauma patients consulting at the center hospitalier universitaire de Kigali emergency department. *African Journal of Emergency Medicine*, 13(4), 221–224, <https://doi.org/10.1016/j.afjem.2023.08.001>.

- Sahoo, G. K., Das, S. K. and Singh, P. 2022. A deep learning-based distracted driving detection solution implemented on embedded system. *Multimedia Tools and Applications*, 82, 11697-11720, <https://doi.org/10.1007/s11042-022-13450-6>.
- Saifuzzaman, M., Haque, M., Zheng, Z. and Washington, S. 2015. Impact of mobile phone use on car-following behaviour of young drivers. *Accident Analysis & Prevention*, 82, 10–19, <https://doi.org/10.1016/j.aap.2015.05.001>.
- Sajid, F., Javed, A. R., Basharat, A., Kryvinska, N., Afzal, A. and Rizwan, M. 2021. An efficient deep learning framework for distracted driver detection. *IEEE Access*, 9, 169270–169280. <https://doi.org/10.1109/ACCESS.2021.3138137>.
- Seghiour, A., Abbas, H. A., Chouder, A. and Rabhi, A. 2023. Deep learning method based on autoencoder neural network applied to faults detection and diagnosis of photovoltaic system. *Simulation Modelling Practice and Theory*, 123, 102704, <https://doi.org/10.1016/j.simpat.2022.102704>.
- Sembajwe, G., Kassaw, C., Petrov, A. and Hareru, H. E. 2022. The epidemiology of road traffic accidents and associated factors among drivers in Dilla Town, Southern Ethiopia. *Frontiers in Public Health*, 10, 1007308, <https://doi.org/10.3389/fpubh.2022.1007308>.
- Sennaroglu, B. and Varlik, Celebi, G. 2018. A military airport location selection by AHP integrated PROMETHEE and VIKOR methods. *Transportation Research Part D: Transport and Environment*, 59, 160–173, <https://doi.org/10.1016/j.trd.2017.12.022>.
- Shajari, A., Asadi, H., Glaser, S., Arogonlo, A., Mohamed, S., Kooijman, L., Abu Alqumsan, A. and Nahavandi, S. 2023. Detection of driving distractions and their impacts. *Journal of Advanced Transportation*, 2023, 2118553, 1–17, <https://doi.org/10.1155/2023/2118553>.
- Sharma, N., Advani, M., Dhyani, R., Nagar, S. and Chaudhary, H. 2022. Reduction in idling fuel losses and corresponding emissions due to awareness campaign at the signalized intersections in delhi. *Transportation in Developing Economies*, 8(11), 1-11, <https://doi.org/10.1007/s40890-021-00146-z>.
- Sharma, N., Baral, S., Paing, M. P. and Chawuthai, R. 2023. Parking time violation tracking using YOLOv8 and tracking algorithms. *Sensors*, 23(13), 1-14, <https://doi.org/10.3390/s23135843>.
- Sharma, N., Kumar, P., Dhyani, R., Ravisekhar, C. and Ravinder, K. 2019. Idling fuel consumption and emissions of air pollutants at selected signalized intersections in Delhi. *Journal of Cleaner Production*, 212, 8-21, <https://doi.org/10.1016/j.jclepro.2018.11.275>.
- Sidey-Gibbons, J. A. M. and Sidey-Gibbons, C. J. 2019. Machine learning in medicine: a practical introduction. *BMC Medical Research Methodology*, 19(1), 64, <https://doi.org/10.1186/s12874-019-0681-4>.

