

**TOBB EKONOMİ VE TEKNOLOJİ ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**

**BÜYÜK VERİ ALGORİTMALARIYLA BÜYÜK ŞEHİRLERİN TRAFİK  
PROBLEMLERİNİN İNCELENMESİ**

**YÜKSEK LİSANS TEZİ**  
**Yusuf Gökhan KÜÇÜKAYAN**

**Bilgisayar Mühendisliği Anabilim Dalı**

**Tez Danışmanı: Yrd. Doç. Dr. Ahmet Murat ÖZBAYOĞLU**

**Nisan 2016**

Fen Bilimleri Enstitüsü Onayı

.....  
**Prof. Dr. Osman EROĞUL**  
Müdür

Bu tezin Yüksek Lisans derecesinin tüm gereksinimlerini sağladığını onaylarım.

.....  
**Prof. Dr. Murat ALANYALI**  
Anabilimdalı Başkanı

TOBB ETÜ, Fen Bilimleri Enstitüsü'nün **131111028** numaralı Yüksek Lisans öğrencisi **Yusuf Gökhan KÜÇÜKAYAN**'nın ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı "**BÜYÜK VERİ ALGORİTMALARIYLA BÜYÜK ŞEHİRLERİN TRAFİK PROBLEMLERİNİN İNCELENMESİ**" başlıklı tezi **11.04.2016** tarihinde aşağıda imzaları olan jüri tarafından kabul edilmiştir.

**Tez Danışmanı:** **Yrd. Doç. Dr. A. Murat ÖZBAYOĞLU** .....  
TOBB Ekonomi ve Teknoloji Üniversitesi

**Jüri Üyeleri:** **Prof. Dr. Erdoğan DOĞDU (Başkan)** .....  
TOBB Ekonomi ve Teknoloji Üniversitesi

**Yrd. Doç. Dr. Atila BOSTAN** .....  
Atılım Üniversitesi

## TEZ BİLDİRİMİ

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, alıntı yapılan kaynaklara eksiksiz atıf yapıldığını, referansların tam olarak belirtildiğini ve ayrıca bu tezin TOBB ETÜ Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırlandığını bildiririm.

Yusuf Gökhan KÜÇÜKAYAN

## ÖZET

Yüksek Lisans Tezi

### BÜYÜK VERİ ALGORİTMALARIYLA BÜYÜK ŞEHİRLERİN TRAFİK PROBLEMLERİNİN İNCELENMESİ

Yusuf Gökhan KÜÇÜKAYAN

TOBB Ekonomi ve Teknoloji Üniversitesi  
Fen Bilimleri Enstitüsü  
Bilgisayar Mühendisliği Anabilim Dalı

Tez Danışmanı: Yrd. Doç. Dr. A. Murat ÖZBAYOĞLU

Tarih: Nisan 2016

Günümüzün sosyal ve insan yaşam standartları açısından en büyük problemlerinden birisi içinde bulunduğumuz trafik haline gelmiştir. Artan nüfus ve araç sayısı neticesinde mevcutta oluşan trafik problemleri katlanarak artmaktadır. Bu sebepten dolayı trafikte geçirilen zaman ve riskler de aynı oranda artmaktadır. Bu çalışmada araç trafiğinin rahatlatılması ve oluşabilecek risklerin minimuma veya önceden engellenebilmesi amaçlanmıştır. Bu kapsamda, büyük veri altyapıları ve algoritmaları, trafikte olay diye nitelendirilen kaza, trafik sıkışıklığı, yol çalışması, habersiz yapılan çalışmalar vb. gibi sebeplerden oluşabilecek aksaklıkların tespitinde kullanılmıştır. Bu tespitlerin yapılmasında yapay sinir ağlarından ve trafik problemi için optimize edilmiş modellerden faydalanılmıştır. Çalışmanın esas amacı büyük veri algoritmalarını kullanarak trafikte oluşabilecek herhangi bir olayın veya sıkışıklığın anlık tespiti ve buna bağlı olarak alınabilecek tedbirleri göstermektir. Tez kapsamında dünyada da en yoğun trafiklerden birisi olarak kabul gören İstanbul'un, pilot bölgesinden alınan trafik sensörlerindeki veriler işlenmiş olup toplamda 1 yıl içindeki veriler üzerinden model oluşturulup olay tespiti yapılmıştır. Yapılan çalışmalarda ve oluşturulan modelde %97 doğruluk oranıyla trafikteki olaylar tespit edilmiştir. Bu tespit edilen modele göre olay oluşmaya başladığında, verinin gelme hızını dikkate alarak, anlık tespit edilebilmektedir. Bu tespitlerden yola çıkarak önceden alınabilecek tedbirler ile olayın olduğu bölgedeki trafiğin diğer yollara aktarılması, olayın durumuna göre gerekli ekiplerin olay yerine gönderilmesi ve sinyalizasyon değişimleriyle kontrol altına alınıp bölgedeki trafik yoğunluğunun ve trafik güvenliğinin sağlanması hedeflenmiştir. Yapılan çalışmalar İstanbul Büyükşehir Belediyesi Trafik Müdürlüğü'nün 2015 yılı trafik verisi kapsamında yapılmış olup

değişen trafik koşullarına göre oluşturulan model değişim koşullarına göre geliştirilip uyum sağlanması düşünülmüştür.

**Anahtar Kelimeler:** Olay algılama, Trafik modelleme, Yapay sinir ağları.



## **ABSTRACT**

Master of Science

### **ANALYSIS OF THE TRAFFIC FLOW AND ACCIDENTS WITH BIG DATA ALGORITHMS**

Yusuf Gökhan KÜÇÜKAYAN

TOBB University of Economics and Technology  
Institute of Natural and Applied Sciences  
Department of Computer Engineering

Supervisor: Asst. Prof. Ahmet Murat ÖZBAYOĞLU

Date: April 2015

In terms of social and individual living conditions, traffic has been one of the most significant problems of today's world. As a result of increasing population and vehicle number, existing traffic problems increase exponentially. Because of this reason, time wasted in traffic and possibility of having an accident increases with the rate. This thesis intends to relieve the vehicle traffic and reduce the probability of occurrence of risks to minimum or prevent in advance. In this context, big data infrastructures and algorithms are used in order to predict accident, traffic congestion, and road works, without notice works, which are named as "event". To predict all these events, this work takes advantages of artificial neural networks and models optimized for traffic congestion problems. The main purpose of the study is to predict real-time traffic events or congestion probability on time and offer related precautions to be taken. In the context of the thesis, the data from the traffic sensors has been collected for one year and used to form a model from the pilot area of Istanbul, which is known as one of the most crowded traffic on the world. As a result of the study and the model, traffic events has been detected with an accuracy rate of 97%. The events have been detected taking in the consideration of the data velocity. Based on the detections, the thesis has aimed transferring the traffic to another road, notifying the emergency units and proving the traffic security and resolving the traffic congestion with the help of the change in signalization. The study has been constructed with the 2015 traffic data from Istanbul Metropolitan Municipality Traffic Unit and the model formed by this data has been considered to be developed and accommodated with the changing conditions.

**Keywords:** Event detection, Traffic modelling, Neural network.

## TEŐEKKÜR

Çalıőmalarım boyunca deęerli yardım ve katkılarıyla beni yönlendiren hocam Yrd. Doç. Dr. Ahmet Murat ÖZBAYOęLU'na, kıymetli tecrübelerinden faydalandıęım TOBB Ekonomi ve Teknoloji Üniversitesi Bilgisayar Mühendislięi Bölümü öğretim üyelerine, AR-GE (Araőtırma ve Geliőtirme) bursu saęladıęı için TOBB Ekonomi ve Teknoloji Üniversitesi'ne ve destekleriyle her zaman yanımda olan aileme ve arkadaşlarıma çok teőekkür ederim.

Tezde kullanılan verilerin saęlanması hususunda İstanbul Büyük Őehir Belediyesi Trafik Müdürlüęü'ne, bünyesinde bulunduęum Dr. M. Umut DEMİREZEN'in yönetiminde olduęu STM Savunma Teknolojileri Mühendislik ve Ticaret A.Ő. Büyük Veri ve Veri Bilimi Grubu'na altyapı ve desteklerinden dolayı teőekkürlerimi sunarım.

Her zaman yanımda olan ve yardım eden, manevi desteklerini bir an bile esirgemeyen o güzel ve tatlı insana ayrıca çok teőekkür ederim.

## İÇİNDEKİLER

	<u>Sayfa</u>
<b>ÖZET</b> . . . . .	<b>iv</b>
<b>ABSTRACT</b> . . . . .	<b>vi</b>
<b>TEŞEKKÜR</b> . . . . .	<b>vii</b>
<b>İÇİNDEKİLER</b> . . . . .	<b>viii</b>
<b>ŞEKİL LİSTESİ</b> . . . . .	<b>x</b>
<b>ÇİZELGE LİSTESİ</b> . . . . .	<b>xii</b>
<b>KISALTMALAR</b> . . . . .	<b>xiii</b>
<b>RESİM LİSTESİ</b> . . . . .	<b>xiv</b>
<b>1. GİRİŞ</b> . . . . .	<b>1</b>
<b>2. TRAFİK VE İLGİLİ LİTERATÜR ÇALIŞMALARI</b> . . . . .	<b>5</b>
2.1 Trafik Verileri Üzerinde Yapılan İyileştirme Çalışmaları . . . . .	5
2.2 Trafik Yönetim Sistemleri . . . . .	6
2.2.1 Aktif trafik talep yönetim sistemleri (active traffic demand management systems) . . . . .	7
2.2.2 Trafik optimizasyon kontrolörleri . . . . .	7
2.2.3 Trafik otomasyonu ve iletişimi . . . . .	7
2.2.4 Görüntü işleme yöntemleriyle trafik kontrolü . . . . .	8
2.3 Amaca Özel Araç Ağı (Vehicle Ad Hoc Network) . . . . .	8
2.3.1 Çevresel etkiler . . . . .	9
2.3.2 Trafik takip ve kaza tespiti . . . . .	10
2.3.3 Olay bazlı mimari (event driven architecture - eda) . . . . .	10
2.4 Trafikte Olay Tespit Çalışmaları . . . . .	10
2.4.1 Anomali tespit çalışmaları . . . . .	11
2.4.2 Trafik kaza tespit modelleri . . . . .	12
2.4.3 Sinir ağları ile kaza tespit modelleri . . . . .	12
2.4.4 Trafik kazaları ve destek vektör makinesi (support vector machine) . . . . .	14
2.4.5 Saklı markov modeli (hidden markov model) . . . . .	15
2.4.6 Mobil cihazlar ile olay algılama . . . . .	15
2.4.7 Sosyal ağlar ile olay tespiti . . . . .	17
2.5 Çevresel Etkilerin Trafik Etkileşimleri . . . . .	17
2.5.1 Hava koşullarının etkileri . . . . .	17
2.5.2 Coğrafi konum bazlı etkiler . . . . .	18
<b>3. VERİ ANALİZİ VE MODELLEME</b> . . . . .	<b>21</b>
3.1 Trafik Sensörleri . . . . .	22
3.1.1 Video dedektörü . . . . .	22
3.1.2 Led ekranlı radar sistemi . . . . .	23
3.1.3 Döngüsel sensör . . . . .	25
3.1.4 Bluetooth sensör . . . . .	26
3.1.5 Uzak mikrodalga radar sensör (rtms) . . . . .	27
3.2 Pilot Bölgedeki RTMS Sensörler . . . . .	29



3.2.1 Sensör bilgileri . . . . .	29
3.2.2 Sensör konumları . . . . .	30
3.3 Pilot Bölgedeki Olaylar . . . . .	31
3.4 Modeller ve Tanımları . . . . .	33
3.4.1 Yapay sinir ağları (artificial neural network) . . . . .	34
3.4.2 Yapay sinir ağlarının özellikleri ve kullanım alanları . . . . .	35
3.4.3 Yapay sinir ağlarının yapısı . . . . .	35
3.4.4 Yinelenebilir sinir ağları (recurrent neural network) . . . . .	36
3.4.5 Yinelenebilir sinir ağları kullanımının güçlükleri . . . . .	37
3.5 Büyük Veri Yöntemleriyle Verinin Analizi . . . . .	37
3.5.1 Çıkar-dönüştür-yükle (extract-transform-load etl) yöntemi ile verinin hazırlanması . . . . .	38
3.5.2 Hazırlanan verinin analizi ve incelenmesi . . . . .	41
<b>4. GELİŞTİRİLEN MODEL VE DENEYSEL SONUÇLAR . . . . .</b>	<b>47</b>
4.1 Model Girdilerinin Ayarlanması . . . . .	47
4.1.1 Model girdilerinin belirlenmesi . . . . .	47
4.1.2 Şerit verilerinden yol verisi hesaplanması . . . . .	48
4.1.3 Yol kapasite hesaplanması . . . . .	49
4.1.4 Model girdilerinin temizlenmesi . . . . .	49
4.1.5 Model olay girdilerinin işaretlenmesi ve eğitim setinin hazırlan- ması . . . . .	53
4.2 Modelin Sinir Ağları ile Denenmesi . . . . .	53
4.2.1 Modelin girdiler ile denenmesi . . . . .	54
4.2.2 Modelin sinir ağları ile çıktıları . . . . .	56
4.3 Olay Tespit Modelinin Sonuçları . . . . .	59
4.4 Olay Tespit Modelinden Geliştirilen Uygulama . . . . .	61
<b>5. ÇIKARIMLAR VE TARTIŞMA . . . . .</b>	<b>65</b>
5.1 Tartışma . . . . .	65
5.2 Geleceğe Yönelik Çalışmalar . . . . .	66
<b>KAYNAKLAR . . . . .</b>	<b>67</b>
<b>EKLER . . . . .</b>	<b>73</b>
<b>ÖZGEÇMİŞ . . . . .</b>	<b>87</b>

## ŞEKİL LİSTESİ

	<b>Sayfa</b>
Şekil 2.1: Çalışma öncesi sinir ağı modeli. . . . .	13
Şekil 2.2: Çalışma sonrası sinir ağı modeli. . . . .	13
Şekil 2.3: Kaza anı resim yükleme. . . . .	16
Şekil 2.4: Kanada'da hava olaylarının trafiğe etkisi. . . . .	18
Şekil 3.1: Video dedektörü çalışma prensibi. . . . .	23
Şekil 3.2: Döngüsel sensör çalışma prensibi. . . . .	25
Şekil 3.3: Bluetooth otoyol algılama sistemi. . . . .	26
Şekil 3.4: RTMS sensör. . . . .	27
Şekil 3.5: RTMS 429 numaralı sensörün yıllık verisinin 24 saatlik gösterimi. . .	30
Şekil 3.6: Seçilen pilot bölgedeki sensörlerin haritası. . . . .	30
Şekil 3.7: Tüm olayların harita üzerindeki konumları. . . . .	33
Şekil 3.8: Örnek yapay sinir ağı topolojisi. . . . .	34
Şekil 3.9: Yapay sinir ağlarının katmanları. . . . .	36
Şekil 3.10: McCulloch-Pitts nöron modeli. . . . .	36
Şekil 3.11: Yinelenen sinir ağı modeli. . . . .	37
Şekil 3.12: HDDS altapısı. . . . .	39
Şekil 3.13: Hadoop MapReduce çalışma prensibi. . . . .	40
Şekil 3.14: Verinin MS Sql veri tabanından HDDS'ye aktarılması. . . . .	40
Şekil 3.15: Bollinger Bant - RTMS 441 numaralı sensörün pazartesi günlerinin yıllık verisi. . . . .	43
Şekil 3.16: Bollinger Bant - RTMS 441 numaralı sensörün cuma günlerinin yıllık verisi. . . . .	43
Şekil 3.17: Bollinger Bant - RTMS 336 numaralı sensörün cuma günlerinin yıllık verisi. . . . .	44
Şekil 3.18: Polinom - RTMS 441 numaralı sensörün cuma günlerinin yıllık verisi. . . . .	44
Şekil 3.19: Polinom - RTMS 436 numaralı sensörün cuma günlerinin yıllık verisi. . . . .	45
Şekil 3.20: Polinom - RTMS 430 numaralı sensörün cuma günlerinin yıllık verisi. . . . .	45
Şekil 4.1: RTMS 345 numaralı sensörün S1 şerit histogramı. . . . .	50
Şekil 4.2: RTMS 345 numaralı sensörün S2 şerit histogramı. . . . .	50
Şekil 4.3: RTMS 345 numaralı sensörün S3 şerit histogramı. . . . .	50
Şekil 4.4: RTMS 441 numaralı sensörün cuma günlerinin yıllık verisi. . . . .	51
Şekil 4.5: RTMS 441 numaralı sensörün pazartesi günlerinin yıllık verisi. . . . .	52
Şekil 4.6: Kullanılan sinir ağı yapısı. . . . .	54
Şekil 4.7: Sinir ağının sonuç göstergeleri. . . . .	57
Şekil 4.8: Sinir ağının eğitim kısmındaki hata grafiği. . . . .	57
Şekil 4.9: Modelin doğrulama grafiği - 15. tekrar. . . . .	58
Şekil 4.10: Sinir ağı performans grafikleri. . . . .	58

Şekil 4.11: Uygulamadaki modelin, olay tespitinde bulunmadığı bir andaki sensör bölgesinin görünümü. . . . .	62
Şekil 4.12: Uygulamadaki modelin, olay tespitinde bulunduğu bir andaki sensör bölgesinin görünümü. . . . .	63
Şekil 5.1: RTMS 345 numaralı sensörün 2 haftalık işlenmemiş verisi. . . . .	76
Şekil 5.2: RTMS 429 numaralı sensörün 2015 yılı işlenmemiş verisi. . . . .	76
Şekil 5.3: RTMS 429 numaralı sensörün 2 haftalık işlenmemiş verisinin grafiksel olarak yakınlaştırılmış hali. . . . .	77
Şekil 5.4: RTMS 430 numaralı sensörün 2 haftalık işlenmemiş verisi. . . . .	77
Şekil 5.5: RTMS 432 numaralı sensörün 2 haftalık işlenmemiş verisi. . . . .	78
Şekil 5.6: RTMS 436 numaralı sensörün 2015 yılı işlenmemiş verisi. . . . .	78
Şekil 5.7: RTMS 440 numaralı sensörün 2015 yılı işlenmemiş verisi. . . . .	79
Şekil 5.8: RTMS 441 numaralı sensörün 2015 yılı işlenmemiş verisi. . . . .	79
Şekil 5.9: RTMS 436 numaralı sensörün S1 şerit histogramı. . . . .	81
Şekil 5.10: RTMS 436 numaralı sensörün S2 şerit histogramı. . . . .	81
Şekil 5.11: RTMS 436 numaralı sensörün S3 şerit histogramı. . . . .	82
Şekil 5.12: RTMS 430 numaralı sensörün S1 şerit histogramı. . . . .	82
Şekil 5.13: RTMS 430 numaralı sensörün S2 şerit histogramı. . . . .	83
Şekil 5.14: RTMS 430 numaralı sensörün S3 şerit histogramı. . . . .	83
Şekil 5.15: RTMS 440 numaralı sensörün S1 şerit histogramı. . . . .	84
Şekil 5.16: RTMS 440 numaralı sensörün S2 şerit histogramı. . . . .	84
Şekil 5.17: RTMS 440 numaralı sensörün S3 şerit histogramı. . . . .	85
Şekil 5.18: RTMS 441 numaralı sensörün S1 şerit histogramı. . . . .	85
Şekil 5.19: RTMS 441 numaralı sensörün S2 şerit histogramı. . . . .	86
Şekil 5.20: RTMS 441 numaralı sensörün S3 şerit histogramı. . . . .	86

## ÇİZELGE LİSTESİ

	<b>Sayfa</b>
Çizelge 1.1: Genel kaza istatistikleri. . . . .	1
Çizelge 1.2: İllere göre 2014 yılı kaza istatistikleri . . . . .	2
Çizelge 2.1: Yang, Kalpakis ve Biem, elde edilen sonuçlar. . . . .	12
Çizelge 3.1: İBB Trafik RTMS verisi . . . . .	29
Çizelge 3.2: İBB olaylar veri tablosundan örnek veri seti. . . . .	32
Çizelge 3.3: Hatalı verinin çıkarımı. . . . .	41
Çizelge 3.4: Şerit korelasyon tablosu. . . . .	42
Çizelge 4.1: Hatalı veri inceleme tablosu. . . . .	52
Çizelge 4.2: Deneme seti örnek veri tablosu, 270.000'lik veri seti. . . . .	55
Çizelge 4.3: Sinir ağının olay tespit sonuçları. . . . .	56
Çizelge 4.4: Karışıklık matrisi(Confusion Matrix) tanımı. . . . .	59
Çizelge 4.5: Karışıklık matrisi(Confusion Matrix) verileri. . . . .	60
Çizelge 5.1: Edinilen trafik verisinin ham hali. . . . .	75

## KISALTMALAR

<b>İBB</b>	: İstanbul Büyük Şehir Belediyesi
<b>SVM</b>	: Destek Vektör Makinesi (Support Vector Machine)
<b>EDA</b>	: Olay Tabanlı Mimari (Event Driven Architecture)
<b>HDDS</b>	: Hadoop Dağıtık Dosya Sistemi (HDFS)
<b>ANN</b>	: Yapay Sinir Ağı (Artificial Neural Network)
<b>RNN</b>	: Yinelenen Sinir Ağı (Recurrent Neural Network)
<b>ATMS</b>	: Gelişmiş Trafik Yönetim Sistemi (Advanced Traffic Management Systems)
<b>APID</b>	: Çok Amaçlı Kaza Tespiti (All Purpose Incident Detection)
<b>VANET</b>	: Amaca Özel Araç Ağı (Vehicle AdHoc Network)
<b>GPS</b>	: Küresel Konumlandırma Sistemi (Global Pointing System)
<b>PCA</b>	: Temel Bileşenler Analizi (Principal Component Analysis)
<b>ED</b>	: Öklit Uzaklığı (Euclidean Distance)
<b>GIS</b>	: Coğrafi Bilgi Sistemi (Geographic Information System)
<b>SQL</b>	: Yapılandırılmış Sorgu Dili (Structured Query Language)
<b>GB</b>	: GigaByte
<b>VACS</b>	: Araç Otomasyon ve İletişim Sistemi
<b>ATDMS</b>	: Aktif Trafik Talep Yönetim Sistemi
<b>RTMS</b>	: Uzak Mikrodalga Trafik Sensörü (Remote Traffic Microwave Sensor)

## RESİM LİSTESİ

	<u>Sayfa</u>
Resim 2.1: Video izleme yöntemi ile anormal olay tespiti. . . . .	11
Resim 3.1: Led ekranlı trafik bilgi paneli. . . . .	24
Resim 3.2: RTMS sensör ölçümleri. . . . .	28



## 1. GİRİŞ

Trafik, günümüzde gittikçe önemi artan ve insan ile birlikte sürekli gelişmeye açık bir kavramdır. Bu çerçevede trafik, önemi riskleriyle birlikte yükselen teknolojinin eşliğinde artan bir olgudur. Trafiğin insan hayatına girmesi ve fark edilmesi ilk olarak MS 1500 yıllarında, Leonardo da Vinci'nin insan ve araç trafiğini ayırması ve yayalara kaldırım yapılması önerisiyle ortaya atılmıştır [1]. Tarihte yaşanan trafik kazaları trajedileri aynı zamanda araçların teknolojisinin gelişmesine ve insanların bu konuda bilinçlenmesine önayak olmuştur. Bu yaşanan olumsuzluklardan ötürü gelişen teknolojinin ve insan güvenliğine verilen önemin doğrultusunda trafik üstünde ve trafiği oluşturan unsurlar üstünde yapılan çalışmalar arttırılmıştır.

