

T.C.
İSTANBUL ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
İŞLETME (İKTİSAT) ANABİLİM DALI

DOKTORA TEZİ

VERİ MADENCİLİĞİ VE MAKİNE ÖĞRENMESİ
YÖNTEMLERİ İLE İSTANBUL TRAFİĞİNİN ANALİZİ:
D100 KARAYOLU UYGULAMASI

Cihan ÇİFTÇİ

2502150161

TEZ DANIŞMANI

PROF. DR Halim KAZAN

İSTANBUL-2021

ÖZ

VERİ MADENCİLİĞİ VE MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE İSTANBUL TRAFİĞİNİN ANALİZİ: D100 KARAYOLU UYGULAMASI

CİHAN ÇİFTÇİ

Trafik problemi, mevcut ve gelecekteki trafik verilerine dayanarak yakın gelecekteki trafik önlemlerinin öngörülmesi adına, Akıllı Ulaşım Sistemlerinde kullanıcıların ve karar vericilerin trafik planlama ve yönetimlerini iyileştirmek, trafik sorunu ile başa çıkmak için son dönemlerde çok önemli bir konu haline gelmiştir. Akıllı Ulaşım Sistemleri sayesinde büyük miktarda trafik verisinin oluşması sonucunda veri odaklı modellerin oluşmasına imkan sağlamıştır. Veri madenciliği ve makine öğrenmesi yöntemleri ile büyük veri odaklı karmaşık senaryolar modellenerek trafik önlemlerinin tahminlemesine olan ilgi giderek artmaktadır. Bu çalışmada, önerilen trafik analiz modellemesinde, öncelikle araştırılması gerçekleştirilecek olan bölgenin trafiğine etki eden parametreler istatistiksel yöntemler sayesinde belirlenerek birbirleri ile olan ilişkileri ve etkileri ortaya çıkarıldı. Trafik yoğunluğu ve trafik olaylarının saat, gün, ay, mevsim, yıl, hava olayları, kaza durumları parametreleri ile aralarındaki ilişkiler belirlendi. Elde edilen parametreler, makine öğrenmesi yöntemleri ile modellenerek trafik yoğunluk analizi ve trafik olayları analizleri gerçekleştirildi. Bu modelde amaç her bölgenin trafik problemine etki eden kendine has parametreler olmasından dolayı, konumsal olarak spesifik trafik uyarı sisteminin gerçekleştirilmesi adına önemli bir çalışma olmuştur. İstanbul ili D100 karayolunun Anadolu yakası, Avrupa yakası ve 15 Temmuz Şehitleri köprüsü hatlarında meydana gelen trafik yoğunluğu ve trafik olaylarına etki eden parametreler istatistiksel yöntemler ile belirlenerek analizleri gerçekleştirilmiştir. Bayes ağı ve Yapay sinir ağı yöntemleri ile trafik yoğunluğu ve kaza olaylarının modelleri oluşturulmuştur. Bu modeller sayesinde bölgeye has oluşabilecek trafik yoğunluk durumları ve trafik olayları için erken uyarı sisteminin alt yapısının oluşturulması sağlanmıştır.

Anahtar Kelimeler: Akıllı Ulaşım, Trafik Yönetimi, Trafik Analizi, Büyük Veri, Veri Madenciliği, Makine Öğrenmesi, Yapay Sinir Ağları, Bayes Ağları

ABSTRACT

ANALYSIS OF ISTANBUL TRAFFIC WITH DATA MINING AND MACHINE LEARNING METHODS: D100 HIGHWAY APPLICATION

CİHAN ÇİFTÇİ

For the prediction of traffic measures in the near future based on the traffic problem, current and future traffic data, Improving the traffic planning and management of users and decision makers in Intelligent Transportation Systems has recently become a very important issue to cope with the traffic problem. Thanks to the Intelligent Transportation Systems, it has enabled the formation of data-oriented models as a result of the formation of a large amount of traffic data. There is an increasing interest in the prediction of traffic measures by modeling big data-driven complex scenarios with data mining and machine learning methods. In this study, in the proposed traffic analysis modeling, the parameters affecting the traffic of the region to be investigated were determined by statistical methods, and their relations and effects with each other were revealed. The relationships between traffic density, and parameters of hour, day, month, season, year, weather events, accident situations were determined. Obtained parameters were modeled with machine learning methods and traffic density analysis and traffic incident analyzes were performed. In this model, the aim has been an important study for the realization of a spatially specific traffic warning system, since each region has its own parameters that affect the traffic problem. The traffic density on the Anatolian side, the European side and the 15 July Martyrs Bridge lines of the Istanbul D100 highway and the parameters affecting the traffic incidents were determined by statistical methods and analyzed. Models of traffic density and accident events were created with Bayesian network and Artificial neural network methods. Thanks to these models, the infrastructure of the early warning system has been created for traffic density situations and traffic incidents that may occur specific to the region.

Keywords: Intelligent Transportation, Traffic Management, Traffic Analysis, Big Data, Data Mining, Machine Learning, Artificial Neural Networks, Bayesian Networks

ÖNSÖZ

İstanbul gibi mega kentlerde, yaşamış olduğumuz pandemi dönemi gibi olayların yaşanması ile insanları araç kullanmaya iten sebeplerin giderek artması ve nüfus yoğunluğunun her geçen gün mega kentlere kayması ile trafik problemi maalesef içinden çıkılması güç bir hale gelmektedir. Ülkemizin gelecekteki vizyonları doğrultusunda dünyanın en büyük ekonomileri arasına girme hedefine paralel olarak, trafik sorunlarını en aza indirgeyerek işlevsel ve verimli bir ulaşım sisteminin oluşturulması kaçınılmazdır. Bu noktada veri madenciliği ve makine öğrenmesi yöntemleri ile trafik analizlerinin gerçekleştirilerek Akıllı Ulaşım Sistemleri için bir alt yapı oluşturması açısından bu çalışmamızın katkı sağlayacağını ümit etmekteyim.

Bu bağlamda, doktora tez danışmanlığımı yürüten ve her daim bana varlığını hissettirerek yardımını esirgemeyen **Prof. Dr. Halim Kazan** hocama emekleri için sonsuz teşekkürlerimi arz ederim. Tez izleme komitesinde bulunan ve değerli katkılar sunan **Prof. Dr. Selim Zaim** hocama ve **Doç. Dr. Bora Yıldız** hocama teşekkürlerimi sunarım.

Benim en değerli varlığım olan, bu süreçte bana her daim güç ve destek veren eşim **Emel Seyhan Çiftçi**'ye sonsuz şükranlarımı sunuyorum. Değerli aileme de bana gösterdikleri desteklerinden dolayı onlara da sonsuz teşekkürlerimi sunarım.

CİHAN ÇİFTÇİ

İSTANBUL, 2020

İÇİNDEKİLER

ÖZ.....	ii
ABSTRACT	iii
ÖNSÖZ.....	iv
İÇİNDEKİLER	v
TABLolar LİSTESİ.....	vii
ŞEKİLLER LİSTESİ.....	xiii
KISALTMALAR LİSTESİ.....	xv
GİRİŞ	1

BİRİNCİ BÖLÜM

VERİ MADENCİLİĞİ

1.1. Veri Madenciliği İşlevleri	5
1.1.1. Sınıflandırma	5
2.1.2. Kümeleme Yöntemleri.....	16
2.1.3. Zaman Serisi Yöntemleri.....	19
1.2. Makine Öğrenmesi	20

İKİNCİ BÖLÜM

TRAFİKTE VERİ MADENCİLİĞİ

2.1. Trafikte Veri Madenciliği Uygulamaları	22
2.2. Sosyal Medyanın Trafik Analizinde Kullanımı	24

ÜÇÜNCÜ BÖLÜM

LİTERATÜR ARAŞTIRMASI

3.1. Trafik Analizinde Makine Öğrenmesi Yöntemleri	40
3.2. Trafik Tahminleme Probleminin Uygulamaları.....	29

DÖRDÜNCÜ BÖLÜM

VERİ MADENCİLİĞİ VE MAKİNE ÖĞRENMESİ

YÖNTEMLERİ İLE İSTANBUL TRAFİĞİNİN ANALİZİ: D100

KARAYOLU UYGULAMASI

4.1. Tezin Problem Durumu.....	53
4.2. Tezin Amacı	53
4.3. Tezin Motivasyonu.....	54
4.4. Tezin Yöntemleri	54
4.5. Tezin Verileri	54
4.6. Tezin Hipotezleri.....	55
4.7. İstatistiksel Analiz Yöntemleri ile Trafik Analizi	57
4.7.1. D100 Karayolunun Trafik Araç Yoğunluk Analizi	57
4.7.2. D100 Karayolunun Trafik Olaylarının İstatistiksel Analizi	76
4.8. Makine Öğrenmesi Yöntemleri ile Trafik Analiz Modellemesi	84
4.8.1. Yapay Sinir Ağı İle Trafik Yoğunluk Modellemesi	85
4.7.2. Bayesian Ağı ile Trafik Analiz Modellemesi	101
4.7.3. Seyahat Bilgi Sistemi.....	145
SONUÇ ve DEĞERLENDİRME	164
KAYNAKÇA.....	175
EKLER.....	207
ÖZGEÇMİŞ	214

TABLolar LİSTESİ

TABLO 1.1. KARAR AĞACI ALGORİTMALARININ TEMEL ÖZELLİKLERİ.....	7
TABLO 1.2. DESTEK VEKTÖR MAKİNALARI LİTERATÜR ARAŞTIRMASI	9
TABLO 1.3. DESTEK VEKTÖR MAKİNALARI LİTERATÜR ARAŞTIRMASI DEVAMI.....	10
TABLO 1.4. BAYESİAN YÖNTEMİNİN TÜRLERİ.....	12
TABLO 1.5. KÜMELEME YÖNTEMLERİ KARŞILAŞTIRMASI	17
TABLO 1.6. KÜMELEME YÖNTEMLERİ KARŞILAŞTIRMASI	18
TABLO 2.1. SOSYAL MEDYANIN ULAŞTIRMA ALANINDA KULLANIM VE UYGULAMALARI	27
TABLO 2.2. TRAFİK TAHMİNLEME PROBLEMİNİN LİTERATÜR ARAŞTIRMASI	32
TABLO 2.3. AKILLI ULAŞIMDA MAKİNE ÖĞRENMESİ UYGULAMALARINA GENEL BAKIŞ	47
TABLO 4.1. D100 KARAYOLU 75 FARKLI NOKTANIN ARAÇ SAYILARI.....	57
TABLO 4.2. D100 15 TEMMUZ ŞEHİTLER KÖPRÜSÜ VERİ SETİ ÖRNEĞİ	59
TABLO 4.3. VERİLERİN NORMALLİK ANALİZ SONUÇLARI	60
TABLO 4.4. VERİLERİN NORMALLİK ANALİZ SONUÇLARI DEVAMI	60
TABLO 4.5. ARAÇ YOĞUNLUK ORT. YIL DEĞİŞKENİNE GÖRE KRUSKAL WALLİS ANALİZİ	61
TABLO 4.6. ARAÇ YOĞUNLUK ORT. YIL DEĞİŞKENİNE GÖRE U TESTİ TABLOSU	61
TABLO 4.7. ARAÇ YOĞUNLUK ORT. YIL DEĞİŞKENİNE GÖRE DEĞİŞİMİ	62
TABLO 4.8. ARAÇ YOĞUNLUK ORT. AY DEĞİŞKENİNE GÖRE KRUSKAL WALLİS ANALİZİ	62
TABLO 4.9. ARAÇ YOĞUNLUK ORT. AY DEĞİŞKENİNE GÖRE U TESTİ TABLOSU.....	63
TABLO 4.10. ARAÇ YOĞUNLUK ORT. AY DEĞİŞKENİNE DEĞİŞİMİ.....	64
TABLO 4.11. ARAÇ YOĞUNLUK ORT. GÜN DEĞİŞKENİNE GÖRE KRUSKAL WALLİS ANALİZİ	65
TABLO 4.12. ARAÇ YOĞUNLUK ORT. GÜN DEĞİŞKENİNE GÖRE U TESTİ TABLOSU ...	65
TABLO 4.13. ARAÇ YOĞUNLUK ORT. GÜN DEĞİŞKENİNE GÖRE DEĞİŞİMİ.....	66
TABLO 4.14. ARAÇ YOĞUNLUK ORT. MEVSİM DEĞİŞKENİNE GÖRE KRUSKAL WALLİS ANALİZİ	67

TABLO 4.15. ARAÇ YOĞUNLUK ORT. MEVSİM DEĞİŞKENİNE GÖRE U TESTİ TABLOSU	67
TABLO 4.16. ARAÇ YOĞUNLUK ORT. MEVSİM DEĞİŞKENİNE GÖRE DEĞİŞİMİ	68
TABLO 4.17. ARAÇ YOĞUNLUK ORT. HAVA DURUMU DEĞİŞKENİNE GÖRE KRUSKAL WALLİS ANALİZİ	68
TABLO 4.18. ARAÇ YOĞUNLUK ORT. HAVA DURUMU DEĞİŞKENİNE GÖRE U TESTİ TABLOSU	69
TABLO 4.19. ARAÇ YOĞUNLUK ORT. HAVA DURUMU DEĞİŞKENİNE GÖRE DEĞİŞİMİ	69
TABLE 4.20. GÜNLERE GÖRE MEYDANA GELEN ARAÇ YOĞUNLUĞUNA İLİŞKİN Kİ-KARE TESTİ SONUÇLARI	71
TABLE 4.21. AYLARA GÖRE MEYDANA GELEN ARAÇ YOĞUNLUĞUNA İLİŞKİN Kİ-KARE TESTİ SONUÇLARI	71
TABLE 4.22. MEVSİMLERE GÖRE MEYDANA GELEN ARAÇ YOĞUNLUĞUNA İLİŞKİN Kİ-KARE TESTİ SONUÇLARI	72
TABLE 4.23. YILLARA GÖRE MEYDANA GELEN ARAÇ YOĞUNLUĞUNA İLİŞKİN Kİ-KARE TESTİ SONUÇLARI	72
TABLE 4.24. AVRUPA YAKASI GÜNLERE GÖRE MEYDANA GELEN ARAÇ YOĞUNLUĞUNA İLİŞKİN Kİ-KARE TESTİ SONUÇLARI	72
TABLE 4.25. AVRUPA YAKASI AYLARA GÖRE MEYDANA GELEN ARAÇ YOĞUNLUĞUNA İLİŞKİN Kİ-KARE TESTİ SONUÇLARI	73
TABLE 4.26. AVRUPA YAKASI MEVSİMLERE GÖRE MEYDANA GELEN ARAÇ YOĞUNLUĞUNA İLİŞKİN Kİ-KARE TESTİ SONUÇLARI	73
TABLE 4.27. AVRUPA YAKASI YILLARA GÖRE MEYDANA GELEN ARAÇ YOĞUNLUĞUNA İLİŞKİN Kİ-KARE TESTİ SONUÇLARI	74
TABLE 4.28. ANADOLU YAKASI GÜNLERE GÖRE MEYDANA GELEN ARAÇ YOĞUNLUĞUNA İLİŞKİN Kİ-KARE TESTİ SONUÇLARI	74
TABLE 4.29. ANADOLU YAKASI MEVSİMLERE GÖRE MEYDANA GELEN ARAÇ YOĞUNLUĞUNA İLİŞKİN Kİ-KARE TESTİ SONUÇLARI	74
TABLE 4.30. ANADOLU YAKASI AYLARA GÖRE MEYDANA GELEN ARAÇ YOĞUNLUĞUNA İLİŞKİN Kİ-KARE TESTİ SONUÇLARI	75
TABLE 4.31. ANADOLU YAKASI YILLARA GÖRE MEYDANA GELEN ARAÇ YOĞUNLUĞUNA İLİŞKİN Kİ-KARE TESTİ SONUÇLARI	75

TABLE 4.32. TRAFİK OLAYLARININ SAYISALLAŞTIRILMASI	77
TABLE 4.33. SAATLERE GÖRE MEYDANA GELEN TRAFİK OLAYLARINA İLİŞKİN Kİ-KARE TESTİ SONUÇLARI	77
TABLE 4.34. GÜNLERE GÖRE MEYDANA GELEN TRAFİK OLAYLARINA İLİŞKİN Kİ-KARE TESTİ SONUÇLARI	78
TABLE 4.35. AYLARA GÖRE MEYDANA GELEN TRAFİK OLAYLARINA İLİŞKİN Kİ-KARE TESTİ SONUÇLARI	79
TABLE 4.36. ŞERİTLERE GÖRE MEYDANA GELEN TRAFİK OLAYLARINA İLİŞKİN Kİ-KARE TESTİ SONUÇLARI	79
TABLE 4.37. MEVSİMLERE GÖRE MEYDANA GELEN TRAFİK OLAYLARINA İLİŞKİN Kİ-KARE TESTİ SONUÇLARI	80
TABLO 4.38. SAATLERE GÖRE GERÇEKLEŞEN TRAFİK OLAYLARINA İLİŞKİN Kİ-KARE TESTİ SONUÇLARI	81
TABLO 4.39. GÜNLERE GÖRE GERÇEKLEŞEN TRAFİK OLAYLARINA İLİŞKİN Kİ-KARE TESTİ SONUÇLARI	81
TABLO 4.40. AYLARA GÖRE GERÇEKLEŞEN TRAFİK OLAYLARINA İLİŞKİN Kİ-KARE TESTİ SONUÇLARI	82
TABLO 4.41. MEVSİMLERE GÖRE GERÇEKLEŞEN TRAFİK OLAYLARINA İLİŞKİN Kİ-KARE TESTİ SONUÇLARI	82
TABLO 4.42. ŞERİTLERE GÖRE GERÇEKLEŞEN TRAFİK OLAYLARINA İLİŞKİN Kİ-KARE TESTİ SONUÇLARI	83
TABLO 4.43. YOĞUNLUĞA GÖRE GERÇEKLEŞEN TRAFİK OLAYLARINA İLİŞKİN Kİ-KARE TESTİ SONUÇLARI	83
TABLO 4.44. ŞERİTLERE GÖRE KAZALARDA YOĞUNLUĞA İLİŞKİN Kİ-KARE TESTİ SONUÇLARI	83
TABLO 4.45. GÜNLERE GÖRE KAZALARDA ŞERİTLERE İLİŞKİN Kİ-KARE TESTİ SONUÇLARI	84
TABLO 4.46. TRAFİK YOĞUNLUK PARAMETRELERİN SAYISALLAŞTIRILMASI VE MİN-MAX NORMALİZE DEĞERLERİ	86
TABLO 4.47. YAPAY SİNİR AĞI GİRDİ PARAMETRELERİ	88
TABLO 4.48. FARKLI MODELLER VE PERFORMANS SONUÇLARI	89
TABLO 4.49. SİMÜLASYON SONUÇLARI	95

TABLO 4.50. SİMÜLASYON SONUÇLARI DEVAMI_1	96
TABLO 4.51. SİMÜLASYON SONUÇLARI DEVAMI_2	97
TABLO 4.52. SİMÜLASYON SONUÇLARI DEVAMI_2	98
TABLO 4.52. D100 KARAYOLU HATTI YOĞUNLUK MODELİ SINIFLANDIRMA DEĞERLENDİRME SONUÇLARI	99
TABLO 4.53. D100 KARAYOLU HATTI TRAFİK OLAYLARI MODELİ SINIFLANDIRMA DEĞERLENDİRME SONUÇLARI	100
TABLO 4.54. TRAFİK OLAYLARI SENARYO_1	102
TABLO 4.55. TRAFİK OLAYLARI SENARYO_2	103
TABLO 4.56. TRAFİK OLAYLARI SENARYO_3	105
TABLO 4.57. TEMMUZ ŞEHİTLER KÖPRÜSÜ SAĞ ŞERİT YOĞUNLUK İHTİMALLERİ SENARYO_1	110
TABLO 4.58. TEMMUZ ŞEHİTLER KÖPRÜSÜ SAĞ ŞERİT YOĞUNLUK İHTİMALLERİ SENARYO_2	111
TABLO 4.59. TEMMUZ ŞEHİTLER KÖPRÜSÜ SAĞ ŞERİT YOĞUNLUK İHTİMALLERİ SENARYO_3	112
TABLO 4.60. TEMMUZ ŞEHİTLER KÖPRÜSÜ SAĞ ŞERİT YOĞUNLUK İHTİMALLERİ SENARYO_4	113
TABLO 4.61. TEMMUZ ŞEHİTLER KÖPRÜSÜ SAĞ ŞERİT YOĞUNLUK İHTİMALLERİ SENARYO_5	114
TABLO 4.62. TEMMUZ ŞEHİTLER KÖPRÜSÜ SAĞ ŞERİT YOĞUNLUK İHTİMALLERİ SENARYO_6	115
TABLO 4.63. TEMMUZ ŞEHİTLER KÖPRÜSÜ SAĞ ŞERİT YOĞUNLUK İHTİMALLERİ SENARYO_7	116
TABLO 4.64. TEMMUZ ŞEHİTLER KÖPRÜSÜ SAĞ ŞERİTTE GÜNLERE GÖRE ORT. YOĞUNLUK İHTİMALLERİ	117
TABLO 4.65. TEMMUZ ŞEHİTLER KÖPRÜSÜ SAĞ ŞERİTTE GÜNLERİN ZAMANA GÖRE ORT. YOĞUNLUK İHTİMALLERİ	117
TABLO 4.66. TEMMUZ ŞEHİTLER KÖPRÜSÜ SOL ŞERİT YOĞUNLUK İHTİMALLERİ SENARYO_1	119
TABLO 4.67. TEMMUZ ŞEHİTLER KÖPRÜSÜ SOL ŞERİT YOĞUNLUK İHTİMALLERİ SENARYO_2	120

TABLO 4.68. TEMMUZ ŞEHİTLER KÖPRÜSÜ SOL ŞERİT YOĞUNLUK İHTİMALLERİ SENARYO_3	121
TABLO 4.69. TEMMUZ ŞEHİTLER KÖPRÜSÜ SOL ŞERİT YOĞUNLUK İHTİMALLERİ SENARYO_4	122
TABLO 4.70. TEMMUZ ŞEHİTLER KÖPRÜSÜ SOL ŞERİT YOĞUNLUK İHTİMALLERİ SENARYO_5	122
TABLO 4.71. TEMMUZ ŞEHİTLER KÖPRÜSÜ SOL ŞERİT YOĞUNLUK İHTİMALLERİ SENARYO_6	124
TABLO 4.72. TEMMUZ ŞEHİTLER KÖPRÜSÜ SOL ŞERİT YOĞUNLUK İHTİMALLERİ SENARYO_7	125
TABLO 4.73. TEMMUZ ŞEHİTLER KÖPRÜSÜ SOL ŞERİTTE GÜNLERE GÖRE ORT. YOĞUNLUK İHTİMALLERİ.....	126
TABLO 4.74. TEMMUZ ŞEHİTLER KÖPRÜSÜ SOL ŞERİTTE GÜNLERİN ZAMANA GÖRE ORT. YOĞUNLUK İHTİMALLERİ	126
TABLO 4.75. TEMMUZ ŞEHİTLER KÖPRÜSÜ ORTA ŞERİT YOĞUNLUK İHTİMALLERİ SENARYO_1	128
TABLO 4.76. TEMMUZ ŞEHİTLER KÖPRÜSÜ ORTA ŞERİT YOĞUNLUK İHTİMALLERİ SENARYO_2	129
TABLO 4.77. TEMMUZ ŞEHİTLER KÖPRÜSÜ ORTA ŞERİT YOĞUNLUK İHTİMALLERİ SENARYO_3	130
TABLO 4.78. TEMMUZ ŞEHİTLER KÖPRÜSÜ ORTA ŞERİT YOĞUNLUK İHTİMALLERİ SENARYO_4	131
TABLO 4.79. TEMMUZ ŞEHİTLER KÖPRÜSÜ ORTA ŞERİT YOĞUNLUK İHTİMALLERİ SENARYO_5	132
TABLO 4.80. TEMMUZ ŞEHİTLER KÖPRÜSÜ ORTA ŞERİT YOĞUNLUK İHTİMALLERİ SENARYO_6	133
TABLO 4.81. TEMMUZ ŞEHİTLER KÖPRÜSÜ ORTA ŞERİT YOĞUNLUK İHTİMALLERİ SENARYO_7	134
TABLO 4.82. TEMMUZ ŞEHİTLER KÖPRÜSÜ ORTA ŞERİTTE GÜNLERE GÖRE ORT. YOĞUNLUK İHTİMALLERİ.....	135
TABLO 4.83. TEMMUZ ŞEHİTLER KÖPRÜSÜ ORTA ŞERİTTE GÜNLERİN ZAMANA GÖRE ORT. YOĞUNLUK İHTİMALLERİ	135