- Sieklicka, A., Chądzyńska, P. and Iwanowicz, D. 2022. Analysis of the behavior of vehicle drivers at signal-controlled intersection approach while waiting for a green signal-a case study in Poland. *Applied Sciences*, 12(19), <https://doi.org/10.3390/app121910133>.
- Singh, H., & Kathuria, A. 2021. Profiling drivers to assess safe and eco-driving behavior – a systematic review of naturalistic driving studies. *Accident Analysis and Prevention*, 161, <https://doi.org/10.1016/j.aap.2021.106349>.
- Soylu, E. and Soylu, T. 2023. A performance comparison of YOLOv8 models for traffic sign detection in the Robotaxi-full scale autonomous vehicle competition. *Multimedia Tools and Applications*, 1-31, <https://doi.org/10.1007/s11042-023-16451-1>.
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I. and Salakhutdinov, R. 2014. Dropout: A simple way to prevent neural networks from overfitting. *Journal of Machine Learning Research*, 15, 1929–1958.
- Sun, L., Hu, G., Chen, C., Cai, H., Li, C., Zhang, S. and Chen, J. 2022. Lightweight apple detection in complex orchards using YOLOV5-PRE. *Horticulturae*, 8(12), <https://doi.org/10.3390/horticulturae8121169>.
- Şenalp, F. M. 2022. Termal görüntü çözünürlüğünün artırılması için derin öğrenme tabanlı bulut sisteminin geliştirilmesi. Doktora Tezi, Konya Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, Elektrik-Elektronik Mühendisliği Ana Bilim Dalı, 94, Konya.
- Tang, Y. M., Ip, A. W. H. and Li, W. 2022. Artificial intelligence approach for aerospace defect detection using single-shot multibox detector network in phased array ultrasonic, In: *Aerospace Engineering*, Yung, K. L., Ip, A. W. H., Xhafa, F. and Tseng, S. I. (eds.), Elsevier, 1-27, Amsterdam, <https://doi.org/10.1016/B978-0-12-821051-2.00008-8>.
- Tien, P. W., Wei, S., Darkwa, J., Wood, C. and Calautit, J. K. 2022. Machine learning and deep learning methods for enhancing building energy efficiency and indoor environmental quality – a review. *Energy and AI*, 10, 100198. <https://doi.org/10.1016/j.egyai.2022.100198>
- Toepfer, J. R. 2019. A comparison of multi-attribute utility theory, the analytic hierarchy process, the analytic network process, and new hybrid approaches for a case study involving radon. Ph.D Thesis, Old Dominion University, Engineering Management & Systems Engineering, 693, Norfolk, Virginia.
- Tortum, A. 2003. Yapay sinir ağları ve birleştirilmiş sinirsel bulanık sistemler ile şehirlerarası yük taşınması tür seçiminin modellenmesi. Doktora Tezi, Atatürk Üniversitesi, Fen Bilimleri Enstitüsü, İnşaat Mühendisliği Ana Bilim Dalı, 389, Erzurum.
- Turan, M. 2017. Web Sitesi: <https://www.aa.com.tr/tr/sirkethaberleri/finans/trafik-kazalarinin-yuzde-60i-cep-telefonu-kullanimindan-kaynaklaniyor/635846>, Erişim Tarihi: 04.09.2022.

- Turner, A. 2022. Web Sitesi: <https://www.bankmycell.com/blog/how-many-phones-are-in-the-world>, Erişim Tarihi: 04.09.2022.
- Uijlings, J. R. R., van de Sande, K. E. A., Gevers, T. and Smeulders, A. W. M. 2013. Selective search for object eecognition. *International Journal of Computer Vision*, 104(2), 154–171 <https://doi.org/10.1007/s11263-013-0620-5>.
- Unal Cilek, M., Guner, E. D. and Tekin, S. 2022. The combination of fuzzy analytical hierarchical process and maximum entropy methods for the selection of wind farm location. *Environmental Science and Pollution Research*, 29(43), 65391–65406, <https://doi.org/10.1007/s11356-022-20477-7>.
- Valeriano, L. C., Napoletano, P. and Schettini, R. 2018. Recognition of Driver Distractions Using Deep Learning. *IEEE 8th International Conference on Consumer Electronics (ICCE)*, 2-5 September, Book of Proceedings, 1-6, Berlin, Germany.
- Vargas, L. G. 1990. An overview of the analytic hierarchy process and its applications. *European Journal of Operational Research*, 48(1), 2–8, [https://doi.org/10.1016/0377-2217\(90\)90056-H](https://doi.org/10.1016/0377-2217(90)90056-H)
- Wagner, B., Taffner, F., Karaca, S. and Karge, L. 2022. Vision based detection of driver cell phone usage and food consumption. *IEEE Transactions on Intelligent Transportation Systems*, 23(5), 4257–4266, <https://doi.org/10.1109/TITS.2020.3043145>.
- Wang, C. N., Le, T. Q., Chang, K. H. and Dang, T. T. 2022. Measuring road transport sustainability using MCDM-based Entropy objective weighting method. *Symmetry*, 14(5), <https://doi.org/10.3390/sym14051033>.
- Wang, C., Bochkovskiy, A. and Liao, H.Y.M. 2022. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors. *arXiv preprint arXiv:2207.02696*
- Webb, M. J. 2018. Estimating uncertainty attributable to inconsistent pairwise comparisons in the Analytic Hierarchy Process (AHP). Ph.D Thesis, The George Washington University, The School of Engineering and Applied Science, 130, Columbia, USA.
- Weihong, B., Yun, J., Jiaxin, L., Lingling, S., Guangwei, F. and Wa, J. 2023. In-Situ detection method of jellyfish based on improved Faster R-CNN and FP16. *IEEE Access*, 11, 81803–81814, <https://doi.org/10.1109/ACCESS.2023.3300655>.
- Wieczorek, W. F. and Delmerico, A. M. 2009. Geographic information systems. *Wiley Interdisciplinary Reviews: Computational Statistics*, 1(2), 167–186, <https://doi.org/10.1002/wics.21>.