İnsani boyutlar düşünüldüğünde, trafik insanı sadece ulaşım için etkileyen bir etmen olmaktan çıkarak psikolojik ve sosyolojik olarak da etkilemeye başlamıştır. Trafikte geçirilen uzun zamanlar insanların psikolojik dengelerini bozabilmekte ve yaşanan üzücü olaylar insanların trafiğe çıktıklarında tedirginlik hissiyatlarını da etkilemektedir. Bu sebeplerden ötürü, bu kapsamda yapılan çalışmalar ve iyileştirmeler gün geçtikçe, teknolojinin de gelişmesiyle birlikte, artmakta ve olumsuz etkilerinin minimuma indirilmesine çalışılmaktadır.

Türkiye'deki trafik kazaları incelendiğinde yıllar bazında trafiğe giren araç sayıları arttıkça oluşan trafik kazalarının da arttığı gözlemlenmiştir. Trafik kazalarının en büyük sebepleri sürücülerin ve yayaların kurallara uymayarak kendilerini ve trafikteki diğer unsurları tehlikeye atmasıdır. Kazalarla ilgili genel istatistikler Çizelge 1.1 [2] ve Çizelge 1.2 [3] ile gösterilmektedir.

Çizelge 1.1: Genel kaza istatistikleri.

Yıl	Kaza Sayısı	Ölü Sayısı	Yaralı Sayısı
2005	620.789	4.505	154.086
2006	728.755	4.633	169.080
2007	825.561	5.007	189.057
2008	950.120	4.236	184.468
2009	1.053.346	4.324	201.380
2010	1.104.388	4.045	211.496
2011	1.228.928	3.835	238.074
2012	1.296.634	3.750	268.079
2013	1.207.354	3.685	274.829
2014	1.199.010	3.524	285.059

Çizelge 1.2: İllere göre 2014 yılı kaza istatistikleri .

İller	Ölüm.-Yaral. Kaza	Mad.Has.Kaza	Ölü	Yaralı
ANKARA	10.910	33.992	126	17.500
ANTALYA	5.805	6.552	95	8.871
BURSA	5.447	9.462	56	8.243
İSTANBUL	15.077	33.596	188	21.768
İZMİR	9.209	19.573	98	12.671
KAYSERİ	3.506	3.712	61	6.168
KONYA	5.754	6.368	101	9.308

İstatistiklerden anlaşılacağı üzere trafik ve trafik kazaları insan can ve mal kaybına sebep olmaktadır. Bu kapsamda trafik yönetim sistemlerinin sürekli geliştirilip yeni yöntemler ile güncel tutulması gerekmektedir. Kazaların trafiği etkilediği kadar, kaza veya olayların da tespiti ve buna göre alınacak önlemler de bir o kadar önem arz etmektedir. Trafikte bir olayın yaşanması ve bu olayın tespit edilmesi ileride oluşacak trafiği veya diğer olaylara sebebiyet teşkil etmesi nedeniyle oldukça önemlidir. Çünkü olay olduktan hemen sonra olayın tespiti yapılarak gerekli önlemler hızlı bir şekilde alınabilirse can ve mal güvenliği bir o kadar güvende olacaktır.

Bütün bu trafik ile ilgili tanımlar ve tehlikeler dâhilinde araç, trafiğinin oluşmasındaki en büyük etmenlerden bazıları araç kazaları ve trafik sıkışıklıklarıdır. Bu çalışma kapsamında, bu konular üstünde çalışılmış ve trafiğin oluşumu dâhilinde trafikteki olayların tespit edilebilmesi amaçlanmıştır. Trafikte oluşan olaylardan kastedilmek istenen şey trafikteki kazalar, yol yapım çalışmaları, trafik sıkışıklıkları, araç bozulması vb. gibi durumlardır. İstatistiklerden anlaşılacağı üzere, İstanbul trafik yoğunluğu ve trafik olaylarının en yoğun yaşandığı ildir. Bu kapsamda yapılacak çalışma için pilot şehir olarak İstanbul seçilmiştir. İstanbul'un 2015 yılı trafik verileri İstanbul Büyükşehir Belediyesi Trafik Müdürlüğü'nün izni ve müsadesi ile sağlanmıştır. Sağlanan veriler ile İstanbul'da seçilen pilot bölgedeki trafik akışı yıllık olarak analiz edilip trafikteki olaylar tespit edilmeye çalışılmıştır. Bu çalışmadaki hedef, büyük veri yöntemleriyle olayların tespitini sağlamak ve tespit edilen olaylar neticesinde trafik yönetim sistemlerine destek sağlamaktır. Çünkü, olayların tespit edilebilmesi ile olayın bulunduğu bölgeye yetkililerin erken müdahalede bulunabileceği ve erken müdahale ile oluşması muhtemel diğer olayların önüne geçilebileceği, ayrıca trafik güvenliğinin arttırılabileceği düşünülmektedir.

Bu kapsamda genel problem düşünüldüğünde İstanbul gibi metropol bir şehirde şehir trafiğinin parametreleri çok değişken ve dinamik olabilmektedir. İstanbul Büyükşehir Belediyesi Trafik Müdürlüğü yetkilileri ile yapılan görüşmelerden elde edilen bilgiler kapsamında geleneksel olay algılama metodolojileri her zaman doğru bir ölçüm yapamayabilmektedir. Geleneksel yöntemler dışında verilerin matematiksel ve bilimsel



yollarla incelenmesinin yenilikçi yaklaşımlar ile olay algılamada kesinlik ve doğruluk anlamında yenilikler getirebileceği düşünülmüştür. Bu yüzden veriler büyük veri yöntemleri ile incelenmiştir. Çalışmada kullanılan sinir ağları ile yaklaşık %97 doğruluk oranı ile olayların tespit edilebileceği saptanmıştır. Tezin diğer bölümlerinde detaylı olarak verilerin analizleri ve olay tespit modelleri üzerinde detaylı çalışmalar yapılmıştır.

Bölüm 2 içerisinde konu ile alakalı literatürdeki konsept çalışmalardan bahsedilmiştir. Geçmişten günümüze trafik konularında yapılmış çalışmalar anlatılmaya çalışılmıştır. Bölüm 3'te verinin analiz çalışmaları ve trafik modellemeleri üzerinde yapılan çalışmalardan, bölüm 4'te düşünülen modelin uygulaması ve sonuçlarıyla ilgili analiz çalışmalardan bahsedilmiştir. Bölüm 5'te ise sonuç doğruluk oranlarından, konu ile alakalı tartışma ve gelecek çalışmalardan bahsedilmiştir.





## 2. TRAFİK VE İLGİLİ LİTERATÜR ÇALIŞMALARI

Trafik ve bu alan ile ilgili çalışmalar, Türkiye’de, hem de halen gelişmekte olan ülkeler ve mevcutta akıllı şehir diye nitelendirilebilen şehirlerde için büyük problem arz etmektedir. Bu kapsamda yapılmış ve halen devam eden ciddi çalışmalar mevcuttur. Dünyadaki ve Türkiye’deki konsept çalışmalar gittikçe artmakta ve trafik problemine çözüm aranmaktadır. Konu ile alakalı çalışmalar aşağıda başlıklar altında sunulmuştur. Genel anlamda bakıldığında, trafik denilen problem çok parametrelili ve sürekli dinamikliğini kaybetmeyen ve insanın hayatını sosyal ve psikolojik açılardan etkileyen en büyük etmenlerden birisidir. Bu bölümde diğer çalışmalar yansıtılarak, bugüne kadarki literatüre girmiş çalışmaların özetleri ve kapsamaları anlatılmaya çalışılmıştır.

### 2.1 Trafik Verileri Üzerinde Yapılan İyileştirme Çalışmaları

Lee, otobanlar üzerindeki trafik takip verilerini iyileştirme üzerine yaptığı çalışmasında, birbirine bağlı denetim cihazlarından yararlanmış [4]. Bu verilerin yolcu bilgisi, rampa yerleştirme kararı, kaza algılama, seyahat süresi belirleme ve araç sınıflandırma gibi çeşitli alanlarda kullanıldığı belirtilen çalışma, söz konusu denetim araçlarının performansının toplanan veriye bağlı olduğunu belirtir. Verilerde meydana gelen hatanın, bunları takip eden diğer uygulamalarda da hataya sebep olduğunu savunan çalışma, özellikle bireysel araçlar söz konusu olduğunda, doğru verilerin oluşmasının güç olduğunu belirtir. Çalışmada söz konusu durumlarda meydana gelen iki hata incelenmiştir:

- \* Üzerinde sıçrama olarak tanımlanan yan yana şeritler arası olay karmaşası
- \* Nabız kırma olarak tanımlanan araçta meydana gelen durumun bir ya da birkaç farklı durum gibi algılanması.

Sonuç olarak ise, güncel hataları tanımlamak üzere algoritmalar geliştirilmiş ve test verileri ile çalışılmıştır.

Wang, kesin ve zamanlamalı trafik akış bilgisinin gelişmiş trafik yönetimi ve yolcu bilgi sistemleri için önemli birer kıstas olmasından yola çıkmıştır [5]. Güncel trafik bilgi sistemlerinin, kesin yol bilgisi olmadan tam doğru bilgiye ulaşmasının imkânsız olduğunu savunan Wang, gerçek zamanlı trafik kontrolü, dinamik yol rehberliği ve

kaza belirleme sistemlerinin konuyla ilgili olarak revaçta olduğunu belirtmiştir. Çalışmada, Toronto'da 1960'lardan bu yana kullanılan trafik denetleme sistemlerinin bugün 1500'den fazla sayıda olması ve halen geliştirme çalışmaları bulunduğu değerlendirilmiştir. Ontario gibi diğer 15 bölgede de benzer trafik denetleme ve otoyol takip sistemleri çalışmalarının açıklandığı çalışma, Endüktif Döngü Detektör (Inductive Loop Detector - ILD) sistemlerini ele alır. Maliyetten tasarruf ettirecek yapıya sahip ve ILD sistemlerinin yerini alacak yeni bir trafik kontrol yöntemi olarak Mikrodalga Trafik Sensör (Road Traffic Microwave Sensor - RTMS), çalışmanın asıl konusu olmuştur. Benzer sistemlerle karşılaştırılan ve yeni sistemin avantajlarının da anlatıldığı bu çalışma, RTMS'in yeni kullanım şekilleri üzerine yoğunlaşmıştır.

## 2.2 Trafik Yönetim Sistemleri

Trafik yönetim sistemlerinin iyileştirilmesi ve bu alandaki çalışmalar aktif olarak devam etmektedir. Trafik yönetim sistemlerinin zorluğu ve gün geçtikçe artan trafiğe cevap verememesi veya adaptasyon sağlayamaması yeni araştırmaların ve bulguların incelenmesine vesile olmuştur. Bu sayede yeni birçok teoriler ve yeni yöntemler büyüyen trafikler için geliştirilmiştir. Bu kısımda trafik yönetim sistemlerindeki araştırmalara değinilmiştir.

Masters, Lam ve Wong, trafik izleme ve kazalara müdahale etme amacı ile kullanılan gelişmiş trafik yönetim sistemlerinin (Advanced Traffic Management Systems-ATMS) erken uyarı mekanizmaları ile kaza belirleme ve yön tercihi konularında da kullanılabileceğini savunmuştur. Çalışmada yer verilen ve Toronto bölgesi için uygulanan gelişmiş trafik yönetim sistemi, COMPASS, birçok akıllı araç-yol sistemlerinin teknolojileri ile donatılmıştır. Çalışma, COMPASS olarak isimlendirilen bu sistemin geliştirilmesi ve otomatik kaza algılama algoritmalarının açıklanmasına yer verir. Söz konusu sistemin asıl amacı, trafik akışı takibinden yararlanarak, olası trafik kazalarını tahmin etmek ve gerekli koşullar içerisinde engellemeye yardımcı olmaktır. Sistem, iki farklı kaza algılama algoritması kullanır: Çok Amaçlı Olay Algılama (All Purpose Incident Detection - APID) ve Çift Üssel Düzeltme (Double Exponential Smoothing - DES). APID, trafik akış türlerini belirleme amacı ile üretilmiştir ve hafif ya da orta ölçekli trafik yoğunluğunda, genel yoğunluktan daha fazla görev almaktadır. DES ise, belirli zaman birimlerinde trafikte oluşan anormallikleri belirlemede görevlidir. Trafik izleme sinyali ve standart sapma verilerini kullanan algoritma, normal verilerin dışına çıktığında bir kaza olduğunu tespit edebilmektedir. COMPASS, trafik verisi olarak yoğunluk, doluluk oranı ve hızı kullanmaktadır. Her iki algoritma da, daha fazla veri kullanıldığında yanlış uyarı oranını daha belirgin düşürmektedir [6].

### **2.2.1 Aktif trafik talep yönetim sistemleri (active traffic demand management systems)**

Feng, Hourdos ve Davis, otoyollarda gerçek zamanlı trafik izleme yöntemlerini kullanarak, ortalama seyahat süresi hesaplamalarına yoğunlaşmıştır [7]. Çalışmada, Amerikan otoyol sistemlerinde kullanılan Aktif Trafik Talep Yönetim Sistemi (Active Traffic Demand Management Systems - ATDMS) yaklaşımına standart sapma eklenerek, otobüs ya da kamyon gibi farklı araç türlerinin farklı seyahat sürelerini belirlemek amaçlanmıştır. Seyahat süresini etkileyen etkenler olarak araç kullanım alışkanlıkları, etkin trafik ışığı süreleri, kavşak dönüş süreleri ve sürücü psikolojisi dikkate alınmıştır. Bayés teoremi kullanılarak yapılan çalışma, GPS verilerini kullanarak ortalama seyahat süreleri ve söz konusu etkenlerin trafik üzerindeki etkileri incelenmiştir.

### **2.2.2 Trafik optimizasyon kontrolörleri**

Pascale, Hoang ve Nair tarafından gerçekleştirilen çalışma, kentsel yollarda, kısa ve etkili bir ağ-seviyeli trafik kontrol sistemi sunmayı amaçlamıştır [8]. Çalışmada sunulan model, faz sınıflandırmasında görevli bir detektör ve faz geçişinde görevli detektör birleşimleri kullanılarak gerçekleştirilmiştir. Buradaki anahtar nokta, yolun herhangi bir sebeple verimsizleşmesi, yani kapasitesine etkisi, gibi geçici durumların tespit edilebilmesidir. Çalışmada, Dubai'de gerçekleştirilen adaptif trafik kontrol tabanlı SCATS kontrol sistemlerinden yararlanılmıştır. Trafiğin en yoğun olduğu zamanlarda bile, eskisinden %20 daha fazla kapasite ile kullanılacak yollar belirlenmiştir.

### **2.2.3 Trafik otomasyonu ve iletişimi**

Diakaki, Papageorgiou, Papamichail ve Nikolos tarafından yapılan trafik yönetim çalışması, araç otomasyon ve iletişim sistemlerinin yetersizliğinden yola çıkılarak başlamıştır [9]. Bilindiği üzere, Araç Otomasyonu ve İletişim Sistemi (Vehicle Automation and Communication Systems-VACS) seyahat sayısı, güvenlik, yakıt tüketimi, çevresel etmenler ve diğer negatif etmenleri takip etmek üzere kurulmuştur. Çalışmaya göre bu sistemler, trafik yönetimi için daha yenilikçi araçlar olarak kullanılabilir. Çalışmanın sonuçlarına bakıldığında, VACS kullanımı ile trafik yönetiminde pozitif bulgular artmıştır. Etkin bir analiz yöntemi olan SWOT analizi (strength-weakness-opportunities-threats) kullanılarak, ilgili konudaki farklı sınıflandırmalar gerçekleştirilmiştir. Aynı metot kullanılarak, güncel yöntemler ile gelecekte gerçekleştirilebilecek yeni kullanımlara yer verilmiştir.

#### 2.2.4 Görüntü işleme yöntemleriyle trafik kontrolü

Jain, Sharma ve Subramanian, trafik yoğunluğunun hedeflenen yere ulaşmada gecikme, yıllık ortalama yakıt tüketiminde artış ve benzer maddi zararları arttırdığını belirtir [10]. Bu çalışma, trafik yoğunluk seviyesi tespiti için CCTV kullanılarak görüntü işleme mekanizması sunar. CCTV, açılımı kapalı devre televizyon anlamına gelen, kameralar aracılığı ile alınan görüntünün belirli konumlara iletilmesini sağlayan sistemlerdir. Çalışmada kullanılan algoritma, özellikle düşük görüntü koşullarında, örneğin sis gibi, ve çok yoğun trafik durumlarında kullanılmak üzere tasarlanmıştır. Kenya ve Brezilya'da yapılan gerçek zamanlı çalışmalar sonucunda, küçük bölgelerdeki trafik ışığı koordinasyonu sağlayan ve "local de-congestion protocol" diye isimlendirilen bir yöntem sunulmuştur. Gerçekleme yapılarak elde edilen bir analiz ile bu çalışmanın yol kapasitesini arttırdığı ve yerel trafik ayarları ile yoğunluk azaltmada etkili olduğu ortaya konulmuştur.

Büyüközcü, video bazlı olay algılama probleminde sezgisel yöntemlerden esinlenerek yaklaşmıştır [11]. Çalışmada, otoban tünellerinden elde edilen görüntü verileri kullanılarak, sembolik veriler elde etme ve bu verilerden olay çıkarımı yapma amaçlanmıştır. Video algılamadan yola çıkılarak elde edilen veriler, görüntü işleme yöntemleri kullanılarak incelenmiş ve arka plan çıkarma, gölge indirgeme ve nesne izleme metotları kullanılmıştır. Kullanılan sistemde, tüneldeki aracın durduğunu, geri hareket ettiğini, şerit değiştirdiğini ya da araçlar tünelde hareket ederken bir yayanın yürüdüğünü algılamaya yönelik üretilmiştir. Çalışmada, Earley ayrıştırıcısı kullanılmış ve sistemin gerçek zamanlı görüntüyü işlerken verileri kaydetmesi sağlanmıştır. Böylece, yanlış doğruların sayısında azalma sağlanmıştır. Sonuç verileri Destek Vektör Makinası(SVM) algoritması ile karşılaştırılmış ve algılama ve yanlış doğru performansında daha iyi sonuçlar elde etmiştir.

#### 2.3 Amaca Özel Araç Ağı (Vehicle Ad Hoc Network)

Bu bölümde kablosuz ağlar vasıtasıyla araçlar arası gerçekleştirilen trafik ölçümü ve bunun verilerinin anlık olarak işlenmesi konusunda yapılan çalışmalar incelenmiştir.

Soylu, kablosuz haberleşme sistemleri ve güncel kullanım alanlarına yoğunlaşmıştır [12]. Özellikle kablosuz algılayıcı ağlar üzerinde duran çalışma, bu sistemlerin diğer ağlardan farklı olarak çift taraflı iletişime olanak vermesine değinmiştir. Aynı zamanda akıllı ağ olarak tanımlanan bu sistemler, veri alma, gönderme ve yorumlama gibi çeşitli özelliklere sahiptir. Bu özellikler kullanılarak, kablosuz algılayıcı sistemleri geniş kullanım alanlarına yayılmış, tarım, trafik, endüstri ya da eğitim gibi farklı sektörlerde

yer almıştır. Soylu, çalışmasında, kablosuz algılayıcı sistemlerinin bu geniş kullanım alanlarını incelemiş, trafik alanındaki araçların birbirleriyle haberleşmeleri ile ilgili uygulamalara değinmiştir.

Koçkan, çalışmasında haberleşme araçlarını, kontrolcülerini, sensörlerini ve sabit baz istasyonu iletişimi kullanarak sayısal haberleşme yöntemlerini incelemiştir [13]. Yeni nesil araçlarda kullanılan kablosuz haberleşme teknolojisini büyük bir gelişme olarak ele alan çalışma, kendi kendine organize olabilen kablosuz iletişim sistemlerinin kullanımını ele almıştır. Çalışma, bu kablosuz iletişim sistemlerinden elde edilen veriler ile araç sürücülerinin çevre koşullarından daha fazla haberdar olacağını belirtmiştir. Özellikle acil durumlarda erken uyarı olarak görev göreceği olan sistem, araçtan araca bir ağ kurulum uygulaması sunmuştur. Önerilen sistemin uygulanabilirliği için gerekli önkoşullar belirlenmiş ve GPS cihazı teknolojileri kullanılmıştır.

Zeng, Li ve Vasilakos tarafından gerçekleştirilen çalışma, araç sensör ağlarının yüksek hareket görülen yollarda büyük zorluklarla karşılaşmasından yola çıkarak başlamıştır [14]. Araç sensör ağlarının veri merkezli ağlar olduğunu belirten çalışma, daha verimli topoloji yapılarının sistem performansını arttıracaklarını savunur. Çalışma, davranış bazlı yapı topolojisi oluşturmuş ve araçları davranış biçimlerine göre şemalara ayırmıştır. Temelden sonuca mantığını benimseyen çalışma, araç davranış biçimleri üzerine analiz yapmıştır. Test amaçlı simülasyonlar hazırlanmış ve sonuçları çalışmanın faydalarını kanıtlamıştır. Söz konusu sistem kullanıldığında, diğer yol olay belirleme metodlarından daha verimli sonuçlar elde edildiği gösterilmiştir.

Aşağıdaki çalışmalar Amaca Özel Araç Ağı(VANET) akıllı trafik iletişim ağı çerçevesinde gerçekleştirilmiş ve bu kapsamda elde edilen veriler ile çalışmalar yapılmıştır.

### **2.3.1 Çevresel etkiler**

Yuan, Liu, Li, Zhang ve Yang, trafik yoğunluğunu yakıt tüketimi ve hava kirliliği ile bağdaştırarak, gerçek zamanlı trafik bilgilendirme sistemleri ile bu olumsuzlara çözüm bulmayı hedeflemiştir [15]. Bu amaçla, trafik takip sistemleri ve araçlar arası bilgilendirme sistemlerine yönelik çalışma, uzun yıllardır trafik yoğunluğu belirlemede kullanılan tümevarım döngü sisteminden faydalanmıştır. Çalışmada, gerçek zamanlı trafik bilgisi vermede kullanılan VANET sistemlerini, özellikle Google Maps tarafından kullanılan GPS verileri ile birleştirme üzerinde durulmuştur. Trafik yoğunluğunun araç sürücülerinin akıllı telefonları kullanılarak, araçlar arası mesajlaşma yöntemi üzerinde durulmuş ve bu yöntemin belirli yoldaki yoğunluğu bildirmesi amaçlanmıştır. Bilgi iletilen sürücülerin farklı yolları denemesi ve yoğun bölgedeki trafiğin azalması denenmiştir.

### 2.3.2 Trafik takip ve kaza tespiti

Baiocchi, Cuoma, Felice ve Fusco tarafından yapılan çalışma, akıllı ulaşım sistemlerinin, kaza takibi ve trafik izleme sistemleri gibi pahalı altyapılarla donatılmış olmasından yola çıkmıştır [16]. Bu çalışmada, VANET kullanılarak iki farklı (SAME ve TOME) trafik ölçme yöntemi sunulmuş ve gerçek zamanlı kaza belirleme uygulamaları aktarılmıştır. 68 km uzunluğundaki otopanda araç hareketleri iletişimi sağlanan ortamda, GPS yardımıyla veri toplanmıştır. Örnek izleme protokolü olan SAME saniyeler içerisinde %10'dan daha küçük hata payı ile veri toplarken, detaylı protokol olarak tanımlanan TOME metodunun hemen hemen tamamına yakını doğru bilgi topladığı belirtilmiştir.