TABLO 4.84.	YOĞUNLUK DEĞİŞKENİ DUYARLILIK ANALİZİ.....	137
TABLO 4.85.	TEMMUZ ŞEHİTLER KÖPRÜSÜ PAZARTESİ GÜNÜ TRAFİK_OLAYLARI İHTİMALLERİ SENARYO_1.....	138
TABLO 4.86.	TEMMUZ ŞEHİTLER KÖPRÜSÜ PAZARTESİ GÜNÜ TRAFİK_OLAYLARI İHTİMALLERİ SENARYO_2.....	138
TABLO 4.87.	TEMMUZ ŞEHİTLER KÖPRÜSÜ PAZARTESİ GÜNÜ TRAFİK_OLAYLARI İHTİMALLERİ SENARYO_3.....	139
TABLO 4.88.	TEMMUZ ŞEHİTLER KÖPRÜSÜ PAZARTESİ GÜNÜ TRAFİK_OLAYLARI İHTİMALLERİ SENARYO_4.....	139
TABLO 4.89.	TEMMUZ ŞEHİTLER KÖPRÜSÜ PAZARTESİ GÜNÜ TRAFİK_OLAYLARI İHTİMALLERİ SENARYO_4.....	140
TABLO 4.90.	TEMMUZ ŞEHİTLER KÖPRÜSÜ PAZARTESİ GÜNÜ TRAFİK_OLAYLARI İHTİMALLERİ SENARYO_5.....	140
TABLO 4.91.	TEMMUZ ŞEHİTLER KÖPRÜSÜ PAZARTESİ GÜNÜ TRAFİK_OLAYLARI İHTİMALLERİ SENARYO_5.....	141
TABLO 4.92.	TEMMUZ ŞEHİTLER KÖPRÜSÜ PAZARTESİ GÜNÜ TRAFİK_OLAYLARI İHTİMALLERİ SENARYO_6.....	141
TABLO 4.93.	TEMMUZ ŞEHİTLER KÖPRÜSÜ PAZARTESİ GÜNÜ TRAFİK_OLAYLARI İHTİMALLERİ SENARYO_7.....	142
TABLO 4.94.	TEMMUZ ŞEHİTLER KÖPRÜSÜ PAZARTESİ GÜNÜ TRAFİK_OLAYLARI İHTİMALLERİ SENARYO_8.....	142
TABLO 4.95.	TEMMUZ ŞEHİTLER KÖPRÜSÜ PAZARTESİ GÜNÜ TRAFİK_OLAYLARI İHTİMALLERİ SENARYO_9.....	143
TABLO 4.96.	TEMMUZ ŞEHİTLER KÖPRÜSÜ PAZARTESİ GÜNÜ TRAFİK_OLAYLARI İHTİMALLERİ SENARYO_10.....	143
TABLO 4.97.	15 TEMMUZ ŞEHİTLER KÖPRÜSÜ PAZARTESİ GÜNÜ TRAFİK OLAYLARI ORT. İHTİMALLERİ	144
TABLO 4.98.	TRAFİK OLAYLARI DEĞİŞKENİ DUYARLILIK ANALİZİ.....	145

ŞEKİLLER LİSTESİ

ŞEKİL 1.1. VERİ MADENCİLİĞİ UYGULAMA ALANLARI.....	4
ŞEKİL 1.2. VERİ MADENCİLİĞİ UYGULAMA ADIMLARI	5
ŞEKİL 1.3. SINIFLANDIRMA YÖNTEMLERİ.....	6
ŞEKİL 1.4. KESİKLİ BAYESİAN AĞ SINIFLANDIRICILARININ $P(X, C)$ ÇARPANLARINA GÖRE SINIFLANDIRILMASI.....	11
ŞEKİL 1.5. KÜMELEME PROSEDÜRÜ	16
ŞEKİL 1.6. KÜMELEME YÖNTEMLERİ	17
ŞEKİL 1.7. KÜMELEME YÖNTEMLERİ	19
ŞEKİL 2.1. ITS’DE BÜYÜK VERİ ANALİTİĞİ BASAMAKLARI	23
ŞEKİL 2.2. TRAFİK VERİ KAYNAKLARININ SINIFLANDIRILMASI.....	24
ŞEKİL 3.1. TRAFİK TAHMİN PROBLEMLERİNİN TAKSONOMİSİ.....	31
ŞEKİL 4.1 TRAFİK ANALİZİ AKIŞ ŞEMASI	56
ŞEKİL 4.2. YAPAY SİNİR AĞI TRAFİK YOĞUNLUK MODELİ.....	87
ŞEKİL 4.4. MODEL 2 EĞİTİM VE TEST R DEĞERLERİ VE HATA GRAFİĞİ	90
ŞEKİL 4.5. MODEL 3 EĞİTİM VE TEST R DEĞERLERİ VE HATA GRAFİĞİ	90
ŞEKİL 4.6. MODEL 4 EĞİTİM VE TEST R DEĞERLERİ VE HATA GRAFİĞİ	91
ŞEKİL 4.7. MODEL 5 EĞİTİM VE TEST R DEĞERLERİ VE HATA GRAFİĞİ	91
ŞEKİL 4.8. MODEL 6 EĞİTİM VE TEST R DEĞERLERİ VE HATA GRAFİĞİ	92
ŞEKİL 4.9. MODEL 7 EĞİTİM VE TEST R DEĞERLERİ VE HATA GRAFİĞİ	92
ŞEKİL 4.10. MODEL 8 EĞİTİM VE TEST R DEĞERLERİ VE HATA GRAFİĞİ	93
ŞEKİL 4.11. MODEL 9 EĞİTİM VE TEST R DEĞERLERİ VE HATA GRAFİĞİ	93
ŞEKİL 4.12. BAYESİAN AĞI YOĞUNLUK TAHMİN MODELİ	102
ŞEKİL 4.13. BAYESİAN AĞI ŞERİT BAZLI TAHMİN MODELİ	103
ŞEKİL 4.14. BAYESİAN AĞI TRAFİK OLAY BAZLI TAHMİN MODELİ	105
ŞEKİL 4.15. BAYESİAN AĞI TRAFİK OLAYLARI DURUM BAZLI TAHMİN MODELİ	107
ŞEKİL 4.16. BAYESİAN AĞI TRAFİK OLAY BAZLI TAHMİN MODELİ	107
ŞEKİL 4.17. BAYESİAN AĞI GÜNLER BAZLI TAHMİN MODELİ.....	108
ŞEKİL 4.18. BAYESİAN AĞI ZAMAN BAZLI TAHMİN MODELİ	108
ŞEKİL 4.19. BAYESİAN AĞI MEVSİM BAZLI TAHMİN MODELİ.....	109
ŞEKİL 4.20. 15 TEMMUZ ŞEHİTLER KÖPRÜSÜ YOĞUNLUK MODELİ	109

ŞEKİL 4.21. 15 TEMMUZ ŞEHİTLER KÖPRÜSÜ TRAFİK OLAYLARI MODELİ	137
ŞEKİL 4.22. D100 KARAYOLU HATTI	145
ŞEKİL 4.23. AVCILAR KONUMU TRAFİK ANALİZİ	146
ŞEKİL 4.24. BEYLİKDÜZÜ KONUMU TRAFİK ANALİZİ.....	146
ŞEKİL 4.25. FLORYA KONUMU TRAFİK ANALİZİ	147
ŞEKİL 4.26. HACİŞERİF KONUMU TRAFİK ANALİZİ.....	147
ŞEKİL 4.27. HALIÇ KONUMU TRAFİK ANALİZİ	148
ŞEKİL 4.28. HARAMİDERE KONUMU TRAFİK ANALİZİ.....	148
ŞEKİL 4.29. İNCİRLİ KONUMU TRAFİK ANALİZİ.....	149
ŞEKİL 4.30. KÜÇÜKÇEKMECE KONUMU TRAFİK ANALİZİ.....	149
ŞEKİL 4.32. MERTER KONUMU TRAFİK ANALİZİ.....	150
ŞEKİL 4.33. SEFAKÖY KONUMU TRAFİK ANALİZİ.....	151
ŞEKİL 4.34. ŞİRİNEVLER KONUMU TRAFİK ANALİZİ	151
ŞEKİL 4.35. YENİBOSNA KONUMU TRAFİK ANALİZİ	152
ŞEKİL 4.36. ZİNCİRLİKUYU KONUMU TRAFİK ANALİZİ	152
ŞEKİL 4.38. KARTAL KONUMU TRAFİK ANALİZİ	153
ŞEKİL 4.39. MALTEPE KONUMU TRAFİK ANALİZİ	154
ŞEKİL 4.40. KOZYATAĞI KONUMU TRAFİK ANALİZİ	154
ŞEKİL 4.42. UZUNÇAYIR KONUMU TRAFİK ANALİZİ	155
ŞEKİL 4.44. ACIBADEM KONUMU TRAFİK ANALİZİ.....	156
ŞEKİL 4.46. TUZLA KONUMU TRAFİK ANALİZİ	157
ŞEKİL 4.48. D100 KARAYOLU ANADOLU HATTI ARAÇ YOĞUNLUK ANALİZ MODELİ	158
ŞEKİL 4.49. D100 SELİMPAŞA KONUMU ARAÇ YOĞUNLUĞU	159
ŞEKİL 4.50. D100 KÜÇÜKÇEKMECE KONUMU ARAÇ YOĞUNLUĞU	159
ŞEKİL 4.52. D100 KARTAL KAVŞAĞI KONUMU ARAÇ YOĞUNLUĞU.....	160
ŞEKİL 4.53. D100 KARAYOLU HATTI AVRUPA YAKASI OCAK AYI PAZARTESİ GÜNÜ ARAÇ YOĞUNLUĞU.....	161
ŞEKİL 4.54. D100 KARAYOLU HATTI ANADOLU YAKASI TEMMUZ AYI CUMA GÜNÜ ARAÇ YOĞUNLUĞU.....	162
ŞEKİL 4.55. D100 KARAYOLU HATTI YOĞUNLUK VE TRAFİK OLAYLARI.....	163

KISALTMALAR LİSTESİ

ITS: Akıllı Ulaşım Sistemleri

İBB: İstanbul Büyükşehir Belediyesi

GBS: Küresel Konumlama Sistemi

YSA: Yapay Sinir Ağları



GİRİŞ

Birçok araştırma konusunda ilgi odağı haline gelen büyük veri ve veri madenciliği yöntemleri akıllı ulaşım sistemlerinde (ITS) ilgi odağı haline gelmiştir. Gelişen teknoloji sayesinde akıllı ulaşım sistemleri büyük veri üretmeye başlamışlardır. Üretilen büyük veri sayesinde akıllı ulaşım sistemlerinin daha güvenli, verimli ve karlı hale gelmesi açısından tasarım ve uygulamaları üzerinde derin etkileri olacaktır.

Veri madenciliği uygulamaları birçok alanda faydalı sonuçlar alınması sonucunda akıllı ulaşım sistemlerinde uygulanmaya başlanmıştır. Akıllı ulaşım teknolojilerinin sensör teknolojileri, veri iletim teknolojileri, akıllı kart uygulamaları gibi sistemsel yapılarından dolayı sürekli veri üretmektedirler. Akıllı ulaşım sistemlerinde veriler GPS, sensörler, video dedektörleri, sosyal medya gibi çeşitli kaynaklardan veriler elde edebilirler.

Veri madenciliği yöntemleri sayesinde tarihsel yoğun trafik verilerinin analizleri sayesinde birçok ITS'lerdeki birçok trafik yönetim departmanlarına trafik akışının gerçek zamanlı olarak tahmin ederek verimliliği artırılabilir. Büyük analizi sayesinde trafik kazalarının meydana geliş nedenini etkili bir şekilde tahmin ederek ITS'de güvenlik seviyesini arttırabilir. Bilgi işlem ve iletişim teknolojilerinin ürettiği verilerdeki karmaşık ve gizli kalıpları ortaya çıkarmak için makine öğrenme algoritmaları giderek ihtiyaç haline gelmiştir. Bu algoritmalar sayesinde büyük ve karmaşık veri setlerine otomatik olarak uyum sağlayabilen ve senaryoları gerçek zamanlı olarak tahmin edebilen modeller geliştirmek mümkün hale gelmiştir.

Akıllı ulaşım sistemleri de giderek veriye dayalı entegre bir sisteme dönüşmektedir. Trafik koşullarının özellikle trafik akış yoğunluğunun doğru bir şekilde öngörülmesinin önemi giderek artmaktadır. Bu veri sayesinde araştırmacılar gelecekteki eğilimleri tahmin etmek için gerçek zamanlı olarak trafik akış modellemeleri üreterek ITS uygulamalarının mevcut ulaşım sisteminin verimliliğini geliştirmeye odaklanmaktadır. Böylelikle hem trafik planlayıcılarına hem de kullanıcılara planlarında karar vermelerine yardımcı olmak için doğru ve güvenilir tahminler sağlamaktadır.

Trafik sıkışıklığı metropollerde en önemli sorunları haline gelmekte, maliyetli ve olanaksız yeni yolların geliştirmesine alternatif bir yol olarak mevcut altyapıdaki trafik akışını iyileştirmenin yollarını araştırmışlardır. Trafik sıkışıklığını azaltmanın faydalı yollarından biri de trafik akışını tahmin etmektir. Akıllı şehir girişimlerinin geliştirilmesinde akıllı ulaşım büyük bir rol oynadığından trafik akış tahminlemesinin doğruluğu büyük önem taşımaktadır. Bu hedeflere ulaşmada ise karşılaşılan en önemli sorun ise oluşan büyük veriyi örnekleme, trafik yoğunluğunu tahmin ederek gelecekteki davranışları tahmin etme zorluğudur.

Bu çalışmada, İstanbul D100 karayolunun araç yoğunluğu, trafik olayları ve araçların hız değerlerinin analizi gerçekleştirilmiştir. İstanbul Büyük Şehir Belediyesi (İBB Veri Portalı) tarafından sağlanan büyük veri işlenerek düzenlenmiştir. D100 karayolunda oluşan araç yoğunluğuna ve trafik olaylarına etki eden trafik dışı parametrelerin etkileri ve ilişkileri incelenmiştir. Hipotezlerin test edilmesinde parametrik olmayan testlerden Kruskal Wallis ve Mann-Whitney testleri ile D100 karayolunun araç yoğunluk ortalamalarının saat, gün, ay, mevsim, yıl, hava durumu gibi trafik dışı değişkenler ile farklılık oluşturup-oluşturmadığının analizi gerçekleştirilmiştir. Trafik olaylarının analizinde ise yayınlanan trafik olay mesajlarından, D100 karayolunda meydana gelen 35697 adet kaza gün, ay, yıl, mevsim, hasarlı, zincirleme, yaralanmalı, yoğunluk, sol, sağ, orta şeritler olmak üzere sayısallaştırma işlemi gerçekleştirilmiştir. Elde edilen sınıflama değişkenleri ile trafik olaylarından araç arızası, bakım-onarım çalışması ve kaza bildirimi ile aralarında istatistiksel anlamda ilişkinin olup-olmadığı Ki-kare testleri ile incelenmiştir. İstatistik yöntemlerin uygulanmasındaki hedef, D100 karayolu 26 bölgeye ayrılarak her bölgenin kendine özgü trafik yoğunluğunun olması ve bu trafik dışı parametrelerin etkisinin ayrı ayrı incelenerek konum bazlı spesifik trafik analizlerini gerçekleştirmektir. Böylece her bölgenin kendine özgü trafik haritası çıkarılmıştır. İstatistik analizler sonucunda D100 karayolunun trafiğine etki eden trafik dışı parametreler ve etkileri belirlendikten sonra 15 Temmuz Şehitler Köprüsünün trafik araç yoğunluğu ve trafik olaylarının önceden tahminlemesinin gerçekleştirilmesi için yapay sinir ağı analizinden yararlanılmıştır. Bu modeller ile köprü üzerinde gerçekleşecek araç yoğunluğu ve trafik olaylarının önceden tahmin edilmesi

sağlanarak önlemlerin alınması noktasında büyük katkılar sunacaktır. Ayrıca Bayes ağları ile oluşturulan modeller ile D100 karayolu hattı boyunca Avrupa Yakası, 15 Temmuz Şehitler Köprüsü ve Anadolu Yakasının trafik yoğunluğu ve trafik olaylarını önceden tahmin etmeye dayalı bir uyarı sisteminin alt yapısının oluşmasına öncülük yapacaktır.


Çalışmanın birinci bölümde veri madenciliğinin önemi ve yöntem çeşitleri anlatılmıştır. İkinci bölümde akıllı ulaşım sistemlerinde veri madenciliği ve makine öğrenmesinin uygulamaları anlatılmıştır. Üçüncü bölümde veri madenciliği ve makine öğrenmesinin trafik ile ilgili çalışmaları hakkında geniş bir literatür araştırması yapılmıştır. Dördüncü bölümde çalışmanın metodolojisi anlatılmıştır. Araştırmanın modeli oluşturulmuştur. Oluşturulan modele ait uygulama çalışmaları yapılmıştır. Beşinci bölümde elde edilen sonuçlar değerlendirilerek oluşturulan modelin önemi tartışılmıştır.

BİRİNCİ BÖLÜM

VERİ MADENCİLİĞİ


Veri madenciliği, veri tabanları, veri ambarları veya bilgi havuzlarında depolanan büyük miktardaki veri kümelerinden ilginç bilgileri, potansiyel ve faydalı kalıpları keşfedip, gizli bilgilerin çıkarımında algoritmaların kullanılmasını içeren süreçtir. Veri madenciliği sürecinin amacı, büyük miktardaki veriler için genelleştirilebilen etkili bir öngörücü veya tanımlayıcı bir model oluşturmaktır (Mukhopadhyay ve ark., 2014). Veri madenciliği, literatürde veri çıkarma, bilgi çıkarma, veri/kalıp analizi, veri arkeolojisi, veri tarama ve bilgi toplama gibi terimler ile aynı anlamda kullanılmaktadır. Veri madenciliğinin araştırma ve geliştirme, disiplinlerarası doğası, uygulama odaklı bir alan olarak istatistik, makine öğrenmesi, örüntü tanıma, veri tabanı, veri ambarı sistemleri, bilgi alma, görselleştirme, algoritmalar gibi diğer birçok teknik veri madenciliğinin gelişmesinde önemli katkılar sunmaktadır (Han ve ark., 2012).

Şekil 1.1. Veri madenciliği uygulama alanları



Veri madenciliği süreci Şekil 1.2.'deki aşamalardan oluşmaktadır: Veri hazırlama sürecinde, veri kaynaklarından elde edilen çeşitli veriler entegre edilerek hedef veriler hazırlanır ve ön işleme tabi tutulur. Veri madenciliği sürecinde keşfedilen bilginin modelini bulmak ve değerlendirmek için çeşitli algoritmalar uygulanır. Sunum aşamasında veriler görselleştirilir.

Şekil 1.2.Veri madenciliği uygulama adımları




1.1 Veri Madenciliği İşlevleri

Veri madenciliğinin işlevleri sınıflandırma, kümeleme, ilişkilendirme analizi, zaman serisi analizi ve aykırı analizi içerir. Sınıflandırma, nesnelerin sınıflarını tahmin ve ayırt etmek için bir dizi model veya fonksiyon bulma sürecidir. Kümeleme analizi, belli bir modele danışmadan nesneleri analiz eder. Birliktelik (İlişkilendirme) analizi, belirli bir veri kümesinde sıkça bir arada bulunan değer veya özellikleri birleştirme kurallarını keşfeder. Zaman serisi analizi, anlamlı istatistikleri ve verilerin diğer özelliklerini ortaya çıkaran yöntem ve teknikleri içerir. Aykırı analizi, davranışları zaman içinde değişen ve gelişen nesnelerin eğilimlerini veya düzenlerini tanımlar ve modeller (Chen ve ark.,2015).

1.1.1 Sınıflandırma

Karar verme için önemli bir işleve sahip olan sınıflandırma analizi, bir nesneyi önceden tanımlanmış hedef kategorilerinden veya sınıflardan birine atamaktır. Sınıflandırma analizinin yapılmasındaki amaç, nesnelerin sınıf atamasında mevcut verilerin hedef sınıfını doğru tahmin yapabilmektir (Kesavaraj ve Sukumaran, 2013). Sınıflandırma analizinde, karar ağaçları, kural tabanlı uzman sistemler, hiyerarşik sınıflandırma, sinir ağları, bayesian ağları, destek vektör makinaları yöntemleri kullanılmaktadır (Chen ve ark.,2015).

Şekil 1.3. Sınıflandırma Yöntemleri



Karar Ağaçları, dikdörtgen veya yaprak benzeri düğümlerin akış şeması benzeri bir ağaç yapısıdır. Tüm iç düğümler iki veya daha fazla alt düğümden oluşur. Tüm iç düğümler, özniteliklerin ifadesini değerini test eden bölümler içerir. Her düğüm, kendisi ile ilişkilendirilmiş bir sınıf etiketine sahiptir. Karar ağaçlarından ID3 (İteratif Dichotomiser 3), basit bir karar ağacı öğrenme algoritmasıdır (Quinlan, 1986). C4.5, ID3'ün gelişmiş bir versiyonu olup, en yüksek kazanç oranını kullanarak verileri tekrar tekrar bölerek bir karar ağacı oluşturur (Quinlan, 1993). ID3 ikili bölmeler kullanırken, C4.5 ise çoklu bölmeler kullanır. SLIQ (Quest Denetimli Öğrenme), daha büyük veri kümelerinin kolay ve daha hızlı sınıflandırma yeteneğine sahiptir (Chandra ve Varghese, 2008). SPRINT, hızlı ve yüksek ölçeklendirilebilen ve depolama kısıtlaması olmayan daha büyük verileri sınıflandıran algoritmaya sahiptir. CART, parametrik olmayan bir karar ağacı yöntemi olup, değişkenlerin kategorik veya sürekli olmasına bağlı olarak sınıflandırma veya regresyon ağaçları oluşturur. CHAID (ki-kare otomatik etkileşim dedektörü), veri setinde yanıt değişkenine göre farklılık gösteren özel ve ayrıntılı bölümlere ayrılarak sınıflandırma yapar. Genel olarak, çok

sayıda sürekli değişken olduğunda CART, çok sayıda kategorik değişken olduğunda CHAID tercih edilir. Karar ağaçları algoritmalarının karşılaştırmalı temel özellikleri Tablo 1.1.'de gösterilmiştir (Sing ve Giri, 2014).

Tablo 1.1. Karar ağacı algoritmalarının temel özellikleri

Karakteristik (→) Algorithm(↓)	Ayrırma Kriterleri	Özellik tipi	Eksik değerler	Budama Stratejisi	Aykırı Değer Tespiti
ID3	Bilgi Kazancı	Yalnızca Kategorik	Eksik değerler işlemez	Budama Yapılmaz	Aykırı değerlere duyarlı
CART	Çekme Kriteri	Kategorik ve Sayısal	Eksik değerler kullanılır	Maliyet Karmaşıklığı budaması kullanılır	Aykırı değerlerde çalışabilir
C4.5	Kazanç Oranı	Kategorik ve Sayısal	Eksik değerler kullanılır	Hata Tabanlı budama kullanılır	Aykırı değerlere duyarlı

KNN (k- En Yakın Komşu) yönteminin ana fikri, gözlenen nesnenin en yakın noktasını bulmak için geliştirilen algoritmalar. KNN algoritmasının birçok farklı geliştirilmiş yöntemleri bulunmaktadır. WKPDS (Wavelet Based K-Nearest Neighbor Partial Distance Search), Dalgacık Tabanlı k-En Yakın Komşu Kısa Mesafeli Arama yöntemi, kısmi mesafe aramasına dayanan hızlı bir KNN algoritma türüdür. Veri kümesindeki en yakın k vektörünü etkili bir şekilde tanımlayarak, hesaplama karmaşıklığını azaltır (Hwang ve Wen, 1998). Dönüşüm katsayılarından saklanan bilgilerden yararlanılarak WKPDS, WAKNN (Yaklaşık katsayıları temel alan KNN arama algoritmaları), WSAKNN (alt yaklaşım katsayılarına dayanan KNN arama algoritmaları), WADKNN (Yaklaşım ve detay katsayılarına dayanan KNN arama algoritmaları), WADPS (yaklaşım ve detay katsayılarına dayalı dalgacık piramidi arama algoritması) gibi hızlı KNN algoritmaları elde edilmiştir. Vektör ölçümü için toplam ve varyans özelliklerinden tam yararlanılarak yeni ve daha hızlı algoritmalar geliştirilmiştir. ENNS (Equal Average Nearest Neighbor Search), Eşit Ortalama En Yakın Komşu Arama algoritması (Guan ve Kamel, 1992), EENNS (Equal-Average Equal-Norm Nearest Neighbor), Eşit-Ortalama Eşit-Norm En Yakın Komşu algoritması (Lee ve Chen, 1994), EEENNS (Equal-Average Equal-Variance Equal-

Norm Nearest Neighbor Search), Eşit Ortalama Eşit Varyans Eşit Norm En Yakın Komşu Arama algoritması.

Destek Vektör Makinaları (SVM), verileri analiz eden ve istatistiksel öğrenmeye dayanarak hesaplama açısından güçlü araçlar olan, kalıpları tanıyan ilişkili öğrenme algoritmalarıyla denetlenen sınıflandırma problemlerinde yaygın olarak kullanılan bir öğrenme modelidir. GSVM (Granular Support Vector Machines), istatistiksel ve ayrıntılı bilgi işlem teorilerinin ilkelerini sistematik olarak birleştiren karma bir modeldir (Tang ve ark., 2004). SVM'nin performans ve etkinliğini arttırarak, büyük veri kümeleri için sınıflandırma açısından çok etkili bir yöntem olduğu göstermektedir (Guo ve ark., 2009). FSVM (Fuzzy Support Vector Machines), SVM'yi bulanık hale dönüştürerek aykırı değerlerin etkisinin azaltılmasında iyileştirme sağlar. Veri noktalarındaki modellenmemiş özelliklere sahip uygulamalarda kullanılır (Lin ve Wang, 2002). SVM'lerin fazla uyum sorunu nedeniyle aykırı değerlere çok hassas olduğundan bu sorunun üstesinden gelmek için FSVM yöntemi önerilmiştir. Elde edilen sonuçlara göre FSVM'lerin aykırı değerlerin etkisini azalttığı ve SVM'ler daha yüksek sınıflandırma oranına sahip olduğu sonucuna varılmıştır (Huang ve Liu, 2002; Yan ve He, 2009). TWSVMs (Twin Support Vector Machines), her biri SVM'den daha küçük olan iki ilişkili SVM problemine iki paralel olmayan düzlemi belirleyen ikili bir sınıflandırma yöntemidir (Khemchandani ve ark., 2007).Yapılan çalışmalar sonucunda önerilen yöntemin sağlamlığı, hesaplama süresi ve sınıflandırma doğruluğunda SVM'ye göre üstünlüklerinin olduğunu göstermektedir (Qi ve ark., 2013). VaR-SVM (Value-at-Risk Support Vector Machines), SVM ile karşılaştırıldığında aykırı değerlere sahip veri kümeleri üzerinde üstün bir performansa sahip olduğu görülmüştür (Tsyurmasto ve ark., 2014).