- Wu, D., Jiang, S., Zhao, E., Liu, Y., Zhu, H., Wang, W. and Wang, R. 2022. Detection of camellia oleifera fruit in complex scenes by using YOLOv7 and data augmentation. *Applied Sciences*, 12(22), <https://doi.org/10.3390/app122211318>.
- Xing, Y., Lv, C., Wang, H., Cao, D., Velenis, E. and Wang, F.Y. 2019. Driver activity recognition for intelligent vehicles: a deep learning approach. *IEEE Transactions on Vehicular Technology*, 68(6), 5379–5390, <https://doi.org/10.1109/TVT.2019.2908425>.
- Xiong, Q., Lin, J., Yue, W., Liu, S., Liu, Y. and Ding, C. 2019. A Deep Learning Approach to Driver Distraction Detection of Using Mobile Phone, 2019 IEEE Vehicle Power and Propulsion Conference (VPPC), 14-17 October, Book of Proceedings, 1–5, Hanoi, Vietnam, <https://doi.org/10.1109/VPPC46532.2019.8952474>.
- 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, <https://doi.org/10.1007/s13244-018-0639-9>.
- Yanbin, Y., Lijuan, Z., Mengjun, L., and Ling, S. 2017. Early Warning of Traffic Accident in Shanghai Based on Large Data Set Mining, 2016 International Conference on Intelligent Transportation, Big Data and Smart City (ICITBS), 17-18 October, Book of Proceedings, 1-4, Changsha, China.
- Yang, J. and Yang, G. 2018. Modified convolutional neural network based on dropout and the stochastic gradient descent optimizer. *Algorithms*, 11(3), 1-15, <https://doi.org/10.3390/a11030028>.
- Yılmaz, M., Alp, H., Tosunoğlu, F., Aşıkoğlu, Ö. L. and Eriş, E. 2022. Impact of climate change on meteorological and hydrological droughts for Upper Coruh Basin, Turkey. *Natural Hazards*, 112(2), 1039–1063, <https://doi.org/10.1007/s11069-022-05217-x>.
- Zahedi, F. 1986. The analytic hierarchy process: a survey of the method and its applications. *Interfaces*, 16(4), 96–108.
- Zare, Banadkouki, M. R. 2023. Selection of strategies to improve energy efficiency in industry: a hybrid approach using entropy weight method and fuzzy TOPSIS. *Energy*, 279, <https://doi.org/10.1016/j.energy.2023.128070>.
- Zhang, L., Cui, B., Yang, M., Guo, F. and Wang, J. 2019. Effect of using mobile phones on driver's control behavior based on naturalistic driving data. *International Journal of Environmental Research and Public Health*, 16(8), <https://doi.org/10.3390/ijerph16081464>.
- Zhong, R., Salehi, C. and Johnson, R. 2022. Machine learning for drilling applications: a review. *Journal of Natural Gas Science and Engineering*, 108, 104807, <https://doi.org/10.1016/j.jngse.2022.104807>.

- Zhou, J., Zhang, Y. and Wang, J. 2023. RDE-YOLOv7: an improved model based on YOLOv7 for better performance in detecting dragon fruits. *Agronomy*, 13(4), <https://doi.org/10.3390/agronomy13041042>.
- Zhou, L., Pan, S., Wang, J. and Vasilakos, A. V. 2017. Machine learning on big data: Opportunities and challenges. *Neurocomputing*, 237, 350–361, <https://doi.org/10.1016/j.neucom.2017.01.026>.
- Zhou, R., Zhang, Y. and Shi, Y. 2020. Driver's distracted behavior: The contribution of compensatory beliefs increases with higher perceived risk. *International Journal of Industrial Ergonomics*, 80, 103009, <https://doi.org/10.1016/j.ergon.2020.103009>.