### 2.3.3 Olay bazlı mimari (event driven architecture - eda)

Saénz, Vela, Martínéz, Moreo ve Skarmeta tarafından yapılan çalışma, trafik yoğunluğu problemi üzerinde durmuştur [17]. VANET sistemlerinde olduğu gibi, yer bildirimlerini kullanarak araçların periyodik mesajlaşmasına yönelik bir yaklaşımda bulunulmuştur. Bu çalışmada, olay bazlı mimari (Event Driven Architecture-EDA) kullanılarak VANET mesajları ile farklı trafik kazalarının algılanması ve sınıflandırılması hedeflemiştir. Aynı zamanda, bu veri ile çevresel faktörler ve hava durumunun da belirlenmesi hedeflenmiştir. Söz konusu mimari EDA, karmaşık olay işleme (complex-event-processing) teknolojisi için kullanılmıştır. Gerçek zamanlı testler ile bu mekanizmanın çok şeritli yollarda ve az bir gecikme ile trafik yoğunluğunu tespit ettiği gösterilmiştir.

## 2.4 Trafikte Olay Tespit Çalışmaları

Trafikte yaşanan olayları tespit etmek ve bunlara anında müdahale ile birçok aksaklığın ve riskin önüne geçilmiş olunur. Bu olaylar içinde trafik kazaları, habersiz yol yapım çalışmaları, araçların arızalanması vb. olaylarda bu olayların erken algılanması çoğu zaman gelecekteki yeni olayların ve tehlikelerin önüne geçilmesinde çok büyük etkindir. Bu sebeple bu alanda yapılan gerçek zamanlı tespit sistemleri ya da geliştirilen modeller önem arz etmekte ve bu sistemlerin algıladığı olayların doğruluk oranları hayati öneme sahiptir. Bu kapsamda birçok yapılmış ve yeni yapılmaya başlanmış çalışma mevcuttur. Bu başlık altında olay tespit çalışmalarına değinilmiştir.


Yaşar tarafından, kaza-olay tespit algoritmalarına yönelik yapılan çalışma, gündün güne ciddileşen ve kentsel ulaşımı zorlaştıran trafik yoğunluğuna odaklanmıştır [18]. Çalışmaya göre, gerek aşırı trafik, gerekse kaza, hava koşulları ya da yol bakım-onarım



çalışmaları gibi nedenlerden kaynaklanan trafik yoğunluğu tespit yöntemleri olarak, çeşitli sıklık yönetim stratejileri kullanılmaktadır. Yaşar, kaza-olay tespitinin kaza-olay yönetimi ve etkinliğini belirlemede büyük öneme sahip olduğunu belirtmektedir. Mevcut kaza-olay tespiti yöntemleri çalışma içerisinde detaylandırılırken, kentsel trafik sorunlarına çözüm niteliğinde bilgiler paylaşılmıştır.

#### 2.4.1 Anomali tespit çalışmaları

Cui, Li, Chen ve Li, video izleme yöntemleri ile belirlenen yerel özelliklerden yararlanarak, anormal olay belirleme metodu sunar [19]. İlk olarak, hareketli kısım benzeştirme yöntemleri kullanılarak belirlenmiştir. Ardından, her bir bölgenin alanı, şekilsel özellikleri çıkarılmıştır. Böylece, her bir bölge yayalara ait, araçlara ait ya da sesli bölge gibi sınıflandırma yapılmıştır ve bu sınıflara ait özellikler belirlenmiştir. Çalışma, bu özelliklerden yararlanarak nesnelerin asıl durumunu ve böylece anormal durumda olup olmadığını belirlemeye yönelmiştir. Akıllı trafik sistemlerinin gelişmesi sayesinde, anormallik algılama sistemi erken uyarı sistemleri ile bağdaşmıştır. Resim 2.1’de, bu yeni sistemin faydaları ve kullanıldığı alanlar gösterilmiştir. Sarı olarak işaretlenen nesnelere araçları, kırmızı olarak işaretlenen nesnelere anormallik tespitlerini ifade etmektedir.



Resim 2.1: Video izleme yöntemi ile anormal olay tespiti.

Yang, Kalpakis ve Biem, anormal durumların tespiti ve paylaşımı ile sürücülerin daha uygun yolların seçmesini kolaylaştıracak bir çalışma yapmışlardır [20]. Kaza, yol çalışması ya da hava durumu gibi trafik koşullarını aksatan ya da değiştiren durumların tespit edilmesinde, Bayesian metodunu genişleten Sağlam Temel Bileşenler Analizi (Robust Principal Component Analysis-RPCA) yaklaşımı kullanılmıştır. Bu yeni metod, çoklu trafik verilerini eşleştirir ve aralık yapısı oluşturur. Aralık yapısı, trafik olaylarının yer ve zaman belirlemede yararlı olmuştur. Trafik verileri, farklı sensörler sayesinde toplanmış ve trafik akışı ya da yol yoğunluğu gibi farklı ölçütler olarak incelenmiştir. Eşleştirmeli Bayesian RPCA metodu deneysel olarak Minnesota I-494 yolundan alınan gerçek zamanlı veri olarak incelenmiştir. Sonuç olarak, söz konusu metodun diğer geleneksel PCA ya da bireysel Bayesian RPCA metodlarına göre algılama

kesinlik oranını arttırdığı kanıtlanmıştır. Çizelge 2.1’de sonuçlar gösterilmektedir.

Çizelge 2.1: Yang, Kalpakis ve Biem, elde edilen sonuçlar.


Yöntem	Değişken	Sonuç
PCA	Akış	%46.1
PCA	İşgaliyet	%54.3
BRPCA	Akış	%80.2
BRPCA	İşgaliyet	%81.5
Coupled BRPCA	Akış & İşgaliyet	%83.2

#### 2.4.2 Trafik kaza tespit modelleri


Hojati, Ferrira, Washington, Charles ve Shobeirinejad tarafından yapılan çalışma, beklenmedik yoğunluk yaratan en büyük etkenlerden biri olan trafik kazalarına yoğunlaşmıştır [21]. Çalışmaya göre, kaza sürelerini tetikleyen etkenler belirlenirse, bu süreyi kısaltma yöntemleri de geliştirilebilir. Çalışmada, geçmiş kaza kayıtlarından faydalanılarak, kaza süreleri incelenmiştir ve bu verilerden yola çıkılarak kaza süresi modellemeleri yapılmıştır. Modeller, aynı zamanda kaza tespiti ve kaza sonuçlarını ortadan kaldırma sürelerini de kapsar. Bu çalışmada, hasar bazlı süre modelleme yaklaşımı uygulanmış ve sonuçları irdelenmiştir. Sonuç analizleri belirtir ki, kaza süresini etkileyen sebepler kaza sonucu, altyapı özellikleri gibi değişikliklere sahiptir. Elde edilen sonuçlara göre, olay türüne göre toplam kazaların etkilediği süreler de farklıdır ve bu türlere farklı müdahaleler gerektirir.

#### 2.4.3 Sinir ağları ile kaza tespit modelleri

Lu, Chen, Wang ve Zuylen tarafından yapılan sinir ağları bazlı trafik kazası belirleme çalışmasında, iki modeli birleştiren bir kaza tespit modeli üzerinde durulmuştur [22]. Çalışmada, halen daha gelişmesini tamamlamadığına inanılan kaza tespit modellerine, çoğu modelde de kullanılan Kısmi En Küçük Kareler (PLS - Partial Least Squares) metodu ve sinir ağları (NN-neural networks) yöntemleri kullanılmıştır. Bu iki metodu birleştiren yeni bir model tasarlanarak, daha verimli bir model elde edilmesi amaçlanmıştır. Gerçek zamanlı trafik verileri toplanarak, veri temizleme (data cleansing) yöntemi ile kaza modeli belirleme yöntemi elde edilmiştir. Tespit yönteminde yanlış alarm oranı, ortalama tespit süresi ve sınıflandırma oranı gibi inceleme kıstasları oluşturulmuştur. Çalışma sonuçlarına göre, bu yöntem PLS performansını arttırmış ve kaza tespitinde kullanılan sinir ağları sonuçlarını sadeleştirmiştir. Çalışma öncesi sinir ağlarının öğrenme modeli Şekil 2.1’de gösterilmiştir, PLS ve NN metotlarının birleştirilmesi sonucu Şekil 2.2’te gösterilen biçime gelmiştir.



Şekil 2.1: Çalışma öncesi sinir ağı modeli.



Şekil 2.2: Çalışma sonrası sinir ağı modeli.

Cinsdikici tarafından hazırlanan çalışma [23], yapay sinir ağları hakkında temel bilgi vermek üzere hazırlanmıştır. Çalışmada, yapay sinir ağlarının elektronik devreler ile başlayan yaşamından, bugün geldiği yazılım alanlarına kadar gelişim süreci ve yaygın kullanım alanları ele alınmıştır. Cinsdikici, yapay sinir ağlarında öğrenme aktivitelerinin nasıl gerçekleştiğini, Hard Limiter fonksiyonu, Treshold fonksiyonu ve Sigmoid fonksiyonu ile açıklamıştır. Yapay sinir ağlarının öğrenmeden sonraki işlevinin sorgulama olduğunu belirten çalışmada, hata-tolerans mekanizması hakkında bilgi verilmiştir. Sorgulama aşamasında kullanılan Hamming Mesafesi (HD), Öklid Mesafesi (ED), Paçalanmış Genelleştirilmiş Öklid Mesafesi (PGED) gibi uzaklık ölçüm tekniklerine değinilmiş, sorguya karşılık gelen cevap algoritmalarından bahsedilmiştir. Hebb Ağı, Perception, Kohonen SOM, Geri Yayılım (Backpropagation) Ağı, Hopfield, Maren gibi temel yapay sinir ağları modelleri incelenmiştir. Bu modellerin günümüzdeki kullanım alanlarına değinilerek, görüntü işleme ve makine öğrenmesi alanlarındaki kullanımına değinilmiştir.

Yıldırım ve Özcan tarafından yapılan trafik kazaları analizinde, yapay sinir ağı modeli kullanılmıştır [24]. Çalışma, trafik kazalarına çözüm olarak, alternatif güzergâh

seçeneği sunacak bir sinir ağı modeli geliştirmeyi amaçlamıştır. Ankara ili örnek alınarak, yapay zekâ teknikleri uygulanmış ve yeni bir yapay sinir ağı modeli geliştirilmiştir. Ankara ili içerisinde gerçekleşen kaza tutanakları veri olarak kullanılmış ve riskli bölge tespiti yapılmıştır. Çalışmalar sonucunda, hava koşulları, yol durumu ve araç türlerine bağlı olarak, sürücünün ulaşmak istediği konuma alternatif yollar üretilmiştir. Levenberg-Marquardt algoritmasından yararlanan çalışma, eğitim ve test süreçlerinde %95 olumlu sonuç elde etmiştir. Alternatif güzergâha yönlendirme aşamasında ise, Google Maps teknolojisinin harita gösterme ve rota hesaplama gibi özelliklerinden yararlanılmıştır.

Çetiner, Sari ve Borat, 15 milyondan fazla nüfusa sahip İstanbul'un en büyük problemlerinden biri olan trafik sorununa yönelmişlerdir [25]. Şehrin ulaşım koşullarını gözlemeye yardımcı olan sensörler sayesinde, ilgili ulaşım birimleri sürekli veri toplamaktadır. Elde edilen veriler ile bu birimlerin çeşitli iletişim kanallarından sürücüleri ve yolcuları bu konularda bilgilendirmekte olduğunu vurgulayan çalışma, son olarak insan deneyiminin de bu sisteme dâhil olduğunu belirtir. Bu deneyim, geçmişe yönelik olmasa da sonraki iki ya da üç saat için olay beklentisi çıkarabilmektedir. Bu çalışma, söz konusu sistemin yapısına yapay sinir ağları (ANNs-Artificial Neural Networks) entegre etmeyi amaçlamıştır. Yapay sinir ağları ile geçmiş verilerden faydalanmayı ve gelecek zamanlar için durum tahmini yapmayı hedefleyen çalışma, verdiği örneklerle sonuçlarını kuvvetlendirmiştir.

#### **2.4.4 Trafik kazaları ve destek vektör makinesi (support vector machine)**

Lu, Chen, Wang ve Ran tarafından yapılan otomatik trafik kazası algılama çalışması [26], trafik kazalarının ekonomik gelişmelerle doğru orantılı olarak arttığı düşüncesi ile başlamıştır. Bu sebeple etkili bir otomatik kaza algılama sistemi (Automated Incident Detection-AID) geliştirmenin faydalı olacağına inanılmıştır. Bu çalışmada, nFoil'e dayalı yeni yaklaşım, endüktif mantık programlama (Inductive Logic Programing - ILP) ile desteklenerek gösterilmiştir. Singapur'daki Ayer Rajah Otobanı ve Kaliforniya'daki I-880 üzerinde gerçekleştirilen gerçek zamanlı çalışmada, performans metriği olarak algılama oranı, yanlış alarm oranı, ortalama algılama zamanı, sınıflandırma süresi ve area under Receiver Operating Characteristics (ROC)-(AUC) kullanılmıştır. Karşılaştırma için sinir ağları ve Karar Destek Makinası (SVM) kullanılmıştır. Çalışmadaki deney sonuçları gösterir ki, nFoil veri setindeki pozitif ve negatif örneklere hassastır. Sonuç olarak, iki farklı teknik ile (resampling ve ensemble learning) ILP sınıflandırması gerçekleştirilmiştir ve AID performansı ölçülmüştür. ILP bazlı AID yaklaşımının daha olumlu olduğu ortaya konulmuştur ve sinir ağları ya da SVM'e oranla daha güçlü sonuç verdiği gösterilmiştir.

Singliar ve Hauskrecht, çalışmalarında makine öğrenmesi metotlarından faydalanarak, zengin trafik verilerini işlemeyi hedeflemiştir. Çoğu sistem trafik kazası algılama yöntemi olarak insan müdahalesi gerektiren algoritmalar kullanırken, bu çalışmada müdahale düşürülerek, trafik algılama ağı veri tabanı üzerinde makine öğrenmesine yer verilmiştir. İlk olarak, SVM'e dayalı, denetimli (supervised) öğrenme kullanılarak kaza detektörleri kullanılmıştır. İkinci olarak ise, çalışma verisi ile öğrenme performansı artırılarak, kaza süresi belirleme üzerine çalışılmıştır. Sonuç olarak, dinamik Bayes tabanlı etiketleme yönteminden yararlanılarak, kaza süresi ve kaza yeri tespiti üzerinde durulmuştur. Çalışma sonuçları incelendiğinde, otomatik olarak çalışan veri ile çalışmanın, kaza yeri belirleme performansını arttırdığı sonucuna ulaşılmaktadır [27].

#### **2.4.5 Saklı markov modeli (hidden markov model)**


Aköz ve Karslıgil, trafik olaylar sınıflandırması üzerine yaptığı çalışmada, kavşaklardaki yoğunluğu ele almıştır [28]. Sunulan sistem, normal ve genel olarak tanımlanan trafik akışından öğrenir. Normal araç yönleri Genel Saklı Markov Modeli(Common Hidden Markov Model) kullanılarak işlenirken, normal dışı durumlardaki araçlar maksimum benzerlik kurallarına göre belirlenmiştir. Ayrıca, çalışmada olay türlerini belirlemek için Karar Destek Makinesi(Support Vector Machine-SVM) ve yakın komşu(k-Nearest Neighborhood) algoritmaları kullanılmıştır. Sonuçlara bakıldığında, sunulan metotların kaza algılamada ve durum belirlemede başarılı olduğu ortaya konulmuştur.

#### **2.4.6 Mobil cihazlar ile olay algılama**

White, Thompson, Turner, Dougherty ve Schmidt, akıllı telefonlar ile trafik kazası belirleme sistemlerini birleştiren bir çalışma yapmıştır [29]. Bilindiği gibi, kaza olma anı ve ilkyardım ekibin kaza yerine ulaşma süresi kazaların en kritik kısmıdır. Çalışmaya göre, kaza anı ve ilk yardım ekibinin ulaşması arasında geçen süre, kazayı algılayan ve acil ekibine haber veren araç içi otomatik kaza algılama ve uyarı sistemleri ile çözülebilir. Bu çalışma, akıllı telefonlardaki (Phone ve Google Android) akustik veri akışı ve ivmeölçer ile acil merkezlerine uyarı göndermeyi (fotoğraf, GPS koordinatları göndermeyi, VOIP iletişim kanallarını kullanarak) hedefler. Çalışma, akıllı telefonlar ile kaza algılama sistemi olarak şu yöntemleri sunar:

- \* Sensör ve veriyi birleştirerek kullanan genel bir yöntem.
- \* Akıllı telefonların sensörlerini, ağ bağlantıları ve web servisleri kullanılarak ilk yardım merkezlerine uyarı gönderecek bir yöntem.

Akıllı telefon kaza algılama sistemlerinin deneysel sonuçları ile yanlış uyarı algılama oranının düşürüldüğü ve doğru alarm oranının artırıldığı tespiti yapılmıştır. Şekil 2.3'te kaza fotoğraflarının nasıl birleştirildiği gösterilmiştir.



Şekil 2.3: Kaza anı resim yükleme.

Zaldivar, Calafate, Cano ve Manzoni , Android tabanlı akıllı cihazlar ile, kaza tespiti üzerine çalışmıştır [30]. Çalışma, hızla yaygınlaşan akıllı telefon kullanımı ve güncel otomobil özelliklerini birleştirerek, akıllı araç kiti oluşturmayı hedeflemiştir. Çalışma temel olarak, OBD (On Board Diagnostics) üzerindeki araçları takip ederek kaza tespiti yapabilen, Android tabanlı bir uygulama üzerine kurulmuştur. Sunulan uygulama, ön çarpmalı kazalarda hava yastıklarının da kullandığı G kuvvetini algılayacaktır. Kaza, telefon yolu ile acil servislere bildirilecek, kaza yeri SMS ve e-mail yolu ile söz konusu acil servislere iletilecektir. Uygulama testleri verilerine göre, kaza 3 saniyeden kısa bir sürede acil servislere haber verilmiş ve yolcu güvenliğine katkı sağladığı belirtilmiştir.

Yamamoto, Oku, Huang ve Kawagoe, Akıllı ve Hızlı Beklenmedik Olay Algılama (SQUED - Smart and Quick Unexpected-Event Detector) olarak adlandırdıkları sistem üzerine çalışma yapmışlardır [31]. SQUED, akıllı cihazlardan sağlanan veriyi kullanarak, trafik kazaları ya da yoğun trafik sıkışıklığı gibi beklenmedik durum tespiti yapmakla görevlidir. Akıllı cihaz kullanıcıları içinde buldukları trafikte bir durum olduğunu fark ettiklerinde, bu bölgeye bir işaretleme yaparlar. Sistem, durumun gerçekleştiği alanı, olayın gerçekleşme zamanını ve etkin olduğu süreleri GPS verileri ile birleştirerek belirlemektedir. Akıllı cihaz kullanıcısı bu sistemde yalnızca cihazı durumun gerçekleştiği bölgeye yöneltmekle görevlidir. Çalışmalar gösterir ki, SQUED yoğun trafik ya da karmaşık veri halinde bile, olay algılamada yüksek oranlarda başarı gösterebileceği savunulmuştur.

## 2.4.7 Sosyal ağlar ile olay tespiti

Andrea, Ducange, Lazzerini ve Marcelloni, sosyal ağların durum belirlemede ve kaza ya da yoğunluk tespitinde önemli bir kaynak olduğunu savunmuştur [32]. Çalışma, Twitter verilerini kullanarak gerçek zamanlı trafik olay belirleme sistemi sunar. Sistem, belirli kriterlere bağlı olarak Twitter verilerini çeker, metin belirleme metotları kullanarak tweetleri inceler ve tweet sınıflandırma ile işlemi sonlandırır. Tüm bu işlemin amacı, söz konusu tweet'in herhangi bir sınıf etiketine bağlı olup olmadığını belirlemektir. Trafik algılama sistemi, gerçek zamanlı olarak birçok İtalyan yollarında çalıştırılmış, çevrimiçi trafik haberleri veren web sitelerinden daha hızlı olduğu gösterilmiştir. Sınıflandırma modeli için Karar Destek Makinesi (SVM) kullanılmış ve trafik ile ilgili ya da trafik ile ilgili değil olarak çözülen ikili sınıflandırma probleminde %95.75 doğruluk sağlanmıştır. Ayrıca, trafik yoğunluğunun sebebinin dış etken olup olmadığı da çoklu sınıflandırma problemi olarak ele alınmış ve burada da %88.89 doğruluk sağlanmıştır.

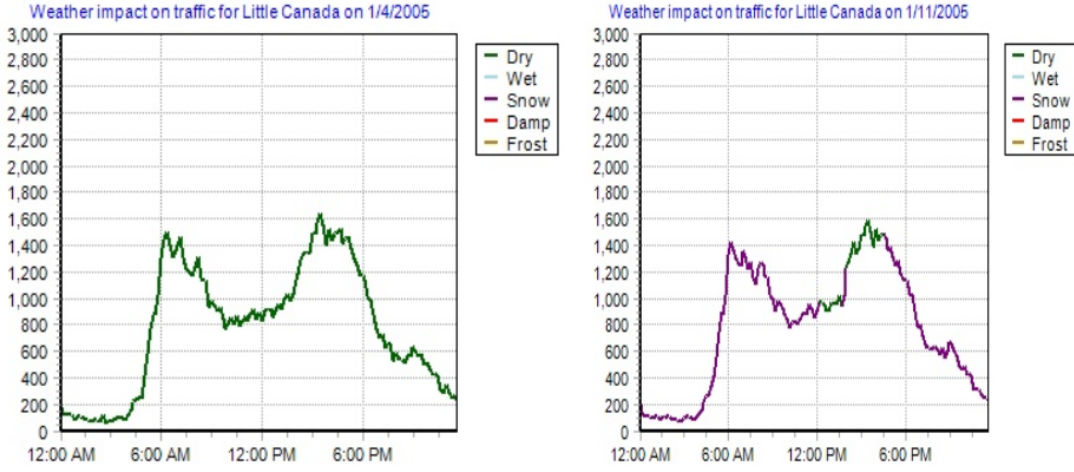
Gutiérrez, Figuerias, Oliveira, Costa ve Jardim-Goncalves, bilgiye kolay ulaşım sağlayan akıllı telefonlar ve tabletlerin piyasada aktif olarak çoğalmasından yola çıkarak, sosyal ağları en verimli paylaşım aracı olarak ele almıştır [33]. Çalışmaya göre, navigasyon cihazları ile yoğun veri akışını sağlamak ve bilgiyi kişiselleştirmede kimi zaman yetersiz kalmaktadır. Çalışma, Birleşik Krallık'ta trafik ajansları tarafından yayınlanan tweet'leri inceleyerek, trafik olaylarına coğrafik olarak yoğunlaşmayı hedeflemiştir. Tweet'ler, benzersiz oldukları ve yalnızca 140 karakter içerdikleri için, olay algılamada kullanılabilir kabul edilmiştir. Söz konusu çalışmada, tweet sınıflandırma, olay tipi sınıflandırma, isim tanıma, yer tanımlama ve olay takibi gibi farklı aşamalar takip edilmiştir. Söz konusu metodun doğruluğunun testi için, gerçek zamanlı bir deneye de yer verilmiştir. Çalışma, halen daha devam eden bir sürecin önemli bir parçası olarak tanımlanmış, asıl amacın temel parçası olarak belirtilmiştir.

## 2.5 Çevresel Etmenlerin Trafik Etkileşimleri

### 2.5.1 Hava koşullarının etkileri

Nookala tarafından yapılan çalışmada [34], hava koşullarından kaynaklanan trafik yoğunluğu araştırılmış ve hava koşullarının trafikte kalma süresi ve trafik akışına etkileri incelenmiştir. Hava koşulları RWIS ile farklı bölgelerde kaydedilmiştir. Hava koşullarının trafik yoğunluğuna etkisini görmek amacı ile renkli kayıtlı hava durumu grafikleri ve renkli kayıtlı hacim/doluluk oranı grafikleri analiz edilmiştir. Hava koşullarına bağlı olarak trafik yoğunluğunun arttığı ve yol kapasitesinin düştüğü gözlemlendiği belirtilmiştir.

tır. Ayrıca, kısa süreli seyahat zamanı değişim tahminlerinin sert hava koşullarından nasıl etkilendiği gösterilmiştir. Tahmindeki hatanın büyük olması çalışmada hata oranının düşürülmesine odaklanmıştır. Bu hatanın, trafik yoğunluğu ile doğrudan orantılı olduğu gösterilmiştir. Yoğunluk değişikliği ve hava koşullarını bir araya getiren, tahmin hata oranını düşüren yeni bir model sunulmuştur. Şekil 2.4'te yapılan çalışmanın çıktısı gösterilmektedir.