Destek Vektör Makinaları algoritmalarının türlerinin literatürde sınıflandırma amacıyla kullanımı Tablo 1.2. ve Tablo 1.3.'te özetlenmiştir.

Tablo 1.2. Destek vektör makinaları literatür araştırması


	Referans	Model	Fonksiyon	Uygulama
1	G. Valentini, (2002)	SVM	Gaussian	Classification
2	L. Shutao, J. T. Kwok, H. Zhua and Y. Wang, (2003)	SVM	Polynomial	Classification
3	Y. Zhan and D. Shen, (2005)	SVM	Gradient Descent	Classification
4	Y. Tang, B. Jin, Y. Sun and Y. Zhang, (2004)	GSVM	Polynomial	Classification
5	B. Yang, W. Hwang, D. Kim and A. Tan, (2005)	SVM	Gaussian	Classification
6	R. Chen and C. Hsieh, (2006)	WVSV M	Polynomial	Classification
7	S. Du and S. Chen, (2005)	WCSV M	Polynomial	Classification
8	C. Tsai, (2005)	SVM	Polynomial	Image Classification
9	C. Lin, C. Yeh, S. Liang, J. Chung and N. Kumar, (2006)	SVFN N	Polynomial	Pattern Classification
10	K. Polat and S. Güneş, (2007)	LSSV M	Polynomial	Medical Diagnosis
11	S. Chaplot, L. M. Patnaik and N. R. Jagannathan, (2006)	SVM	Polynomial	Image Classification
12	S. R. M. Claudio and E. Zio, (2007)	SVM	Gaussian	Nuclear Component Classification
13	J. Hong, J. Min, U. K. Cho and S. B. Cho, (2008)	OVAS VM	Polynomial	Fingerprint Classification
14	F. Lauer and G. Bloch, (2008)	SVM	Linear-Polynomial-Gaussian	Classification
15	M. D. Shieh and C. C. Yang, (2008)	FSVM	Linear-Polynomial-Gaussian	Product Classification
16	A. M. Kumar and M. Gopal, (2009)	TSVM	Linear	Pattern Classification
17	W. Zhang, T. Yoshida and X. Tang, (2008)	SVM	Linear-Polynomial	Text Classification
18	U. B. Parikh, B. Das and R. Maheshwari, (2010)	SVM	Linear-Polynomial-Gaussian(RBF)-Sigmoid	Fault Classification
19	A. Este, F. Gringoli and L. Salgarelli, (2009)	SVM	Gaussian	Traffic Classification
20	C. Wu, Y. Ken and T. Huang, (2010)	HGAS VM	Linear-Polynomial-Gaussian(RBF)	Patent Classification
21	T. Kitamura, S. Takeuchi, S. Abe and K. Fukui, (2009)	SS- SVM	Polynomial	Pattern Classification
22	A. Chaudhuri and K. De, (2011)	FSVM	Polynomial	Bankruptcy Prediction
23	J. Qu and M. J. Zuo, (2010)	SVM	Linear	Wear degree Classification

Tablo 1.3. Destek vektör makinaları literatür araştırması devamı

	Referans	Model	Fonksiyon	Uygulama
24	N. Barakat and A. P. Bradley, (2010)	SVM	Polynomial	Rule Extraction
25	S. Dutta, A. Chatterjee and S. Munshi, (2010)	LS-SVM	Gaussian	ECG Beat classification
26	H. Eris, A. Ucar and A. Demir, (2010)	SVM	Gaussian	Power System Classification
27	J. Taylor and S. Sun, (2011)	SVM	Polynomial	Optimization
28	Y. H. Shao and Y. N. Deng, (2012)	CDMTSVM	Quadratic	Classification
29	A. Kazem, E. Sharifi, F. K. Hussain, M. Saberi and O. K. Hussain, (2013)	SVR-GA/CGA/FA	RBF	Forecasting
30	E. A. Zanaty, (2012)	SVM	GRPF	Classification
31	C. H. Wan, L. H. Lee, R. Rajkumar and D. Isa, (2012)	SVM-NN	Polynomial	Text Classification
32	S. Scherer, J. Kane, C. Gobl and F. Schwenker, (2013)	FSVM	Sinusoid	Voice Classification
33	Y. Tian, X. Ju, Z. Qi and Y. Shi, (2013)	?-LSSVM	Linear-RBF	Pattern classification
34	Z. Wu, H. Zhang and J. Liu, (2014)	FSVM	Gaussian	Clustering
35	Z. Qi, Y. Tian and Y. Shi, ()	S-TWSVM	Polynomial	Classification
36	H. Rai and A. Yadav, (2014)	SVM	Polynomial	Iris Recognition
37	J. S. Chou, M. Y. Cheng, Y. W. Wu and A. D. Pham, (2014)	GASVM	Polynomial-RBF-Sigmoid	Dispute Classification
38	L. Suzhen, L. Xiangjie and Y. Gang, (2014)	SVM	Cauchy	Risk Minimization
39	Y. H. Chen, Y. F. Zheng, J. F. Pan and N. Yang, (2013)	HS-KCNN-SVM	Polynomial	Text Classification
40	Z. Lu, J. Sun and K. Butts, (2014)	SVM	Wavelet	System Identification
41	Y. Zhang, X. Ma, Y. Zhang and J. Yang, (2013)	SVM	Gaussian-Polynomial	Fault Diagnosis
42	S. R. Dindarloo, (2014)	SVR	Gaussian	Reliability Analysis
43	A. Shabri and Suhartono, (2012)	LSSVM	Least Square	Forecasting
44	N. R. Sakthivel, V. Sugumaran and B. B. Nair, (2010)	PSVM	Polynomial	Fault Classification
45	M. Saimurugan and K. I. Ramachandran, (2014)	SVM	Polynomial	Signal Analysis

Bayes Ağı, denetimli sınıflandırma türleri için tasarlanmış, bir dizi yordayıcı değişkenlere ve özelliklere kategori veya etiket atamayı amaçlayan ağ türüdür (Bielza ve Larrañaga, 2014). İstatistiksel olasılığa dayalı olan bu sınıflandırma yöntemi, koşullu olasılık ile marjinal olasılık arasındaki ilişkiyi ortaya çıkarır. Bir olayın gerçekleşme durumunda birden fazla bağımsız olayın etkilerinin olması durumunda, bu değişkenlerden her birinin olayı meydana getirme olasılıkları hesaplamak için kullanılan yöntemdir. Bayesian sınıflandırıcıları düşük hata oranları ile önemli sonuçlar elde edilmektedir. Bu özelliğinden dolayı diğer sınıflandırma yöntemleri olan karar ağaçları ve yapay sinir ağları ile karşılaştırmaları yapılmaktadır. Navie Bayes teoremi, Bayes teoremine dayanarak koşullu bağımsızlık önermesi ile daha basitleştirilmiş türüdür. Bu önermeden dolayı diğer sınıflandırıcılardan daha doğru sonuçlar vermektedir. Sınıf kümeleri içindeki her bir elemanın olasılık değerini hesaplar ve en yüksek olasılık değerine göre sınıflandırma gerçekleştirir.

Şekil 1.4. Kesikli Bayesian ağ sınıflandırıcılarının $p(x, c)$ çarpanlarına göre sınıflandırılması.



Navie Bayes Teoremi şu şekilde hesaplanır:

$P(A|B)$ = B olayı gerçekleştiğinde A olayının gerçekleşme olasılığı


$P(A)$ = A olayının gerçekleşme olasılığı



$P(B|A)$ = A olayı gerçekleştiğinde B olayının gerçekleşme olasılığı

$P(B)$ = B olayının gerçekleşme olasılığı



$$P(A|B) = \frac{P(B|A) * P(A)}{P(B)}$$

Tablo 1.4. Bayesian Yönteminin Türleri

YÖNTEM	YAPI	MODEL	ÖZNİTELİK ALKTKÜME SEÇİMİ	ÇOKLU SINIFLANDIRMA
NAİVE BAYES		En basit Bayesian ağ sınıflandırıcı türü Naive Bayes (NB) sınıflandırıcısıdır (Maron and Kuhns 1960; Minsky 1961). Değişkenlerin her çıktı etiketinde bağımsız olduğu varsayımına dayanır ve tek değişkenli koşullu olasılıkların tahminine dayanır (Langley et al., 1992; Mitchell, 1997; Domingos and Pazzani, 1997; Hand and Yu, 2001). Bir dizi uygulama alanına göre çok yüksek doğruluk değerleri veren, çok basit ve hesaplama açısından verimli bir öğrenme algoritmasıdır.	NA	Özyinelemeli Naive Bayesian sınıflandırıcı (Langley 1993), Ardışık Naive Bayes sınıflandırıcısı (Kononenko 1993), NBtree, Naive Bayes ve karar ağaçları (Kohavi, 1996), Naive Bayes ve the k-nearest neighbor (en yakın komşu) Ağırlıklı Naive Bayes sınıflandırıcısı (Frank ve ark., 2003), tembel Bayesian kuralı öğrenme algoritması (Zheng ve Webb 2000)

SELECTİVE NAVİE BAYES		Yüksek derecede ilişkili değişkenleri sınıflandıran ve sınıflandırma doğruluğunu optimize eden değişkenlerin alt kümelerini seçen sarmalayıcı bir yaklaşımdır(Langley ve Sage, 1994;Kohavi ve John, 1997). Makul sayıda değişkene sahip olan veri setlerinde iyi sonuçlar elde edilmektedir. Mümkün olan en iyi sınıflandırıcıyı bulmak için değişkenlerin tüm alt kümeleri arasında arama yapar. Seçmeli Bayesian sınıflandırıcısı, tahminlerde sadece belirtilen özelliklerin bir alt kümesini kullanan naif yöntemin bir çeşididir.	Fitreleme Yaklaşımı (Pazzani ve Billsus, 1997), Sarmalama Yaklaşımı (Langley ve Sage, 1994)	Rastgele Naive Bayes (Prinzie and Van den Poel 2007),Navie Bayesian sınıflandırıcı komitesi (Zheng 1998), Bayesian model ortalamaları (Dash and Cooper, 2002).
SEMİ-NAVİE BAYES		Navie Bayes doğruluğunu daha da arttırmak için birçok girişimde bulunulmuştur. Öznitelik karşılıklı bağımlılığı azaltırken, sadeliği ve verimliliği korumaktadır. Nitelikler arasındaki karşılıklı bağımlılığın doğru koşullu olasılık üretebildiği sürece Navie Bayes'in doğruluğunu etkilemeyeceğini belirtmektedir(Domingos and Pazzani 1996). Semi-Navie Bayes yönteminin başarısı da nitelik bağımsızlığının uygun bir şekilde gevşetilmesinin doğruluk değerlerinin arttırmada etkili olduğunu göstermektedir. Semi-NavieBayes yöntemi 5 gruba ayrılmıştır: İlk grup NB'yi, özellikleri silerek oluşturulan bir özellik grubuna uygular (Langley and Sage, 1994). İkinci grup nitelik arasına açık bağımlılıklar ekler, 1-bağımlılık sınıflandırıcıları (Friedman ve diğerleri, 1997; Webb ve diğerleri, 2005; Cerquides and M'antaras, 2005a; Zheng ve Webb, 2006) Üçüncü grup NB'yi bir eğitim örneği alt	Fitreleme Yaklaşımı (Blanco ve ark., 2005), Sarmalama Yaklaşımı (Robles ve ark., 2003)	Aralık tahmini Navie Bayes (Robles ve ark., 2004)


		kümesine uygular (Langley, 1993).Dördüncü grup doğrudan çalışmasını değiştirmeden NB'nin çıktısını değiştirir (Gama, 2003).Beşinci grup gizli değişkenleri NB'ye tanıtır (Zhang ve ark., 2005; Langseth ve Nielsen, 2006)		
--	--	---	--	--

ONE-DEPENDENCE NAVİE BAYES	 1. TAN, 2.FAN, 3. SPODE	Navie Bayes yöntemi ile aralarındaki en önemli fark, her bir tahmin değişkeninin sınıfa ek olarak en fazla bir başka tahminciye dayanmasına izin verir. Onun dışında, Navie Bayes'e benzer. Tree-Augmented Naive Bayes (TAN) (Friedman ve ark, 1997), Forest-augmented naive Bayes (FAN) (Lucas, 2004), SuperParent-One-Dependence Estimators (SPODE) (Keogh ve Pazzani, 2002) geliştirilmiş yeni algoritmalarıdır.	Fitreleme Yaklaşımı TAN (Blanco ve ark., 2005), FAN (Ziebart ve ark.,), SPODE (NA). Sarmalama Yaklaşımı TAN (Keogh ve Pazzani, 2002), SPODE (NA).	Torbalama-randomTAN (Ma ve Shi, 2004), Ortalama bir bağımlılık tahmincisi (AODE) (Webb et al. 2005)
k-BAĞIMLI BAYESIAN SINIFLANDIRICILAR (KDB)		k-Bağımlı Bayesian Sınıflandırıcıları, her bir değişkenin sınıf değişkeninden ayrı bir maksimum k-ebeveyn değişkenine sahip olmasını sağlar (Sahami, 1996).	Fitreleme Yaklaşımı (Blanco ve ark., 2005), Sarmalama Yaklaşımı (Blanco ve ark., 2005)	Torbalama k-bağımlılık olasılık ağları (Louzada ve Ara, 2012)

1.1.2 Kümeleme Yöntemleri


Kümeleme yöntemleri, veriyi benzer nesne gruplarına bölme işlemidir. Kümeleme süreci, özellik seçimi/çıkarma, kümeleme algoritması tasarımı/seçimi, küme değerlendirme, sonuçların yorumlanması adımlarından oluşmaktadır (Xu ve WunschII, 2005).

Şekil 1.5. Kümeleme prosedürü



Kümeleme algoritmalarının birçok alan ile ilgili olmalarından dolayı, farklı başlangıç noktaları ve kriterlerin kümeleme algoritmalarının farklı taksonomilerinin oluşmasına neden olmuştur. Kümeleme tekniklerini 5 kategoriye ayırmıştır ve şekil 1.6'da beş kategorinin kümeleme algoritmalarının detaylı özellikleri yer almıştır (Benabellah ve ark., 2019).

Şekil 1.6. Kümeleme Yöntemleri



Tablo 1.5. Kümeleme Yöntemlerinin Özellikleri

Kategoriler	Algoritmalar	Hacim			Çeşitlilik	
		Veri kümesi boyutu	Yüksek boyutluluk	Gürültülü veri	Veri kümesi türü	Küme şekli
HİYERARŞİK TABANLI	Ward	Büyük/Küçük	Hayır	Hayır	Nümerik	Konveks
	BIRCH	Büyük	Hayır	Hayır	Nümerik	Konveks
	CURE	Büyük	Evet	Evet	Nümerik	Keyfi
	ROCK	Büyük	Hayır	Hayır	Categorik	Keyfi
	Chameleon	Büyük	Evet	Hayır	Nümerik/Categorik	Keyfi
BÖLÜMLEME TABANLI	K-means	Büyük/Küçük	Hayır	Hayır	Nümerik	Konveks
	K-modes	Büyük	Evet	Hayır	Categorik	Konveks
	K-medoids	Küçük	Evet	Evet	Categorik	Konveks
	PAM	Küçük	Hayır	Hayır	Nümerik	Konveks
	CLARA	Büyük	Hayır	Hayır	Nümerik	Konveks
YOĞUNLUK TABANLI	DBSCAN	Büyük	Hayır	Hayır	Nümerik	Keyfi
	OPTICS	Büyük	Hayır	Evet	Nümerik	Keyfi
	DENCLUE	Büyük	Evet	Evet	Nümerik	Keyfi
ŞEBEKE TABANLI	STING	Büyük	Hayır	Evet	Uzaysal	Keyfi
	CLIQUE	Büyük	Evet	Hayır	Uzaysal	Keyfi
	OPTIGRID	Büyük	Evet	Evet	Nümerik	Keyfi
	Wavecluster	Büyük	Hayır	Evet	Uzaysal	Keyfi
MODEL TABANLI	EM	Büyük	Evet	Hayır	Uzaysal	Konveks
	COBWEB	Küçük	Hayır	Hayır	Nümerik	Konveks
	SOM	Küçük	Evet	Hayır	Çok Değişkenli	Konveks


Tablo 1.6’da beş kategorinin birbirlerine olan üstünlükleri ve zayıflıkları yer almıştır (Benabellah ve ark., 2019).

Tablo 1.6. Kümeleme Yöntemlerinin Karşılaştırması

Kategoriler	AVANTAJLAR	DEZAVANTAJLAR
HİYERARŞİK TABANLI	- İlk aşamada küme sayısının bilinmesi zorunlu değildir. - Giriş parametreleri gerekmez. - Uygulaması kolay.	- Yorumlanabilirlik eksikliği. - Aykırı değerlere karşı çok hassastır. - Örnekler bir kümeye atandıktan sonra, önceki adımı geri almak mümkün değildir.
BÖLÜMLEME TABANLI	- Güçlü, ölçülebilir ve basit. - Anlaması kolaydır ve alan bilgisi gerektirmez. - Merkez yeniden hesaplandığında kümeler değişir.	- Kümelerin sayısının tahmin etme zorluğu. - Ölçeğe karşı duyarlılığı yüksek olduğundan, normalleştirme ve standardizasyon sonuçları tamamen değişir.
YOĞUNLUK TABANLI	- Ratgele şekilli küme oluşturur. - Gürültü ve aşınmaya karşı dirençlidir.	- Büyük ve seyrek veri setleri ile verimli çalışamaz. - Yüksek boyutlu veri kümelerine uygun değildir.
ŞEBEKE TABANLI	- İstatistiki bilgiler sorgulardan bağımsız olarak mevcuttur. - Yüksek boyutlu veri setleri için artan güncelleme ve verimliliğe sahiptir.	- Yüksek boyutlu bir veri kümesinin düşük boyutlu bir alt alanında kümelerinde zayıf performans gösterin. - Çıkıntıların dikkatlice seçilmesini, yoğunluk tahminini ve optimum kesme düzlemini gerektirir
MODEL TABANLI	- Elde edilen bölüm istatistiksel açıdan yorumlanabilir. - Vektör ölçümü için başarıyla kullanılabilir. - Bileşen dağılımını seçmede esneklik sağlar. Her küme için bir yoğunluk tahmini sağlar.	- Her bileşende daha fazla veri noktası gerektiren parametrelerin tahmin edilmesi gerekir. - Veri setinin tamamını kullanmamamız nedeniyle tahminlerin kalitesinin düşüklüğü.

Kümeleme algoritmalarının sınıflandırılması yapılan başka bir çalışmada şu şekilde elde edilmiştir (Xu ve WunschII, 2005):

Şekil 1.7. Kümeleme yöntemleri



Hiyerarşik kümeleme yöntemlerinin iki sınıflaması vardır: Birleştirme (aşağıdan yukarıya) ve Ayırma (yukarıdan aşağıya) yaklaşımlar. Bölümleme algoritmaları kümeleri alt kümeler arasında yinelemeli olarak yeniden konumlandırarak veya verilerle yoğun biçimde doldurulmuş alanları belirleyerek keşfeder. Yüksek boyutsal veri kümeleme yöntemleri, yüzlerce niteliğe sahip verileri işlemek için tasarlanmıştır.

1.1.3 Zaman Serisi Yöntemleri

Veri madenciliğinde zaman serisi yöntemlerinin temel amacı, serinin doğal yapısına en uygun modeli geliştirmek için, geçmiş gözlemleri dikkatlice ve titiz bir şekilde incelemektir. Elde edilecek en uygun model ile gelecekteki değerleri tahmin etmek için kullanılacaktır. Başarılı bir zaman serisi elde etmek için birçok literatürde yöntem geliştirilmiştir.

1. Stokastik Modeller Kullanarak Zaman Serisi Tahmini

- Otoregresif Hareketli Ortalama (ARMA) Modelleri
- Otoregresif Entegre Hareketli Ortalama (ARIMA) Modelleri

- Mevsimsel Otoregresif Entegre Hareketli Ortalama (SARIMA) Modelleri
 - Bazı Lineer Olmayan Zaman Serisi Modelleri
 - Box-Jenkins Metodolojisi
2. Yapay Sinir Ağlarını Kullanarak Zaman Serisi Tahmini
- Yapay Sinir Ağları (YSA)
 - Gecikmeli Sinir Ağları (TLNN)
 - Mevsimsel Yapay Sinir Ağları (SANN)
3. Destek Vektör Makinelerini Kullanarak Zaman Serisi Tahmini
- Ampirik Risk Minimizasyonu (ERM)
 - Vapnik-Chervonenkis (VC) Ölçüsü
 - Yapısal Risk Minimizasyonu (SRM)
 - Destek Vektör Makineleri (SVM'ler)
 - Destek Vektör Çekirdekleri
 - Regresyon için SVM (SVR)
 - LS-SVM Yöntemi
 - DLS-SVM Yöntemi

1.2 Makine Öğrenmesi

Makine öğrenmesi, bilgisayarlara net talimatlar vermeden verilerden öğrenme yeteneği sağlayan farklı tür algoritmaların incelenmesi, tasarımı ve geliştirilmesi ile ilgilidir. Makine öğrenmesi algoritmaları, herhangi bir insan yardımı olmadan bilgileri otomatik olarak çıkarabilir. Makine öğrenimi bir bilgisayar bilimi ve yapay zeka alanıdır. Ayrıca istatistik ve optimizasyon gibi alanlarla yakın bir bağlantısı vardır. Makine öğrenme algoritmaları istenen çıktıya dayanarak öğrenme türüne göre şu şekilde sınıflandırılabilir: Denetimli Öğrenme, Denetimsiz Öğrenme, Yarı Denetimli Öğrenme.

Denetimli öğrenme, etiketli, giriş ve çıkış değişkenlerine sahip olan, bu verilerden elde edilecek sonuçların ne olacağını önceden bildiğimiz, bir veri kümesinin eğitilerek girdi ve çıktı değişkenleri arasında bir eşleşme sonucunda fonksiyonun ortaya çıkarılması sonucu gerçekleştirilen öğrenme çeşididir. Fonksiyon sayesinde

gerçekleştirilen öğrenme ile, yeni verileri etiketleme ve kategorize işlemleri gerçekleştirilir. Elde edilen fonksiyon sayesinde verilerdeki geçmiş bilgilerden yararlanılarak gelecekte gerçekleşecek benzer olayların tahmin edilmesinde makine öğrenmesi uygulamalarında sıklıkla kullanılan bir yöntemdir. Denetimli öğrenme, kategorik ilişkilerin belirlenmesi problemlerinde sınıflandırma ve nicel değişkenler arasındaki ilişkilerin belirlenmesi problemlerinde regresyon olmak üzere iki işleve ayrılır. Denetimli öğrenme algoritmaları, K-En Yakın Komşular • Doğrusal Regresyon • Lojistik regresyon • Rastgele Orman • Gradyan Güçlendirilmiş Ağaçlar • Destek Vektör Makineleri (SVM) • Karar Ağaçları • Yapay Sinir Ağları • Naive Bayes en yaygın olarak kullanılan algoritmalarıdır.

Denetimsiz öğrenme, etiketsiz ve sınıflandırılmamış veriler üzerinde algoritmaların öğrenmesi sonucunda verilerin gruplandırılması veya kümelenmesi işlevidir. Veriler hakkında daha fazla bilgi elde ederek ortak özelliklerin varlığına göre yapıları modeller. Bu tür öğrenmede veriler hakkında önceden neler arayacağımızı bilmediğimiz problemlerde uygulanır.

Yarı denetimli öğrenme, denetimli ve denetimsiz öğrenme arasında yer almaktadır. Etiketlenmemiş veriler ile etiketlenmiş az miktarda verinin birlikte kullanılarak gerçekleştirdiği denetimli öğrenme problemleri ile aynı uygulamalar için kullanılan öğrenme türüdür.

Makine öğrenmesi, günlük hayatta kullanım alanları giderek artmaktadır. Üretkenliğin arttırılmasında, hastalıkların tespitinde, görüntü ve ses tanıma, ürün önerilerinde, duygu analizlerinde, sosyal medyada, sahtekarlık ve kötü amaçlı durumların tespitinde kullanılmaktadır. Akıllı ulaşım sistemlerinin giderek hayatımıza girdiği son dönemlerde trafik tahminlerinin analizinde önemli bir yer edinmektedir. Oluşabilecek trafik yoğunluğunun tahmin edilerek oluşabilecek yoğunluk ve tıkanıkların önceden belirlenmesinde kullanılmaktadır. Günlük ve geçmiş verilerden yararlanılarak tıkanıklığın oluşabileceği bölgelerin tespitinde önemli sonuçlar elde edilmiştir.


İKİNCİ BÖLÜM

TRAFİKTE VERİ MADENCİLİĞİ

2.1. Trafikte Veri Madenciliği Uygulamaları

Ulaşım sisteminin gelecekteki yönü olan Akıllı Ulaşım Sistemlerinde üretilen büyük veri, araştırmalarda giderek odak noktası haline gelmektedir. Elde edilen büyük veri sayesinde, daha güvenli, verimli ve karlı akıllı ulaşım sistemlerinin tasarım ve uygulamasında önemli bir yere sahip olacaktır. ITS’de akıllı kartlar, GPS, sensörler, video dedektörleri ve sosyal medya aracılığıyla elde edilen büyük veriler, doğru ve etkili veri analizleri ile ITS’yi daha verimli bir noktaya taşıyabilir (Shi ve Abdel-Aty, 2015). ITS’de elde edilen verilerin miktarı ve karmaşıklığı her geçen gün artmasından dolayı, geleneksel veri işleme ve analiz yöntemlerinin yetersizliği ortaya çıkmaktadır. Bu problemin çözümünde büyük veri analizi ITS’ye yeni teknik ve yöntemler sağlamaktadır. Büyük veri analizi ile ITS’de verilerin işlem verimliliği artırılarak, mevcut ve geçmiş verilerin analizi ile gerçek zamanlı trafik akışı tahmini, toplu taşıma hizmet planlaması, en uygun rota planlaması, trafik kaza olayı ve yer tahmini gibi konularda büyük faydalar sağlayabilmektedir. ITS’de büyük veri analizi sırasıyla şekil 2.1’de olduğu gibi veri toplama, veri analizi ve uygulama aşamalarından oluşmaktadır (Zhu ve ark., 2018).