Şekil 2.4: Kanada'da hava olaylarının trafiğe etkisi.

### 2.5.2 Coğrafi konum bazlı etkiler

Güvenal, Çabuk ve Yavuz tarafından gerçekleştirilen çalışma [35], hareket algılama ve coğrafi bilgi sistemlerinin verimini arttırmaya yöneliktir. Veri analizinin servis kalitesi, güvenilirlik, kesinlik ve güncellik olarak belirli kriterlere bağlıdır ve Coğrafi Bilgi Sistemi (GIS-Geographic Information Systems) veri analizi aracı olarak kullanılmıştır. GIS sayesinde akıcı ve kesin bilgi akışı sağlanmış ve çevresel planlama gereken alanlarda bile karar mekanizması güçlendirilmiştir. Hareket algılama ve coğrafi bilgi sistemlerinden sağlanan istatistiksel veri, bilgi sistemleri ve çözümler bazında incelenmiştir. Coğrafi bilgi sistemleri, gelecekte yapılması beklenen yoğunluk tespiti çalışmaları için de objektif analizler vermektedir. Çalışmada Eskişehir ilinde gerçekleşen trafik kazalarının verileri ulaşım planlama için ve kritik kaza bölge tespiti amacı ile kullanılmıştır. Sonuç olarak, kritik kaza bölgelerini de içeren güncel ulaşım planı incelenmiştir. Coğrafi bilgi sistemleri çalışmalarına dayanarak, tekrar düzenlenmesi gereken trafik kurallarından bahsedilmiş ve bu sistemlerin sonuçları irdelenmiştir.

Aydınöglü, Sağlam, Şenbil ve Demir, çalışmalarında coğrafi bilgi sistemleri (GIS) kullanılarak park yeri planlaması üzerinde durmuşlardır [36]. Yapılan çalışma, sayısı her geçen gün artan araçlar için, yeterli kapasiteye sahip otopark alanları gerekliliğinden doğmuştur. Yetersiz park alanların, plansız inşa ve hızlı artan nüfus ile ilgili olduğunu



belirten çalışma, coğrafi bilgi sistemlerinden alınan veriler ile park alanı belirleme analiz algoritması sunmuştur. Park alanı ihtiyacı ve talep hesaplandıktan sonra, ağ analizi yer-yerleştirme tekniği kullanılarak en iyi park alanı belirlenmiştir. Bu teknikler, kent- sel bölgelerde test edilmiştir ve sonuç olarak en iyi park alanını belirlemeye yönelik yenilikçi bir metot geliştirilmiştir.

Erkan ve Aydınöglü tarafından yapılan çalışmada, trafik ölçme sensör verileri kullanılmıştır [37]. Sensörlerden gerçek zamanlı trafik bilgisi, uzaktan trafik mikrodalga sensör anlamına gelen RTMS ile sağlanmıştır. Bu verilerin zamana bağlı yönetimi, kontrolü ve raporlanması için ise coğrafi bilgi teknolojileri kullanılmıştır. RTMS ile sağlanan İstanbul ili trafik verileri, coğrafi veri tabanı ile birleştirilmiştir. Çalışma sonucunda, veri tabanında istenen zamana göre ulaşım planlamasına olanak tanıyan raporlar elde edilmiştir.





### 3. VERİ ANALİZİ VE MODELLEME

Analiz çalışmasındaki model çıkarımı, İBB Trafik Müdürlüğü'nden sağlanan veriler kapsamında gerçekleştirilmiştir. İBB'den alınan veriler yolların anlık olarak doluluk, hız, ortalama hız, şerit bilgileri, araç sayısı gibi verileri içermektedir. Bu çalışmadaki model İstanbul trafiğinin davranışlarına göre çıkarılmıştır. Bu davranışlar yoldan yola göre değişmektedir. Her yolun kendine ait bölgesi olduğu düşünülürse, örneğin TEM otoyolu, Bostancı bölgesindeki yollar ya da Taksim bölgesindeki yollar gibi, bunların trafiğe göstermiş olduğu tepkiler de farklı olacaktır. Her bölgenin kendine has özellikleri olduğu yıllık tabanda incelenmiş olup yolların reflekslerinin de farklı olduğu gözlemlenmiştir. Buradan yapılan çıkarımlar sonucunda oluşturulacak model tek tek sensör tabanlı değil, bölgesel tabanlı olacaktır. Diğer bir konu ise, çıkarılan model tüm İstanbul'daki sensörleri kapsamayacaktır. Çünkü, tüm sensörler için tek bir model çıkartmak farklı özelliklere sahip yollar için çok verimli değildir. Tüm sensörler için çıkartılan model gelecekteki gerçek zamanlı gelen veriler için her zaman doğru sonuç vermesi beklenmemektedir. Örneğin, küçük bir kaza TEM otoyolunda trafiği çok fazla aksatmazken, küçük çaptaki kaza Avrupa yakasındaki herhangi sensör bölgesinde trafiği oldukça etkileyebilmektedir. Buradaki analizlerdeki ve oluşturulan modeldeki en büyük zorlukların başını çeken etmen, İstanbul gibi metropoliten bir şehirde her yolun çok farklı bağlantı noktası olabilmesi ve ayrıca yapı olarak alınabilecek tedbirlerin kısıtları olmasıdır. Örneğin, İstanbul'da sıkışıklığı tespit edilen bir yolun dar bir sokaktan geçmesi ve bu yolun büyütülememesi ya da altyapının yolun alternatifinin yapılmasına engel olması gibi durumlar, buna istinaden aynı yolun birçok bağlantısı olması da zorlukların başını çekmektedir. Bununla birlikte, edinilen verilerdeki sensörlerdeki bazı verilerin çeşitli zamanlarda hatalı olduğu tespit edilmiştir. Çünkü bir yolda en sol şerit ortalama 100-110 km/s hızla seyrederken, orta şerit ya da sağ şeritten birinin 10-15 km/s gibi hızla saatlerce ya da tam gün boyunca seyretmesi mantıklı değildir. Bu sebepten, sensördeki verinin her zaman doğru ve sağlıklı olduğunu söylemek güçtür. Modeli geliştirirken ve eğitirken verinin mümkün olduğunca sağlıklı ve doğru olması çok önemlidir. İleride gelecek verilerden doğru analiz ve çıkarımlar yapabilmek için, modelin doğru eğitilmesi ve buna bağlı olarak verinin doğru yapılandırılması büyük önem taşır. Elde edilen verinin detaylı incelemesi ve oluşturulan modelin türü ve kapsamı, ilgili bölümlerde detaylı bir biçimde anlatılmıştır.

### 3.1 Trafik Sensörleri


Trafik sensörleri, yolları daha iyi gözlemleyip olayları takip ve trafiğin gidişatını daha düzenli hale getirmek için kullanılan en temel yöntemlerden birisidir. İBB bu kapsamda kendi kurduğu firma olan İSBAK A.Ş. ile yolları akıllı hale getirip, İstanbul'un trafik yaratan ve trafik anlamında kalbi olan yollara çeşitli trafik sensörleri yerleştirilerek denetlenmektedir. Buradaki amaç trafiği anlık olarak tespit etmek ve akıllı ulaşım kavramına ayak uydurmaktır. Bu kapsamda, trafik sensörlerinden gelen veriler incelenip anlık olarak trafik takip edilmektedir. Anlık olarak takip edilen trafik, eğer sıkışmış ya da kaza olduğu tespit edilmişse gerekli planlamalar yapılarak yönlendirmeler uygulanmaktadır. Buna bağlı olarak teknolojik sensörler ve bu sensörlerin idaresi ve takibi 7/24 yapılmaktadır. Bu bağlamda kullanılan sensör ve teknolojilerden bazıları aşağıda belirtilmiştir.

#### 3.1.1 Video dedektörü

Video dedektörler, adında da anlaşılacağı üzere görüntü işleme tabanlı çalışarak trafiği anlık olarak takip eder ve görüntülerden faydalanarak belli başlı trafik verileri üretmektedir. Bu veriler, toplam geçen araç sayısı, araç uzunluklarına göre sınıflandırma, araçların ortalama hız bilgileri ve yolun ortalama işgal bilgisi gibi veriler görüntü işleme teknikleriyle video dedektörlerden saptanabilmektedir. Türkiye'de olduğu gibi dünyanın diğer büyük şehirlerinde de sıkça kullanılmaktadır. Video dedektörler genellikle yolların ana arterlerinde, kavşak ışıklarında, yol ayrımlarında ve yol katılımlarında trafiğin anlık akış bilgisini incelemektedir. Şekil 3.1'de çalışma prensibi görsel olarak belirtilmiştir [38].

Özellikleri:

- \* Görüntü işleme yöntemi ile 8 şeride kadar ölçüm imkânı,
- \* Sanal alanlar oluşturularak şerit genişlikleri ayarlayabilme,
- \* Kızılötesi kesici lens özelliği ile gece görüş netliği,
- \* Donanımsal kart yapısı ile kolay ölçümleme,
- \* Uygulama alanında genişlik,
- \* Araç hızları,
- \* Araç sayıları,



Şekil 3.1: Video dedektörü çalışma prensibi.

- \* Yol işgaliet bilgileri,
- \* Araç sınıflandırma,
- \* TCP/IP (G.SHDSL, GPRS, Fiber veya 3G) çalışabilme,
- \* Windows tabanlı ve Türkçe yazılım.

### 3.1.2 Led ekranlı radar sistemi

Bu tip sensörler belirli arterlerde ve bölgelerde araçların hızlarını tespit edip, sürücülere hızlarının normal ya da hızlı olduğunu uyararak trafik kurallarına uymalarını belirtmektedir. Aynı zamanda, yolun ilerisinde oluşmuş ya da oluşacak olan herhangi bir olayla ilgili ikaz yapmak için de kullanılır. Örneğin, bu tip sensörler en çok tünel girişleri, dönemeç başlangıçları ya da otoyol girişlerinde bulunarak sürücüleri bilgilendirirler. Resim 3.1’de İBB’de kullanılan örnek sistem gösterilmiştir [39].




Resim 3.1: Led ekranlı trafik bilgi paneli.

#### Özellikleri:

- \* Tüm renkleri gösterebilme (Tam Renk, minimum 16 milyon renk)
- \* 20mm piksel aralığı
- \* 1280mm x 800mm LED Ekran
- \* Yüksek ışık şiddeti
- \* EN 12966 optik sınıf
- \* IP65 Alüminyum kabin
- \* Sanal Piksel (Virtualpixel) teknolojisi
- \* 100.000 saat LED ömrü
- \* TCP/IP (G.SHDSL, GPRS, Fiber veya 3G Bağlantıda çalışabilme özelliği)
- \* Windows tabanlı ve Türkçe yazılım
- \* 24 Ghz Doppler Radar
- \* Tüm resim ve video formatlarına uygunluk.

### 3.1.3 Döngüsel sensör

Döngüsel sensörler elektromanyetik alan teorisi kullanarak, araçların belirlenen sınırları ihlal edip etmediğini, belirlenen bölgeden kaç adet araç geçtiğini ve araç uzunluklarını tespit etmekte kullanılan bir yöntemdir. Bu sistemleri en çok gördüğümüz yerler kırmızı ışıklardır. Kırmızı ışık ihlalinin olup olmadığı ya da aracın kırmızı ışık yanıldığında yaya geçtiğinde durup durmadığı gibi ihlalleri tespit etmekte kullanılır. Şekil 3.2'de sensörün çalışma yapısı gösterilmiştir [40].




Şekil 3.2: Döngüsel sensör çalışma prensibi.

Özellikleri:

- \* %99 oranında doğru uyarım
- \* %0,02-%0,1 arasında üç kademe duyarlılık ayarı imkânı
- \* Kendi kendini ayarlama özelliği
- \* Devre dışında kalması durumunda otomatik alarm alma.

### 3.1.4 Bluetooth sensör

Bluetooth sensörler, İSBAK tarafından kullanımları şu şekilde tanımlanmıştır: "Bluetooth sensörler, bluetooth özelliği açık ve görülebilir durumda olan, sensöre azami 100m uzaklıktan geçen taşıtlarda bulunan cep telefonu, kulaklık, navigasyon cihazı, araç kiti gibi cihazlardan yayılan bluetooth sinyallerini, taşıtların hızının azami 150 km/saat olması halinde bile algılayabilen sensörlerdir. Bu sensörler, yol kenarında bulunan direklere ya da baş üstü konstrüksiyonlara kurulmakta olup kurulum ve bakım onarım sırasında yol üzerinde asfalt kesme gibi herhangi bir çalışma gerektirmemektedir. Bu sensörlerin algıladığı objelere ait kimlik kod bilgisi, zaman damgalı olarak merkeze aktarılmakta ve sistem geliştirilen yazılım aracılığıyla, algılanan kimlik kod bilgilerini kaydederek, sensörlerin kurulduğu güzergâh boyunca, ortalama seyahat süresi bilgisi üretmektedir. Üretilen ortalama seyahat süreleri, internet, mobil uygulamalar ve kritik lokasyonlara kurulan bilgilendirme levhaları vasıtasıyla, sürücü, yolcu ve yayalara ulaştırılacaktır." [41]. Şekil 3.3'te sistemin çalışması ile ilgili görsel eklenmiştir [42].



Şekil 3.3: Bluetooth otoyol algılama sistemi.

Özellikleri:

- \* 6 şeritten 12 şeride kadar ölçüm imkânı
- \* Açık frekans olan 2,4 Ghz bant genişliğinde çalışma
- \* ARM 9 işlem ve Linux işletim sistemi



- \* Modem üzerinden veya direkt sensörden bilgisayara bağlantı sağlayacak giriş/girişler (USB, RS232, Ethernet vb.) imkânı
- \* Sensörlerin güvenlik duvarı ile sadece belli bilgisayar ya da IP adresi ya da ağdan erişme imkânı
- \* TCP/IP ve GPRS üzerinden uzaktan erişim, internet tarayıcısı ile sensörlerin yapılandırma kolaylığı
- \* Saat senkronizasyonu yapmak ve konumlarını belirlemek için dâhili GPS (Global Positioning System) modülü
- \* Araçların bir noktadan bir noktaya varış sürelerini belirleme.

### 3.1.5 Uzak mikrodalga radar sensör (rtms)


Trafik ölçüm dedektörlerinden Radar Tabanlı RTMS (Remote Traffic Microwave Sensor)'ler trafik algılama uygulaması için özel tasarlanmış dedektörlerdir. Mikrodalga ışınlarının alanına giren nesnelere olan uzaklığı ölçer. Menzil aralığı sayesinde, bu dedektörler, her türlü hava koşullarında yolda duran ve hareket halindeki araçları, belirlenen bölgelerde tespit edebilir. Konumlandırıldığı noktadaki anlık trafik akış bilgisini elde eder [43]. Resim 3.2 [44] ve Resim 3.4'te [45] RTMS sensörün görünümü ve ölçüm anınınından bir görünüm verilmiştir.



Şekil 3.4: RTMS sensör.

## Özellikleri:

- \* 8 şeride kadar şerit bazında ölçüm imkânı
- \* Araç sayım bilgisi
- \* Araç hız bilgisi
- \* Trafik yoğunluk bilgisi
- \* En az %90 doğru ölçüm
- \* Güneş enerjili besleme sistemi ile en az 2 hafta güneş olmadan çalışabilme
- \* GPRS veya 3G ile çalışabilme
- \* Windows tabanlı yazılım
- \* Kalibrasyon kolaylığı
- \* Trafik Yoğunluk Haritasına veri sağlar.



Resim 3.2: RTMS sensör ölçümleri.

## 3.2 Pilot Bölgedeki RTMS Sensörler

Model oluşturulurken, İstanbul'daki sensörlerden pilot bölge seçilerek model oluşturuldu ve test edilmiştir. Bunun başlıca sebebi, yollardaki sensörlerin hepsinin karakteristik bir özelliği olması ve her bir yol için parametrelerin farklılık göstermesidir. Bunun yanında, verinin zorluğu da hesaba katılmıştır. Örneğin, 2015 senesinde herhangi bir sensör tüm sene boyunca veri verirken, diğer sensör hatalı veri verebilmektedir. Verilerdeki bozukluk ve bu bozuklukların kolay anlaşılır olmaması, bazı yollardaki azalan hızların gerçekte orada bir olay değil tamamen yolun kendisinden yani coğrafi olarak yapısından kaynaklanması gibi etmenler her bir yol grubunun kendine has model oluşturulması ihtiyacını doğurmuştur. Bu sebepten dolayı bir yolun yani sensör grubunun seçilmesi ihtiyacı ortaya çıkmıştır. Bahsi geçen sensör grubu ve pilot bölge olarak tem otoyolunun Sultanbeyli bölgesindeki Ataşehir-Tuzla istikametlerindeki 7 adet sensörler kullanılmıştır. Aşağıda sensörler ile ilgili veriler ve konum bilgileri verilmiştir.


### 3.2.1 Sensör bilgileri

Seçilen pilot bölgedeki 7 sensör TEM otoyolu üzerindeki 345, 436, 440, 441, 432, 430 ve 429 RTMS numaralı sensörlerdir. Bu sensörlerden elde edilen veriler RTMS sensörlerin basitçe tanımda da bahsedildiği gibi ölçüm alınan periyottaki şerit bazlı ortalama hız, toplam geliş şeridi için ortalama hız, toplam gidiş şeridi için ortalama hız, şerit bazlı toplam geçen araç sayısı, şerit bazlı ortalama işgaliyet değeri % olarak, toplam geliş şeridi için ortalama işgaliyet değeri, toplam gidiş şeridi için ortalama işgaliyet değeri, şerit bazlı araçların uzunluklarına göre kaç adet olduğu örneğin kamyon, tır ve otomobil için ayrı sayım bilgileri kullanılmıştır. Ancak araç büyüklüklerine göre kullanılan sayım yöntemi her zaman doğru olmadığı İBB Trafik yetkililerinden doğrulanmıştır. Çizelge 3.1 kullanılan verinin ham hali göstermektedir. Verinin tam hali EK 1'de Çizelge 5.1'te yer almaktadır.

Çizelge 3.1: İBB Trafik RTMS verisi

MsgTime	RtmsNo	S1	S2	S3	S4	S5	S6	S7	S8	SGelisGraf	SGidisGraf	V1	V2	V3	V4	V5	V6	V7	V8	O1	O2	O3	O4	O5	O6	O7	O8
2015-02-12 23:59:03.000	432	61	95	115	119	96	83	NULL	NULL	90	99	16	20	12	8	18	9	NULL	NULL	8	4	2	1	5	5	NULL	NULL
2015-02-12 23:59:05.000	436	41	93	116	87	77	NULL	NULL	NULL	83	87	13	11	3	8	14	NULL	NULL	NULL	6	4	0	1	7	NULL	NULL	NULL
2015-02-12 23:59:14.000	441	68	93	105	101	80	NULL	NULL	NULL	88	90	16	23	18	17	12	NULL	NULL	NULL	8	6	3	3	5	NULL	NULL	NULL
2015-02-12 23:59:29.000	440	59	83	97	91	88	65	NULL	NULL	79	81	12	20	12	17	17	11	NULL	NULL	6	6	2	3	5	4	NULL	NULL
2015-02-12 23:59:48.000	345	65	104	124	87	100	50	NULL	NULL	97	93	10	23	8	19	20	20	NULL	NULL	3	5	1	2	5	8	NULL	NULL
2015-02-13 00:01:47.000	345	73	106	125	98	99	52	NULL	NULL	101	98	12	18	10	10	19	14	NULL	NULL	3	3	1	1	3	4	NULL	NULL
2015-02-13 00:02:42.000	429	49	89	116	107	98	NULL	NULL	NULL	84	102	10	20	22	6	29	NULL	NULL	NULL	7	8	3	1	10	NULL	NULL	NULL
2015-02-13 00:03:03.000	432	52	102	116	112	88	82	NULL	NULL	90	94	14	25	11	13	17	15	NULL	NULL	6	7	2	2	5	9	NULL	NULL
2015-02-13 00:03:05.000	436	45	89	115	82	63	NULL	NULL	NULL	83	82	10	17	7	14	14	NULL	NULL	NULL	4	4	1	4	7	NULL	NULL	NULL
2015-02-13 00:03:14.000	441	74	87	102	100	83	NULL	NULL	NULL	87	91	16	23	19	25	14	NULL	NULL	NULL	7	7	3	7	6	NULL	NULL	NULL
2015-02-13 00:03:29.000	440	48	83	87	90	91	64	NULL	NULL	72	81	14	23	24	12	19	12	NULL	NULL	6	8	6	2	6	5	NULL	NULL
2015-02-13 00:03:39.000	430	70	72	100	119	100	NULL	NULL	NULL	80	109	18	21	18	16	14	NULL	NULL	NULL	8	7	4	5	7	NULL	NULL	NULL
2015-02-13 00:04:25.000	345	71	111	122	96	103	50	NULL	NULL	101	99	13	16	10	14	19	17	NULL	NULL	5	3	1	2	5	7	NULL	NULL
2015-02-13 00:04:42.000	429	48	86	114	109	109	NULL	NULL	NULL	82	109	10	23	24	2	24	NULL	NULL	NULL	6	8	4	0	5	NULL	NULL	NULL
2015-02-13 00:05:03.000	432	50	105	113	107	87	84	NULL	NULL	89	92	16	22	4	16	20	13	NULL	NULL	8	5	0	3	8	7	NULL	NULL
2015-02-13 00:05:05.000	436	50	90	112	93	54	NULL	NULL	NULL	84	93	6	15	5	10	14	NULL	NULL	NULL	2	4	0	2	8	NULL	NULL	NULL
2015-02-13 00:05:14.000	441	67	89	102	105	89	NULL	NULL	NULL	86	97	12	20	14	23	17	NULL	NULL	NULL	6	6	2	6	8	NULL	NULL	NULL
2015-02-13 00:05:29.000	440	51	85	91	90	96	63	NULL	NULL	75	83	14	18	16	10	17	13	NULL	NULL	5	6	4	2	4	5	NULL	NULL
2015-02-13 00:05:41.000	430	70	67	95	106	84	NULL	NULL	NULL	77	95	16	29	24	25	13	NULL	NULL	NULL	8	10	5	9	9	NULL	NULL	NULL


Ayrıca, örnek olarak RTMS 429 numaralı sensörün 2015 yılındaki tüm ham hız verisi saatlik olarak çizdirilmiş ve incelenmiştir, Şekil 3.5'te tüm yılın verileri noktalar olarak gösterilmiştir.



Şekil 3.5: RTMS 429 numaralı sensörün yıllık verisinin 24 saatlik gösterimi.

### 3.2.2 Sensör konumları

Sensör konumları TEM otoyolu üzerinde seçilmiştir. Sensörler seçilirken sensörlerin özellikleri ve anayol bağlantıları dikkate alınmıştır. TEM otoyolunun seçilmesindeki en büyük sebeplerden birisi, bu yolda sık sık kazaların olması ve elde edilen kaza verilerinin yoğun olarak görülmesidir. Aynı zamanda bu yolu sık kullananlardan edinilen bilgilere ve trafik yetkilileri ile yapılan görüşmelere göre, bu yolun oldukça yoğun kullanılan bir yol olmasıdır. Sensör konumları Şekil 3.6'daki gibidir.



Şekil 3.6: Seçilen pilot bölgedeki sensörlerin haritası.