Şekil 2.1. ITS’de Büyük Veri Analitiği Basamakları



Akıllı ulaşım sistemlerinde altı temel bileşen içermektedir: ileri taşımacılık yönetim sistemleri, ileri seyahat bilgi sistemleri, ileri araç kontrol sistemleri, iş araç yönetimi, ileri toplu taşıma sistemleri ve ileri şehir içi ulaşım sistemleri. Bu bileşenlerin çoğunun araç ve karayolu taşımacılığına özgü olduğu belirtilmiştir (Qi, 2008). Akıllı ulaşım sistemlerinin bünyesinde yer alan ileri teknoloji uygulamalarından elektronik sensör teknolojileri, veri iletim teknolojilerini ve akıllı kontrol teknolojileri tarafından toplanan veriler büyük verinin özellikleri olan hız, hacim ve çeşitlilik özelliklerine sahip olduğunu belirtmiştir. Akıllı şehirlerde zengin çeşitlilik gösteren veri kaynaklarının olduğunu ve bu veri kaynaklarının doğrudan çeşitli cihazlardan, ağ yapılarından, uygulamalardan, veri sağlayıcılarından, bilgi sistemleri olan Akıllı Ulaşım Sistemleri (ITS), Mekânsal Bilgi Sistemleri (GIS) gibi kaynaklardan elde edilebileceği literatürde belirtilmiştir.

Trafik veri kaynakları altı kategoride toplanmıştır (Dabiri ve Heaslip, 2018):

Şekil 2.2. Trafik veri kaynaklarının sınıflandırılması



Sosyal medyadan ulaştırma verilerinin toplanarak kullanıcıların ihtiyaç ve bakış açılarının aşılmasında büyük bir öneme sahip yeni bir alan olması ve ulaştırma planlaması, yönetimi ve kontrolünde kullanılması literatürde giderek önemli bir trafik veri kaynağı haline gelmektedir. Sosyal medya ulaşım sorunları için aşağıdaki konularda faydalı veriler elde edilebilir (Grant-Muller ve ark. 2015; Pender ve ark. 2014):

- Kalkış noktası verileri
- Sosyoekonomik ve bağlamsal veriler
- Mod talebine ilişkin kanıt
- Bağlantı talebine ilişkin kanıt
- Seyahat sürelerinin tahmini
- Duyarlı ajanslara talep üzerine kanıt
- Birçok olay ve olayın tespiti
- Mod seçimi mantığını anlama bilgisi
- Motorsuz modlardan elde edilen veriler (bisiklet sürücüleri ve yayalar gibi)
- Metin içeriğinin analizi

2.2. Sosyal Medyanın Trafik Analizinde Kullanımı

Sosyal medyanın ulaştırma alanında kullanım amacına bağlı olarak aşağıdaki kategorilere ayrılmıştır (Nikolaidou ve Papaioannou, 2018):

- olay tespiti
- hareketlilik ve faaliyet kalıplarını anlamak
- sürücü memnuniyetinin ölçülmesi
- ulaştırma makamları ve kamu kurumları tarafından bilgi paylaşımı ve iletişim
- ulaşım araştırmaları yapmak.

İnsan davranışlarını daha iyi anlamak, tahmin etmek ve yönlendirmek için sosyal medya verilerinden yararlı bilgileri çıkarmak için metin madenciliği ve veri madenciliği tekniklerinin kullanılması gerektiğini belirtmişlerdir (Abbasi ve ark. 2015; Maghrebi ve arkadaşları 2015).

Fu ve ark. (2015), sosyal medya verilerinin trafik olaylarını tespit etmek için uygulanabilirliğini arařtırdı. Twitter'den elde edilen veriler ile trafik olaylarının bilgilerini çıkarmak ve analiz etmek için bir yaklaşım geliřtirdiler.

Steuer (2015), Twitter verilerini kullanarak olay tespiti ve yol kullanıcılarına olay iletimi için yararlı bir bilgi kaynağı olacağı sonucuna ulařılmıştır.

Daly ve ark. (2013), sosyal medyanın yararlı bilgileri toplayarak mevcut trafik kořullarını görselleřtirmek için kullanılabileceğini öngörmüřtür. Trafik kazaları ve büyük olaylar hakkında kullanıcıları güncellemek için sosyal medyadan elde edilen dinamik verileri birleřtirdiler.

Wanichayapong ve ark. (2011), Twitter'den trafik sıkışıklığı, hava olayları gibi trafik bilgilerini çıkararak, trafik haberlerinin sınıflandırılması ve olayların mekânsal boyutlarla ilişkilendirilmesi gerçekteřtirilmiştir. Sınıflandırma sonucunda kullanıcıların rotalarını planlamalarına ve gerçekte zamanlı olarak trafik sıkışıklığını önlemelerine yardımcı olacağı belirtildi.

Abel ve ark. (2012), Twitter'den yayınlanan acil durum olayları ile ilgili bilgileri otomatik olarak filtrelemek, aramak ve analiz etmek için bir çerçeve oluşturulmuřtur.

Kumar ve ark. (2014), Twitter verilerinden yararlanılarak kötü yol kořullarını tespit etmek için kullanılmıştır. Trafik ve yol tehlikeleri ile ilgili tweetler toplanarak duygu analiz yapılmıştır.

Mai ve Hranac (2013), sosyal medyadan trafik sıkışıklığının nedenleri hakkında bilgi toplanarak duyarlılık analizi gerçekteřtirildi. Sosyal medya verilerinin ulařtırma arařtırmasında kullanıcıların etkinliklerinin ve mekânsal hareketliliklerinin belirlenmesinde kullanılmıştır.

Hasan ve diğ. (2013), Twitter kullanıcılarının konum tabanlı verilerinden kentsel insan hareketliliği ve aktivitelerini inceledi.

Chaniotakis ve ark. (2015), Twitter'den toplanan verileri boş zaman etkinlikleri talep modellemesi için kullanma potansiyeli arařtırılmıştır.

Cheng ve ark. (2011), sosyal medya verileriyle insan hareketlilik modellerini değerlendirerek zamansal, mekânsal ve sosyal yönlerini analiz etmişleridir.

Schweitzer (2012), taşımacılık hizmetlerinin kalitesi ile ilgili görüşlerin değerlendirilmesinde, kullanıcıların memnuniyetindeki eğilimlerinin ve gerçek zamanlı olayların belirlenmesinde Twitter'ın verilerinin duygu analizi uygulanabileceğini belirtmiştir.

Collins ve ark. (2013), transit sistemleri kullanan kullanıcıların memnuniyetlerini değerlendirmek için Twitter verilerine duyarlılık analizi kullanıldı.

Luong ve Houston (2015), demiryolu taşımacılığı hizmetlerine ilişkin Twitter'den kullanıcıların tutumlarını duygu analizi kullanarak incelemişlerdir.

Gal-Tzur ve diğ. (2014), ulaşım hizmetlerine duyulan ihtiyacı belirlemek, taşıma ile ilgili olayları bildirmek için Twitter verilerinin farklı kategorilerde sınıflandırılması gerçekleştirildi.

Hassan ve Ukkusuri (2014), sosyal medya verilerini kullanarak kullanıcıların konum verilerinden yararlanarak sınıflandırmaya dayalı bir seyahat hareketlilik model yaklaşımı önermiştir.

Ni ve ark. (2017), metro yolcu akış tahmini için sosyal medya verilerinden yararlanılmıştır. Twitter verileri toplanarak tahmin modeli geliştirmişlerdir.

Cottrill ve ark.(2017), sosyal medya platformlarından gelen verilerden ulaşım ile ilgili verileri paylaşmak ve halkın koordinasyonunu sağlamak hedeflenmiştir. Twitter verilerinin analizi yapılarak ulaşımında yolculara zamanında bilgi paylaşımının potansiyelini belirtmişlerdir.

Maghrebi ve ark.(2017), sosyal medya verilerinden yararlanılarak seyahat modu seçimi gerçekleştirilmiştir. Twitter verileri ile seyahat modu seçimi analiz yapılarak ulaşımında sosyal medyanın potansiyel bir uygulama alanı olduğu önerildi.

Huang ve ark. (2017), Twitter verilerinden yararlanılarak mekansal ve istatistiksel analizler yoluyla varış yeri veya rota seçimi problemlerinde sosyal medya verilerinin analiz ve görselleştirme yöntemleri araştırılmıştır.

Rashidi ve ark.(2017), sosyal medya verilerinin ulaşım alanındaki boyutu araştırılmıştır. Seyehat amacı, ulaşım şekli, varış yeri seçimi gibi konulardaki uygulamaları incelenmiştir.

Xu ve ark.(2019), sosyal medya verilerinden çok miktarda trafik ile ilgili verilerin olduğu, Toronto'da Kanada'da Twitter verilerini kullanarak bir vaka çalışması yapılmıştır. Twitter verileri analiz edilerek ilişkilendirme kuralları ile makine öğrenmesi yöntemlerine dayanarak trafik olayları sınıflandırması gerçekleştirilmiştir.

Rahman ve ark.(2019), gerçek zamanlı trafik bilgilerini paylaşmak için Twitter hesabından toplanan verilerin bir analizini önermektedir. Sosyal medya üzerinden gerçek zamanlı trafik bilgi paylaşımının etkinliğini arttırmak için çeşitli ölçümler ile sosyal medya tabanlı uyarlanabilir gerçek zamanlı trafik beslemesi (SMART-Feed) modeli geliştirilmiştir.

Dabiri ve Heaslip (2019), trafik olaylarını tespit etmek ve trafik koşullarını takip etmek için Twitter verileri sınıflandırılarak yararlanılmıştır. Konvolüsyonel sinir ağını (CNN) ve tekrarlayan sinir ağını (RNN) kullanılarak model önerilmiştir.

Huang ve ark.(2019), kentsel trafiği ile ilgili bilgilerin sosyal medya verilerinden çıkarılarak, insan faaliyetlerinin günlük trafik sıklığı üzerindeki potansiyel etkisi araştırılarak bir çözüm önerisi geliştirilmiştir.

Tablo 2.1.'de literatürde son yıllarda sosyal medya verilerinin ulaştırma alanında kullanım ve uygulamalarının özeti verilmiştir.

Tablo 2.1. Sosyal Medyanın Ulaştırma Alanında Kullanım ve Uygulamaları

Yazar	Yıl	Sosyal Medya	Ulaşım Modu	Kategori	Kapsam
Wanichayapong ve ark.	2011	Twitter	Genel	Olay Tespiti	Twitter verilerinden trafik bilgilerinin çıkarılması ve sınıflandırılması
Cheng ve ark.	2011	Facebook	Genel	Hareketlilik ve aktivite kalıplarını anlama	İnsan seyahat hareketlilik kalıplarının analizi ve değerlendirilmesi
Abel ve ark.	2012	Twitter	Genel	Olay Tespiti	Acil durum yayın servislerinden bilgilerin filtrelenmesi ve otomatikleştirilmesi
Daly ve ark.	2013	Twitter	Genel	Olay Tespiti	Trafik sıklığının nedenlerinin araştırılması
Mai and Hranac	2013	Twitter	Genel	Olay Tespiti	Trafik sıklığının nedenlerinin araştırılması

Hasan ve ark.	2013	Twitter	Genel	Hareketlilik ve aktivite kalıplarını anlama	İnsan hareketlilik kalıplarının zamansal ve mekansal analizi ve değerlendirilmesi
Kumar ve ark.	2014	Twitter	Genel	Olay Tespiti	Gerçek zamanlı yol tehlike uyarı sisteminin oluşturulması, twitter ile kötü yol koşullarının tespiti
Collins ve ark.	2014	Twitter	Toplu Taşıma	Kullanıcı memnuniyetini ölçmek	Gecikmeler ve aşırı hava koşulları gibi düzensiz olaylarla ve ulaşım hizmetinin güvenliği
Gal-Tzur ve ark.	2014	Twitter	Genel	Kullanıcı memnuniyetini ölçmek	Ulaşım hizmetlerine duyulan ihtiyacı belirlemek
Hassan ve Ukkusuri	2014	Twitter	Genel	Hareketlilik ve aktivite kalıplarını anlama	İnsan hareketlilik kalıplarının sınıflandırmak için model geliştirmek
Fu ve ark.	2015	Twitter	Genel	Olay Tespiti	Gerçek zamanlı trafik analizi ile trafik kaza yönetimi
Steuer	2015	Twitter	Genel	Olay Tespiti	Trafik kazalarının gerçek zamanlı twitter verilerinden araştırılması
Chaniotakis ve ark.	2015	Twitter	Genel	Hareketlilik ve aktivite kalıplarını anlama	Seyahat talep tahmini için twitter verilerinin kullanılması
Zhang ve ark.	2016	Twitter	Genel	Olay Tespiti	Trafik olaylarının tespit algoritmasının geliştirilmesi
Ni ve ark.	2017	Twitter	Toplu Taşıma	Hareketlilik ve aktivite kalıplarını anlama	Metro yolcu akışı tahmini
Cottrill ve ark.	2017	Twitter	Genel	Hareketlilik ve aktivite kalıplarını anlama	Ulaşım bilgi yönetimi, trafik akışı tahmini
Maghrebi ve ark.	2017	Twitter	Genel	Hareketlilik ve aktivite kalıplarını anlama	Seyahat modu tespiti
Huang ve ark.	2017	Twitter	Genel	Hareketlilik ve aktivite kalıplarını anlama	Variş yeri veya rota seçimi analizi
Rashidi ve ark.	2017	Twitter	Genel	Hareketlilik ve aktivite kalıplarını anlama	Sosyal medya verilerinin seyahat davranışını modelleme kapasitesini araştırmak
Xu ve ark.	2019	Twitter	Genel	Olay Tespiti	Twitter verilerini kullanarak trafik olayları analizi
Rahman ve ark.	2019	Twitter	Genel	Hareketlilik ve aktivite kalıplarını anlama	Gerçek zamanlı trafik bilgi sisteminin geliştirilmesi
Dabiri ve Heaslip	2019	Twitter	Genel	Olay Tespiti	Twitter verilerini kullanarak trafik olayları analizi
Huang ve ark.	2019	Twitter	Genel	Hareketlilik ve aktivite kalıplarını anlama	Kentsel insan faaliyetleri ve günlük trafik koşulları arasındaki etkileşimin araştırılması

ÜÇÜNCÜ BÖLÜM


LİTERATÜR ARAŞTIRMASI

3.1. Trafik Tahminleme Probleminin Uygulamaları

Trafik tahmini, Akıllı Ulaşım Sistemlerinde kullanıcıların ve karar vericilerin önceden planlamalarını ve yönetimlerini iyileştirmek, trafik sıkışıklığı ile başa çıkmak, mevcut ve gelecekteki trafik verilerine dayanarak yakın gelecekteki trafik önlemlerinin öngörülmesi adına son dönemlerde çok önemli bir konu haline gelmiştir. Verilerin ortaya çıkması ve artan hesaplama kaynakları ile trafik tahmin için farklı modelleme yaklaşımlarının ortaya konulduğu üstün bir yaklaşım haline gelmiştir (Vlahogianni ve ark., 2014). Trafik tahminleme yöntemleri olarak trafik teorisi modelleri ile klasik istatistiksel yöntemler kullanılarak tek bir yerdeki trafiği tahmin etmeye odaklıydı. Akıllı Ulaşım Sistemleri ile büyük miktarda trafik verisinin oluşması sonucunda veri odaklı modellerin oluşturulmasına neden olmuştur. Hesaplama kapasiteleri ve büyük veri işleme yöntemleri arttıkça, toplu verilerin işlenmesi için yeni teknolojilerin ve tekniklerin gelişmesi, görünmeyen verilere dayanarak sürekli trafik önlemlerinin tahminlemesini yapmak için geleneksel yaklaşımları geride bırakarak karmaşık senaryolar elde edilebilen Makine Öğrenmesi yöntemlerine olan ilgi yoğun bir şekilde artmıştır (Lana ve ark., 2018). Vlahogianni ve ark. (2014), Trafik tahmin yöntemlerinin uygulanmasında uygulanacak senaryolar için bir takım trafik ve model özelliklerinin belirlenmesi gerektiği Tablo 'da önerilmiştir. Akıllı ulaşım sistemlerinde gelişen teknolojilerdeki gelişmeler sonucunda farklı kaynaklardan elde edilmesine imkan sağlamıştır. Trafik tahmini için veri kaynaklarının sınıflandırılması üç gruba ayrılmıştır: nokta dedektörleri, aralık dedektörleri ve hareketli sensörler. Nokta dedektörleri, yakınındaki araçların varlığını tespit ederek akış, doluluk ve yoğunluk verileri elde edilir. Aralık dedektörleri, bir yoldaki sabit iki nokta arasındaki daha fazla mekansal alanı kapsayarak trafik ölçümlerini hesaplar. Hareketli sensörler, GPS'lerin ortaya çıkması ile daha detaylı trafik veri kaynağını toplayan araçlardır. Trafik tahminlerinin kapsam boyutlarında üç alt seviyeye ayrılmıştır. Birinci alt seviye, bağlam kısmında trafik tahminlemesinin kentsel veya otoban ortamına karşılık gelmektedir. İkinci alt seviye, mekansal

kapsama olarak nokta, bölüm veya ağ konumları ifade etmektedir. Üçüncü alt seviye, hedef kısmında tahminlerin gerçekleştirildiği yerlerin sayısını ifade etmektedir. Tek bir nokta veya birden fazla nokta, segment ve ağ için trafik tahminlerinin yapılmasını ifade etmektedir. Problemlerin belirlenmesi kısmı dört alt seviyeye ayrılmıştır. Birinci alt seviye, verilerin girdi olarak kullanıldığı zamansal, zamansal ve mekansal ile trafik dışı veriler oluşturmaktadır. Zamansal veriler, aynı trafik dedektörü tarafından alınan tek bir trafik ölçüsü ile ilişkili zaman serisi verilerinden oluşmaktadır. Zamansal verilerin yanında, mekansal verilerinde kullanılarak tahmin doğruluğunun yapılmasını içermektedir. Trafik dışı verilerin, tahminlerin doğruluğunda önemli rol oynayabilen hava durumu ve zamanı gibi unsurlardan oluşmaktadır. İkinci alt seviye, trafik değişkeninin tahmin edilecek zamanın belirlenmesini belirtmektedir. 60 dakikadan daha az zamandaki trafik problemlerine kısa dönem, 60 dakikadan daha fazla zamandaki trafik problemlerine uzun dönem olarak belirtilmiştir. Üçüncü alt seviye, tahminlerin yapıldığı zamanın sıklığını ifade etmektedir. Her 30 saniyede bir elde edilen ve gürültülü veri olan yüksek çözünürlüklü verilerdir. 5-15 dakikada elde edilen verilerin orta çözünürlükte veriler olduğu ve veri ön işlemenin gerekli olduğu verilerdir. Çıktıların belirlenmesi aşamasında, mevcut verilerin türüne bağlı olarak beklenen trafik koşullarını belirlemek için iki alt seviyeden oluşmaktadır. Birinci alt seviye, akış, yoğunluk, doluluk ve hız içeren temel trafik değişkenleri oluşturmaktadır. İkinci alt seviye, seyahat süresi tahmini oluşturmaktadır. Modellerin oluşturulmasında giriş verilerinin nasıl modellendiğini belirtmektedir. Vektör ve yüksek dereceli tensörler olarak alt seviyelerden oluşmaktadır. Model çıktıları olarak tahmin edilecek değişkenin tekli veya birden fazla olması durumuna göre belirlenmiştir. Tahmin modellerinin gelecekteki tek bir zaman adımı için tahmini ile tekli, birden fazla zaman diliminin tahmin edilmesi çoklu şeklinde belirlenmiştir.

Şekil 3.1. Trafik tahmin problemlerinin taksonomisi



Tablo 3.1. Trafik Tahminleme Probleminin Literatür Araştırması

Yazarlar		YIL	TRAFİK ÖZELLİKLERİ								Model Özellikleri				YÖNTEMLER
			Veri Kaynağı	Kapsam			Problemlerin Belirlenmesi								
				Bağlam	Mekansal Kapsama	Hedef	Girişlerin Belirlenmesi	Zaman	Zaman Adımı	Çıktıların Belirlenmesi	Model Girişleri	Model Çıktıları	Adım Tahmini	Veri Ön İşleme	
1	H.-F. Yang, T. S. Dillon, E. Chang, and Y.-P. P. Chen	2019	Nokta	Otoban	Bölüm	Çoklu	Zamansal	Uzun	Yüksek +Orta	Temel	Vektör	Tekli Hedef	Çoklu	-	Üstel Pürüzsüzleştirme ve Aşırı Öğrenme Makinesi (ELM)
2	F. Su, H. Dong, L. Jia, Y. Qin, and Z. Tian	2018	Nokta	Kentsel	Nokta	Tekli	Zamansal	Kısa	Orta	Temel	Vektör	Tekli Hedef	Tekli	-	k-NN
3	H. Yang, Y. Zou, Z. Wang, and B. Wu	2018	Aralık	Otoban	Bölüm	Tekli	Zamansal+Me kansal	Uzun	Orta	Seyehat Süresi	Vektör	Tekli Hedef	Çoklu	Veri Hazırlama	ANN, Markov Zinciri
4	Q. Liu, B. Wang, and Y. Zhu	2018	Nokta	Otoban	Nokta	Çoklu	Zamansal+ Mekansal	Kısa	Orta	Temel	Yüksek Dereceli Tensör	Tekli Hedef	Çoklu	Veri Hazırlama	ANN
5	W. Jin, Y. Lin, Z. Wu, and H. Wan	2018	Hareketli	Kentsel	Ağ	Tekli	Zamansal+ Mekansal+ Trafik Dışı	Kısa	Orta+ Küçük	Temel	Yüksek Dereceli Tensör	Tekli Hedef	Çoklu	Veri Hazırlama	Konvolüsyonlu Sinir Ağı (CNN) ve Uzun Kısa Süreli Bellek (LSTM)
6	Z. Liu, J. Guo, J. Cao, Y. Wei, and W. Huang	2018	Nokta	Otoban	Nokta	Çoklu	Zamansal+ Mekansal	Kısa	Orta	Temel	Vektör	Tekli Hedef	Tekli	Veri Hazırlama	ANN, k-NN

7	S. Cheng, F. Lu, P. Peng, and S. Wu	2018	Nokta+ Hareketli	Kentsel+ Otoban	Nokta+Bölüm	Çoklu	Zamansal+ Mekansal	Kısa	Orta	Temel	Yüksek Dereceli Tensör	Tekli Hedef	Tekli	Veri Hazırlama+ Kusurlu Veri	Spatiotemporal k-en yakın komşu modeller (ST-KNN'ler),çoklu görüşe dayalı öğrenme (MVL)
8	B. Sharma, S. Kumar, P. Tiwari, P. Yadav, and M. I. Nezhurina	2018	Aralık	Otoban	Bölüm	Tekli	Zamansal	Kısa	Orta	Temel	Vektör	Tekli Hedef	Tekli	-	ANN
9	A. Raza and M. Zhong	2017	Nokta	Kentsel	Bölüm	Çoklu	Zamansal	Kısa	Orta	Temel	Vektör	Tekli Hedef	Çoklu	Kusurlu Veri+Veri Azaltma	ANN+LWR
10	B. Yu, H. Yin, and Z. Zhu	2017	Nokta	Kentsel+ Otoban	Bölüm	Çoklu	Zamansal+ Mekansal	Kısa	Orta	Temel	Yüksek Dereceli Tensör	Tekli Hedef	Çoklu	Veri Hazırlama+ Kusurlu Veri	Deep Learning
11	A. Attanasi, L. Meschini, M. Pezzulla, G. Fusco, G. Gentile, and N. Isaenko	2017	Nokta	Kentsel	Nokta	Çoklu	Zamansal	Kısa	Orta	Temel	Vektör	Çoklu Hedef	Çoklu	-	Sinir Ağı, Yapay Zeka, Bayesian Ağı
12	C. Song, H. Lee, C. Kang, W. Lee, Y. B. Kim, and S. W. Cha	2017	Nokta	Otoban	Bölüm	Tekli	Zamansal+ Mekansal	Kısa	Yüksek	Temel	Vektör	Tekli Hedef	Çoklu	Veri Hazırlama	ANN
13	X. Chen, Z. Wei, X. Liu, Y. Cai, Z. Li, and F. Zhao	2017	Nokta	Otoban	Nokta	Çoklu	Zamansal+ Mekansal	Kısa	Orta	Temel	Vektör	Tekli Hedef	Tekli	Veri Hazırlama	Genetik Algoritma, Makine Öğrenmesi