Buradaki konumlardan anlaşıldığı üzere, seçilen bölgedeki sensörler art arda ve birbirlerine yakın sensörlerdir. Buradaki mantık ise, modeli oluştururken ve eğitirken ana-

lizlerin ve bulguların tutarlı çıkmasıdır. Model, eğitildikten sonra bir sonraki tahminlerinde ve bulgularında buradaki geçmiş bilgisinden yararlanarak, orada bir olay olup olmadığını tahmin etmeye çalışılacaktır. Bu noktada modele girdi sağlayan verinin kalitesi ve doğruluğu önem arz etmektedir.

### 3.3 Pilot Bölgedeki Olaylar

Tablo halinde saklanan pilot bölge olay raporları, İBB Trafik Müdürlüğü'nün arşivinden alınmıştır. Veriler incelendiğinde, tabloda bulunan değerler şu şekildedir: Duyuru-Tipi, KullaniciId, DuyuruBaslik, DuyuruMetin, gCoordinate ve diğer alanlardan oluşmaktadır. Diğer alanlar, MsjDurum, AgentId, KameraId gibi, olayların tespitinde yararlı olmadığı için dikkate alınmamıştır. Bu verilerde önemli olan noktalar duyuruyla ilgili açıklama, olayın olduğu bölgenin koordinatı ve oluş zamanıdır. Bu üç etmene bakılarak, o bölgedeki olaylar çıkarılmıştır. Örnek olaylar şu şekildedir:

- \* "FSM Köp. Anadolu -Avrupa Yönü Yol Bakım Çalışması"
- \* "D100 Acıbadem-Altunizade yönü kalan araç."
- \* "D100 Kozyatağı-Bostancı Yönü Trafik kazası (hasarlı)"
- \* "D100 Haliç-Okmeydanı Yönü Trafik kazası (zincirleme)"


Olaylardan anlaşılacağı üzere, trafik oluşturan etmenler bir tek kazalar ya da yol çalışmaları değildir. Değişik duyurularla trafik oluşturan etmenler belirtilmiştir. Çizelge 3.2'de olay tablosundan örnek satırlara yer verilmiştir.

Çizelge 3.2: İBB olaylar veri tablosundan örnek veri seti.

DuyuruId	DuyuruTipi	DuyuruBaslik	GirisTarihi	BitisTarihi	Oncelik	gCoordinate
32396	17	FSM Köp. Anadolu -Avrupa Yönü Yol Bakım Çalışması	12.02.2013 14:29	2013-02-12 15:12:43.000	2	41.092280,29.086496
32764	23	D100 Şirinevler-İncirli istikameti araç arızası	18.02.2013 08:48	2013-02-18 10:37:24.000	1	40.991086,28.851587
33201	17	TEM Çamlıca Gişeler - Kartal yönü yol bakım çalışması	25.02.2013 10:33	2013-02-25 13:18:59.000	3	40.997296,29.135967
33208	16	D100 İncirli-Şirinevler Yönü Trafik kazası (zincirleme)	25.02.2013 11:43	25.02.2013 12:30	1	40.996875,28.869766
33211	23	D100 Mecidiyeköy-Çağlayan Yönü Araç Arızası	25.02.2013 12:07	25.02.2013 12:54	1	41.066354,29.001564
33224	23	D100 Acıbadem-Altunizade yönü kalan araç.	2013-02-25 15:11:49.030	25.02.2013 15:58	3	41.015482,29.056364
33227	16	Çapa-Aksaray Trafik kazası (hasarlı)	25.02.2013 15:16	25.02.2013 15:48	2	41.014697,28.934321
33236	16	D100 Haliç-Okmeydanı Yönü Trafik kazası (zincirleme)	25.02.2013 15:58	25.02.2013 16:44	1	41.051600,28.949320
33292	16	D100 Kozyatağı-Bostancı Yönü Trafik kazası (hasarlı)	26.02.2013 08:45	2013-02-26 09:14:48.000	1	40.964669,29.104818
33298	16	Halkalı - İkitelli (yan yol) Yönü Trafik kazası (hasarlı)	26.02.2013 09:43	26.02.2013 10:30	1	41.061565,28.769836
33309	16	D100 Merter-Cevizlibağ Yönü Trafik kazası (hasarlı)	26.02.2013 11:45	2013-02-26 12:29:52.000	1	41.016342,28.908937
33316	16	D100 Pendik-Kartal Yönü Trafik kazası (hasarlı)	26.02.2013 14:02	26.02.2013 14:48	1	40.889442,29.237196
33508	23	D-100 Boğaziçi Köpr. Avrupa-Asya geçişinde araç arızası	28.02.2013 23:07	28.02.2013 23:53	1	41.057745,29.018193
33526	16	D100 Bostancı-Kozyatağı Yönü Trafik kazası (hasarlı)	01.03.2013 09:35	2013-03-01 10:19:10.000	1	40.964669,29.104818
33527	16	Tem Hasdal-Seyrantepe Yönü Trafik kazası (hasarlı)	01.03.2013 09:38	2013-03-01 10:58:34.000	1	41.100039,28.966808
33529	16	D100 Avcılar-Hacışerif Yönü Trafik kazası!	01.03.2013 09:44	2013-03-01 10:44:01.000	1	40.984520,28.723074
33530	23	D100 Şirinevler - Çobançeşme yönünde kalan araç	01.03.2013 10:01	2013-03-01 11:35:46.000	1	40.991086,28.851587
36024	23	D100 Sefaköy-Florya Yönü Araç Arızası	27.03.2013 15:01	27.03.2013 15:49	1	40.999474,28.799064
36025	16	Bayrampaşa Yıldırım-Otagar Trafik kazası (hasarlı)	2013-03-27 15:01:53.070	2013-03-27 15:50:06.000	2	41.067178,28.881471
36492	16	D100 Çobançeşme-Sefaköy Yönü Trafik kazası (hasarlı)	01.04.2013 19:33	01.04.2013 20:06	1	40.99321,28.81768
36534	16	D100 İncirli-Şirinevler Yönü Trafik kazası (hasarlı)	01.04.2013 22:38	01.04.2013 23:26	2	40.991086,28.851587

Edinilen olay verilerine dayanılarak modele koordinatları bilinen verilerle test eğitim setleri hazırlanmıştır. Modelde kullanılan eğitim setleri ‘olay var’ ya da ‘olay yok’ şeklinde çıkarılmıştır. Seçilen bölgede kazaların olup olmadığı, verideki koordinatlarından anlaşılmış ve verilerdeki olay olma anının en fazla 20 dakika gerisine bakılarak olaylar sensör verileriyle doğrulanmıştır. 20 dakika aralığı taranan olay duyuruları ile RTMS sensör verileri incelenerek çıkarılmıştır. RTMS sensör verileri en fazla geriye dönük 20 dakika içerisinde olayın olduğunu doğrulamıştır. Bunun başlıca sebebi ise olay oluktan bir süre sonra trafik merkezine olay ile ilgili bilginin gelmesidir. Anlık olarak gelmeyen veriler için bu yöntemle gidilmiş ve 20 dakika aralığı bu şekilde tespit edilmiştir.

Olayların seçilen bölgedeki harita konumu ve harita üstündeki gösterimi Şekil 3.7’deki gibidir.



Şekil 3.7: Tüm olayların harita üzerindeki konumları.


### 3.4 Modeller ve Tanımları

Trafik modellemede popüler olarak kullanılan yöntemlerin başında Yapay Sinir Ağları (Artificial Neural Network) gelir. Yapay sinir ağları, bu tip problemler için uygulanabilecek, karmaşık verileri alabilen ve sürekli değişen koşullar için kolay adapte olabilecek yapısı sayesinde tercih sebebidir. Tanımından da çıkarılacağı gibi, insandaki sinir ağlarına benzerliğiyle tanınmış ve ondan esinlenerek geliştirilmiş yapılardır. İnsanın yeni öğrendiği ya da ilk defa karşılaştığı bir olaya tepkisi nasılsa ve ilk karşılaştığı durumu deneyimleyerek öğrendikten sonra verdiği tepkilerde bu yönde değişmişse, yapay sinir ağları da benzer şekilde ilk karşılaştığı ve sonrasında öğrendiği yön-

temlerden edindiği tecrübelerine göre olacaktır. Yapay sinir ağları konusunda, Donald Hebb (1949) sinir ağları teorisinin atası olarak nitelendirilmektedir. Kendisi nörolog olan Hebb, beynin ve nöronların nasıl çalıştığı ve tüm bu sistemin işlevi hakkında çalışmalar yapmış, bunlarla ilgili teoriler ortaya çıkarmıştır. Hebb'in yaptığı çalışmalar, bugün bilgisayar ortamındaki kullanılan sinir ağları algoritmalarının ve temellerinin atılmasına vesile olmuştur. Buradaki amaç, mevcut teknoloji ve algoritmaların çözemediği karmaşık problemleri yapay sinir ağları ile çözmektir. Bu alanda yapay sinir ağ modellerinin başarısının yüksek olduğu bilinmektedir [46]. İlerleyen başlıklarda, sinir ağlarının temelinden ve çeşitli modellerinden detaylı olarak bahsedilmektedir.

### 3.4.1 Yapay sinir ağları (artificial neural network)

İnsan beyni, birbirine bağlı sinir hücrelerinin elektrik sinyallerini özenle ilettiği bir biyolojik sinir ağı olarak tanımlanabilir. İnsan beyni ve çalışma prensipleri oldukça karmaşık olsa da, en basit hali ile elektriksel sinyaller alınır, bu sinyallere bağlı olarak bir çıkış sinyali çıkarılır. 1943 yılında, sinirbilimci Warren S. McCulloch ve mantık bilimcisi Walter Pitts, yapay sinir ağları üzerine ilk modeli ortaya koymuştur. İnsan beyninin çalışma prensibinden etkilenen bu ilk model, sinir hücresinin mekanizmasını ve sinir ağı olarak görev hücrelerin giriş, çıkış ve işlemlerinden bahseder (A Logical Calculus of the Ideas Immanent in Nervous Activity). Biyolojik bir sinir hücresinden çok, yapay ve hesaplanabilir bir sinir hücresinden bahseden bu çalışma, sonraki çalışmalara da bir ışık kaynağı olmuştur. Şekil 3.8'de örnek topoloji verilmiştir.



Şekil 3.8: Örnek yapay sinir ağı topolojisi.



Yapay sinir ağlarının (Artificial Neural Networks - ANN) günümüzdeki en yaygın kullanımını, insanlar için kolay, ancak bilgisayarlar için zor problemlerdir. "Model tanımlama" olarak adlandırılan bu görev, herhangi bir karakter tanımlama ya da yüz algılama gibi birçok dala ayrılabilir. Yapay sinir ağları, ilişkisel hesaplama sistemleri olarak tanımlanır. Bu sinir ağlarındaki her bir nöron, girdi alıp, çıktı veren tek bir kod işleme elementi olarak görülür. Ancak, nöronlar bir araya gelip sinir ağlarını oluşturduğunda, sistemsel bir çalışma ortaya çıkar. Geleneksel kodlamalardan farklı olarak; kodu okuma, işleme ve sonuç verme yerine, işlem ağdaki tüm nöronlar tarafından müşterek olarak yerine getirilir.

### 3.4.2 Yapay sinir ağlarının özellikleri ve kullanım alanları

Yapay sinir ağlarının en belirgin özelliği, öğrenmedir. Çalışmalara adapte olabilen bu sistemler, kendi altyapılarını edindikleri bilgilere bağlı olarak değiştirebilirler. Ayarlanabilir ağırlıklar ile birbirine bağlı işlem birimleri, genelleme yapma ya da sınıflama gibi yeteneklere sahiptir. Geçmiş veriler kullanılarak, yapay sinir ağlarının problemleri tanımlaması, öğrenmesi ve gelecek veriler için tahminde bulunması sağlanabilir. Genel olarak özellikleri aşağıdaki şekilde açıklanabilir [47]:


- \* Model tanımlama (Yüz tanıma, optik karakter tanımlama, vb.)
- \* Zaman serileri tahmini (Ekonomi tahminleri, hava tahminleri, vb.)
- \* Sinyal İşleme (Ses işleme, video işleme, vb.)
- \* Kontrol (Sürücüsüz araçlar, simülasyon araçları, vb.)
- \* Anormallik tespiti (Trafik olay tespiti, değişiklik tespiti, vb.)

### 3.4.3 Yapay sinir ağlarının yapısı

Yapay sinir ağları, her biri basit bir işlemci olarak tanımlanabilen ve giriş-işlem-çıkış görevini gerçekleştirebilen mekanizmalardır. Geleneksel bilgisayar işlemleri gibi fonksiyonel çalışmaları da, gerçekleştirdikleri matematiksel fonksiyonun tam bir karşılığı bulunmaktadır. Biyolojik sinir ağlarının basitleştirilmiş bir modeli olarak düşünüldüğünde, yapay sinir ağları da birbirine bağlı işlem birimlerinden oluşur.


Temel olarak beş bileşenden oluşan yapay sinir ağlarının elemanları girdiler, ağırlıklar, toplama fonksiyonu, transfer fonksiyonu ve çıktılardır [48]. Girdiler, dışarıdan ağa gelen bilgilerdir ve nöronun algısına bağlı olarak ağda sınırsız sayıda girdi olabilir.

$[-1, 1]$  aralığındaki ağırlıklar, gelen verinin nörona olacak etkisini belirler ve bu ağırlıkların değiştirilmesi sinir ağlarının veriden öğrenmesini sağlar. Toplama fonksiyonu, nörona gelen verilerin ilgili ağırlıklar ile çarpımını hesaplar. Aktivasyon fonksiyonu, net girdiyi hesaplayarak karşılık gelen çıktıyı belirler ve bu fonksiyon sinir ağının ne öğrenmek istediğine göre değişmektedir. Çıktı ise, aktivasyon fonksiyonunun çıktısı olmakla birlikte, başka bir nörona ya da dışarıya aktarılan değerdir. Şekil 3.9'da ağırlık katmanları gösterilmektedir [49].



Şekil 3.9: Yapay sinir ağlarının katmanları.

Yapay sinir ağlarında, işlem birimleri birbirine uzaysal olarak bağlıdır. Böylelikle, bir işlem biriminin çıktısı, bir diğer işlem biriminin girdisi olabilir. Girdiler, sürekli ya da ayrık olabildiği gibi, çıktılar da değişken ya da belirsiz olabilir. Çıktıları bir başka birim tarafından kullanılan işlem biriminin toplam çıktı sayısı, birimler arası bağın ağırlığına bağlıdır. Şekil 3.10'da gösterilmiştir.



Şekil 3.10: McCulloch-Pitts nöron modeli.

### 3.4.4 Yinelenen sinir ağları (recurrent neural network)

Şekil 3.11'de örnek olarak gösterildiği gibi yinelenen yapay sinir ağları, dinamik ve dizileri dizilerle bağdaştıran sistemlerdir. Genel olarak, 3 ağırlık matrisi ve 3 önyargı

ile ölçülür. Algoritma 3.1 kullanılarak  $(v_1, v_2, \dots, v_t)$  ile verilen bir girdi, yinelenen sinir ağları tarafından hesaplanır ve  $(h_1, h_2, \dots, h_t)$  gizli fazı ve  $(z_1, z_2, \dots, z_t)$  çıktı dizisi elde edilir:

---

Algoritma 3.1: Yinelenen Sinir Ağı

---


```

1: for  $t = 1 : T$  do
2:    $u_t \leftarrow W_{hv}v_t + W_{hh}h_{t-1} + b_h$ 
3:    $h_t \leftarrow e(u_t)$ 
4:    $o_t \leftarrow W_{oh}h_t + b_o$ 
5:    $z_t \leftarrow g(o_t)$ 
6: end for

```

---

Algoritma 3.1'deki  $e()$  fonksiyonu ve yinelenen sinir ağlarındaki gizli fazın ve çıktının doğrusal olmayışı ve  $h_0$  ilk gizli fazın parametresini temsil eder.



Şekil 3.11: Yinelenen sinir ağı modeli.

### 3.4.5 Yinelenen sinir ağları kullanmanın güçlükleri

Yinelenen sinir ağlarının hesaplamaları uygulanabilir olsa da, bu sistemler öğrenme söz konusu olduğunda olumlu değildir [50]. Lineer olmayan tekrarlamalı yapıları dolayısı ile bağımlı problemlerde zorluk çıkarabilirler. Fazın başındaki bir değişiklik, çok sonraki bir tekrar sırasında sorun çıkarabilir. "Kelebek etkisi" olarak bilinen bu sorun, çok büyük sorunlara yol açabilir. Hızla artan problemlerde yinelenen sinir ağlarının düzenlenmesi güçtür ve geniş bağımlılıklarla çalışan makine öğrenmesi çalışanlarının karşılaştıkları büyük zorluklardandır.

### 3.5 Büyük Veri Yöntemleriyle Verinin Analizi

Verinin ham halinden işlenebilecek duruma getirilmesinde büyük veri yöntemleri kullanılmıştır. Buradaki çalışma verinin ham halini alıp büyük veri altyapısında işlenip tekrar büyük veri altyapısında saklanmasından başlar. Büyük veri altyapısına geçmiş veri bu aşamadan sonra özellik çıkartma yöntemleri (feature engineering), çıkart-

dönüştür-yükle (ETL) metodolojisi ve hangi verinin uygun olduğu ve ne kadar değerli olduğu ile ilgili çalışmalar yapılmıştır. Bu yöntemler sırasıyla bu bölümde anlatılmıştır.


### **3.5.1 Çıkart-dönüştür-yükle (extract-transform-load etl) yöntemi ile verinin hazırlanması**

Veriler İBB Trafik Müdürlüğü'nden MS Sql Server formatında alınmıştır. Geleneksel yöntemler kullanarak veri önce MS Sql Server makinesinde açılmıştır. İlk bakışta ve denemelerde verileri çekmek hızlı ve masrafsız gibi gözükse de, üzerinde analiz yapıldığı zaman geleneksel sorgulama dilinin verimsiz olduğu ve uzun zaman aldığı gözlemlenmiştir. Örneğin; birkaç sorgulama dilinde kullanılan basit birleştirme sorgusu (Join) oldukça fazla zaman almakta ve çoğu zaman cevap dönememektedir. Bu sebeplerden dolayı dağıtık yapıda kullanılan ve dağıtık sorgulama yapılabilen yöntemler seçilmiştir. Bu çerçevede, büyük verinin en temel altyapılarını oluşturan Hadoop Dağıtık Dosya Sistemi (HDFS) ve Spark veri işleme araçlarından faydalanılmıştır.

Hadoop Dağıtık Dosya Sistemi, Java ile geliştirilmiş, Hadoop MapReduce özelliklerini birleştiren açık kaynaklı bir kütüphanedir. HDDS sayesinde, pahalı olamayan basit diskler kullanılarak, büyük verinin temelini oluşturan büyük bir depolama alanı elde edilebilir. Örneğin; 500 GB 5 adet makine ile disklerin birleşimden tek bir depolama alanı olarak gözükürken 1,5 - 2 TB'lık bir ana alan elde edilir. Birebir  $5 \times 500GB = 2500GB$  alan elde edilemez, çünkü yapısı gereği HDDS'nin depolama alanı dışında bu verilerin kararlı ve güvenli olması için bir kısım alanı sürdürülebilirlik için kendine ayırmasındandır. Kısaca, HDDS'e bir adet ana makine ve istenildiği kadar veri makinesinden oluşabilir. Ana makinenin görevi sistemi ayakta tutup kararlılık işlemlerini yerine getirmektir. Diğer makinelerin yani veri makinelerinin görevi veriyi saklayıp onların yedekleri ve verinin parçalarını saklamaktır. Özet ile HDDS'nin yapısı Şekil 3.12'de gösterilmiştir [51].

Hadoop MapReduce yöntemi, Hadoop teknolojisinin en temel ve önemli kısmını oluşturmaktadır. MapReduce teknolojisi büyük verilerin rahat ve esnek biçimde sorgulanmasına imkân veren, büyük veriler üzerinde analiz ve sorgulayıcı çalışmalarda yüksek performans sağlayan, dağıtık yapılarda kullanılan en temel teknolojidir. Yapısal olarak ise, her bir veri düğüm makinesinin üzerinde sadece kendi verisi ile istenen sorguyu çalıştırarak birden fazla makinede aynı anda sorgunun çalıştırılmasına, ve böylelikle dağıtık yapıyı ve her bir makinenin işlem gücünü en verimli şekilde kullanmasına yarayan bir teknolojidir [52]. Şekil 3.13'de MapReduce ile ilgili çalışma prensibine yer verilmiştir [53].

## HDFS Architecture




Şekil 3.12: HDDS altapısı.

Bunların yanında, Hadoop HDDS'ye veri atmak için geliştirilmiş olan Sqoop isimli veri transfer aracı, geleneksel veri tabanında bulunan veriler için çok güçlü bir teknolojidir. Sqoop aracının en büyük özellikleri SQL Server, Oracle, MySQL vb. geleneksel veri tabanlarında bulunan verileri Hadoop HDDS'ye aktarmak gibi önemli bir görevi üstlenmektedir. Bu teknolojinin avantajı, geleneksel veri tabanlarında saklanan verileri dağıtık ekosisteme aktararak büyük veri çalışmalarının gerçekleştirileceği altyapının hazırlanmasını kolaylaştırmaktır.

Trafik verilerinin ham halleri İBB Trafik Müdürlüğü'nden SQL Server yedeği şeklinde alındığından, ilk olarak açılan veriler SQL Server'da bulunmaktadır. Ancak, yapılan çalışmalar dağıtık veri ortamında yapılacağından ve işlenen veriler ve sorgular dağıtık yapıya uygun olduğundan, SQL Server'da bulunan verilerin Hadoop ekosistemine aktarılmasına ihtiyaç duyulmuştur. Bu ihtiyacı karşılamak için Sqoop kullanılmıştır. Sqoop - SQL Server bağlantısı yapıldıktan sonra istenilen alanları hız, araç sayısı, işgaliyet vb. alanları HDDS'ye aktarmıştır. Kullanılan örnek Sqoop komutu Komut 3.1'deki gibidir.

Komut 3.1: Sqoop aktarma komutu.

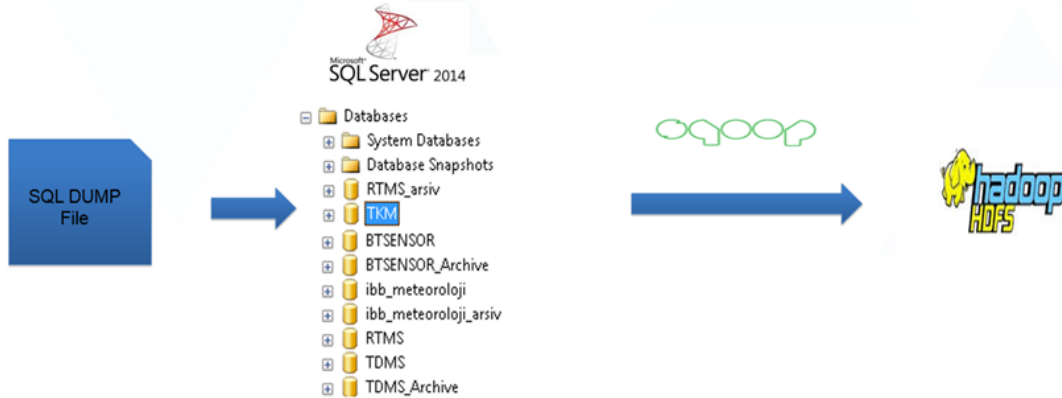
```
$ sudo -E -u hdfs sqoop import --connect jdbc:sqlserver  
://10.10.12.129:1433 --username hadoop --password  
12345 --table MESSAGES --columns "MsgTime,RtmsNo,S1,S2  
,S3,S4,S5,S6,S7,S8,SGelisGraf,SGidisGraf,V1,V2,V3,V4,
```



Şekil 3.13: Hadoop MapReduce çalışma prensibi.