14	B. Sun, W. Cheng, P. Goswami, and G. Bai	2017	Nokta	Otoban	Nokta	Tekli	Zamansal	Kısa	Yüksek	Temel	Vektör	Tekli Hedef	Tekli	-	k-NN
15	T.-I. Theodorou, A. Salamanis, D. D. Kehagias, D. Tzovaras, and C. Tjortjis	2017	Nokta	Otoban	Nokta	Çoklu	Zamansal	Kısa	Orta	Temel	Vektör	Tekli Hedef	Tekli	-	Destek Vektör Makineleri, K-En Yakın Komşu, Otheregressive Entegre Hareketli Ortalama
16	H. Yu, Z. Wu, S. Wang, Y. Wang, and X. Ma	2017	Hareketli	Kentsel	Ağ	Tekli	Zamansal+ Mekansal	Kısa	Orta	Temel	Yüksek Dereceli Tensör	Tekli Hedef	Çoklu	-	derin evrişimli sinir ağlarının (DCNNs), uzun kısa süreli belleğin (LSTM) sinir ağları, spatiotemporal yinelenen evrişimli ağlar (SRCNs)
17	K. Liu, S. Gao, P. Qiu, X. Liu, B. Yan, and F. Lu	2017	Hareketli	Kentsel	Ağ	Tekli	Zamansal+ Mekansal	Kısa	Orta	Temel	Vektör	Tekli Hedef	Tekli	Veri Azaltma	ANN, SVM
18	A. Raza and M. Zhong	2017	Nokta	Kentsel	Bölüm	Tekli	Zamansal	Kısa	Orta	Temel	Vektör	Tekli Hedef	Tekli	Kusurlu Veri+Veri Azaltma	ANN+ Yerel Ağırlıklı Regresyon (LWR)
19	B. Z. Yao et al.,	2017	Hareketli	Kentsel	Bölüm	Çoklu	Zamansal+ Mekansal	Kısa	Orta	Temel	Vektör	Tekli Hedef	Tekli	Kusurlu Veri+Veri Azaltma	SVM
20	I. Laña, J. Del Ser, M.	2017	Nokta	Kentsel	Nokta	Çoklu	Zamansal	Uzun	Orta	Temel	Vektör	Tekli Hedef	Çoklu	Veri Azaltma	Yapay Sinir Ağları

	Vélez, and I. Oregi,														Biyoçeşitli sezgisel tarama
21	Cai, P., Wang, Y., Lu, G., Chen, P., Ding, C., & Sun, J.	2016	Hareketli	Kentsel	Ağ	Tekli	Zamansal+ Mekansal+ Trafik Dışı	Kısa	Orta	Temel	Vektör	Tekli Hedef	Çoklu	Veri Hazırlama+ Kusurlu Veri	k-NN
22	F. Su, H. Dong, L. Jia, Y. Qin, and Z. Tian	2016	Nokta	Otoban	Bölüm	Tekli	Zamansal+ Trafik Dışı	Uzun	Orta	Temel	Vektör	Tekli Hedef	Çoklu	Veri Hazırlama	Fonksiyonel parametrik olmayan regresyon, otokorelasyon analizi
23	J. Zhao and S. Sun	2016	Nokta	Kentsel	Nokta	Çoklu	Zamansal	Kısa	Orta	Temel	Vektör	Tekli Hedef	Tekli	-	Gauss süreci dinamik modeli
24	Bezuglov, A., & Comert, G.	2016	Nokta	Otoban	Nokta	Çoklu	Zamansal+Me kansal	Kısa	Yüksek	Temel+ Seyehat Süresi	Vektör	Çoklu Hedef	Tekli	Veri Hazırlama+ Kusurlu Veri	Gri Sistem teorisi tabanlı modeller
25	Y. Chun-Xia, F. Rui, and F. Yi-Qin	2016	Nokta	Otoban	Nokta	Tekli	Zamansal+ Trafik Dışı	Uzun	Orta	Temel	Vektör	Tekli Hedef	Çoklu	Veri Hazırlama	Dalgacık sinir ağı
26	Zhang, Y., & Zhang, Y.	2016	Nokta	Otoban	Bölüm	Tekli	Zamansal	Kısa	Orta	Temel	Vektör	Tekli Hedef	Tekli	Kusurlu Veri	Çok Değişkenli Tahmin, Yapay Sinir Ağı,
27	Y. Cong, J. Wang, and X. Li	2016	Hareketli	Kentsel	Nokta	Tekli	Zamansal	Kısa	Orta	Temel	Vektör	Tekli Hedef	Tekli	Veri Hazırlama	En küçük kareler destek vektör makinesi (LSSVM)
28	J. Wang, I. Tsapakis, and C. Zhong	2016	Aralık	Kentsel	Ağ	Tekli	Zamansal+Me kansal	Kısa	Orta	Seyehat Süresi	Vektör	Tekli Hedef	Çoklu	Kusurlu Veri	Uzay-zaman otoregressif entegre hareketli ortalama (STARIMA), Naïve, ARIMA

29	H.-J. Yang and X. Hu	2016	Nokta	Kentsel	Nokta	Tekli	Zamansal	Uzun	Orta	Temel	Vektör	Tekli Hedef	Çoklu	Veri Hazırlama	Dalgacık sinir ağı Parametre optimizasyonu Geliştirilmiş genetik algoritma
30	A. Wibisono, W. Jatmiko, H. A. Wisesa, B. Hardjono, and P. Mursanto	2016	Nokta+ Aralık+ Hareketli	Otoban	Ağ	Tekli	Zamansal+ Trafik Dışı	Kısa	Orta	Temel	Vektör	Tekli Hedef	Tekli	Veri Hazırlama	Hızlı Artımlı Model Ağaçlar- Kayma Tespiti (FIMT-DD)
32	Z. Ma, G. Luo, and D. Huang	2016	Nokta	Kentsel	Nokta	Çoklu	Zamansal	Kısa	Orta	Temel	Yüksek Dereceli Tensör	Tekli Hedef	Tekli	-	Aşırı Öğrenme Makinesi (ELM)
33	Ma, X., Tao, Z., Wang, Y., Yu, H., & Wang, Y.	2015	Nokta	Kentsel	Bölüm	Tekli	Zamansal	Kısa	Yüksek	Temel	Vektör	Tekli Hedef	Tekli	Veri Hazırlama+ Kusurlu Veri	Uzun Kısa Süreli Sinir Ağı (LSTM NN)
34	H. Yang, T. S. Dillon, and Y.-P. P. Chen	2015	Nokta+ Aralık+ Hareketli	Otoban	Bölüm	Tekli	Zamansal	Kısa	Orta	Temel+ Seyehat Süresi	Vektör	Çoklu Hedef	Çoklu	Kusurlu Veri+Veri Azaltma	Sinir Ağı (NN),Genelleştirilmiş Katkı Modeli (GAM),Otomatik Regresif Entegre Hareketli Ortalama (ARIMA)
35	Pan, H., Liu, J., Zhou, S., & Niu, Z.	2015	Nokta	Kentsel	Nokta	Çoklu	Zamansal	Uzun	Küçük	Temel	Vektör	Tekli Hedef	Çoklu	Veri Hazırlama+ Kusurlu Veri	Blok Regresyonu (BR)
36	Li, L., Su, X., Wang, Y., Lin, Y., Li, Z., & Li, Y.	2015	Nokta	Kentsel	Nokta	Çoklu	Zamansal	Kısa	Orta	Temel	Vektör	Tekli Hedef	Tekli	Kusurlu Veri	Nedensel bağımlılık (Granger nedensellik)

															testi),Lasso regresyonu
37	Moretti, F., Pizzuti, S., Panzieri, S., & Annunziato, M.	2015	Nokta	Kentsel	Nokta	Çoklu	Zamansal	Kısa	Küçük	Temel	Vektör	Tekli Hedef	Tekli	-	Istatistiksel ve sinir ağı hibrid modelleme
38	X. Niu, Y. Zhu, Q. Cao, X. Zhang, W. Xie, and K. Zheng,	2015	Aralık	Kentsel	Ağ	Tekli	Zamansal+Me kansal+Trafik Dışı	Kısa	Yüksek	Temel	Vektör	Tekli Hedef	Tekli	Veri Hazırlama+ Veri Azaltma	Derin Öğrenme, SVM
39	Meng, M., Shao, C., Wong, Y., Wang, B., & Li, H.	2015	Nokta	Otoban	Nokta	Tekli	Zamansal	Kısa	Yüksek	Temel	Vektör	Tekli Hedef	Çoklu	Kusurlu Veri	k-NN, otomatik gerici ve hareketli ortalama (ARMA)
40	J. Abdi and B. Moshiri	2015	Nokta	Otoban	Bölüm	Tekli	Zamansal	Uzun	Yüksek	Temel	Vektör	Tekli Hedef	Çoklu	-	Yapay sinir ağları, yayılım algoritması, tahmin, zamansal fark öğrenme
42	M.-L. Huang	2015	Nokta	Otoban	Nokta	Tekli	Zamansal+ Trafik Dışı	Kısa	Orta	Temel	Vektör	Tekli Hedef	Tekli	Veri Hazırlama	Destek vektör makinesi, Gauss kaybı fonksiyonu, Genetik Algoritma
43	Dong, C., Xiong, Z., Shao, C., & Zhang, H.	2015	Nokta	Otoban	Ağ	Tekli	Zamansal+Me kansal	Kısa	Yüksek	Temel	Vektör	Tekli Hedef	Tekli	Veri Hazırlama	Otoregressive entegre hareketli ortalama (ARIMA)

44	Liu, S., Li, D., Xi, Y., & Tang, Q.	2015	Nokta	Otoban	Nokta	Tekli	Zamansal+ Trafik Dışı	Kısa	Yüksek	Temel	Vektör	Tekli Hedef	Çoklu	Veri Hazırlama+ Veri Azaltma	Sinir ağı (NN), hibrit parçacık sürüsü optimizasyonu- sinir ağı (HPSO-NN) algoritması
46	Y. Wu, H. Tan, J. Peter, and B. Shen	2015	Nokta	Otoban	Nokta	Çoklu	Zamansal	Uzun	Orta	Temel	Vektör	Tekli Hedef	Çoklu	Veri Azaltma	Çoklu Doğrusal Analiz ve En Yakın Komşu Regresyonu
47	J. Rupnik, J. Davies, B. Fortuna, A. Duke, and S. S. Clarke	2015	Nokta	Otoban	Ağ	Tekli	Zamansal+Mekansal	Kısa	Yüksek	Seyehat Süresi	Vektör	Tekli Hedef	Çoklu	Veri Hazırlama	Makine öğrenmesi, değişken katsayılı model
48	Y. Hou, P. Edara, and C. Sun	2015	Nokta	Otoban	Bölüm	Tekli	Zamansal+ Trafik Dışı	Uzun	Yüksek	Temel	Vektör	Tekli Hedef	Çoklu	Veri Hazırlama	Sinir ağı, parametrik olmayan regresyon, rastgele orman, regresyon ağacı
49	H.-P. Lu, Z.-Y. Sun, W.-C. Qu, and L. Wang	2015	Nokta	Otoban	Nokta	Tekli	Zamansal+ Mekansal	Kısa	Orta	Temel	Vektör	Tekli Hedef	Tekli	Veri Hazırlama	Bulanık Sinir Ağı
50	P. Dell'Acqua, F. Bellotti, R. Berta, and A. De Gloria	2015	Nokta	Otoban	Bölüm	Tekli	Zamansal+ Mekansal+ Trafik Dışı	Kısa	Orta	Temel	Vektör	Tekli Hedef	Çoklu	Veri Hazırlama	En yakın komşu regresyonu, çok değişkenli analiz, bağlam farkındalığı, örüntü tanıma

															algoritması, Bayes ağları
51	W. Ma and R. Wang	2015	Nokta	Otoban	Nokta	Tekli	Zamansal	Kısa	Orta	Temel	Vektör	Tekli Hedef	Tekli	Veri Hazırlama	Sinir ağı Bayesian normalize teorisi
52	G. Fusco, C. Colombaroni, L. Comelli, and N. Isaenko	2015	Hareketli	Kentsel	Ağ	Tekli	Zamansal	Kısa	Orta	Temel	Vektör	Tekli Hedef	Çoklu	Veri Azaltma	Bayesian Ağları, Yapay Sinir Ağları
53	D. Xia, B. Wang, H. Li, Y. Li, and Z. Zhang	2015	Hareketli	Otoban	Bölüm	Tekli	Zamansal+ Mekansal	Kısa	Yüksek	Temel	Vektör	Tekli Hedef	Tekli	-	Sinir Ağları
54	Y. Zhang and A. Haghani	2015	Hareketli	Otoban	Bölüm	Tekli	Zamansal+ Mekansal+ Trafik Dışı	Kısa	Orta	Seyehat Süresi	Vektör	Tekli Hedef	Çoklu	Kusurlu Veri	Makine öğrenme, Gradyan artırıcı regresyon ağaçları
55	Y. Xu, H. Chen, Q.-J. Kong, X. Zhai, and Y. Liu	2015	Nokta	Kentsel	Ağ	Tekli	Zamansal+ Mekansal	Kısa	Orta	Temel	Vektör	Tekli Hedef	Çoklu	Kusurlu Veri+Veri Azaltma	Mekansal- zamansal değişken seçimine dayalı destek vektör regresyon (VS-SVR)

3.2 Trafik Analizinde Makine Öğrenmesi Yöntemleri

Artan nüfus ve beraberinde ortaya çıkan araç sayısı ile verimli bir şekilde başa çıkılamadığından trafik sıkışıklığı sorunu giderek artmıştır. Dünyadaki akıllı ve büyük şehirlerde giderek büyük bir sorun haline gelen doğrudan ya da dolaylı trafik problemlerinin üstesinden gelmek, tahmin etmek ve onunla başa çıkmak son dönemlerde büyük bir ilgi gördü. Trafik sıkışıklığı, yakıt tüketimi, kaza sayısı, bekleme süresi, hava kirliliğinin azaltılması ayrıca yol kullanıcıların yol durumu hakkında önceden bilgilendirilerek daha iyi kararlar almalarına yardımcı olacak çalışmaların yapılması yapılan çalışmalar arasında yer almıştır. Çalışmanın bu kısmında literatürde benimsenen akıllı ulaşım sistemlerinde kullanılan makine öğrenmesi yöntemlerinin, kapsamlı bir şekilde araştırılması ve gözden geçirilmesi hedeflenmektedir. Gelişen teknoloji sayesinde büyük trafik verilerinin toplanmasında yaşanan kolaylıklar, beraberinde işlenmesi, analiz edilmesi ve yönetilmesi gibi zorlukları ortaya çıkarmaktadır.

Trafik parametreleri yaklaşımları dört ana kategoride sınıflandırılmıştır. Birinci öngörülen yaklaşım gerçek zamanlı trafik akışını tahmin eden ve öngören yaklaşımlardır. İkincisi, kısa vadeli gerçek zamanlı trafik akışını tahmin eden ve öngören yaklaşımlardır. Üçüncüsü, seyahat zamanını gerçek zamanlı olarak tahmin eden ve öngören yaklaşımlardır. Dördüncüsü, gerçek zamanlı trafik yoğunluğunu tahmin eden ve öngören yaklaşımlardır. Trafik yönetim alanında ise araç kazasının meydana gelmesini öngören yaklaşımlar yer almaktadır (Alsrehin et al., 2019).

Literatürde trafik tahmin teknikleri parametrik ve parametrik olmayan teknikler olmak üzere iki gruba ayrılmıştır (Smith, 2002). Parametrik teknikler hızlı ve kullanım kolaylığı sebebiyle geçmiş dönemlerde yoğun olarak tercih edilmiştir. En popüler parametrik yöntemler zaman serisi analizidir (Ma ve ark., 2017). Box ve Jenkins tekniği, zaman serisi analizlerinde yaygın olarak kullanılan bir yaklaşımdır ve bu kategori altındaki popüler yöntemlerden bazıları; Hareketli Ortalama (MA), Otoregressif (AR), Otoregressif Hareketli Ortalama (ARMA), Otoregressive Entegre Hareketli Ortalama (ARIMA) ve mevsimsel ARIMA şeklindedir. Bu modellerin tercih edilmesinde en önemli etkenlerden gücü ve işlemsel hızlarıdır. Ancak gerçek zamanlı varyasyonları yakalamada yetersiz kalmışlardır (Moreira-Matias, 2015). Trafik

akışının doğrusal olmayan ve stokastik yapısından dolayı parametrik olmayan tekniklerin kullanımına son dönemlerde daha büyük önem verilmiştir.

Gerçek zamanlı trafik akışını öngörecektir bir tahmin mekanizmasını geliştirmek, doğruluğunu, ölçeklenebilirliğini ve uygulanabilirliğini arttırmak için literatürde birçok çalışma gerçekleştirilmiştir.

Zulong ve ark. (2019), trafik akış hacmini tahmin etmek için DTMGP hibrid bir modelini geliştirmişlerdir. Trafik hacim serisine dalgacık dönüşümü uygulandıktan sonra, bileşenleri tahmin etmek için istatistiksel öğrenme teorisine dayanan Guassian Süreç (GP) modeli uygulamıştır.

Ke ve ark. (2019), denetimli öğrenme (AdaBoost learning algorithm) ve dönüşümlü sinir ağı (Convolutional Neural Network) yöntemlerini kullanarak İHA video verilerinden trafik akış parametrelerini sınıflandıran ve tahmin eden bir model uygulamıştır.

Huang ve ark. (2018), trafik akış serilerindeki mevsimsel heterojenliği tespit etmek için mevsimsel ayarlama faktörü adaptif Kalman filtresini (adaptive Kalman filter) kullanarak bir model önermiştir.

Yu ve ark. (2018), otobüs seyahat süresi tahmini için rastgele en yakın komşu ağaçlandırma yöntemi (RFNN) ile doğrusal regresyon (LR), en yakın komşular (KNN), destek vektör makinesi (SVM) ve klasik rastgele ağaçlandırma (RF) yöntemleri karşılaştırılmıştır.

Fancello ve ark. (2018), karayolu güvenliğini arttırmak için kaza verilerine kümele analizi uyguladıktan sonra Poisson ve Negatif Binom modellerini geliştirmişlerdir.

Ma ve Yuan (2018), trafik kazalarının etki derecesi, trafik kaza sayısının azaltılması ve yolun güvenliliğinin artırılması için Poisson regresyonu, negatif binom (NB) regresyonu ve Sıfır Şişirilmiş Negatif Binom (NINB) regresyonuna dayalı bir model geliştirilmiştir. Trafik kaza sayısı ile yol uzunluğu, trafik koşulları gibi faktörler arasındaki ilişki incelenmiştir.

Acı ve Özden (2018), trafik kazalarına hava durumunun etkisini belirlemek için k-Nearest Neighbor, Naive Bayes, Multilayer Perceptron, Decision Tree, Support Vector Machine ve Logistic Regression yöntemleri karşılaştırılmıştır.

Gu ve ark. (2018), trafik kazası ölümlerinin tahmin modelinde mutasyon optimizasyonu geri yayılım sinir ağı tahmin modeli, parçacık sürüsü optimizasyonu destek vektör makine modeli, destek vektör makinesi, geri yayılma sinir ağı, K En Yakın Komşu (K-NN) ve Bayesian ağ yöntemleri kullanılmıştır. Mutasyon optimizasyonu-destek vektör makinesi ile parçacık sürüsü yöntemine dayalı tahmin modelleri en iyi performans sonuçlarına sahiptir.

Contreras ve ark. (2018), trafik kazalarının öngörülmesinde Maksimum Hassasiyet Sinir Ağı yöntemi kullanılmıştır. Lamouik ve ark. (2018), derin öğrenme (DL) yöntemi ile gerçek zamanlı trafik koşullarına dayanan dinamik bir yönlendirme modeli oluşturulmuştur.

Mena-Yedra ve ark. (2017), gerçek zamanlı trafik durumu tahmini için farklı makine öğrenmesi ve veri analiz bileşenlerinden oluşan Adarules adında bir çerçeve geliştirmişlerdir.

Polson ve Sokolov (2017), trafik akışını tahmin etmek için derin öğrenme (Deep learning) modelini kullanmışlardır.

Kumar ve ark. (2017) yılında, otobüs seyahat zamanı tahmininde k-NN sınıflandırma algoritmasını (k-NN classifying algorithm) kullanmışlardır.

Kumar ve ark. (2017), otobüs seyahat süresi tahmini için Kalman fitresine dayanan bir model geliştirmiştir.

Alkheder ve ark. (2017), trafik kazalarında yaralanma ciddiyetini tahmin etmek için yapay bir sinir ağı (ANN) yöntemini kullanmıştır.

You ve ark. (2017), trafik kazalarında risk durumunu modellemek için eşleştirilmiş vaka kontrol yöntemi ve destek vektör makineleri (SVM'ler) kullanılmıştır. Hava durumu verilerinin kaza tahmin modelindeki potansiyel etkisi ortaya çıkarılmıştır.

Sun ve Park (2017), rota seçim modelini oluşturmak için Destek Vektör Makinesini (SVM) ve sinir ağı (NN) yöntemlerini kullanarak model oluşturuldu.

Sun ve ark. (2017), k-en yakın komşular algoritması (k-NN) yöntemi ile bir rota seçim modellemesi geliştirmişlerdir.

Taamneh ve ark. (2016), trafik kazalarında yaranmaların ciddiyetini modellemek için Decision Tree (J48), Rule Induction (PART), Naive Bayes ve Multilayer Perceptron yöntemlerini kullanmışlardır.

Raj ve ark. (2016), trafik yoğunluğu ve seyahat süresi tahmini için En Yakın Komşu (k-NN) ve Yapay Sinir Ağı (ANN) yöntemlerini kullanmışlardır.

Fan ve Gummu (2015), gerçek zamanlı seyahat süresinin doğru tahmini için dinamik bir model geliştirmiştir. Historical Average (HA), Kalman Filtering (KF) and Artificial Neural Network (ANN) modelleri karşılaştırılmıştır.

Sharma ve ark. (2016), trafik kazası tahmin modeli için Gaussian çekirdeğine sahip destek vektör makineleri (SVM) kullanılarak kentsel trafik kaza analizi gerçekleştirmiştir.

Tao ve ark. (2015), sürüş sırasındaki kazaların noktalarının belirlenmesi için Logistic regression yöntemi ile kaza yeri tahmin modeli oluşturuldu.

Elhanawy ve ark. (2014), veri kümeleme (k-means) ve genetik algoritmayı kullanarak seyahat süresi tahmini için bir model geliştirmişlerdir.

Jadaan ve ark. (2014), trafik kazalarının öngörülmesinde Yapay Sinir Ağı (ANN) yöntemini kullanmıştır.

Dong ve ark. (2013), gerçek zamanlı verileri ile geçmiş verilerden yararlanarak k-NN ve ANN yöntemleri ile seyahat süresi tahmini gerçekleştirmişlerdir.

Kumar ve ark. (2013), trafik akış tahmini için yapay sinir ağları (ANN) yöntemini uygulamıştır.

Min ve Wynter (2011), gerçek zamanlı trafik tahmini için uzamsal ve zamansal korelasyon (spatio-temporal correlations) yöntemini kullanmışlardır.

Yu ve ark. (2011), otobüs seyahat süresi tahmini için destek vektör makinesi (SVM), yapay sinir ağı (ANN), k-en yakın komşular algoritması (k-NN) ve doğrusal regresyon (LR) içeren çeşitli yöntemler kullanmışlardır. En iyi performans destek vektör makinesi (SVM) ile elde edilmiştir.

Geetha ve Shanthi (2012), karayolunda gerçekleşen trafik kazalarının sınıflandırılmasında Karar Ağacı algoritmaları olan Random Tree, C4.5, J48 ve Decision Stump yöntemleri, 2010 yılında Büyük Britanya'da meydana gelen ölümcül kaza veri tabanına uygulanmıştır. 159417 kayıt kaza ve 9 özellik kullanılarak trafik kazalarının sınıflandırılması gerçekleştirilmiştir.

Mohamed (2014), trafik kazalarının sebeplerinin araştırılmasında çok sınıflı destek vektör makinalarını kullanarak tahmin yapmıştır. 7048 kaza ve 7 özellik kullanılarak Birleşik Arap Emirlikleri'ne ait trafik kazalarının nedenleri araştırılmıştır.

Tayep ve ark. (2015), Apriori ve Predictive Apriori birlik kuralları algoritmaları kullanılarak, Dubai'deki meydana gelen kazaların ciddiyeti ile kazaların meydana gelme faktörleri arasındaki ilişkiyi ortaya çıkarmak için uygulanmıştır.

Martin ve ark. (2014), İspanya'da meydana gelen trafik kaza sayılarının, yol koşulları ile arasındaki ilişkileri belirlemek için veri madenciliği tekniklerinden Karar Ağaçlarını kullanmıştır.

Fu ve Zhou (2011), yapay sinir ağları kullanılarak trafik kaza tahmini gerçekleştirildi. Trafik kazalarında insan, araba, yol, iklim gibi birçok doğrusal olmayan unsurların varlığından dolayı geliştirilmiş yapay sinir ağı modeli oluşturulmuştur.

Vavasi (2016), makine öğrenmesi tekniklerinden kümeleme ve apriori birleştirme algoritması, kullanılarak kazalar arasındaki ortak özellikleri bularak, kazalardaki gizli kalıpların ortaya çıkarılması amaçlanmıştır.

Razzaq ve ark.(2016), trafik kazalarının değerlendirilmesinde birçok faktöre dayalı bir model oluşturulmuştur. Bu kaza nedenleri çevresel, fiziksel ve zihinsel olarak üç gruba ayrılmıştır. Geliştirilen bulanık tabanlı Çok Faktörlü Tabanlı Yol Kazası Önleme Sistemi (MFBRAPS) ile trafik kazalarının önlemek amaçlanmıştır.

Zhang ve ark.(2018), sosyal medya verilerinden yararlanılarak trafik kazalarının tespit edilmesinde derin öğrenme yönteminden yararlanılmıştır.1 milyon 300 bin tweet içeriği ayrıntılı bir şekilde incelenmiştir.

Zhu ve ark.(2018), trafik olaylarının otomatik olarak tespit edilmesi için derinlemesine bir öğrenme yöntemi olan Konvolüsyonel Sinir Ağları (CNN) önerilmiştir. Kentsel ağlarda trafik akışının hızlı bir şekilde gerçekleştirilmesi için derin öğrenmeye dayalı olay tespitinin önemi belirtilmiştir.

Ren ve ark.(2018),trafik kaza riski tahmini için yüksek hassasiyetli bir derin öğrenme modeli önerilmiştir. Önerilen bu trafik kaza riski modelinin, daha akıllı bir trafik tahmini ve yönetimi için akıllı trafik kontrol sistemlerine entegre edilebileceği öngörülmüştür.