V5, V6, V7, V8, O1, O2, O3, O4, O5, O6, O7, O8, OGelisGraf ,  
OGidisGraf" --target-dir /user/isbak/rtms/Messages

Yapılan aktarım özetle Şekil 3.14'deki gibidir.



Şekil 3.14: Verinin MS Sql veri tabanından HDDS'ye aktarılması.

Aktarım sonucunda veriler büyük veri altyapısında 10 makinenden oluşan bir küme sunucularında Hadoop HDDS üzerine aktarılmıştır. Bu aktarma işleminden sonra, veri büyük veri ekosisteminde işlenebilir hale gelmiştir. İstenilen sorgular ve filtrelemeler, HDDS üzerindeki veriyle dağıtık olarak gerçekleştirilmiştir.

Verilerin işlenmesi ve istenilen sorgularla çalıştırılması Hadoop ekosistemi üzerinde çalışan Apache Spark ile gerçekleştirilmiştir. Apache Spark, Scala dili ile yazılmış ve bellek üzerinde çalışan yapısıyla, dağıtık algoritmalar ve yapılarda performansı oldukça yüksek bir teknolojidir. Spark teknolojisinin en büyük artısı, petabayte'larca veriyi oldukça performanslı ve stabil olarak işleyebilmesidir. En büyük avantajlarından bir diğeri ise, makine öğrenmesi algoritmalarının Spark üzerinde paralel çalışabilme-

sidir. Bu sebepten, 4. Bölümde bahsi geçen verilerin hazırlanması, yol ile ilgili hesaplamaların yapılması, temizleme işlemlerinde kullanılan yöntemler Apache Spark ve HDDS üzerindeki veri ile gerçekleştirilmiştir. Örnek olarak, yolun Ortalama Hız, Hacim ve İşgaliyet değerleri HDDS'e atılmış "Messages" ve "RTMSDetails" tablo verileri ile Rtms numaraları üzerinden birleştime yöntemi (Join) yapılarak gerçekleştirilmiştir. Örnek birleştirme komutu Komut 3.2'deki gibidir.

Komut 3.2: Join işlemi.

```
joinedRdd = parsedMessages . join ( parsedRtmsDetails )
```

Şerit sayıları kullanılarak ortalama hız, hacim ve işgaliyet değerlerinin hesaplanmasında kullanılan örnek komut Komut 3.3'deki gibidir.

Komut 3.3: Ortalama değer hesap işlemi.

```
calcRdd = joinedRdd . map ( calculateAverageValues )
```

Örnek hatalı veri çıkarım sonucu Çizelge 3.3'deki gibidir.

Çizelge 3.3: Hatalı verinin çıkarımı.

MsgTime	RtmsNo	S1	S2	S3	S4	S5	S6	S7	S8
2015-02-12 23:59:25.0	430	90	97	3	null	null	null	null	null

Çizelge 3.3'deki örnek çıktıda, S3 şeridinde hatalı veri saptandığı görülmektedir. Hatalı verilerin nasıl saptandığı ile ilgili çalışmalar ilgili bölümde detaylı olarak anlatılmıştır.

Özet olarak, Apache Spark bunun gibi çalışmaları ve hesaplamaları büyük veri teknolojileriyle dağıtık olarak hesaplamakta ve çok kısa sürelerde sonuçlar döndürülebilmiştir.

### 3.5.2 Hazırlanan verinin analizi ve incelenmesi

Veriler, büyük veri ve dağıtık veri altyapısına geçirildikten sonra analiz kısımlarında verinin anlamlandırılması ve içeriği ile ilgili çalışmalar yürütülmüştür. Bu çalışmalarda verinin üzerinden olay tespiti yapılabilmesi ve sinir ağlarıyla verinin değerlendirilmesi aşamalarında öngörü olacak şekilde veriler incelenmiştir.

İnceleme aşamasında öncelikle "Şerit Verilerinden Yol Verisi Hesaplanması" başlığı altında detaylı olarak anlatıldığı gibi, şeritler arasındaki korelasyon bulunmaya çalışılmıştır. Buradaki amaç verinin şerit verisinden yol verisine ne şekilde dönüştürülüp dönüştürülemeyeceğidir. Çünkü şerit bazlı inceleme yapılmasındansa yol bazlı inceleme yapılmasının daha tutarlı olabileceği öngörülmüştür. Trafikteki olayların yolun

tamamına etkisi olduğu gözlemlenmiş bunun sayısal ve veri anlamında doğruluğuna bakılmıştır. Rastgele pilot bölgedeki bir sensör seçilerek gerçekleştirilen şerit korelasyon çalışması, şeritlerdeki hızlar, bir önceki hıza göre birlikte artış ya da azalış gösteriyorsa «+», birbirinden ayrı artış ya da azalış gösteriyorsa «-» olarak etiketlenmiştir. Bu çalışma ile hatalı çalışan veriler analiz edilebilmekte ve ayrıca şerit bilgisinden yol bilgisine geçilebileceği öngörülmüştür. Korelasyon çalışmasının örneği Çizelge 3.4'te gösterilmiştir.

Çizelge 3.4: Şerit korelasyon tablosu.

S1	S2	S3	S1-S2	S2-S3	S1-S3
92	80	10			
88	78	34	+	-	-
95	83	59	+	+	+
96	85	19	+	-	-
75	79	17	+	+	+
79	83	7	+	-	-


Ayrıca, veriler üzerinde Bollinger Bantları analizi uygulanmıştır. Bollinger Bantları, hareketli ortalamadan uzak iki standart sapmayı işaretleyen bantlardır. Dalgalanmanın bir ölçütü olarak standart sapma kullanıldığından, Bollinger bantları ekonomideki borsa durumlarına ayak uydurabilmektedir. Genel olarak ekonomik alanlarda kullanılan bantlar, burada olduğu gibi teknik analiz aracı olarak da kullanılmaktadır. Teknik olarak, veriler ne kadar dalgalı olursa, bantlar da ortalamadan o kadar uzaklaşmaktadır. Ters durumlarında ise bantlar ortalamaya daha da yaklaşmaktadır. Bantların gerginliği, dalgalanma için bir erken tanı olmakla birlikte, dalgalanmanın aniden artacağını belirtmektedir [54].

Bollinger Bant yöntemi ile ortalama, orta değer ve standart sapma hesaplaması yapılarak hız verilerine üst ve alt limit eklenmiştir. Üst ve alt limit dışında kalan verilerde olay algılama yapılabileceği öngörülmüştür. Kırmızı noktalar ortalama değer verisi, mor noktalar ise alt ve üst limit hız verilerinin orta değer verisi, gri noktalar alt ve üst değer limiti ve pembe noktalar verinin kendisidir. Şekil (3.15 - 3.16 - 3.17)'de gösterilmiştir. Alt ve üst limitler ile ilgili denklem Eşitlik 3.1 ve 3.2'de verilmiştir.




$$Ust\ Limit = Ortalama\ Deger + (2 \times Standart\ Sapma) \quad (3.1)$$

$$Alt\ Limit = Ortalama\ Deger - (2 \times Standart\ Sapma) \quad (3.2)$$

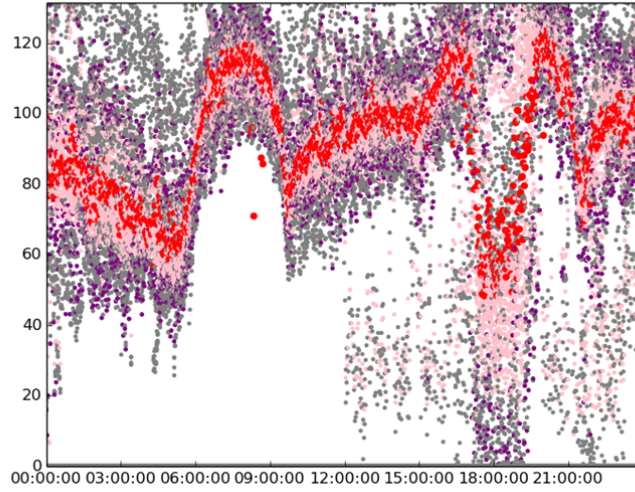


Şekil 3.15: Bollinger Bant - RTMS 441 numaralı sensörün pazartesi günlerinin yıllık verisi.



Şekil 3.16: Bollinger Bant - RTMS 441 numaralı sensörün cuma günlerinin yıllık verisi.

Yapılan diğer bir veri analiz yöntemi ise, veriler üstünde yapılan polinom çalışmasıdır. Buradaki amaç, veriler üstünde olay aranıp aranmayacağını belirlemesidir. Bu çalışma, pilot bölgedeki 7 sensör üzerinde sensörlerin bütün yıl Cuma günü verdiği veriler ile yapılmıştır. Cuma günlerinin trafik verisi ve olay verisinin daha fazla olacağı




Şekil 3.17: Bollinger Bant - RTMS 336 numaralı sensörün cuma günlerinin yıllık verisi.


öngörülmüştür. Toplamda bir sensör için 1440 adet veri noktası saptanmış ve sensörlerdeki hız verilerinin orta değerlerinin 12. dereceden polinom uygulanmıştır. 12. dereceden polinom, yapılan denemelerden elde edilen en iyi sonuca göre karar verilmiştir. Orta değer verisine alt ve üst sınır limitler eklenerek limitler dışında kalan verilerde olay olup olmadığı bilgisi aranabileceği düşünülmüştür. Mavi noktalar orta değer alınan hız verilerini, yeşil çizgi polinom oturtmasını, açık mavi ve mor çizgi alt ve üst limiti, kırmızı çizgi ortalama değeri ifade etmektedir. Şekil (3.18 - 3.19 - 3.20)'de gösterilmiştir. Eşitlik 3.3 ve 3.4'de verilmiştir.

$$Ust\ Limit(Acik\ Mavi) = Ortalama\ Deger + (2 \times Standart\ Sapma) \quad (3.3)$$


$$Alt\ Limit(Mor) = Ortalama\ Deger - (2 \times Standart\ Sapma) \quad (3.4)$$



Şekil 3.18: Polinom - RTMS 441 numaralı sensörün cuma günlerinin yıllık verisi.



Şekil 3.19: Polinom - RTMS 436 numaralı sensörün cuma günlerinin yıllık verisi.



Şekil 3.20: Polinom - RTMS 430 numaralı sensörün cuma günlerinin yıllık verisi.



## 4. GELİŞTİRİLEN MODEL VE DENEYSEL SONUÇLAR

Geliştirilen model, seçilen sensör bölgesindeki sensörlerin 2015 senesindeki 1 yıllık verileriyle oluşturulmuştur. Model, yapay sinir ağları ile denenmiş çıktıları bu kapsamda değerlendirilmiştir. Model geliştirme ve denemesi yapılırken en önemli nokta, modele verilecek girdilerin düzgün ve doğru bir biçimde ayarlanmasıdır. Çünkü, model çıktısının tutarlı ve doğru olması modelin düzgün bir şekilde eğitilmesinden geçmektedir. Model ne kadar düzgün ve doğru veri ile eğitilirse, tutarlılığı ve gelecekte karşısına gelen verilere vereceği tepkiler ve cevaplar daha kararlı olacaktır.

### 4.1 Model Girdilerinin Ayarlanması

Modele verilecek girdilerin belirlenmesi ve bunların doğruluğunun yüksek olması üstünde denenebilecek veri için çok önemlidir. Bu sebepten, model için seçilen girdiler var olan verilerdeki karmaşık yapıda seçmek karmaşıktır. Bu kapsamda aşağıdaki başlıklarda belirtilen çalışmalar yapılmıştır.

#### 4.1.1 Model girdilerinin belirlenmesi

Olay algılama modelinde kullanılacak veriler seçilirken, verinin incelenmesi hassas ve önemli bir kısımdır. Var olan veriler incelendiğinde, araçlarla ilgili ve düzenli olarak elde edilen değişkenler şu şekilde olacaktır:

- \* Araç ortalama hızları
- \* Ölçüm aralığındaki sayılan araç sayıları
- \* Araçların yolu işgal değerleri

Bu verilerin her sensör için sürekli ve kesintisiz olarak geldiği gözlemlenmiştir. Bu veriler vasıtasıyla yolun kapasitesi hesaplanabilir. Kapasite hesaplanması ilgili bölümde detaylı olarak anlatılmaktadır. İlk değişken olarak yolun anlık kapasitesini seçebiliriz. İkinci değişken olarak ölçüm alınan sensördeki 2 ölçüm arasındaki hız farkı alınabilir. Çünkü, buradaki amaç olayı algılamaktır. Eğer bir yolda herhangi bir olay olmuş ise (kaza ya da yol tıkanıklığı vb. gibi), o yoldaki sensörlerden alınacak değerlerde

ani düşme veya ani artma gibi değişimler gözlemlenecektir. Bu sebepten, anlık olarak değil de iki ölçüm arasındaki farka bakmak olay tespiti için uygun bir yöntem olacaktır. Son girdi olarak, yolun işgaliyet değerinden de olayla ilgili bilgi almak mümkündür. Çünkü işgaliyet değeri ölçüm yapan cihazın asfaltı ne süreyle görüp görmediğidir. Örneğin, cihaz ikişer dakikalık aralıklarla ölçüm yapabiliyorsa, ki cihazdan cihaza göre ölçüm aralıkları farklılık gösterebilmektedir ve yaptığı iki ölçüm arasında asfaltı önündeki araçlardan dolayı göremez ise, işgaliyet değeri %100 olarak ölçülecektir. Eğer "tenha" diye tabir edilen yolda ölçüm alınıyorsa, cihaz yaklaşık olarak %8 - %10 arasında bir ölçüm yapacaktır. Bu sebepten, işgaliyet değerine bakmak anlamlı olabilir. Eğer trafikte olay olursa, işgaliyet değerindeki anlık artış ve azalış değerleri gözlemlenebilir.

Bu veriler doğrultusunda model için seçilen girdiler şu şekilde olacaktır:

- \* Ortalama Hız Farkı
- \* Yolun İşgaliyet Değeri Farkı
- \* Yol Kapasitesi Farkı

#### **4.1.2 Şerit verilerinden yol verisi hesaplanması**

Elde edilen verilerde, yollara yerleştirilmiş sensörlerden gelen şerit bazlı veri mevcuttur. Ancak, şerit bazlı inceleme yolun durumu hakkında tam olarak gerçekten olayı ifade edememektedir. Şerit verileri incelendiğinde bazı şeritlerde olay olmasa bile hızlarda düşüş ve buna karşın kalan diğer şeritlerde herhangi bir düşüşe rastlanmaması, şerit bazlı incelemenin uygun olmayacağı düşüncesini oluşturmuştur. Böylelikle, şerit incelemesi yapılmasındansa şeritlerden elde edilen hızların ortalamasının alınması daha uygun olacağı görüşü belirlemiştir. Ancak bu durum ortalama hız hesaplanırken şeritten ancak gelen uygun olmayan verilerin de temizlenmesi ihtiyacını doğurmuştur. Örneğin, trafiğin hızlı aktığı bilinen bir yolda ilk iki şerit ortalama 90 - 100 km/saat ile seyrederken üçüncü ve en yavaş şeridin hızının ortalama 10 km/saat ile akması söz konusu şerit verisinde veride bir hatanın olabileceğini işaret etmektedir. İBB Trafik yetkililerinden edinilen bilgiler kapsamında, sensörler sürekli çalıştığından dolayı bazı zamanlar sensörlerin algılayıcılarının önüne bir cismin gelmesi veya hava muhalefetlerinden dolayı gibi etmenler yüzünden sensörlerin bazı şeritler için trafiği ölçmesinde problemler olduğu vurgulanmıştır. Bu sebeple, verilerin temizlenmesi ihtiyacı çıkmıştır. Temizleme ile ilgili çalışma ilgili bölümde detaylı biçimde anlatılmıştır.

### 4.1.3 Yol kapasite hesaplanması

Yol kapasite hesabı model için oldukça önemlidir. Elde edilen verilerde, şeritten yol hesabına geçildiği için şerit kapasite hesabı değil, yol kapasite hesabı daha uygun olacaktır. Kapasite Eşitlik 4.1’de verilmiştir.

$$\text{Toplam Seritlerdeki Arac Sayısı} \times \text{Toplam Seritlerdeki Ortalama Hiz} = \text{Yol Kapasitesi} \quad (4.1)$$

Bu denklem ile yolların kapasitesi hesaplanmıştır. Hesaplama sonunda elde edilen sayıların çok yüksek çıkması sonucunda, örneğin hızlı akan ve sık araçların geçtiği bir trafikte değer çok yüksek çıkmaktadır. Eşitlik 4.2’de hesaplanmıştır.

$$100 \text{ Arac} \times 105 \text{ km/saat} = 10500 \text{ Arac km/saat} \quad (4.2)$$

Trafik sıkışık olduğu bir zamandaki değer ise çok düşük olarak çıkmaktadır. Eşitlik 4.3’de hesaplanmıştır.

$$20 \text{ Arac} \times 15 \text{ km/saat} = 300 \text{ Arac km/saat} \quad (4.3)$$


Hesaplamalarda görüldüğü gibi, değerler arasındaki fark çok yüksek ve yükseklik modelin kapasite değişkeninin hassasiyetini etkilemektedir. Çünkü bir olay meydana gelirse model, kapasitedeki değişimi fark edebilmektedir. Bu sebepten dolayı, kapasite hesabındaki sonuçlar normalize edilerek daha küçük değerlere yakınsaması sağlanmıştır.

### 4.1.4 Model girdilerinin temizlenmesi


Model girdilerinde verilerden hangilerinin hatalı, hangilerinin temiz veri olduğu, tespit çalışmasında öncelikle verilerdeki şeritlerin hangisinin en hızlı şerit olduğunu belirlemekle başlar. Bu amaçla, şeritlerin yıllık olarak histogramları çıkarılmıştır. Histogramlar Şekil (4.1, 4.2, 4.3 ) ile gösterilmiştir.

Örnek olarak 345 numaralı RTMS sensörün S1,S2 ve S3 şeritleri verilmiştir. Diğer sensörlerin histogramları EK 2’de verilmiştir.


Histogramlar, yıllık bazda 2015 senesi tüm verilerini içermektedir. Anlaşılacağı üzere,



Şekil 4.1: RTMS 345 numaralı sensörün S1 şerit histogramı.



Şekil 4.2: RTMS 345 numaralı sensörün S2 şerit histogramı.



Şekil 4.3: RTMS 345 numaralı sensörün S3 şerit histogramı.


tüm sene boyunca S3 şeridinden en yüksek hız frekansı elde edilmiştir. Bu veri S3 şeridinin en hızlı olduğunu gösterir ve sol şerit diye nitelendirilebilir. Diğer yandan




histogramda da belli olduğu üzere S1, S2 ve S3 şeritlerinde az da olsa 10 - 30 km/saat lik hızlar mevcuttur. Bu verilerden sensörün bazı zamanlar hatalı veri verdiği çıkarımı yapılabilir. Veriler normal bir zamandaki trafik olayını veya sıkışıklığına işaret ediyor olsaydı, histogramda o sıklıkla gözükmez ve diğer yüksek hızlar arasında da veriye sahip olurlardı. Bu sebepten dolayı, verilerde hata olduğu anlaşılmıştır. Bu yöntemi doğrulamak için, bir diğer çalışma da herhangi 7 sensörden birisi olan RTMS 441 numaralı sensörde gerçekleştirilmiştir. 441 numaralı sensör ile haftanın başı ve haftanın sonu olarak Cuma ve Pazartesi günlerindeki yıllık verisi incelenmiştir. Oluşturulan grafikte, sensörün bir yıllık verisi olan 1440 veri noktası kullanılmıştır. Bu veri noktası ilgili zaman aralıklarına yerleştirilmiştir. Zaman aralıkları bir günün 24 saatine yayılmıştır. Grafikte kullanılan veri noktalarının renkleri şu şekildedir:

- \* Griler verinin üst ve alt sınırlarını gösterir
- \* Kırmızılar verinin ortalama değerini gösterir
- \* Pembeler olan verinin kendisidir
- \* Morlar üst ve alt sınırların ortanca değeridir

Şekil (4.4, 4.5)'deki grafiklerden anlaşılacağı üzere, hatalı veriler bir bölgede toplanmıştır. Bu toplanan veriler grafikte 70 ile 40 km/saat arasında, pembe renkli veri noktalarında gözlemlenebilmektedir.



Şekil 4.4: RTMS 441 numaralı sensörün cuma günlerinin yıllık verisi.



Şekil 4.5: RTMS 441 numaralı sensörün pazatesi günlerinin yıllık verisi.

Veride hataların olduğu anlaşıldıktan sonra verinin hatalardan arındırılması için yöntem geliştirilmiştir. Yönteme göre, 3 şeritten gelen hız verisinin 2'si 60 km/saat'in üzerinde ve diğer şeritteki hız 20 km/saat in altındaysa bu verinin hatalı olduğu varsayılarak veri setinden temizlenmiştir. Ancak, şeritlerden birisi 60 km/saat'in üzerinde, diğeri 60 km/saat'in altında ve son şerit ise 20 km/saat'in altındaysa, bu veride problem olmadığı düşünülmüştür. 60 km/saat ve 20 km/saat verileri, söz konusu histogram ve yıllık bazda, haftanın belirli günlerindeki verilerine dayanarak çıkarılmıştır.

Örnek tablo olarak Çizelge 4.1 bu kapsamda incelenmiştir.

Çizelge 4.1: Hatalı veri inceleme tablosu.

S3 Ortalama Hız	S2 Ortalama Hız	S1 Ortalama Hız	Geçerlilik Durumu
105	102	18	Hatalı Veri
63	65	15	Hatalı Veri
57	65	17	Geçerli Veri
45	67	60	Hatalı Veri
90	65	35	Geçerli Veri

Sonuç olarak verinin temizlenmesinde ve değerli verinin elde edilmesinde kullanılan ve incelenen yöntemler, yukarıda anlatıldığı gibi gerçekleştirilmiştir. Bu yöntemler ile verinin %90 oranla temizlenmesinde başarı sağlanmıştır. Bu oran kabul edilebilir olarak düşünülmüştür.

#### 4.1.5 Model olay girdilerinin işaretlenmesi ve eğitim setinin hazırlanması

Oluşturulan modeli eğitmek için modele eğitim seti verilmesi gerekmektedir. Bu eğitim seti verilen olay tablosundan seçtiğimiz referans bölgedeki sensörlere en yakın olan 60 adet olayı içermektedir. 60 adet trafik olayı seçildikten sonra bunların tek tek en yakın olduğu sensörlere bakılmış buradaki trafik sensörlerindeki değişimler ve etkiler gözlemlenmiştir. Ancak burada dikkat edilmesi gereken husus olayın başlangıç saatinde ve dakikasında sensör verisinde bir anormallik olmamasıdır. Çünkü, olayın rapor edilip kayda geçmesi, olay üzerinden biraz zaman geçtikten sonra gerçekleştirilir. Bu sebepten dolayı, sensörlerdeki olayın etkilerini tespit edebilmek için olay başlangıç zamanından 20 dakika geriye dönük bir periyotta incelemeler yapılmış ve başarıya ulaşılmıştır. Buradaki kıstas, olayın olduğu gerçek zamandaki belirlenen sensördeki iki veri arasındaki ani hız düşüşleridir.

20 dakika geriye dönük yapılan incelemelerde olayların olduğu zamanlardaki sensör verileri çıkarılmış ve bu sensör verileriyle 60 adet olay içeren veri elde edilmiştir. Buna istinaden olay içermediğine emin olunan 80 adet veri olaylar tablosundan çıkarılmıştır. Toplamda, olay içerdiğine ve olay içermediğine emin olunan 140 adet veri çıkartılmıştır. Bu veriler, modelin eğitim setini oluşturmaktadırlar.

#### 4.2 Modelin Sinir Ağları ile Denenmesi

Geri yayılım yöntemi (backpropagation) birçok problemde başarılı olduğu için, model sinir ağları ile bu yöntem denenmiştir. Buradaki avantaj, geri beslemeli bir öğrenme yapısına sahip olması, öğretmenli öğrenme (supervised learning) metodolojisine uygun olmasıdır [55].

Geri yayılım net öğrenme fonksiyonu olarak Delta kuralını kullanır [46]. Eşitlik 4.4'te gösterilmiştir.

$$w_{i,j}(new) = w_{i,j}(old) + (\mu * [t - f(y_{in})] * f'(y_{in})) \quad (4.4)$$

Bu fonksiyonu kullanması model için oldukça avantajlıdır, çünkü türevelendirilebilen bir fonksiyon kullanması hatanın 0'a doğru yaklaşması anlamına gelir [23]. Bu yöntem ile hata toleransı artırılmıştır. Ayrıca, diğer yöntemlerde öğrenememe gibi durumlar ortaya çıkma ihtimali daha fazladır.


#### 4.2.1 Modelin girdiler ile denenmesi

Modeli geri yayılım (backpropagation) sinir ağı yöntemiyle çalıştırmak için önceki bölümde belirtilen 140 adet eğitim seti ve tüm sensörlerden oluşturulan 276.351 adetlik deneme seti hazırlanmıştır. Deneme seti hazırlanırken, önceki bölümlerde bahsedilen temizleme işlemi uygulanmıştır. Deneme setinin içerisinde rastgele 11 adet olay içeren veri eklenmiştir.

Modeli denerken kullanılan geri yayılım sinir ağı parametreleri şu şekildedir:

- \* Girdi olarak verilen 276.351 adet deneme seti
- \* 140 adet eğitim seti, 140 adet eğitim setinden 15 adet rastgele değer çapraz doğrulama(cross-validation) seti
- \* 1 adet gizli katmandan oluşan 15 adet nöron
- \* Tekrarlama (epoch) değeri olarak 21

Burada dikkat edilmesi gereken girdi parametreleri, nöron sayısı ve tekrarlama değerleridir. Öyle ki, nöron sayısının az verilmesi modelin eğitim sırasında yetersiz kalmasına ve gerektiği kadar eğitim setinden faydalanamayarak, öğrenememesine sebep olabilmektedir (underfitting). Eğer fazla nöron sayısı girilmişse modelin veriyi çok fazla hassas yapmasına, böylelikle daha karmaşık bir hal almasına neden olmaktadır (overfitting). Diğer yandan, tekrarlama sayısının az verilmesi sinir ağının girdi parametreleri üzerinden, yani deneme setinin üzerinden daha az tekrarla geçmesine sebep olacaktır. Bu sebepten, sinir ağının deneme setindeki girdilere verilen ağırlıkları (weight) en uygun ağırlık seçiminde (bestfit) yetersiz bırakacaktır. Ancak, yüksek verilen tekrarlama değerleri sinir ağını etkilemeyecektir. Bunun sebebi ise, sinir ağının, verilen girdiye en iyi ağırlık değerini atadıktan sonra, o girdi üzerinde tekrar dönmeyecek oluşudur. Kullanılan geri yayılım sinir ağının modeli Şekil 4.6'daki gibidir.



Şekil 4.6: Kullanılan sinir ağı yapısı.

Çizelge 4.2: Deneme seti örnek veri tablosu, 270.000'lik veri seti.

Zaman	Hız Farkı	İşgaliyet Farkı	Kapasite Farkı	Olay Durumu
2015-02-13 07:23	-13	7	-0.57382441581	0
2015-02-13 07:59	-20	13	-0.7287213071	0
2015-02-13 08:09	-27	14	-1.1866164804	0
2015-02-13 10:17	-29	10	-0.7572419969	0
2015-02-13 11:05	-19	0	-0.53410000204	0
2015-02-13 15:05	29	16	2.71226624105	0
2015-02-13 15:07	1	21	0.654212422288	0
2015-02-13 16:37	-29	18	-1.4444441845	0
2015-02-13 16:39	27	31	4.02982671293	0
2015-02-13 17:11	32	36	4.95151000143	0
2015-08-01 10:16	-19	12	-0.8670654335	1
2015-08-03 11:20	-22	22	-1.1086359959	1
2015-08-14 20:05	-3	11	-0.33700314072	1
2015-09-28 07:00	-44	16	-1.6256514779	1
2015-08-02 15:05	-6	5	0.0937782056091	1
2015-03-04 19:15	-15	4	-0.54324371128	1
2015-05-27 08:33	-28	23	-2.3744347356	1
2015-02-13 15:38	-44	24	-1.1693602955	0
2015-02-13 16:03	-30	6	-0.94096961281	0
2015-02-13 16:19	2	14	0.383696346974	0
2015-02-13 16:29	-25	17	-0.577574659	0
2015-05-27 08:35	-39	7	-1.1363917054	1
2015-08-16 20:41	-21	16	-0.265036468	1
2015-08-24 18:38	-26	14	-0.746674602	0
2015-08-24 18:40	-40	14	-0.947403489	0
2015-07-09 06:23	-13	1	-0.5806610742	0
2015-03-18 10:03	-34	22	-0.781068577	0
2015-02-23 08:32	-16	13	-1.026294611	0
2015-06-12 10:47	-30	22	-0.667570715	0
2015-02-13 11:31	-26	6	-1.0226827237	0
2015-02-13 14:47	-5	48	1.56828268803	0
2015-02-13 14:51	-19	8	-0.1541251355	0
2015-07-24 07:47	-44	17	-0.944928845	0
2015-02-13 17:05	31	13	4.16939879682	0

Modelin deneme setinden alınan örnek veri tablosu Çizelge 4.2'deki gibidir.

Çizelge 4.2'de diğer bölümlerde anlatıldığı gibi modelde girdi olarak hız farkı, işgaliyet farkı ve kapasite farkı kullanılmıştır. Kırmızı olarak çizilen veriler kaza verileridir ve zaman kolonu sadece gözlem yapılması amacı ile tabloya eklenmiştir.

#### 4.2.2 Modelin sinir ağırları ile çıktıları


Modelin geri yayılım (backpropagation) sinir ağı yöntemiyle çalıştırılmasından elde edilen sonuçlara göre, deneme setinin içinde bulunan 11 adet olay tespit edilmiş ve bunun yanı sıra 11 adet olaydan farklı olarak 8000 adet veride de olay olduğu, ve 268.340 adet veride olay olmadığı şeklinde işaretlenmiştir. Örnek çıktı Çizelge 4.3'deki gibidir.

Çizelge 4.3: Sinir ağırlarının olay tespit sonuçları.


Hız Farkı	İşgaliyet Farkı	Kapasite Farkı	Olay Durumu	Model Çıktısı	Model Kaza tespiti ( 1 → var, 0 → yok)
-35	29	-1.17342	1	0.820631173	1
-2	5	1.14658	0	0.554000107	0
-58	25	-2.22503	1	1.135409855	1
-4	1	0.045720280102	0	0.076861884	0
-40	16	-1.96363	1	0.861875089	1
5	-4	0.627662864851	0	-0.047216026	0
-24	20	-0.775429294762	1	0.88635808	1
-11	4	-0.762203514181	0	0.573641744	0
-27	13	-0.665457270528	1	0.746141846	1
-14	3	-0.968769818195	0	0.604337661	0
-28	28	-1.08774	1	0.894498229	1
-4	4	0.582450512991	0	0.213225272	0
-23	18	-0.051665679442	1	1.075435595	1
-39	12	-1.016681174	1	0.788135928	1
0	0	0.640001446474	0	0.078085559	0
0	0	0.761809810593	0	0.154909843	0
4	-1	0.0740207810165	0	-0.057897539	0
4	-3	-0.172054314318	0	-0.01074484	0
0	1	0.049593049978	0	0.037478346	0
0	2	0.0842507851822	0	0.059867515	0
-1	0	0.19525555207	0	-0.01510786	0
-2	1	0.230420822125	0	0.026677485	0
-1	-1	-0.198917041303	0	0.077884745	0
0	-2	-0.328882583121	0	0.118800203	0
-4	2	0.211664102322	0	0.089875492	0

Sinir ağı çıktısına göre atanan ağırlıklar ve tahminleri verilmiştir. Buradan çıkan sonuçlar ağırlığı 0,65 üzeri olan veriler de kaza olduğu, 0,65 den az olan verilerde kaza olmadığı yönünde eşik değer verilerek incelenmiştir. Bu bağlamda, model 0,65 in üzerinde olan her bir değere 'olay vardır' olarak işaretlemiştir. Bu işaretleme ile modelin doğru çalıştığı ve verilen parametrelerin uygun olduğu düşünülmektedir.


Modelin sinir ağırları ile çalıştırılmasından elde edilen bazı grafikler Şekil (4.7, 4.8, 4.9, 4.10)'deki gibidir.




Şekil 4.7: Sinir ağının sonuç göstergeleri.



Şekil 4.8: Sinir ağının eğitim kısmındaki hata grafiği.



Şekil 4.9: Modelin doğrulama grafiği - 15. tekrar.



Şekil 4.10: Sinir ağı performans grafikleri.



### 4.3 Olay Tespit Modelinin Sonuçları

Model deneme setinde verilen olayların hepsi algılandığından, modeldeki çıktılar başarılı olarak değerlendirilebilir. Bu düşünce kapsamında Kesinlik (Precision), Duyarlılık (Recall), Doğruluk (Accuracy) ve Hata Oranı (Error Rate) değerleri bilimsel anlamda modelin doğruluğu ve kararlılığı bağlamında modelin başarılı olup olmadığını belirtir. Çizelge 4.4’de karışıklık matrisi (Confusion Matrix) verilmiştir. Karışıklık matrisi, gerekli hesaplamaların yapılabilmesi için kullanılan güncel bir yöntemdir. Hesaplamaların formülleri Eşitlik (4.5, 4.6, 4.7, 4.8)’de verilmiştir. Bu eşitlikler kullanılarak model çıktılarındaki verilerin sayıları üzerinden hesaplamalar yapılmıştır.

Çizelge 4.4: Karışıklık matrisi (Confusion Matrix) tanımı.

Gerçek Sınıf (Actual Class)	Öngörülen Sınıf (Predicted Class)		
		Pozitif	Negatif
	Doğru Yanlış	Gerçek Pozitif	Sahte Negatif
		Sahte Pozitif	Gerçek Negatif

$$\text{Doğruluk (Accuracy)} = \frac{\text{Gerçek Pozitif} + \text{Gerçek Negatif}}{\text{Gerçek Pozitif} + \text{Sahte Pozitif} + \text{Sahte Negatif} + \text{Gerçek Negatif}} \quad (4.5)$$

$$\text{Kesinlik (Precision)} = \frac{\text{Gerçek Pozitif}}{\text{Gerçek Pozitif} + \text{Sahte Pozitif}} \quad (4.6)$$

$$\text{Duyarlılık (Recall)} = \frac{\text{Gerçek Pozitif}}{\text{Gerçek Pozitif} + \text{Sahte Negatif}} \quad (4.7)$$

$$\text{Hata Oranı (Error Rate)} = \frac{\text{Sahte Pozitif} + \text{Sahte Negatif}}{\text{Gerçek Pozitif} + \text{Sahte Pozitif} + \text{Sahte Negatif} + \text{Gerçek Negatif}} \quad (4.8)$$

Model çıktı verileri karışıklık matrisine oturtulması Çizelge 4.5'deki gibidir.

Çizelge 4.5: Karışıklık matrisi(Confusion Matrix) verileri.

Gerçek Sınıf (Actual Class)	Öngörülen Sınıf (Predicted Class)		
		Pozitif	Negatif
	Doğru	11 adet	0 adet
Yanlış	8000 adet	268.340 adet	

Çizelge 4.5 incelendiğinde şu yorumlar yapılabilmektedir:

- \* 11 Adet olay verisi varken modelin olay olarak işaretlediği veri
- \* 8000 adet veri olay verisi yok iken modelin olay olarak işaretlediği veri
- \* 0 adet veri olay varken modelin olay yok olarak işaretlediği veri
- \* 268.340 adet veri olay yok iken modelin olay yok olarak işaretlediği veridir.

Bu kapsamda Çizelge 4.5 ile Doğruluk, Kesinlik, Duyarlılık ve Hata-Oranı denklemleri Eşitlik (4.9,4.10,4.11,4.12)'deki gibi hesaplanmıştır.

$$\text{Dogruluk (Accuracy)} = \frac{11 + 268.340}{11 + 8000 + 0 + 268.340} = 0,9710513079380932 \quad (4.9)$$

$$\text{Kesinlik (Precision)} = \frac{11}{11 + 8000} = 0,0013731119710398 \quad (4.10)$$

$$\text{Duyarlılık (Recall)} = \frac{11}{11 + 0} = 1 \quad (4.11)$$

$$\text{Hata Oranı (Error Rate)} = \frac{8000 + 0}{11 + 8000 + 0 + 268.340} = 0,0287406907106495 \quad (4.12)$$

Doğruluk değeri %97 ile başarılı çıkmıştır. Hata Oranı'ndan düşük ve Duyarlılık'tan ise yüksek sonuçlar elde edilmesi modelin verilen olayları düşük hata payı ve yüksek duyarlılıkla tespit edebildiğini göstermektedir. Ancak, kesinlik değerinin çok düşük elde edilmesi, bu modellemede kesinlik değeri ölçümünün uygun olmadığını belirtmiştir. Bunun sebebi ise, modelin bulunduğu olayların gerçekte var olup olmadığının doğrulanamamasındandır. Çünkü modelin bulunduğu olaylar gerçekte olmuş ancak olay bildirilmemiş ya da kayıtlara alınmamış olabilir. Geçmişe dönük bu tür bir veri öğrenilememektedir. Bu sebepten dolayı kesinlik değeri söylemek çok doğru olmayacaktır.

Ancak, doğruluk ve duyarlılık değeri bu parametreler için oldukça iyi olarak yorumlanmaktadır.

Kesinlik değerini arttırmak için diğer bir yöntem modele özellik eklemek ve farklı girdiler sağlayıp modeli beslemektir. Bu sayede modelin daha kararlı bir biçimde öğrenebileceği öngörülmüştür. Ancak modellemedeki en büyük zorluklardan birisi trafik verilerindeki verinin her zaman kararlı bir şekilde olmayışı ve özellik seçmekteki güçlüktür. Trafik çok parametrelili bir olgudur, buna bağlı olarak ise İstanbul trafiğinin daha da fazla zorluklar ve parametreler içerdiği bilinmektedir. Bu kapsamda İstanbul trafik verilerinden özellik seçilmesi ve seçilen özelliğin faydalı olup olmadığınin tayin edilmesi oldukça zordur. Örneğin; sadece araç sayısından bir çıkarım yapmak mümkün olduğu gibi, ve araç sayısı, hız, işgaliet değeri ve hava koşullarından da çıkarım yapmak mümkündür. Böylelikle seçilen çeşitli özellikler sebebi ile modelin kesinlik değeri ölçümü düşük çıkmaktadır.


Kesinlik değerinin düşük çıkmasındaki diğer sebep ise, olay verilerinin modeli eğitmek için yetersiz kaldığı düşüncesidir. Modelin az bir eğitim kümesiyle eğitim aşamasında koşullara ve durumlara tam olarak adapte olamadığı düşünülmektedir. Olay verilerinin, başka bir deyişle eğitim setinin çeşitli ve rastgele dağıtık olmasının model için faydalı olacağı ve değişik koşullarda modelin karar verme mekanizmasını olumlu yönde etkileyeceği düşünülmektedir. Denetimli ya da öğretmenli öğrenme (Supervised Learning) sinir ağı modeli kullanıldığı için, model eğitim setinin kalitesine göre verilen kararlar da bir o kadar doğruluk ve hassasiyetle olacaktır.

Kesinlik değerinin düşük çıkmasına rağmen, model olay içeren tüm verileri doğru bir biçimde tespit edebilmiştir. Deneme setinde verilen 11 adet olay verisini eksiksiz tespit etmekle beraber, modelin ‘olay yoktur’ dediği tüm verilerde olay görülmemektedir. Bu düşünceden yola çıkarak, var olan olayların tespitini %100 olarak başarılı, model tarafından ‘olay yoktur’ olarak işaretlenen durumlarda ise, %100 olay olmadığı kabul edilebilmektedir. Sonuç olarak model gerçekte oluşmuş olayların tamamını yakalayabilmekte, olay olmadığını tespit ettiği durumların tamamında ise olay olmamaktadır.

#### **4.4 Olay Tespit Modelinden Geliştirilen Uygulama**

Tezde anlatılan olay tespit modelinden yararlanarak, akıllı şehirler konseptine uygun olarak, anlık kazaları tespit etmek amacıyla deneme geliştirme süreci devam eden bir uygulama geliştirilmiştir. Uygulama temel olarak iki katmandan oluşturulmuştur. İlk katman NodeJS ve Leaflet teknolojilerinin birleştirilmesi ile kullanıcıya rahat ve kullanışlı bir arayüz sağlanmıştır. Kullanıcı arayüzü sayesinde, kullanıcı anlık olarak ekrandan olup biteni izleyebilmektedir. Eğer, model gelen canlı trafik verisi üstünden


olay tespitinde bulunur ise, tespit yaptığı sensörün rengini kırmızıya çevirip, sensör bölgesinde olay tespitinde bulunduğunu göstermektedir. Böylelikle kullanıcı uyarılıp gerekli önlemlerin, kullanıcı tarafından alınabilmesine olanak sağlayabilmektedir. Bir diğer kullanıcı tarafında sağladığı fayda ise, kullanıcı ekranda fark ettiği olayı, kendi sistemi üzerinden, rahatça takibini yapabilmektedir. Bu takip gerek çeşitli trafik sensörleri gerek kameralar vasıtasıyla kullanıcı tarafından, anlık olarak canlı trafik üzerinden yapılabileceği öngörülmüştür. Şekil 4.11’de uygulamanın olay tespiti yapmadığı bir zamanda alınmış ekran görüntüsü verilmiştir.



Şekil 4.11: Uygulamadaki modelin, olay tespitinde bulunmadığı bir andaki sensör bölgesinin görünümü.

Uygulamanın ikinci katmanı servis katmanıdır. Servis katmanı, Python dilinde geliştirilmiş olup, anlık olarak sistem üzerinden dinlediği porta gelen veriler ile daha önceden 2015 yılı verileri ile eğitilmiş olan olay tespit modeline girdi sağlamaktadır. Bu girdiler ile model çalıştırılıp, birinci katmandaki ekran vasıtasıyla kullanıcının uyarılması sağlanmıştır. Servis katmanındaki en büyük zorlukların başında, gelen verinin anlık olarak doğru gelmesi hususudur. Çünkü gelen verilerde zaman zaman aksaklıklar ve verinin kalitesinde düşüş yaşanabilmektedir. Yaşanan kalite düşüşündeki kasıt, gelen verinin bazen sensörler tarafından yanlış olarak işlenmesinden kaynaklı olabileceği düşünülmektedir. Tezin önceki bölümlerinde bahsi geçen hata düzeltme yöntemleri her koşulda veriyi temizleyememektedir. Buradaki gelen ham verinin işlenmesi ve temizlenmesi konusu, halen geliştirilmekte olup; uygulamanın kendisine gelen ham verinin, nasıl daha anlaşılabilir olabileceği ve modele daha verimli girdi sağlayabileceği konularında çalışmalar devam etmektedir. Şekil 4.12’de uygulamanın olay tespiti yaptığı bir zamanda alınmış ekran görüntüsü verilmiştir.

Özetle uygulama, akıllı trafik sistemleri ve akıllı şehirler konseptlerinden edinilen fi-



Şekil 4.12: Uygulamadaki modelin, olay tespitinde bulunduğu bir andaki sensör bölgesinin görünümü.

kirler doğrultusunda, tez de bahsedilen olay algılama modeli ile geliştirilmeye devam edilmektedir. İleride yapılacak geliştirmeler ve modelden edinilen daha kararlı sonuçlar doğrultusunda, trafik takip sistemlerine entegre çalışabilecek ya da kendi başına ayrı bir sistem olarak çalıştırılabilecek bir konuma getirilmesi planlanmıştır.



## 5. ÇIKARIMLAR VE TARTIŞMA

### 5.1 Tartışma

Trafik modelinin yapay sinir ağları ile olay tespiti yapılmasından elde edilen doğruluk oranının başarılı olduğu gözükmektedir. Bu oranın yakalanmasında verilerin ham hali üzerinde yapılan temizleme işleminin en doğru şekilde ve hatasız bir biçimde yapılmasının önemli olduğu doğrulanmıştır.

Kapasite çalışmasında kullanılan denklem ve yol kapasite hesabının tespit edilmesinde araç sayısının ve araç hızlarından oluşan denklemin doğru olduğu ve buna bağlı olarak değişen trafik koşullarını doğru temsil ettiği düşünülmektedir. Sonuç değerler yollardaki olayların eğitim setiyle uyumlu olduğu seçilen eğitim setinden yollardaki olayları tespit için doğru zamanların seçildiğini göstermektedir. Yapay sinir ağlarının fazladan bulunduğu olayların hatalı olduğunun düşünülmesi çok doğru bir yaklaşım olmayacaktır. Çünkü, olay var diye işaretlenen verilerde gerçekte olay olup olmadığı doğrulanamamaktadır. Trafikte yaşanan her olayın trafik merkezine bildirilemediği bilinmektedir. Bu yüzden fazladan tespit edilen olayların gerçekte bir olay olmadığı düşünülmesi doğru bir yaklaşım olmayacaktır. Daha fazla yaşanan olay setiyle ya da olay diye işaretlenen veriler ile tekrar eğitim seti oluşturulduğunda kesinlik ve doğruluk oranlarının artabileceği düşünülmektedir.

Yapılan çalışmanın alternatifi olarak derin öğrenme yöntemine gidilmesi düşünülmüştür. Ancak, yukarıda da belirtildiği gibi olay verisinin gerçekte doğrulanamaması ve olay verisinin az olması durumundan dolayı derin öğrenme yöntemine gidilmemiştir. Derin öğrenme yöntemi için daha fazla veriyle ve eğitim setiyle çalıştırılabileceği kanısına varılmıştır.

Şerit bazlı incelemenin çalışma başında daha verimli olacağı yönünde varsayımlarda bulunulmuştur. Olayların şeritlere özgü yaklaşımla algılanabileceği düşünülmüştür. Ancak geliştirilen trafik bazlı modelde kapasite hesaplaması yapılırken şerit kapasitesi değil, yol kapasitesinin daha doğru olacağı verilerin ve olayların yol üzerindeki toplam etkisi incelendikten sonra karar verilmiştir. Çünkü mevcut veri yapısı olay algılama yapılabilmesi için sensörlerdeki verilerin şerit değil, yol bazlı inceleme yapılmasına olanak sağlamaktadır. Muhtemel başka özel sensör tipi verileriyle şerit bazlı çalışmaların detaylı yapılabileceği düşünülmüştür.

Verilerdeki doğruluk oranı ve hassasiyet değerlerinin artırılması için modele daha çok rastgele dağıtık ve toplam deneme setine bakıldığında daha fazla eğitim seti verilerek değerler artırılabilir. Deneme setinin düşük olduğu oranlarda kesinlik, doğruluk ve hassasiyet değerlerinin yüksek çıktığı bilinmektedir. Bunun sebebi ise eğitim setinin deneme setine oranla daha yakın orana sahip olmasındandır. Ancak model için sayıca düşük olan eğitim seti ile gelen yüksek deneme seti girdileri karşısında bazı durumlarda karar verme aşamasında Sahte Gerçek (False Positive) değerler yüksek çıkabilmektedir. Bu değerler doğruluk oranını çok fazla etkilemese de hassasiyet değerleri için oldukça kötü bir etkiye sahiptir. Bunun sebebinin ise eğitim setinin yetersiz kalmasının olduğu düşünülmektedir.