Soua ve ark.(2016), çeşitli kaynaklardan elde edilen büyük veri tabanlı kısa vadeli trafik akış tahmini için Derin İnanç Ağları (DBN'ler) yöntemi uygulanmıştır. Geçmiş trafik akışı, hava durumu verileri kullanılarak trafik akışı tahmin modeli oluşturulmuştur.

Li ve ark.(2017), Los Angeles'ta gerçek dünya büyük ölçekli trafik veri kümesine, uzun kısa süreli bellek (LSTM) birimlerine dayalı derin bir sinir ağı modeli geliştirilmiştir. Trafiğin en yoğun olduğu saatlerde trafik tahmini ve kaza modeli birlikte gerçekleştirilmiştir.

Lv ve ark.(2018), trafik hız tahmini için LC-RNN adlı yeni bir model önerdiler. Tekrarlayan sinir ağları (RNN) ve evrişimli sinir ağı (CNN) yöntemleri ile yolun periyodik ve bağlam faktörlerini de göz önünde bulundurarak daha doğru tahminler elde edilebileceği belirtilmiştir. Elde edilen sonuçlar SVR, H-ARIMA, LSTM, GC, DCNN, ST-ResNet yöntemleri ile karşılaştırılmıştır.

Chen ve ark.(2018), kısa vadeli trafik sıklığını tahmin etmek için periyodik trafik verilerini modelleyen PNCC adında bir model önermişlerdir. PNCC zaman serisi katlanması ve çoklu öğrenme prosedürü bulunmaktadır. Bu model ile hem gerçek zamanlı trafik koşullarını hem de geçmiş trafik düzenleri ele alınarak kısa vadeli tıkanıklık tahmininde iyi sonuçlar elde edildiği belirtilmiştir.

Lv ve ark.(2014), zamansal ve mekansal korelasyonlar dikkate alınarak yeni bir derin öğrenme temelli trafik akış tahmini modeli geliştirilmiştir. Derin öğrenme modelinde otomatik ağ kodlayıcı yapı taşlarından oluşmaktadır.

Wang ve ark.(2016), sürekli hız tahmini için Hata Geri Bildirimi Tekrarlayan Konvolüsyonlu Sinir Ağı (eRCNN) bir derin öğrenme modeli geliştirilmiştir. Uzamsal ve zamansal hız verileri entegre edilerek modelin doğruluk performansı artırılmıştır.

Liu ve ark.(2018), trafik tahmininde mobilite verileri kullanılarak trafik hızı, trafik akışı ve kaza riski gibi trafik göstergelerinin öngörülmesinde derin öğrenmenin doğruluğu ve verimliliği büyük ölçüde arttırmak için modeller önerilmiştir.

He ve ark.(2019), uzun vadeli trafik tahmini probleminin dinamik yapısından dolayı hem trafik bağımlılıklarını hem de trafik modellerini bütünleştirmek için zamansal-mekansal dönüşümlü sinir ağı (STCNN) modeli önerilmiştir. Tarihsel trafik verilerinden mekansal ve zamansal korelasyonları öğrenmeyi amaçlar.

Guo ve ark.(2019), trafik akış tahmininde dikkat temelli uzamsal ve mekansal korelasyon kabiliyetini arttırmak için mekansal-zamansal grafik evrişimli ağ (ASTGCN) modeli önerilmiştir.

Diao ve ark.(2019), trafik verilerinin uzamsal bağımlılık yapısından dolayı doğru trafik tahminlerinin elde edilmesi için dinamik bir uzamsal-zamansal Grafik Evrişimli Sinir Ağları (GCNN) modelini önerilmiştir.

Yapılan geniş kapsamlı literatür araştırmasında Akıllı Ulaşım Sistemlerinde makine öğrenmesi yöntemleri son yıllarda giderek artan yoğun bir ilgi görmüştür. Trafik parametreleri olarak trafik akış hızı tahmini, trafik kazası, seyahat süresi tahminleri ele alınmıştır. Son yıllarda yapılan araştırmalarda trafik verilerinin giderek büyük veri özelliklerinden dolayı yapay sinir ağları ve derin öğrenme yöntemleri daha çok kullanılmıştır. Yapay sinir ağları ve derin öğrenme yöntemleri hibrid modeller oluşturularak tahmin doğruluk performanslarının artırılması hedeflenmiştir. Tablo 2.3.'te yapılan literatür çalışmasının özet elde edilmiştir.

Tablo 3.2. Akıllı Ulaşım da Makine Öğrenmesi Uygulamalarına Genel Bakış

Yazar		Yıl	Gerçekleştirilen Çalışmalar	Trafik Parametre	Makine Öğrenmesi Yöntemi
1	He ve ark.	2019	STCNN: Uzun Süreli Trafik Tahmininde zamansal-mekansal dönüşümlü sinir ağı modeli	Trafik Akışı	Derin Öğrenme(DL)
2	Guo ve ark.	2019	Trafik Akışı Tahmini için Dikkat Temelli Mekansal-Geçici Grafik Konvolüsyon Ağları	Trafik Akışı	Derin Öğrenme(DL)
3	Diao ve ark.	2019	Trafik Tahmini için Dinamik Uzamsal-Geçici Grafik Konvolüsyonlu Sinir Ağları	Trafik Akışı	Derin Öğrenme(DL)
4	Diao, Z., Zhang, D., Wang, X, Xie, K., He, S., Lu, X, ve Li, Y.	2018	Toplu Taşıma Sistemlerinde Kısa Vadeli Trafik Hacmi Tahmini İçin Hibrit Bir Model.	Trafik Akışı	Ayrık dalgacık dönüşümü (DWT) ve Guassion Process
5	Weihong Ma ve Zhenzhou Yuan	2018	Trafik Kazası Regresyon Tahmin Modelinin Analizi ve Karşılaştırılması	Trafik Kazası	Random Forest (RF) Regression, Poisson regression, negative binomial (NB) regression and Zero Inflated Negative Binomial (NINB)
6	Contreras, E., Torres-Treviño, L., & Torres, F.	2018	Maksimum Hassasiyet Sinir Ağı Kullanarak Araba Kazalarının Tahmin Edilmesi	Trafik Kazası	Yapay Sinir Ağları (ANN)
7	Dogru, N., & Subasi, A.	2018	Rastgele ağaç sınıflandırıcı kullanarak trafik kazası tespiti	Trafik Kazası	Artificial Neural Networks (ANN); Random Forests; Support Vector Machines (SVM)
8	Zhang ve ark.	2018	Trafik kazalarını sosyal medya verilerinden tespit etmek için derin bir öğrenme yaklaşımı	Trafik Kazası	Derin Öğrenme(DL)
9	Zhu ve ark.	2018	Kentsel Ağlarda Trafik Olaylarının Tespiti İçin Derin Öğrenme Yaklaşımı	Trafik Kazası	Derin Öğrenme(DL)
10	Ren ve ark.	2018	Şehir Çapında Trafik Kazası Risk Tahminine Derin Öğrenme Yaklaşımı	Trafik Kazası	Derin Öğrenme(DL)
11	Lv ve ark.	2018	LC-RNN: Trafik Hızı Tahmini için Derin Öğrenme Modeli	Trafik Akışı	Derin Öğrenme(DL)
12	Chen ve ark.	2018	PCNN: Kısa Süreli Trafik Sıkışıklığı Tahmini için Derin Döngüsel Ağlar	Trafik Akışı	Derin Öğrenme(DL)
13	Liu ve ark.	2018	Derin Öğrenme Kullanarak Mobilite Verilerinden Kentsel Trafik Tahmini	Trafik Akışı+ Trafik Kazası	Derin Öğrenme(DL)

14	Polson, NG ve Sokolov, VO	2017	Kısa vadeli trafik akışı tahmini için derin öğrenme	Trafik Akışı	Derin Öğrenme(DL)
15	Fan, S.-KS, Su, C.-J., Nien, H.-T., Tsai, P.-F., ve Cheng, C.	2017	Tayvan elektronik ücret toplama işleminden elde edilen geçmiş ve gerçek zamanlı verilere dayanarak seyahat süresini tahmin etmek için makine öğrenimi ve büyük veri yaklaşımlarını kullanmak.	Seyahat Süresi	Random forests ve Apache Hadoop
16	Yu, B., Wang, H., Shan, W., & Yao, B.	2017	Yakın Komşulara Dayalı Rastgele Ormanlar Kullanarak Otobüs Yolculuk Süresinin Tahmini.	Seyahat Süresi	Random Forests Near Neighbors(RFNN),linear regression (LR), k-nearest neighbors (KNN), support vector machine (SVM), ve classic random forest (RF).
17	Kumar, BA, Jairam, R., Arkatkar, SS, & Vanajakshi, L.	2017	K-NN sınıflandırıcısını kullanarak gerçek zamanlı veri yolu seyahat süresi tahmini.	Seyahat Süresi	k-nearest neighbors (KNN)
18	Kumar, BA, Vanajakshi, L., & Subramanian, SC	2017	Bir zaman-alanı ayırma yaklaşımı kullanarak otobüs yolculuğu zamanı tahmini	Seyahat Süresi	Kalman filter
19	Gianfranco, F., Soddu, S., & Fadda, P.	2017	Kentsel karayolu ağları için bir kaza tahmin modeli	Trafik Kazası	Cluster Analysis ve Poisson (negative binomial) model
20	Gu, X, Li, T., Wang, Y., Zhang, L., Wang, Y. ve Yao, J.	2017	Hibrit parçacık sürüşü optimizasyonuna sahip destek vektör makinesini kullanarak trafik ölümleri tahmini	Trafik Kazası	Particle Swarm Optimization, Neural Network, K Nearest Neighbor (K-NN), and Bayesian network
21	Sen, J., Wang, J. ve Guo, J.	2017	Veri madenciliği ve ortaya çıkan teknikleri kullanarak otoyollarda gerçek zamanlı çarpışma tahmini	Trafik Kazası	Support vector machines (SVMs)
22	Sun, B., & Park, B. B.	2017	Destek Vektör Makinesi ile rota seçimi modellemesi	Rota Seçimi	Support Vector Machines (SVM)
23	Amato, G., Carrara, F., Falchi, F., Gennaro, C.,	2017	Merkezi olmayan otopark doluluk tespiti için derin öğrenme	Trafik Akışı	Deep Learning

	Meghini, C. ve Vairo, C.				
24	Yang, J., Han, Y., Wang, Y., Jiang, B., Lv, Z., & Song, H.	2017	Akıllı şehirde DBN ve kümeleme modelini kullanarak IoT verilerine dayanan gerçek zamanlı trafik ağı atamasının optimizasyonu	Trafik Akışı	deep belief network(DBN) ve K-means
25	Li ve ark.	2017	Derin Öğrenme: Aşırı Durum Trafik Tahmini için Genel Bir Yaklaşım	Trafik Akışı	Derin Öğrenme(DL)
26	Raj, J., Bahuleyan, H., & Vanajakshi, LD	2016	Trafik Yoğunluğu Tahmini İçin Veri Madenciliği Tekniklerinin Uygulanması	Trafik Yoğunluğu	k-Nearest Neighbour (k-NN) and Artificial Neural Network (ANN)
27	Siripanpornchana, C., Panichpapiboon, S., & Chaovalit, P.	2016	Derin öğrenme ile seyahat zamanı tahmini	Seyahat Süresi	Derin Öğrenme(DL)
28	Taamneh, M., Alkheder, S., ve Taamneh, S.	2016	Birleşik Arap Emirlikleri'nde trafik kazası modellemesi ve tahmini için veri madenciliği teknikleri	Trafik Kazası	Decision Tree (J48), Rule Induction (PART), Naive Bayes, ve Multilayer Perceptron
29	Bharti Sharma, Katiyar, VK ve Kranti Kumar.	2016	Gaussian Çekirdeği ile Destek Vektör Makineleri Kullanan Trafik Kazası Tahmin Modeli	Trafik Kazası	Multilayer perceptron (MLP) ve support vector machines (SVM)
30	Agarwal, S., Kachroo, P., & Regentova, E.	2016	Trafik olaylarını tespit etmek için lojistik regresyon ve dalgacık dönüşümünü kullanan bir hibrid model	Trafik Kazası	Lojistik regresyon ve Discrete wavelet transform(DWT)
31	A. Ladino, A.Y. Kibangu, C. Canudas de Wit, H. Fourati	2016	Kümelenmiş zaman serilerinden dinamik seyahat süresi için gerçek zamanlı bir tahmin aracı	Seyahat Süresi	Kalman filter ve Clustering
32	Özbayoğlu, M., Kucukayan, G. ve Doğdu, E.	2016	Büyük veri işleme ve bilgi işlem zekasına dayanan gerçek zamanlı bir özerk karayolu kaza tespit modeli	Trafik Kazası	Neural Networks, Nearest Neighbor, Regression Tree
33	Vavasi	2016	Makine öğrenme tekniklerini kullanarak, trafik kazası verilerinde gizli kalıpları çıkarma	Trafik Kazası	Kümeleme ve apriori birleştirme algoritması
34	Razzaq ve ark.	2016	Çok faktörlü trafik kazası önleme sistemi	Trafik Kazası	Bulanık Mantık

35	Soua ve ark.	2016	Derin öğrenme ve demster-shafer teorisini kullanarak büyük veri kaynaklı trafik akışı tahmini ijcn.2016.7727607	Trafik Akışı	Derin Öğrenme(DL)
36	Wang ve ark.	2016	Trafik Hızı Tahmini ve Tıkanıklığı Kaynak Arama: Derin Öğrenme Yöntemi	Trafik Akışı	Derin Öğrenme(DL)
37	Fan, W. ve Gurm, Z.	2015	Yalnızca GPS Verilerini Kullanan Otobüsler İçin Dinamik Seyahat Süresi Tahmin Modelleri	Seyahat Süresi	Historical Average (HA), Kalman Filtering (KF) and Artificial Neural Network (ANN)
38	Moretti, F., Pizzuti, S., Panziera, S., ve Annunziato, M.	2015	Kentsel trafik akışı, istatistiksel ve sinir ağı ile karma hibrit modelleme ile tahmin.	Trafik Akışı	Yapay Sinir Ağları (ANN)
39	Fusco, G., Colombaroni, C., Comelli, L., ve Isaenko, N.	2015	Büyük kentsel trafik ağlarında kısa vadeli trafik tahminleri: Ağ tabanlı makine öğrenme modellerinin uygulamaları ve dinamik trafik tahsis modelleri.	Trafik Akışı	Bayesian Networks and Artificial Neural Networks
40	Hou, Y., Edara, P., & Sun, C.	2015	Kentsel Çalışma Bölgeleri İçin Trafik Akışı Tahmini.	Trafik Akışı	Neural Network, Nonparametric Regression, Random Forest, Regression Tree
41	Tayep ve ark.	2015	Dubai'deki trafik kazaları için birleşme kural madenciliği algoritmalarının uygulanması	Trafik Kazası	Apriori ve Predictive Apriori birlik kuralları algoritmaları
42	Khair S. Jadaan, Muaath Al-Fayyad, and Hala F. Gammoh	2014	Yapay Sinir Ağı (ANN) kullanarak Ürdün'de Yol Trafik Kazası Tahmini	Trafik Kazası	Yapay Sinir Ağları (ANN)
43	Lv, Y., Duan, Y., Kang, W., Li, Z., ve Wang, F.-Y.	2014	Büyük Veri ile Trafik Akışı Tahmini: Derin Öğrenme Yaklaşımı	Trafik Akışı	Derin Öğrenme(DL)
44	Zheng, Z., ve Su, D.	2014	Kısa vadeli trafik hacmi tahmini	Trafik Akışı	k-Nearest Neighbour (k-NN) ve Kalman filter
45	Mohamed, E. A.	2014	Çok sınıflı destek vektör makineleri kullanarak trafikte trafik kazalarının nedenlerini tahmin etmek	Trafik Kazası	Çoklu Destek Vektör Makineleri
46	Martin ve ark.	2014	İspanyol Yollarında karayolu güvenliğinin iyileştirilmesi için veri madenciliği tekniklerinin kullanılması	Trafik Kazası	Karar Ağaçları
47	Lv ve ark.	2014	Büyük Veri ile Trafik Akışı Tahmini: Derin Öğrenme Yaklaşımı	Trafik Akışı	Derin Öğrenme(DL)

48	Kumar, K., Parida, M. ve Katiyar, VK	2013	Yapay Sinir Ağı Kullanarak Kentsel Olmayan Bir Karayolu İçin Kısa Vadeli Trafik Akışı Tahmini	Trafik Akışı	Yapay Sinir Ağları (ANN)
49	Jian Dong, Lu Zou, & Yan Zhang.	2013	Otobüs varış zamanlarının tahmini için karma model	Seyahat Süresi	k-Nearest Neighbour (k-NN)
50	Wang, J. ve Shi, S.	2013	Kaos-Dalgacık Analizi-Destek Vektör Makinesi teorisine dayanan kısa vadeli trafik hızı tahmini hibrid modeli	Trafik Akışı	Chaos-Wavelet Analysis-Support Vector Machine
51	Zheng, F. ve Van Zuylen, H.	2013	Seyrek prob araç verisine dayanan kentsel seyahat süresi tahmini	Seyahat Süresi	Yapay Sinir Ağları (ANN)
52	Liu, T., Anne, J., Guan, W., Song, Y., ve Niu, H.	2012	K-En Yakın Komşu Yöntemi'ne Göre Otobüs Varış Süresi Tahmini	Seyahat Süresi	k-Nearest Neighbour (k-NN)
53	Sinn, M., Yoon, JW, Calabrese, F. ve Bouillet, E.	2012	Gerçek zamanlı GPS ölçümleri kullanarak otobüslerin varış saatlerini tahmin etmek	Seyahat Süresi	k-Nearest Neighbour (k-NN)
54	Baptista, AT, Bouillet, EP ve Pompey, P.	2012	Bir belirsizlik bilincine doğru, GPS veri yolu verilerini kullanarak kısa vadeli seyahat süresi tahmini: Dublin'de örnek olay incelemesi	Seyahat Süresi	k-Nearest Neighbour (k-NN)
55	Vlahogianni, EI, Karlaftis, MG ve Orfanou, FP	2012	İkincil Olay Riski Üzerine Hava ve Trafik Etkilerinin Modellenmesi	Trafik Kazası	Yapay Sinir Ağları (ANN)
56	Lu, J., Chen, S., Wang, W. ve Van Zuylen, H.	2012	Trafik olaylarının tespiti için kısmi en küçük kareler ve sinir ağlarından oluşan hibrit bir model	Trafik Kazası	Partial least squares ve Neural network
57	Geetha ve Shanthi (2012)	2012	Trafik kazası verilerinin modellenmesinde sınıflandırıcı tahmini değerlendirmesi	Trafik Kazası	Karar Ağacı algoritmaları olan Random Tree, C4.5, J48 ve Decision Stump
58	Khosravi, A., Mazloumi, E., Nahavandi, S., Creighton, D., & van Lint, JWC	2011	Tahmini Seyahat Süresi Tahmini Belirsizlik Hesapları.	Seyahat Süresi	Yapay Sinir Ağları (ANN)
59	Mazloumi, E., Rose, G., Currie,	2011	Yapay sinir ağları tahminlerindeki belirsizlikleri hesaba katan tahmin aralıkları: Otobüs seyahat süresi tahmininde metodoloji ve uygulama	Seyahat Süresi	Yapay Sinir Ağları (ANN)

	G., ve Moridpour, S.				
60	Fu ve Zhou	2011	Yapay sinir ağına dayalı trafik kazası tahmini	Trafik Kazası	Yapay Sinir Ağları (ANN)
61	Chang, H., Park, D., Lee, S., Lee, H., & Baek, S.	2010	Otobüs transit verilerini kullanarak dinamik çok aralıklı otobüs seyahat süresi tahmini	Seyahat Süresi	k-Nearest Neighbour (k-NN)
62	Valenti, G., Lelli, M., ve Cucina, D.	2010	Olay süresi tahmini için modellerin karşılaştırmalı bir çalışması	Trafik Kazası	Multiple Linear Regression (MLN), Prediction/Decision tree (DT), Artificial Neural Network (ANN), Support/Relevance Vector Machine (RVM) and K-Nearest-Neighbour (kNN)
63	Padiath, A., Vanajakshi, L., Subramanian, SC, ve Manda, H.	2009	Hindistan trafik koşullarında tıkanıklık analizi için trafik yoğunluğunun tahmini	Trafik Akışı	Yapay Sinir Ağları (ANN)
64	Yu, J., Chang, G.-L, Ho, HW, ve Liu, Y.	2008	Kümelenmiş Yapay Sinir Ağlarını Kullanarak Varyasyona Dayalı Çevrimiçi Seyahat Süresi Tahmini	Seyahat Süresi	Yapay Sinir Ağları (ANN)
65	Su, H., Zhang, L. ve Yu, S.	2007	Artımlı Destek Vektör Regresyonuna Dayalı Kısa Vadeli Trafik Akışı Tahmini	Trafik Akışı	Incremental Support Vector Regression (ISVR)
66	Delen, D., Sharda, R., & Bessonov, M.	2006	Bir dizi yapay sinir ağı kullanarak trafik kazalarında önemli yaralanma belirleyicilerinin belirlenmesi	Trafik Kazası	Yapay Sinir Ağları (ANN)
67	Jeong, R. ve Rilett, L.	2005	Gerçek Zamanlı Uygulamalar için Otobüs Varış Zamanının Tahmin Modeli	Seyahat Süresi	Yapay Sinir Ağları (ANN)

DÖRDÜNCÜ BÖLÜM

VERİ MADENCİLİĞİ VE MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE İSTANBUL TRAFİĞİNİN ANALİZİ: D100 KARAYOLU UYGULAMASI

4.1 Tezin Problem Durumu

- Trafik sıkışıklığı, trafikte araç sayısının artması ve hızlarının düşmesinden dolayı varış noktalarına hareket eden araçların seyahat sürelerinin artmasına neden olan bir durumdur.
- Artan nüfus ve beraberinde ortaya çıkan araç sayısı ile verimli bir şekilde başa çıkılamadığından trafik sıkışıklığı sorunu giderek artmıştır.
- Dünyadaki akıllı ve büyük şehirlerde giderek büyük bir sorun haline gelen doğrudan ya da dolaylı trafik problemlerinin üstesinden gelmek, tahmin etmek ve onunla başa çıkmak son dönemlerde büyük bir ilgi görmesi.
- Büyük veri teknolojisinin ortaya çıkışı ve sinir ağı algoritmalarının başarılı bir şekilde uygulanması, taşımacılıkta veri tabanlı araştırmalar yapma fırsatları sunmaktadır.
- Ulaşım sisteminin gelecekteki yönü olan Akıllı Ulaşım Sistemlerinde üretilen büyük veri, araştırmalarda giderek odak noktası haline gelmektedir. Elde edilen büyük veri sayesinde, daha güvenli, verimli ve karlı akıllı ulaşım sistemlerinin tasarım ve uygulamasında önemli bir yere sahip olacaktır.

4.2 Tezin Amacı:

- İstanbul trafiğinin derinlemesine analizinin gerçekleştirilmesi
- İstanbul trafiğine etki eden parametrelerin belirlenmesi
- İstanbul trafiğine etki eden parametrelerin etkilerinin modellenmesi ve analizlerinin gerçekleştirilmesi.
- Konumsal olarak spesifik trafik uyarı sisteminin gerçekleştirilmesi.
- Büyük Veriden yararlanarak Akıllı Şehir Ulaşım sisteminin analizine katkıda bulunulması.

- Oluşabilecek trafik yoğunluk durumları için erken uyarı sisteminin alt yapısının oluşturulması.

4.3 Tezin Motivasyonu:

- Yapay sinir ağı ile trafikte oluşabilecek bir darboğaz durumunu önceden tespit etmek mümkün mü?
- Makine öğrenmesi ile trafikte oluşabilecek yoğunluk durumuna göre kendi kendine karar verebilen bir alt yapı oluşturmak mümkün mü?

4.4 Tezin Yöntemleri:

- Son yıllarda, büyük veri teknolojisinin ortaya çıkışı ve sinir ağı algoritmalarının başarılı bir şekilde uygulanması, taşımacılıkta veri tabanlı araştırmalar yapma fırsatları sunmaktadır.
- Yapay zekadaki gelişmeler araştırmacılara trafik verilerinden özellikleri hızlı ve derin bir şekilde öğrenme şansı veriyor. Böylece, hem kısa hem de uzun vadede trafik tıkanıklıklarını büyük ve heterojen trafik verileriyle tahmin etmek, veri madenciliği ve makine öğrenmesi yaklaşımı kullanılarak iyileştirilebilme fırsatları sunmaktadır.
- Bu çalışmada darboğaz durumunu önceden tespit etmede erken uyarı sisteminin oluşturulmasında Tahminleme Modelleri ve Makine Öğrenmesi yöntemlerinden Yapay Sinir Ağları ve Bayes Ağları kullanılmıştır.
- Trafik sıkışıklığında kendi kendine karar verebilen bir alt yapı sisteminin oluşturulmasında simülasyon yöntemlerinden yararlanılmıştır.

4.5 Tezin Verileri

- İBB Data Veri Portalında açık erişimi olan verilerden elde edilmiştir.
- Sensör verilerinden günlük araç sayısı, kaza verileri, hız verileri, konum verileri, meteorolojik verilerden oluşmuştur.
- D100 karayolunun 2016-2020 yılları arasında 75 adet noktada bulunan sensör verilerinden 1400 günlük araç verisi elde edilmiştir.
- 2020 yılına ait 2246 noktada sensör verilerinden min, max, ve ortalama hız verileri ile saatlik geçen araç sayıları verisi elde edilmiştir.

- D100 karayolunun 2016-2020 yılları arasında gerçekleşen 35697 kaza verisi elde edilmiştir.