## 5.2 Geleceğe Yönelik Çalışmalar

Geliştirilen trafik modeli başarılı sonuçlar elde etmesine rağmen, gelecekteki taleplere cevap verip veremeyeceği bilinmemektedir. Her geçen gün değişen çevre ve trafik koşulları modellemelerde yenilikçi yaklaşımları da beraberinde getirmektedir. Bu sebepten, modelin daha da etkili ve başka girdilerden de destek alarak geliştirebileceği düşünülmüştür.

Model ile ilgili çalışma çevre koşullarının da hesaba katılarak bir sonraki çalışma olarak devam ettirilebilir. Örneğin; yaz ve kış mevsimlerinin hava koşullarına göre yollardaki hız oranı belli miktarlarda artıp azalabilmektedir. Bu değişimler o yollarda olay olduğuna işaret etmeyebilir. Bu gibi koşullar da hesaba katılarak metroloji verileriyle sonuçlar daha da kuvvetlendirilebilir. Literatür çalışmalarına bakıldığında çevre etkilerinin trafik üstünde oluşturacağı etki araştırılmış ve bu koşulların göz ardı edilemeyecek derecede etkili olabileceği ortaya konulmuştur.

Başka bir çalışma olarak, yollardaki kazalar ve olaylar incelenip geleceğe yönelik olarak riskli yollar çıkartılıp önceden tedbirler alınabilir. Bu çerçevede yol risk haritalarına göre ekipler uyarılabilir ve trafik unsurları bu haritalar konusunda bilinçlendirilebilir. Bu kapsamda trafik güvenliği geliştirilmiş olabilmektedir.

İleride, hemen hemen herkesin sosyal medya ile bağlantısı bir şekilde olacağı düşünülmektedir. Bu düşünceden yola çıkılarak, sosyal medya verileriyle yol verilerinin ve hava durumu verilerinin ortak birleşiminden oluşturulabilecek modelin muhtemelen daha kesin ve doğru sonuçlar çıkaracağı düşünülmektedir. Böylece modelin eğitim seti güçlendirilip yeni özellikler eklenmesi modeli daha kararlı kılacaktır. Bu sayede trafik modeli değişen çevre ve insan temelli koşullara daha kolay adapte olabileceği ve kararları daha etkili verebileceği söylenebilir.



## KAYNAKLAR

- [1] **James Ciment.** *Booms and busts*. Sharpe, 2010.
- [2] GENEL KAZA İSTATİSTİKLERİ. "<http://www.trafik.gov.tr/Sayfalar/Istatistikler/Genel-Kaza.aspx> alındığı tarih:31.03.2016".
- [3] Kaza İstatistikleri. "<http://www.trafik.gov.tr/Sayfalar/Istatistikler.aspx> alındığı tarih:31.03.2016".
- [4] **Ho Lee.** *Algorithms To Improve The Quality Of Freeway Traffic Detector Data*. Ph.d. thesis, The Ohio State University, 2012.
- [5] **Jackson Wang.** The Road Traffic Microwave Sensor (RTMS). *The 3rd International Conference on Vehicle Navigation and Information Systems*, pages 83–90, 1992.
- [6] **Ph Masters, Jk Lam, and Kam Wong.** Incident Detection Algorithms for COMPASS - An Advanced Traffic Management System. *Vehicle Navigation and Information Systems Conference*, pages 295–310, 1991.
- [7] **Yiheng Feng, John Hourdos, and Gary A. Davis.** Probe vehicle based real-time traffic monitoring on urban roadways. *Transportation Research Part C: Emerging Technologies*, 40:160–178, 2014.
- [8] **Alessandra Pascale, Thanh Lam Hoang, and Rahul Nair.** Characterization of network traffic processes under adaptive traffic control systems. *Transportation Research Part C: Emerging Technologies*, 59:340–357, 2015.
- [9] **Christina Diakaki, Markos Papageorgiou, Ioannis Papamichail, and Ioannis Nikolos.** Overview and analysis of Vehicle Automation and Communication Systems from a motorway traffic management perspective. *Transportation Research Part A: Policy and Practice*, 75:147–165, 2015.
- [10] **Vipin Jain, Ashlesh Sharma, and Lakshminarayanan Subramanian.** Road traffic congestion in the developing world. *Proceedings of the 2nd ACM Symposium on Computing for Development - ACM DEV '12*, 2012.
- [11] **Demirhan Büyüközcü.** *Discretized Categorization of High Level Traffic Activities in Tunnels Using Attribute Grammars*. M.sc. thesis, Middle East Technical University, 2012.
- [12] **Tuncay SOYLU.** *Kablosuz Algılayıcı Ağların Uygulama Alanları ve Bir Algılayıcı Düşüm Tasarımı*. Master tezi, Trakya Üniversitesi, 2012.

- [13] **Cafer KOÇKAN.** *Taşıtlar Arası Haberleşme.* Master tezi, İstanbul Teknik Üniversitesi, 2008.
- [14] **Yuanyuan Zeng, Deshi Li, and Athanasios V. Vasilakos.** Opportunistic fleets for road event detection in vehicular sensor networks. *Wireless Networks*, 22(2):503–521, 2015.
- [15] **Quan Yuan, Zhihan Liu, Jinglin Li, Junming Zhang, and Fangchun Yang.** A traffic congestion detection and information dissemination scheme for urban expressways using vehicular networks. *Transportation Research Part C: Emerging Technologies*, 47(P2):114–127, 2014.
- [16] **Andrea Baiocchi, Francesca Cuomo, Mario De Felice, and Gaetano Fusco.** Vehicular Ad-Hoc Networks sampling protocols for traffic monitoring and incident detection in Intelligent Transportation Systems. *Transportation Research Part C: Emerging Technologies*, 56:177–194, 2015.
- [17] **Fernando Terroso-sáenz, Mercedes Valdés-vela, Cristina Sotomayor-martínez, Rafael Toledo-moreo, and Antonio F Gómez-skarmeta.** Detection With Complex Event Processing and VANET. *IEEE Transactions on Intelligent Transportation Systems*, 13(2):914–929, 2012.
- [18] **Yaşar İlgin.** Kaza-Olay Tespit Algoritmalarına Genel Bakış. *DEÜ Mühendislik Fakültesi Mühendislik Bilimleri Dergisi*, 12(1):33–45, 2010.
- [19] **Lili Cui, Kehuang Li, Jiapin Chen, and Zhenbo Li.** Abnormal event detection in traffic video surveillance based on local features. *4th International Congress on Image and Signal Processing (CISP)*, 1:362–366, 2011.
- [20] **Shiming Yang, Konstantinos Kalpakis, and Alain Biem.** Spatio-temporal Coupled Bayesian Robust Principal Component Analysis for Road Traffic Event Detection. In *Proceedings of the 16th International IEEE Annual Conference on Intelligent Transportation Systems (ITSC 2013)*, pages 392–398, The Hague, The Netherlands, 2013.
- [21] **Ahmad Tavassoli Hojati, Luis Ferreira, Simon Washington, Phil Charles, and Ameneh Shobeirinejad.** Modelling total duration of traffic incidents including incident detection and recovery time. *Accident Analysis and Prevention*, 71:296–305, 2014.
- [22] **Jian Lu, Shuyan Chen, Wei Wang, and Henk Van Zuylen.** A hybrid model of partial least squares and neural network for traffic incident detection. *Expert Systems with Applications*, 39(5):4775–4784, 2012.
- [23] **Muhammed Gökhan Cinsdikici.** *Neural Network Solutions for ATM Routing & Multicasting Problems.* M.sc. thesis, Ege University, 1997.
- [24] **Yıldırım Uğur and Ugur Özcan.** Ankara Şehir İçi Trafik Kazalarının Analizi: Bir Yapay Sinir Ağı Modeli. *Gazi Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 17(1):35–63, 2015.

- [25] **Gültekin B. Çetiner, Murat Sarı, and Oguz Borat.** A Neural Network Based Traffic-Flow Prediction Model. *Mathematical and Computational Applications*, 15:269–278, 2010.
- [26] **Jian Lu, Shuyan Chen, Wei Wang, and Bin Ran.** Automatic traffic incident detection based on nFOIL. *Expert Systems with Applications*, 39(7):6547–6556, 2012.
- [27] **T Singliar and M Hauskrecht.** Learning to detect adverse traffic events from noisily labeled data. *Knowledge Discovery in Databases: PKDD 2007, Proceedings*, 4702(California 2):236–247, 2007.
- [28] **Ömer Aköz and M. Elif Karsligil.** Traffic event classification at intersections based on the severity of abnormality. *Machine Vision and Applications*, 25(3):613–632, 2014.
- [29] **Jules White, Chris Thompson, Hamilton Turner, Brian Dougherty, and Douglas C. Schmidt.** WreckWatch: Automatic traffic accident detection and notification with smartphones. *Mobile Networks and Applications*, 16(3):285–303, 2011.
- [30] **Jorge Zaldivar, Carlos T. Calafate, Juan Carlos Cano, and Pietro Manzoni.** Providing accident detection in vehicular networks through OBD-II devices and android-based smartphones. In *Proceedings - Conference on Local Computer Networks, LCN*, pages 813–819, 2011.
- [31] **Taishi Yamamoto, Kenta Oku, Hung Hsuan Huang, and Kyoji Kawagoe.** SQUED: A novel crowd-sourced system for detection and localization of unexpected events from smartphone-sensor data. *2015 IEEE/ACIS 14th International Conference on Computer and Information Science, ICIS 2015 - Proceedings*, pages 383–386, 2015.
- [32] **Eleonora D’Andrea, Pietro Ducange, Beatrice Lazzerini, and Francesco Marcelloni.** Real-Time Detection of Traffic from Twitter Stream Analysis. *IEEE Transactions on Intelligent Transportation Systems*, 16(4):2269–2283, 2015.
- [33] **Carlos Gutiérrez, Paulo Figuerias, Pedro Oliveira, Ruben Costa, and Ricardo Jardim-goncalves.** Twitter Mining for Traffic Events Detection. In *Science and Information Conference*, pages 371–378, London, UK, 2015.
- [34] **Lalit Sivanandan Nookala.** *Weather Impact on Traffic Conditions and Travel Time Prediction*. M.sc. thesis, University of Minnesota Duluth, 2006.
- [35] **B Güvenal, A Çabuk, and M Yavuz.** Trafik Kazaları Verilerine Bağlı Olarak CBS Destekli Ulaşım Planlaması : Eskişehir Kenti Örneği. In *Harita ve Kadastro Mühendisleri Odası 2. Mühendislik Ölçmeleri Sempozyumu*, pages 424–436, İstanbul, Türkiye, 2005.
- [36] **Arif Cagdas Aydinoglu, Metin Senbil, Deniz Saglam, and Selcuk Demir.** Planning of Parking Places on Transportation Infrastructure by Geographic Information Techniques. In *2015 3rd International Istanbul Smart Grid Congress and Fair (ICSG)*, pages 1–5, Istanbul, Turkey, apr 2015. IEEE.

- [37] **A.E. Erkan and A.Ç Aydınöđlu.** Trafik Ölçme Sensörü Verilerinin Zamansal Analizi. In *1. Karayolu Akıllı Ulaşım Sistemleri Kongresi ve Sergisi*, pages 1–10, İstanbul, Türkiye, 2014.
- [38] Video Detector. "<http://www.aldridgetrafficcontrollers.com.au/Products/Video-Detection> alındıđıtarih: 31.03.2016".
- [39] Led Display Radar. "<http://www.isbak.com.tr/tr/icerik/led-displayli-radar-sistem> alındıđıtarih:31.03.2016".
- [40] Induction Loop Traffic Sensor. "<http://auto.howstuffworks.com/car-driving-safety/safety-regulatory-devices/red-light-camera1.htm> alındıđıtarih:29.03.2016".
- [41] İsbak Bluetooth Senör. "<http://www.isbak.com.tr/tr/icerik/bluetooth-sensor> alındıđıtarih:31.03.2016".
- [42] Libellium Bluetooth. "[http://www.libellium.com/vehicle\\_traffic\\_monitoring\\_bluetooth\\_sensors\\_over\\_zigbee/](http://www.libellium.com/vehicle_traffic_monitoring_bluetooth_sensors_over_zigbee/)) alındıđıtarih:31.03.2016".
- [43] İsbak RTMS. "<http://www.isbak.com.tr/tr/icerik/mikrodalga-radar-sensor> alındıđıtarih:31.03.2016".
- [44] **Lawrence a Klein, Milton K Mills, and David R P Gibson.** Traffic Detector Handbook. *Operations Research*, I(October):462, 2006.
- [45] RTMS Sensor. "<http://www.traffictoday.com/news.php?NewsID=32590> alındıđıtarih:31.03.2016".
- [46] **L. Fausett.** *Fundamentals of Neural Networks, Architectures, Algorithms and Applications*. Prentice-Hall International Editions, 1994.
- [47] **B Yegnanarayana.** *Artificial neural networks*. Prentice-Hall of India, New Delhi, 110001 edition, 2005.
- [48] **Mehmet Karahan.** *İstatistiksel Tahmin Yöntemleri: Yapay Sinir Ağları Metodu ile ÜrÜN Talep Tahmini Uygulaması*. Doktora tezi, Selçuk Üniversitesi, 2011.
- [49] **Andrew Ng.** CS294A Lecture Notes Sparse Autoencoder. *Stanford University*, pages 1–19, 2011.
- [50] **Ilya Sutskever.** *Training Recurrent Neural Networks*. Ph.d. thesis, University of Toronto, 2013.
- [51] HDFS Architecture. "<http://hadoop.apache.org/docs/r1.2.1/images/hdfsarchitecture.gif> alındıđıtarih:29.03.2016".
- [52] **Jens Dittrich and Jorge-Arnulfo Quiané-Ruiz.** Efficient Big Data Processing in Hadoop MapReduce. *Proc. VLDB Endow.*, 5(12), 2012.
- [53] Map Reduce. "<http://aimotion.blogspot.com.tr/2012/08/introduction-to-recommendations-with.html> alındıđıtarih:29.03.2016".

- [54] **Jussi Kirves.** *Automated System Trading , Algorithms and Programming - To Buy or To Sell The Trend ?* M.sc. thesis, Aalto University, 2014.
- [55] **Richard P. Lippman.** An introduction to computing with neural nets. *IEEE ASSP Magazine*, 4:4–22, 1987.





## **EKLER**

**EK 1** : Ham Trafik Verileri

**EK 2** : Sensör Histogramları









**EK 1**

**Çizelge 5.1: Edinilen trafik verisinin ham hali.**


MsgTime	RtmsNo	S1	S2	S3	SGelisGraf	SGidisGraf	V1	V2	V3	O1	O2	O3	OGelisGraf	OGidisGraf
2015-02-12 23:59:03.000	432	61	95	115	90	99	16	20	12	8	4	2	4	3
2015-02-12 23:59:05.000	436	41	93	116	83	87	13	11	3	6	4	0	3	1
2015-02-12 23:59:14.000	441	68	93	105	88	90	16	23	18	8	6	3	5	4
2015-02-12 23:59:29.000	440	59	83	97	79	81	12	20	12	6	6	2	4	4
2015-02-12 23:59:48.000	345	65	104	124	97	93	10	23	8	3	5	1	3	3
2015-02-13 00:01:47.000	345	73	106	125	101	98	12	18	10	3	3	1	2	2
2015-02-13 00:02:42.000	429	49	89	116	84	102	10	20	22	7	8	3	6	5
2015-02-13 00:03:03.000	432	52	102	116	90	94	14	25	11	6	7	2	5	5
2015-02-13 00:03:05.000	436	45	89	115	83	82	10	17	7	4	4	1	3	4
2015-02-13 00:03:14.000	441	74	87	102	87	91	16	23	19	7	7	3	5	6
2015-02-13 00:03:29.000	440	48	83	87	72	81	14	23	24	6	8	6	6	4
2015-02-13 00:03:39.000	430	70	72	100	80	109	18	21	18	8	7	4	6	6
2015-02-13 00:04:25.000	345	71	111	122	101	99	13	16	10	5	3	1	3	3
2015-02-13 00:04:42.000	429	48	86	114	82	109	10	23	24	6	8	4	6	2
2015-02-13 00:05:03.000	432	50	105	113	89	92	16	22	4	8	5	0	4	6
2015-02-13 00:05:05.000	436	50	90	112	84	93	6	15	5	2	4	0	2	2
2015-02-13 00:05:14.000	441	67	89	102	86	97	12	20	14	6	6	2	4	7
2015-02-13 00:05:29.000	440	51	85	91	75	83	14	18	16	5	6	4	5	3
2015-02-13 00:05:41.000	430	70	67	95	77	95	16	29	24	8	10	5	7	9
2015-02-13 00:05:47.000	345	71	109	122	100	98	16	21	12	6	4	1	3	4
2015-02-13 00:06:42.000	429	56	84	113	84	105	8	22	20	5	9	3	5	5
2015-02-13 00:07:03.000	432	53	102	113	89	91	14	26	13	7	7	2	5	5
2015-02-13 00:07:05.000	436	47	91	111	83	100	13	14	5	6	4	0	3	3
2015-02-13 00:07:14.000	441	63	96	108	89	97	17	23	20	8	6	3	5	7
2015-02-13 00:07:29.000	440	48	84	92	74	80	10	24	20	4	6	4	4	6
2015-02-13 00:07:39.000	430	64	60	91	71	90	16	19	21	8	7	5	6	7
2015-02-13 00:07:47.000	345	69	109	119	99	99	10	18	7	3	3	0	2	2
2015-02-13 00:08:42.000	429	54	84	112	83	107	9	19	21	6	6	3	5	7
2015-02-13 00:09:03.000	432	43	92	118	84	94	17	27	10	10	8	1	6	5
2015-02-13 00:09:05.000	436	43	91	111	81	100	11	12	4	5	4	0	3	5
2015-02-13 00:09:14.000	441	62	98	104	88	95	13	23	19	6	7	3	5	6
2015-02-13 00:09:29.000	440	47	84	93	74	79	17	28	19	9	9	3	7	5
2015-02-13 00:09:39.000	430	66	68	87	73	86	19	26	16	9	8	3	6	6
2015-02-13 00:09:48.000	345	67	105	114	95	96	16	23	7	6	6	1	4	2
2015-02-13 00:10:42.000	429	55	86	116	85	112	11	17	22	7	8	4	6	6
2015-02-13 00:11:03.000	432	40	96	116	84	97	12	25	8	7	6	1	4	4
2015-02-13 00:11:05.000	436	39	90	114	81	101	11	13	6	5	3	0	2	5
2015-02-13 00:11:14.000	441	56	90	108	84	96	10	19	13	5	5	2	4	8
2015-02-13 00:11:29.000	440	43	82	99	74	77	10	20	17	4	5	3	4	5
2015-02-13 00:11:39.000	430	63	72	90	75	86	18	22	18	9	8	4	7	7
2015-02-13 00:11:47.000	345	55	103	112	90	100	12	20	4	4	4	0	2	3
2015-02-13 00:12:42.000	429	59	88	111	86	110	9	24	20	7	9	5	7	7
2015-02-13 00:13:03.000	432	42	94	116	84	96	16	24	4	8	7	0	5	4
2015-02-13 00:13:05.000	436	41	91	116	82	108	17	15	5	7	5	0	4	2
2015-02-13 00:13:14.000	441	52	95	108	85	97	13	27	16	7	7	2	5	5
2015-02-13 00:13:29.000	440	53	81	97	77	79	12	21	19	4	7	3	4	4
2015-02-13 00:13:39.000	430	62	68	91	73	84	15	27	12	9	9	2	6	9
2015-02-13 00:13:47.000	345	52	103	111	88	101	15	20	6	4	5	0	3	5
2015-02-13 00:14:42.000	429	57	86	112	85	108	9	13	16	6	3	2	3	5
2015-02-13 00:15:03.000	432	47	94	118	86	97	20	22	6	9	8	0	5	4
2015-02-13 00:15:05.000	436	39	92	119	83	119	13	12	6	6	4	1	3	3
2015-02-13 00:15:14.000	441	46	97	104	82	97	10	17	19	5	5	3	4	6
2015-02-13 00:15:29.000	440	50	83	97	76	76	10	20	23	4	6	5	5	4
2015-02-13 00:15:39.000	430	64	70	93	75	81	17	25	15	8	9	3	6	8
2015-02-13 00:15:47.000	345	55	103	114	90	103	16	21	4	6	4	0	3	2




Şekil 5.1: RTMS 345 numaralı sensörün 2 haftalık işlenmemiş verisi.




Şekil 5.2: RTMS 429 numaralı sensörün 2015 yılı işlenmemiş verisi.




Şekil 5.3: RTMS 429 numaralı sensörün 2 haftalık işlenmemiş verisinin grafiksel olarak yakınlştırılmış hali.




Şekil 5.4: RTMS 430 numaralı sensörün 2 haftalık işlenmemiş verisi.




Şekil 5.5: RTMS 432 numaralı sensörün 2 haftalık işlenmemiş verisi.



Şekil 5.6: RTMS 436 numaralı sensörün 2015 yılı işlenmemiş verisi.




Şekil 5.7: RTMS 440 numaralı sensörün 2015 yılı işlenmemiş verisi.




Şekil 5.8: RTMS 441 numaralı sensörün 2015 yılı işlenmemiş verisi.




## EK 2




Şekil 5.9: RTMS 436 numaralı sensörün S1 şerit histogramı.



Şekil 5.10: RTMS 436 numaralı sensörün S2 şerit histogramı.




Şekil 5.11: RTMS 436 numaralı sensörün S3 şerit histogramı.




Şekil 5.12: RTMS 430 numaralı sensörün S1 şerit histogramı.







Şekil 5.13: RTMS 430 numaralı sensörün S2 şerit histogramı.




Şekil 5.14: RTMS 430 numaralı sensörün S3 şerit histogramı.




Şekil 5.15: RTMS 440 numaralı sensörün S1 şerit histogramı.




Şekil 5.16: RTMS 440 numaralı sensörün S2 şerit histogramı.




Şekil 5.17: RTMS 440 numaralı sensörün S3 şerit histogramı.



Şekil 5.18: RTMS 441 numaralı sensörün S1 şerit histogramı.



Şekil 5.19: RTMS 441 numaralı sensörün S2 şerit histogramı.



Şekil 5.20: RTMS 441 numaralı sensörün S3 şerit histogramı.

## ÖZGEÇMİŞ

**Ad-Soyad** : Yusuf Gökhan KÜÇÜKAYAN  
**Uyruğu** : T.C.  
**Doğum Tarihi ve Yeri** : 03.09.1990 - Ankara  
**E-posta** : gokhankucukayan@gmail.com

### ÖĞRENİM DURUMU:

- **Lisans** : 2012, Bilkent Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği

### MESLEKİ DENEYİM VE ÖDÜLLER:

Yıl	Yer	Görev
2012-2015	BTT Bilgi Teknoloji Tasarım Ltd. Şti.	Proje Mühendisi
2015-	STM Savunma Teknolojileri Mühendislik ve Ticaret A.Ş.	Uzman Yazılım Müh.

**YABANCI DİL:** İngilizce

### TEZDEN TÜRETİLEN YAYINLAR, SUNUMLAR VE PATENTLER:

- Ağca, M.A., Ataç, Ş., Yücesan, M.M., Küçükayan, Y.G., Özbayoğlu, A.M., Doğdu, E., 2016. Opinion Mining of Microblog Texts on Hadoop Ecosystem, International Journal Of Cloud Computing, 5(1/2), 79-90.
- Demirezen, M.U., Yılmaz, A.K., Küçükayan, Y.G., Acar, D.B., 2015. Developing Big Data Real-time Stream and Batch Data Processing Platform, USMOS: 6. Ulusal Savunma Uygulamaları Modelleme ve Simülasyon Konferansı, 11-12 Kasım, Ankara, Türkiye.