4.6 Tezin Hipotezleri


İstanbul'un trafiğindeki araç sayısının:

- Saatler açısından aralarında anlamlı düzeyde bir farklılık vardır.
- Günler açısından aralarında anlamlı düzeyde bir farklılık vardır.
- Aylar açısından aralarında anlamlı düzeyde bir farklılık vardır.
- Mevsimsel açıdan aralarında anlamlı düzeyde bir farklılık vardır.
- Meteorolojik açıdan aralarında anlamlı düzeyde bir farklılık vardır.
- Konum açıdan aralarında anlamlı düzeyde bir farklılık vardır.

İstanbul'un kaza olaylarının:

- Saatler açısından aralarında anlamlı düzeyde bir farklılık vardır
- Günler açısından aralarında anlamlı düzeyde bir farklılık vardır
- Aylar açısından aralarında anlamlı düzeyde bir farklılık vardır
- Mevsimsel açıdan aralarında anlamlı düzeyde bir farklılık vardır
- Meteorolojik açıdan aralarında anlamlı düzeyde bir farklılık vardır.
- Konum açıdan aralarında anlamlı düzeyde bir farklılık vardır.

İstanbul'un trafik yoğunluğunun analiz edilmesinde büyük veri analizi ile veriler toplanarak sınıflandırma analizleri gerçekleştirilmiştir. Verilerin sınıflandırılmasından sonra hipotezlerin test edilmesi ve parametrelerin belirlenmesi aşamasında istatistiksel analiz yöntemlerinden parametrik olmayan Kruskal Wallis ve Mann-Whitney testi gerçekleştirilmiştir. Kaza olaylarının ilişkilerinin belirlenmesinde ise Chi-kare analizinden yararlanılmıştır. Makine öğrenmesi yöntemleri ile trafik yoğunluğunun analizi için Yapay Sinir Ağı ve Bayesian Ağı ile model önerilmiştir.



Şekil 4.1 Trafik Analizi Akış Şeması

4.7 İstatistiksel Analiz Yöntemleri ile Trafik Analizi

4.7.1 D100 Karayolunun Trafik Araç Yoğunluk Analizi

İstanbul D100 karayolunda 2016-2020 yılları arasında geçen araç sayılarının saat, gün, ay, mevsim, meteorolojik ve konum açısından analizleri gerçekleştirilmiştir. Bu parametrelerin trafik yoğunluğu üzerinde var olan etkileri incelenerek yapay sinir ağı tahminleme modeli elde edilmiştir. D100 karayolunun 2016-2020 yılları arasında 75 adet noktada bulunan sensör verilerinden 1400 günlük araç verisi elde edilmiştir. Tablo 4.1.'de 2016 yılı 1 Ocak 2016 Cuma yılına ait D100 karayolunda bulunan 75 farklı noktada sensör verilerinden elde edilen araç sayıları verilmiştir.

Tablo 4.1. D100 Karayolu Hattı Farklı Noktaların Araç Sayıları

Tarih	Sensor Adı	Arac Sayısı
1 Ocak 2016 Cuma	Basın Ekspres Yolu D100 Katılımı	14667
1 Ocak 2016 Cuma	Çamlıca TEM-D100 Bağl. Yolu	32272
1 Ocak 2016 Cuma	D100 15 Temmuz Şehitler Köprüsü Avrupa Girişi	72140
1 Ocak 2016 Cuma	D100 Acıbadem	47767
1 Ocak 2016 Cuma	D100 Acıbadem Köprüsü	83772
1 Ocak 2016 Cuma	D100 Altıntepe	99824
1 Ocak 2016 Cuma	D100 Altunizade	21557
1 Ocak 2016 Cuma	D100 Ambarlı	22147
1 Ocak 2016 Cuma	D100 Ambarlı	31027
1 Ocak 2016 Cuma	D100 Avcılar Hacı şerif	76307
1 Ocak 2016 Cuma	D100 Başibüyük	77259
1 Ocak 2016 Cuma	D100 Beylerbeyi	22582
1 Ocak 2016 Cuma	D100 Büyükçekmece	27473
1 Ocak 2016 Cuma	D100 Celaliye 1	11936
1 Ocak 2016 Cuma	D100 Celaliye 2	11440
1 Ocak 2016 Cuma	D100 Cennet Mah.	75420
1 Ocak 2016 Cuma	D100 Çağlayan	31951
1 Ocak 2016 Cuma	D100 Çobançeşme	23670
1 Ocak 2016 Cuma	D100 Çobançeşme	47321
1 Ocak 2016 Cuma	D100 Çobançeşme Havaalanı	25533
1 Ocak 2016 Cuma	D100 Edirnekapı	52246
1 Ocak 2016 Cuma	D100 Florya	75767
1 Ocak 2016 Cuma	D100 Göztepe	52319
1 Ocak 2016 Cuma	D100 Gülsuyu	48963
1 Ocak 2016 Cuma	D100 Güzelce	1662
1 Ocak 2016 Cuma	D100 Güzelyalı	37364
1 Ocak 2016 Cuma	D100 Güzelyalı	60270
1 Ocak 2016 Cuma	D100 Haliç Köprü Çıkışı	81624
1 Ocak 2016 Cuma	D100 Harem	13936
1 Ocak 2016 Cuma	D100 Havaalanı Katılımı	10372
1 Ocak 2016 Cuma	D100 Kartal Kavşağı	57777
1 Ocak 2016 Cuma	D100 Kartal Oto Sanayi	53779
1 Ocak 2016 Cuma	D100 Kaynarca	56986
1 Ocak 2016 Cuma	D100 Kozyatağı	37970
1 Ocak 2016 Cuma	D100 Kozyatağı	107460

1 Ocak 2016 Cuma	D100 Kumburgaz 1	15155
1 Ocak 2016 Cuma	D100 Kumburgaz 2	13202
1 Ocak 2016 Cuma	D100 Küçük Çamlıca	61746
1 Ocak 2016 Cuma	D100 Küçük Çamlıca	71289
1 Ocak 2016 Cuma	D100 Küçükçekmece	77640
1 Ocak 2016 Cuma	D100 Küçükçekmece Gölü 1	87762
1 Ocak 2016 Cuma	D100 Maltepe	58595
1 Ocak 2016 Cuma	D100 Merter	44576
1 Ocak 2016 Cuma	D100 Metroport	37390
1 Ocak 2016 Cuma	D100 Mimarşinan	22064
1 Ocak 2016 Cuma	D100 Okmeydanı	61497
1 Ocak 2016 Cuma	D100 Pendik	32012
1 Ocak 2016 Cuma	D100 Pendik	65593
1 Ocak 2016 Cuma	D100 Pendik Tersane 2	38110
1 Ocak 2016 Cuma	D100 Sahil Florya Bağlantı	15889
1 Ocak 2016 Cuma	D100 Sefaköy	77025
1 Ocak 2016 Cuma	D100 Sefaköy	71559
1 Ocak 2016 Cuma	D100 Sefaköy Havaalanı	30335
1 Ocak 2016 Cuma	D100 Selimpaşa	11923
1 Ocak 2016 Cuma	D100 Soğanlık	51584
1 Ocak 2016 Cuma	D100 Şirinevler	82555
1 Ocak 2016 Cuma	D100 Topkapı Haliç Yönü	73402
1 Ocak 2016 Cuma	D100 Tuzla	39302
1 Ocak 2016 Cuma	D100 Tuzla Piyade	33864
1 Ocak 2016 Cuma	D100 Türk Böbrek Vakfı Önü	106074
1 Ocak 2016 Cuma	D100 Tüyap	15275
1 Ocak 2016 Cuma	D100 Uzunçayır	37959
1 Ocak 2016 Cuma	D100 Uzunçayır	74824
1 Ocak 2016 Cuma	D100 Vatan Metrobüs	37049
1 Ocak 2016 Cuma	D100 Yıldız Katılımı	28191
1 Ocak 2016 Cuma	D100 Zincirlikuyu	33632
1 Ocak 2016 Cuma	D100 Zincirlikuyu	66178
1 Ocak 2016 Cuma	D100 Zümrüt Evler	91015
1 Ocak 2016 Cuma	D100-Altunizade	49701
1 Ocak 2016 Cuma	D100-TEM Esenyurt Bağlantı	36612
1 Ocak 2016 Cuma	D100-TEM Hadımköy Bağlantı	15131
1 Ocak 2016 Cuma	TEM D100 Okmeydanı Bağl. Yolu	16627
1 Ocak 2016 Cuma	TEM-D100 Esenyurt Bağlantı	35450
1 Ocak 2016 Cuma	TEM-D100 Hadımköy Bağlantı	10701

Kaynak: <https://data.ibb.gov.tr/en/dataset>

Bu verilerin gün, ay, mevsim, yıl, meteorolojik ve konum gibi kategorik özelliklere göre sınıflandırılması yapılacaktır. Sınıflandırma işleminin ardından hipotezler test edilerek D100 karayolunun araç yoğunluğuna etki eden parametreler belirlenecektir. Elde edilen parametreler ile D100 karayoluna ait Makine Öğrenmesi modellemesi oluşturularak araç yoğunluğunu etkileyen parametrelere göre tahminlemesi gerçekleştirilerek oluşabilecek darboğazlarda bir erken uyarı sisteminin alt yapısı oluşturulacaktır.

Sınıflandırma işleminde günler Pazartesi:1, Salı:2, Çarşamba:3, Perşembe:4, Cuma:5, Cumartesi:6, Pazar:7 şeklinde tanımlanmıştır. Aylar Ocak:1, Şubat:2, Mart:3, Nisan:4, Mayıs:5, Haziran:6, Temmuz:7, Ağustos:8, Eylül:9, Ekim:10, Kasım:11, Aralık:12 şeklinde tanımlanmıştır. Mevsimler İlkbahar:1, Yaz:2, Sonbahar:3, Kış:4 şeklinde tanımlanmıştır. Yıllar 2016:1, 2017:2, 2018:3, 2019:4, 2020:5 şeklinde tanımlanmıştır. Meteorolojik veriler Güneşli:1, Bulutlu:2, Yağmurlu:3, Sağanak:4, Karlı:5 şeklinde tanımlanmıştır.

D100 karayolu 15 Temmuz Şehitler Köprüsünün belirlenen parametrelere göre veri setine ait örnek tablo 4.2.'de elde edilmiştir.

Tablo 4.2. D100 15 Temmuz Şehitler Köprüsü veri seti örneği

Tarih	Sensor Adı	Araç Sayısı	Hava Durumu	Gün	Ay	Yıl	Mevsim
1 Şubat 2018 Perşembe	D100 15 Temmuz Şehitler K.	121824	2	4	2	3	4
4 Şubat 2018 Pazar	D100 15 Temmuz Şehitler K.	116928	3	7	2	3	4
2 Mart 2018 Cuma	D100 15 Temmuz Şehitler K.	118663	2	5	3	3	1
4 Mart 2019 Pazartesi	D100 15 Temmuz Şehitler K.	145541	2	1	3	4	1
8 Nisan 2019 Pazartesi	D100 15 Temmuz Şehitler K.	186806	4	1	4	4	1
4 Haziran 2019 Salı	D100 15 Temmuz Şehitler K.	185068	1	2	6	4	2
24 Temmuz 2019 Çarşamba	D100 15 Temmuz Şehitler K.	201781	4	3	7	4	2
12 Eylül 2019 Perşembe	D100 15 Temmuz Şehitler K.	197628	2	4	9	4	3
1 Ocak 2020 Çarşamba	D100 15 Temmuz Şehitler K.	173690	5	3	1	5	4

D100 karayolu 15 Temmuz Şehitler Köprüsünün trafik yoğunluğuna etki edebilecek parametrelerin Kruskal Wallis analizi ve Mann Whitney-U analizleri ile sonuçları elde edilmiştir. Araç Sayısı_ Yıl, Araç Sayısı_ Ay, Araç Sayısı_ Gün, Araç Sayısı_ Mevsim, Araç Sayısı_ Kaza, Araç Sayısı_ Kaza Türü, Araç Sayısı_ Kaza Durumu, Araç Sayısı_ Şerit gibi parametreler açısından trafik yoğunluğunun anlamlı düzeylerde farklılıkların olup oluşmadığı test edilmiştir. Öncelikle verilerin Araç sayısı, yıl, ay, gün, mevsim, hava durumu değişkenlerinin normal dağılıma uygunluğu test edilmiştir.

Tablo 4.3. Verilerin Normallik Analiz Sonuçları

	Değişken	Kolmogorov-Smirnov			Shapiro-Wilk		
		İstatistik	df	Anlamlılık	İstatistik	df	Anlamlılık
	YIL						
Araç Yoğunluğu	2018	0,191	329	0,000	0,867	329	0,000
	2019	0,237	352	0,000	0,692	352	0,000
	2020	0,258	313	0,000	0,697	313	0,000
	AY	İstatistik	df	Anlamlılık	İstatistik	df	Anlamlılık
	Ocak	0,192	88	0,000	0,851	88	0,000
	Şubat	0,186	83	0,000	0,841	83	0,000
	Mart	0,12	84	0,004	0,905	84	0,000
	Nisan	0,112	83	0,012	0,930	83	0,000
	Mayıs	0,217	87	0,000	0,771	87	0,000
	Haziran	0,286	85	0,000	0,690	85	0,000
	Temmuz	0,196	93	0,000	0,685	93	0,000
	Ağustos	0,204	90	0,000	0,685	90	0,000
	Eylül	0,352	70	0,000	0,520	70	0,000
	Ekim	0,263	91	0,000	0,667	91	0,000
	Kasım	0,27	79	0,000	0,759	79	0,000
	Aralık	0,277	61	0,000	0,625	61	0,000

Tablo 4.4. Verilerin Normallik Analiz Sonuçları Devamı

	Değişken	Kolmogorov-Smirnov			Shapiro-Wilk		
		İstatistik	df	Anlamlılık	İstatistik	df	Anlamlılık
	TARİH						
Araç Yoğunluğu	Pazartesi	0,157	143	0,000	0,885	143	0,000
	Salı	0,241	145	0,000	0,794	145	0,000
	Çarşamba	0,226	146	0,000	0,796	146	0,000
	Perşembe	0,226	145	0,000	0,777	145	0,000
	Cuma	0,278	144	0,000	0,727	144	0,000
	Cumartesi	0,291	139	0,000	0,712	139	0,000
	Pazar	0,241	132	0,000	0,815	132	0,000
	MEVSİM	İstatistik	df	Anlamlılık	İstatistik	df	Anlamlılık
	İlkbahar	0,123	254	0,000	0,891	254	0,000
	Yaz	0,216	268	0,000	0,668	268	0,000
	Sonbahar	0,278	240	0,000	0,65	240	0,000
	Kış	0,205	232	0,000	0,818	232	0,000
	HAVA DURUMU	İstatistik	df	Anlamlılık	İstatistik	df	Anlamlılık
	Güneşli	0,242	187	0,000	0,739	187	0,000
	Bulutlu	0,242	594	0,000	0,77	594	0,000
	Yağmurlu	0,226	67	0,000	0,834	67	0,000
	Sağanak	0,214	136	0,000	0,828	136	0,000
	Karlı	0,369	10	0,000	0,643	10	0,000

Elde edilen sonuçlara göre verilerimiz normal dağılım göstermemiştir. Tüm değişkenlerde Kolmogorov-Smirnov değerimiz $p < 0,005$ olduğundan verilerimiz normal dağılıma sahip değildir. Verilerimiz normal dağılıma sahip olmadığından ve gruplarda üç veya daha fazla, sıralama ölçeğine sahip olduğundan tek yönlü varyans analizi gerekli olan varsayımlar karşılanmadığından, Kruskal Wallis testi uygulanmıştır. Grupların karşılaştırılmasında ise Mann-Whitney U testi uygulanmıştır. Köprü üzerindeki araç yoğunluğunun yıl, ay, tarih, mevsim ve hava durumu gruplarında ortalamalarında anlamlı düzeyde farklılığın olup oluşmadığının tespit etmek amacıyla Kruskal Wallis ve Mann-Whitney U testi uygulanmış, sonuçları elde edilmiştir.

Tablo 4.5. Araç Yoğunluk Ort. Yıl Değişkenine Göre Kruskal Wallis Analizi

Boyut	Değişken	Kategoriler	N	Ortalama	Sd	X ²	p
Araç Yoğunluğu	Yıllar	2018	329	445,66	2	20,272	.000
		2019	352	567,13	2		
		2020	313	473,68	2		

Tablo 4.5.'te elde edilen sonuçlara göre, köprü üzerindeki araç yoğunluğunun ortalamalarının yıllar değişkenine göre anlamlı bir farklılığın olup olmadığını belirlemek amacıyla gerçekleştirilen Kruskal Wallis-H analizi sonucunda yıllara göre köprü üzerinde araç yoğunluğunun ortalamaları arasındaki fark istatistiksel olarak anlamlı bulunmuştur ($X^2=15,939$; $Sd =6$; $p < .05$). Elde edilen anlamlılığın hangi yıllar arasında meydana geldiğini belirlemek üzere karşılaştırma tekniklerine geçilmiştir. İkili karşılaştırmalarda tercih edilen Mann Whitney-U testi kullanılmıştır.

Tablo 4.6. Araç Yoğunluk Ort. Yıl Değişkenine Göre U testi Tablosu

Boyut	Değişken	Kategoriler	N	Sıra Ort	Sıra Toplamı	Z	U	p
Araç Yoğunluğu	Yıllar	2018	329	298,78	98297,00	-5,415	44012,0	0,000
		2019	352	380,47	133924,00			
		2018	329	311,89	102610,50	-1,347	48325,5	0,178
		2020	313	331,61	103792,50			
		2019	352	363,17	127835,50	-4,295	44468,5	0,000
		2020	313	299,07	93609,50			

Tablo 4.6.'da elde edilen sonuçlara göre, köprü üzerindeki araç yoğunluğunun yıllara göre anlamlı bir şekilde farklılaşıp farklılaşmadığının belirlemek üzere non-

parametrik Mann Whitney-U testi sonucunda 2018-2019 yılları arasında ve 2019-2020 yılları arasında anlamlı düzeyde farklılıklar elde edilmiştir.

Tablo 4.7. Araç Yoğunluk Ort. Yıl Değişkenine Göre Değişimi

Yıllar	Ortalama Araç Sayısı			Std. Deviation	Std. Error
	N	Değer	Değişim		
2018	329	153825,33	na	41946,407	2312,580
2019	352	170785,73	11%	41121,593	2191,788
2020	313	159150,97	-7%	49399,279	2792,212
Total	994	161508,42	na	44692,964	1417,575

Tablo 4.7.'de elde edilen sonuçlara göre, köprü üzerindeki araç yoğunluğunun ortalamalarının yıllara göre anlamlı düzeyde farklılıklar yaşandığı, bu farklılıkların anlamlı düzeyde değişim yaşandığı belirlenmiştir. 2018 yılından 2019 yılına gelindiğinde köprü üzerindeki araç yoğunluğunda 11%'lik bir artış yaşanmıştır. 2019-2020 yılları arasında ise 7%'lik bir azalma meydana gelmiştir. Bu azalmanın en büyük nedenlerinde birinin yaşanan Covid-19 salgını sonucunda kapanmalar yaşandığı ve insanların hareketliliklerinin azalmasından dolayı gerçekleşmiştir.

Köprü üzerindeki araç yoğunluğunun ortalamalarının aylar değişkenine göre anlamlı bir farklılığın olup olmadığını belirlemek amacıyla gerçekleştirilen Kruskal Wallis-H analizi gerçekleştirilmiştir. 2018-2020 yılları arasında 12 aya göre köprü üzerindeki araç yoğunluğunun değişim analizi gerçekleştirilmiştir.

Tablo 4.8. Araç Yoğunluk Ort. Ay Değişkenine Göre Kruskal Wallis Analizi

Boyut	Değişken	Kategoriler	N	Ortalama	df	X ²	p
Araç Yoğunluğu	Aylar	Ocak	88	317,94	11	210,3951	0,000
		Şubat	83	348,30			
		Mart	84	307,69			
		Nisan	83	260,92			
		Mayıs	87	399,53			
		Haziran	85	640,92			
		Temmuz	93	732,55			
		Ağustos	90	675,44			
		Eylül	70	698,25			
		Ekim	91	614,87			
		Kasım	79	475,70			
		Aralık	61	484,58			

Tablo 4.8.'te elde edilen sonuçlara göre, köprü üzerindeki araç yoğunluğunun ortalamalarının ay değişkenine göre anlamlı bir farklılığın olup olmadığını belirlemek amacıyla gerçekleştirilen Kruskal Wallis-H analizi sonucunda aylara göre köprü üzerinde araç yoğunluğunun ortalamaları arasındaki fark istatistiksel olarak anlamlı bulunmuştur ($\chi^2=210,395$; $sd =11$; $p <.05$). Elde edilen anlamlılığın hangi aylar arasında meydana geldiğini belirlemek üzere karşılaştırma tekniklerine geçilmiştir. İkili karşılaştırmalarda tercih edilen Mann Whitney-U testi kullanılmıştır.

Tablo 4.9. Araç Yoğunluk Ort. Ay Değişkenine Göre U testi Tablosu

Boyut	Değişken	Kategoriler	N	Sıra Ort	Sıra Toplamı	Z	U	p
Araç Yoğunluğu	Aylar	Ocak	88	81,98	7214,00	-1,094	3298,00	0,274
		Şubat	83	90,27	7492,00	-1,386	3053,00	0,166
		Şubat	83	89,22	7405,00	-1,719	2949,00	0,086
		Mart	84	78,85	6623,00	-3,188	2588,00	0,001
		Mart	84	90,39	7593,00	-5,199	2000,00	0,000
		Nisan	83	77,53	6435,00	-1,811	3330,50	0,040
		Nisan	83	73,18	6074,00	-1,731	3565,00	0,084
		Mayıs	87	97,25	8461,00	-0,244	3079,00	0,807
		Mayıs	87	66,99	5828,00	-3,359	2200,00	0,001
		Haziran	85	106,47	9050,00	-3,916	2341,00	0,000
		Haziran	85	82,18	6985,50	-0,216	2358,00	0,829
		Temmuz	93	96,19	8945,50			
		Temmuz	93	98,67	9176,00			
		Ağustos	90	85,11	7660,00			
		Ağustos	90	81,29	7316,00			
		Eylül	70	79,49	5564,00			
		Eylül	70	95,07	6655,00			
		Ekim	91	70,18	6386,00			
		Ekim	91	99,27	9034,00			
		Kasım	79	69,63	5501,00			
		Kasım	79	69,85	5518,00			
		Aralık	61	71,34	4352,00			

Tablo 4.9.'da elde edilen sonuçlara göre, köprü üzerindeki araç yoğunluğunun aylara göre anlamlı bir şekilde farklılaşıp farklılaşmadığının belirlemek üzere parametrik olmayan Mann Whitney-U testi sonucunda Nisan-Mayıs, Mayıs-Haziran, Haziran-Temmuz, Eylül-Ekim ve Ekim-Kasım ayları arasında anlamlı düzeyde farklılıklar elde edilmiştir.

Tablo 4.10. Araç Yoğunluk Ort. Ay Değişkenine Değişimi

AYLAR	N	Ortalama		Std. Deviation	Std. Error
		Değer	Değişim		
Ocak	88	145598,09	na	40568,864	4324,655
Şubat	83	147641,95	1,4%	41411,119	4545,461
Mart	84	137511,76	-6,9%	44761,965	4883,931
Nisan	83	119044,41	-13,4%	54372,424	5968,149
Mayıs	87	138940,15	16,7%	64697,227	6936,271
Haziran	85	176606,98	27,1%	36387,385	3946,766
Temmuz	93	188047,29	6,5%	21312,902	2210,045
Ağustos	90	183903,60	-2,2%	22437,646	2365,136
Eylül	70	183324,90	-0,3%	27202,530	3251,324
Ekim	91	182462,89	-0,5%	16917,832	1773,471
Kasım	79	165640,44	-9,2%	35783,143	4025,918
Aralık	61	170150,97	2,7%	33338,783	4268,594
Total	994	161508,42	na	44692,964	1417,575

Tablo 4.10.'da elde edilen sonuçlara göre, köprü üzerindeki araç yoğunluğunun ortalamalarının aylara göre anlamlı düzeyde farklılıklar yaşandığı, bu farklılıkların anlamlı düzeyde değişim yaşandığı belirlenmiştir. Nisan ayından Mayıs aylarına geçişte köprüdeki araç yoğunluğu 16,7% bir artış meydana geldiği ve bu farkın anlamlı olduğu sonucuna varılmıştır. Bu farkın oluşmasında bu aylarda hava sıcaklığının artması ile insanların dışarıda daha fazla vakit geçirmeleri ve daha fazla hareketliliğin oluşması sonucunda meydana gelmektedir. Mayıs ayından Haziran ayına geçişte köprüdeki araç yoğunluğunda 27,1% gibi büyük bir oranda artış göstermiştir. Bu farkın oluşmasında bu aylarda yaşanan yaz mevsimi sonucu insanların tatile gitmeleri ve turistlerinde gelmeleri nedenler arasında sayılmaktadır. Haziran ayından Temmuz ayına geçişte köprüdeki araç yoğunluğu 6,5%'lik bir artış meydana geldiği yaz hareketliliğinden dolayı araç yoğunluğunda bir miktar daha artış sağlanmıştır. Ekim ayından Kasım ayına doğru ise 9,2%'lik bir azalma meydana geldiği ve bu değişimin anlamlı olduğu sonucuna varılmıştır. Bu aylarda okulların açılması ile öğrencilerin daha çok servis ile gitmeleri, işlerine gitmek isteyen insanların daha çok çalıştıkları yerlerin servislerini kullanmaları, toplu taşıma araçlarını daha fazla tercih etmeleri ve en önemlisi bu tarihlerde mevsimden dolayı yağışların oluşması gibi etkenler nedenler arasında sayılabilir.

Köprü üzerindeki araç yoğunluğunun ortalamalarının günler değişkenine göre anlamlı bir farklılığın olup olmadığını belirlemek amacıyla gerçekleştirilen Kruskal Wallis-H analizi gerçekleştirilmiştir. 2018-2020 yılları arasında haftanın günlerine göre köprü üzerindeki araç yoğunluğunun değişim analizi gerçekleştirilmiştir.

Tablo 4.11. Araç Yoğunluk Ort. Gün Değişkenine Göre Kruskal Wallis Analizi

Boyutlar	Değişken	Kategoriler	N	Ortalama	df	X ²	p
Araç Yoğunluğu	Günler	Pazartesi	143	476,84	6	38,572	0,000
		Salı	145	450,26			
		Çarşamba	146	498,27			
		Perşembe	145	526,19			
		Cuma	144	575,04			
		Cumartesi	139	560,03			
		Pazar	132	388,97			

Tablo 4.11.'de elde edilen sonuçlara göre, köprü üzerindeki araç yoğunluğunun ortalamalarının gün değişkenine göre anlamlı bir farklılığın olup olmadığını belirlemek amacıyla gerçekleştirilen Kruskal Wallis-H analizi sonucunda yıllara göre köprü üzerinde araç yoğunluğunun ortalamaları arasındaki fark istatistiksel olarak anlamlı bulunmuştur ($\chi^2=38,572$; $sd=6$; $p<.05$).

Tablo 4.12. Araç Yoğunluk Ort. Gün Değişkenine Göre U testi Tablosu

Boyutlar	Değişken	Kategoriler	N	Sıra Ort	Sıra Toplamı	Z	U	p
Araç Yoğunluğu	Günler	Pazartesi	143	130,92	18721,00	-2,661	8425,00	0,008
		Cuma	144	156,99	22607,00			
		Pazartesi	143	131,73	18837,00	-2,041	8541,00	0,041
		Cumartesi	139	151,55	21066,00			
		Pazartesi	143	149,56	21387,00	-2,509	7785,00	0,012
		Pazar	132	125,48	16563,00			
		Salı	145	133,90	19415,00	-2,356	8830,00	0,018
		Perşembe	145	157,10	22780,00			
		Salı	145	125,44	18189,00	-3,992	7604,00	0,000
		Cuma	144	164,69	23716,00			
		Salı	145	126,81	18387,00	-3,289	7802,00	0,001
		Cumartesi	139	158,87	22083,00			
		Salı	145	148,34	21510,00	-2,035	8215,00	0,042
		Pazar	132	128,73	16993,00			
		Çarşamba	146	133,66	19514,50	-2,421	8783,5	0,015
		Cuma	144	157,50	22680,50			
		Çarşamba	146	154,32	22530,00	-3,231	7473	0,001
		Pazar	132	123,11	16251,00			
		Perşembe	145	136,67	19817,00	-3,231	7473	0,001
		Cumartesi	139	148,58	20653,00			
		Perşembe	145	157,49	22836,00	-4,026	6889	0,000
		Pazar	132	118,69	15667,00			
		Cuma	144	163,11	23488,00	-5,35	5960	0,000
		Pazar	132	111,65	14738,00			
		Cumartesi	139	157,08	21834,00	-4,543	6244	0,000
		Pazar	132	113,80	15022,00			

Elde edilen anlamlılığın hangi günler arasında meydana geldiğini belirlemek üzere karşılaştırma tekniklerine geçilmiştir. İkili karşılaştırmalarda tercih edilen Mann Whitney-U testi kullanılmıştır. Tablo 4.12.'de elde edilen sonuçlara göre, köprü üzerindeki araç yoğunluğunun günlere göre anlamlı bir şekilde farklılaşıp farklılaşmadığının belirlemek üzere Mann Whitney-U testi sonucunda pazartesi, salı, çarşamba ve perşembe günlerinin cuma, cumartesi ve pazar günleri arasında ile arasında anlamlı düzeyde farklılıklar elde edilmiştir.

Tablo 4.13. Araç Yoğunluk Ort. Gün Değişkenine Göre Değişimi

Günler	N	Ortalama		Std. Deviation	Std. Error
		Değer	Değişim		
Pazartesi	143	161701,68	na	37762,902	3157,893
Cuma	144	170017,63	5,1%	38890,723	3240,894
Pazartesi	143	161701,68	-	37762,902	3157,893
Cumartesi	139	159204,19	-1,5%	57435,678	4871,631
Pazartesi	143	161701,68	-	37762,902	3157,893
Pazar	132	142995,02	-11,6%	57449,465	5000,334
Salı	145	161288,00	-	39293,571	3263,153
Perşembe	145	168635,54	4,6%	35617,513	2957,873
Salı	145	183324,90	-	39293,571	3263,153
Cuma	144	182462,89	-0,5%	16917,832	1773,471
Salı	145	161288,00	-	39293,571	3263,153
Cumartesi	139	170017,63	5,4%	57435,678	4871,631
Salı	145	161288,00	-	39293,571	3263,153
Pazar	132	142995,02	-11,3%	57449,465	5000,334
Çarşamba	146	164998,95	-	37739,468	3123,341
Cuma	144	170017,63	3,0%	38890,723	3240,894
Çarşamba	146	164998,95	-	37739,468	3123,341
Pazar	132	142995,02	-13,3%	57449,465	5000,334
Perşembe	145	168635,54	-	35617,513	2957,873
Cumartesi	139	159204,19	-5,6%	57435,678	4871,631
Perşembe	145	168635,54	-	35617,513	2957,873
Pazar	132	142995,02	-15,2%	57449,465	5000,334
Cuma	144	170017,63	-	38890,723	3240,894
Pazar	132	142995,02	-15,9%	57449,465	5000,334
Cumartesi	139	159204,19	-	57435,678	4871,631
Pazar	132	142995,02	-10,2%	57449,465	5000,334

Tablo 4.13.'te elde edilen sonuçlara göre, köprü üzerindeki araç yoğunluğunun ortalamalarının günlere göre anlamlı düzeyde farklılıklar yaşandığı, bu farklılıkların anlamlı düzeyde değişim yaşandığı belirlenmiştir. Pazar gününden pazartesiye geçişte araç yoğunluğunda 11,6%'lık bir artış yaşanmıştır. Cumartesi gününden pazar gününe

geçişte 10,2%'lik bir azalma meydana gelmiştir. Çarşamba gününden pazar gününe kadar 13,3%'lük bir azalma gerçekleşirken, perşembeden pazar gününe kadar 15,2%'luk bir azalma meydana gelmektedir. Cuma gününden pazar gününe kadar araç yoğunluğunda 15,9%'luk bir azalma meydana gelmiştir. Köprüdeki araç yoğunluğunun Çarşamba gününden itibaren azalmaya başladığı gözlemlenmiştir.

Köprü üzerindeki araç yoğunluğunun ortalamalarının mevsim değişkenine göre anlamlı bir farklılığın olup olmadığını belirlemek amacıyla gerçekleştirilen Kruskal Wallis-H analizi gerçekleştirilmiştir.

Tablo 4.14. Araç Yoğunluk Ort. Mevsim Değişkenine Göre Kruskal Wallis Analizi

Boyutlar	Değişken	Kategoriler	N	Ortalama	df	X ²	p
Araç Yoğunluğu	Mevsim	İlkbahar	254	323,86	3	277,063	0,000
		Yaz	268	684,31			
		Sonbahar	240	593,38			
		Kış	232	372,62			

Tablo 4.14.'te elde edilen sonuçlara göre, köprü üzerindeki araç yoğunluğunun ortalamalarının mevsim değişkenine göre anlamlı bir farklılığın olup olmadığını belirlemek amacıyla gerçekleştirilen Kruskal Wallis-H analizi sonucunda yıllara göre köprü üzerinde araç yoğunluğunun ortalamaları arasındaki fark istatistiksel olarak anlamlı bulunmuştur ($X^2=277,063$; $Sd =3$; $p <.05$). Elde edilen anlamlılığın hangi yıllar arasında meydana geldiğini belirlemek üzere karşılaştırma tekniklerine geçilmiştir. İkili karşılaştırmalarda tercih edilen Mann Whitney-U testi kullanılmıştır.

Tablo 4.15. Araç Yoğunluk Ort. Mevsim Değişkenine Göre U testi Tablosu

Boyutlar	Değişken	Kategoriler	N	Sıra Ort	Sıra Toplamı	Z	U	p
Araç Yoğunluğu	Mevsim	İlkbahar	254	172,80	43890,50	-	11505,50	0,000
		Yaz	268	345,57	92612,50	13,081		
		Yaz	268	285,46	76502,00	-5,023	23864,00	0,000
		Sonbahar	240	219,93	52784,00	-9,708		
		Sonbahar	240	296,43	71142,00	-3,006	24816,00	0,003
		Kış	232	174,51	40486,00	-		
		Kış	232	263,53	61140,00	-		
		İlkbahar	254	225,20	57201,00	-		

Tablo 4.15.'te elde edilen sonuçlara göre, köprü üzerindeki araç yoğunluğunun mevsimlere göre anlamlı bir şekilde farklılaşıp farklılaşmadığının belirlemek üzere parametrik olmayan Mann Whitney-U testi sonucunda ilkbahar-yaz, yaz-sonbahar,

sonbahar-kış, kış-ilkbahar mevsimlerine geçişlerde araç yoğunluk ortalamalarında anlamlı düzeyde farklılıklar elde edilmiştir.

Tablo 4.16. Araç Yoğunluk Ort. Mevsim Değişkenine Göre Değişimi

Mevsimler	Ortalama			Std. Deviation	Std. Error
	N	Değer	Değişim		
İlkbahar	254	131966,41	na	55857,291	3504,798
Yaz	268	183027,29	38,69%	27623,263	1687,359
Yaz	268	183027,29	-	27623,263	1687,359
Sonbahar	240	177176,92	-3,20%	28372,454	1831,434
Sonbahar	240	177176,92	-	28372,454	1831,434
Kış	232	152785,01	-13,77%	40325,145	2647,475

Tablo 4.16.'da elde edilen sonuçlara göre, köprü üzerindeki araç yoğunluğunun ortalamalarının mevsimlere göre anlamlı düzeyde farklılıklar yaşandığı, bu farklılıkların anlamdı düzeyde değişim yaşandığı belirlenmiştir. İlkbahardan yaz mevsimine geçişte köprüdeki araç yoğunluğunda 38,69%'lik artış meydana gelmiştir. Yaz mevsiminden sonbahar mevsimine geçişte ise 3,2%'lik bir azalma meydana gelmiştir. Sonbahar mevsiminden kış mevsimine geçişte ise 13,77%'lik bir azalma meydana gelmiştir. İlkbahar mevsiminden yaz mevsimine geçişte köprüdeki araç yoğunluğu artışı önlemek adına gerekli tedbirlerin alınması gerektiği sonucu elde edilmiştir.

Köprü üzerindeki araç yoğunluğunun ortalamalarının hava koşulları değişkenine göre anlamlı bir farklılığın olup olmadığını belirlemek amacıyla gerçekleştirilen Kruskal Wallis-H analizi gerçekleştirilmiştir.

Tablo 4.17. Araç Yoğunluk Ort. Hava Durumu Değişkenine Göre Kruskal Wallis Analizi

Boyutlar	Değişken	Kategoriler	N	Ortalama	df	X ²	p
Araç Yoğunluğu	Hava Durumu	Güneşli	187	593,19	4	38,446	0,000
		Bulutlu	594	495,91			
		Yağmurlu	67	408,87			
		Sağanak	136	429,06			
		Karlı	10	326,75			

Tablo 4.17.'de elde edilen sonuçlara göre, köprü üzerindeki araç yoğunluğunun ortalamalarının hava durumu değişkenine göre anlamlı bir farklılığın olup olmadığını belirlemek amacıyla gerçekleştirilen Kruskal Wallis-H analizi sonucunda yıllara göre köprü üzerinde araç yoğunluğunun ortalamaları arasındaki fark istatistiksel olarak anlamlı bulunmuştur ($X^2=38,446$; $Sd =4$; $p <.05$). Elde edilen anlamlılığın hangi yıllar arasında meydana geldiğini belirlemek üzere karşılaştırma tekniklerine geçilmiştir. İkili karşılaştırmalarda tercih edilen Mann Whitney-U testi kullanılmıştır.

Tablo 4.18. Araç Yoğunluk Ort. Hava Durumu Değişkenine Göre U testi Tablosu

Boyutlar	Değişken	Kategoriler	N	Sıra Ort	Sıra Toplamı	Z	U	p
Araç Yoğunluğu	Hava Durumu	Güneşli	187	450,45	84234,50	-4,132	44421,50	0,000
		Bulutlu	594	372,28	221136,50			
		Güneşli	187	139,75	26134,00	-4,441	3973,00	0,000
		Yağmurlu	67	93,30	6251,00			
		Güneşli	187	183,45	34305,50	-4,841	8704,50	0,000
		Sağanak	136	132,50	18020,50			
		Güneşli	187	101,53	18987,00	-2,698	461	0,007
		Karlı	10	51,60	516,00			

Tablo 4.18.'de elde edilen sonuçlara göre, köprü üzerindeki araç yoğunluğunun hava durumuna göre anlamlı bir şekilde farklılaşıp farklılaşmadığının belirlemek üzere non-parametrik Mann Whitney-U testi sonucunda havanın güneşli-bulutlu, güneşli-yağmurlu, güneşli-sağanak, güneşli-karlı durumlarına göre köprüdeki araç yoğunluk ortalamalarında anlamlı düzeyde farklılıklar elde edilmiştir.

Tablo 4.19. Araç Yoğunluk Ort. Hava Durumu Değişkenine Göre Değişimi

Hava Durumu	Ortalama			Std. Deviation	Std. Error
	N	Değer	Değişim		
Güneşli	187	171740,99	na	38854,264	2841,305
Bulutlu	594	161296,16	-6,08%	45264,288	1857,216
Güneşli	187	171740,99	-	27623,263	1687,359
Yağmurlu	67	155238,48	-9,61%	40786,117	4982,817
Güneşli	187	171740,99	-	28372,454	1831,434
Sağanak	136	152346,01	-11,29%	48526,338	4161,099
Güneşli	187	171740,99	-	38854,264	2841,305
Karlı	10	149384,90	-13,02%	52592,692	16631,269

Tablo 4.19.'da elde edilen sonuçlara göre, köprü üzerindeki araç yoğunluğunun ortalamalarının yıllara göre anlamlı düzeyde farklılıklar yaşandığı, bu farklılıkların anlamlı düzeyde değişim yaşandığı belirlenmiştir. Bulutlu havalarda, güneşli havalara göre araç yoğunlukları ortalamasının 6,08%'lik bir azalış meydana gelmiştir. Yağmurlu havalarda, güneşli havalara göre araç yoğunlukları ortalamasının 9,61%'lik bir azalış meydana gelmiştir. Sağanak yağışlı havalarda, güneşli havalara göre araç yoğunlukları ortalamasının 11,29%'luk bir azalış meydana gelmiştir. Karlı havalarda, güneşli havalara göre araç yoğunlukları ortalamasının 13,02%'lik bir azalış meydana gelmiştir.

D100 karayolu hattında 60 farklı konumun günlere göre araç yoğunluğu ile günler, aylar, mevsimler, yıllar ve konumsal olarak aralarındaki ilişkiler Chi-kare ile analiz edilmiştir. Bu konumlarda geçen araçların sayılarının 10 binden daha fazla olanlar gün sayısı ($\geq 10B$), 20 binden daha fazla olanlar gün sayısı ($\geq 20B$), 40 binden daha fazla olanlar gün sayısı ($\geq 40B$), 40 binden daha fazla olanlar gün sayısı ($\geq 40B$), 60 binden daha fazla olanlar gün sayısı ($\geq 60B$), 80 binden daha fazla olanlar gün sayısı ($\geq 80B$), 100 binden daha fazla olanlar gün sayısı ($\geq 100B$), 130 binden daha fazla olanlar gün sayısı ($\geq 130B$), 150 binden daha fazla olanlar gün sayısı ($\geq 150B$), 180 binden daha fazla olanlar gün sayısı ($\geq 180B$), 200 binden daha fazla olanlar gün sayısı ($\geq 200B$) olarak alınmıştır. Tablo 4.20.-Tablo 4.31. arasında elde edilen sonuçlara göre D100 karayolu hattında günler, aylar, mevsimler, yıllar göre araç yoğunluğu açısından anlamlı derecede ilişki elde edilmiştir. Ayrıca D100 karayolu hattında Avrupa yakası ve Anadolu yakası kısımlarında günler, aylar, mevsimler ve yıllara göre araç yoğunluğu açısından anlamlı derecede ilişki elde edilmiştir.

Table 4.20. Günlere Göre Meydana Gelen Araç Yoğunluğuna İlişkin Ki-Kare Testi Sonuçları

	>=10B	f	>=20B	f	>=40B	f	>=60B	f	>=80B	f	>=100B	f	>=130B	f	>=150B	f	>=180B	f	>=200B	f	X	p
PAZARTESİ	319	9,7	866	14,31	910	13,69	905	16,36	1884	15,83	3292	14,63	2226	13,84	1498	13,82	199	13,89	46	22,33		
SALI	337	10,3	912	15,07	899	13,52	767	13,86	1935	16,26	3455	15,36	2344	14,58	1328	12,25	177	12,35	16	7,77		
ÇARŞAMBA	273	8,3	829	13,70	933	14,03	741	13,39	1800	15,12	3438	15,28	2357	14,66	1578	14,56	210	14,65	21	10,19		
PERŞEMBE	358	10,9	822	13,58	920	13,84	733	13,25	1754	14,74	3424	15,22	2330	14,49	1612	14,87	222	15,49	25	12,14	1500,201	.000
CUMA	349	10,6	856	14,14	917	13,79	670	12,11	1704	14,32	3381	15,03	2315	14,40	1704	15,72	238	16,61	35	16,99		
CUMARTESİ	778	23,7	925	15,28	968	14,56	654	11,82	1428	12,00	2806	12,47	2332	14,50	1809	16,69	236	16,47	58	28,16		
PAZAR	873	26,6	843	13,93	1101	16,56	1063	19,21	1397	11,74	2702	12,01	2175	13,53	1311	12,09	151	10,54	5	2,43		

a.Pearson Chi-Square, $X^2=1500,201^a$, $p=0,000<0,005$, $v=0,056$

Table 4.21. Aylara Göre Meydana Gelen Araç Yoğunluğuna İlişkin Ki-Kare Testi Sonuçları

	>=10B	f	>=20B	f	>=40B	f	>=60B	f	>=80B	f	>=100B	f	>=130B	f	>=150B	f	>=180B	f	>=200B	f	X	p
OCAK	425	12,93	651	10,75	804	12,09	773	13,97	1088	9,14	1874	8,33	1197	7,44	701	6,47	87	6,07	0	0,00		
ŞUBAT	274	8,34	547	9,04	628	9,45	531	9,60	998	8,39	1758	7,81	1295	8,05	870	8,03	89	6,21	13	6,31		
MART	359	10,92	669	11,05	669	10,06	532	9,62	1101	9,25	1833	8,15	1382	8,60	825	7,61	81	5,65	15	7,28		
NİSAN	512	15,58	650	10,74	639	9,61	517	9,34	1075	9,03	1789	7,95	1209	7,52	860	7,93	91	6,35	10	4,85		
MAYIS	554	16,85	834	13,78	633	9,52	443	8,01	863	7,25	1820	8,09	1413	8,79	906	8,36	131	9,14	13	6,31		
HAZİRAN	171	5,20	418	6,91	583	8,77	381	6,89	971	8,16	1887	8,39	1466	9,12	1081	9,97	152	10,61	33	16,02	2614,183	.000
TEMMUZ	149	4,53	390	6,44	509	7,66	458	8,28	947	7,96	1919	8,53	1456	9,06	1152	10,63	162	11,30	47	22,82		
AĞUSTOS	164	4,99	329	5,44	466	7,01	376	6,80	939	7,89	2051	9,12	1426	8,87	1014	9,35	145	10,12	36	17,48		
EYLÜL	125	3,80	348	5,75	417	6,27	350	6,33	987	8,29	1998	8,88	1413	8,79	1045	9,64	136	9,49	20	9,71		
EKİM	113	3,44	368	6,08	413	6,21	292	5,28	1030	8,65	2088	9,28	1629	10,13	1030	9,50	153	10,68	8	3,88		
KASIM	188	5,72	441	7,29	466	7,01	453	8,19	1004	8,44	1880	8,36	1145	7,12	721	6,65	113	7,89	8	3,88		
ARALIK	253	7,70	408	6,74	421	6,33	427	7,72	899	7,55	1601	7,12	1048	6,52	635	5,86	93	6,49	3	1,46		

a.Pearson Chi-Square, $X^2=2614,183^a$, $p=0,000<0,005$, $v=0,059$

Table 4.22. Mevsimlere Göre Meydana Gelen Araç Yoğunluğuna İlişkin Ki-Kare Testi Sonuçları

	>=10B	f	>=20B	f	>=40B	f	>=60B	f	>=80B	f	>=100B	f	>=130B	f	>=150B	f	>=180B	f	>=200B	f	X	p
İLKBAHAR	1425	43,35	2153	35,57	1941	29,20	1492	26,97	3039	25,53	5442	24,19	4004	24,90	2591	23,90	303	21,14	38	18,45	1975,312	.000
YAZ	484	14,72	1137	18,78	1558	23,44	1215	21,96	2857	24,00	5857	26,03	4348	27,04	3247	29,95	459	32,03	116	56,31		
SONBAHAR	426	12,96	1157	19,11	1296	19,49	1095	19,79	3021	25,38	5966	26,52	4187	26,04	2796	25,79	402	28,05	36	17,48		
KIŞ	952	28,96	1606	26,53	1853	27,87	1731	31,29	2985	25,08	5233	23,26	3540	22,02	2206	20,35	269	18,77	16	7,77		

a.Pearson Chi-Square, $X^2=1975,312^a$, $p=0,000<0,005$, $v=0,088$

Table 4.23. Yıllara Göre Meydana Gelen Araç Yoğunluğuna İlişkin Ki-Kare Testi Sonuçları

	>=10B	f	>=20B	f	>=40B	f	>=60B	f	>=80B	f	>=100B	f	>=130B	f	>=150B	f	>=180B	f	>=200B	f	X	p
2016	653	19,87	2221	36,69	2711	40,78	1684	30,44	3172	26,65	4900	21,78	3503	21,79	1747	16,12	124	8,65	4	1,94	3800,963	.000
2017	602	18,31	1374	22,70	1338	20,13	973	17,59	2586	21,73	4917	21,86	3655	22,73	2373	21,89	314	21,91	77	37,38		
2018	354	10,77	662	10,94	1007	15,15	792	14,31	2001	16,81	3998	17,77	3822	23,77	2811	25,93	353	24,63	66	32,04		
2019	784	23,85	934	15,43	897	13,49	1080	19,52	2344	19,69	4342	19,30	2732	16,99	2174	20,06	344	24,01	58	28,16		
2020	894	27,20	862	14,24	695	10,45	1004	18,15	1799	15,12	4341	19,30	2367	14,72	1735	16,01	298	20,80	1	0,49		

a.Pearson Chi-Square, $X^2=3800,963^a$, $p=0,000<0,005$, $v=0,106$

Table 4.24. Avrupa Yakası Günlere Göre Meydana Gelen Araç Yoğunluğuna İlişkin Ki-Kare Testi Sonuçları

	>=10B	f	>=20B	f	>=40B	f	>=60B	f	>=80B	f	>=100B	f	>=130B	f	>=150B	f	>=180B	f	>=200B	f	X	p
PAZARTESİ	217	11,12	647	14,18	479	13,55	306	16,52	644	17,70	1609	14,25	1139	13,62	696	14,42487	100	14,08	37	22,70	637,875	.000
SALI	223	11,43	707	15,50	458	12,95	241	13,01	607	16,68	1795	15,90	1140	13,63	612	12,68394	89	12,54	15	9,20		
ÇARŞAMBA	193	9,89	642	14,07	496	14,03	238	12,85	558	15,34	1753	15,53	1218	14,56	673	13,94819	104	14,65	16	9,82		
PERŞEMBE	243	12,46	623	13,66	487	13,77	246	13,28	526	14,46	1749	15,49	1206	14,42	700	14,50777	101	14,23	18	11,04		
CUMA	221	11,33	665	14,58	507	14,34	238	12,85	480	13,19	1706	15,11	1240	14,83	712	14,75648	103	14,51	27	16,56		
CUMARTESİ	408	20,91	667	14,62	534	15,10	229	12,37	413	11,35	1359	12,04	1279	15,29	754	15,62694	112	15,77	48	29,45		
PAZAR	446	22,86	611	13,39	575	16,26	354	19,11	410	11,27	1319	11,68	1142	13,65	678	14,05181	101	14,23	2	1,23		

a.Pearson Chi-Square, $X^2=637,875^a$, $p=0,000<0,005$, $v=0,051$

Table 4.25. Avrupa Yakası Aylara Göre Meydana Gelen Araç Yoğunluğuna İlişkin Ki-Kare Testi Sonuçları

	>=10B	f	>=20B	f	>=40B	f	>=60B	f	>=80B	f	>=100B	f	>=130B	f	>=150B	f	>=180B	f	>=200B	f	X	p
OCAK	286	14,66	506	11,09	430	12,16	264	14,25	333	9,15	997	8,83	605	7,23	279	5,78	65	9,15	0	0,00		
ŞUBAT	191	9,79	437	9,58	372	10,52	187	10,10	281	7,72	843	7,47	692	8,27	370	7,67	62	8,73	13	7,98		
MART	224	11,48	515	11,29	393	11,11	200	10,80	360	9,90	818	7,25	731	8,74	363	7,52	59	8,31	15	9,20		
NİSAN	269	13,79	495	10,85	374	10,58	189	10,21	380	10,45	800	7,09	691	8,26	378	7,83	56	7,89	10	6,13		
MAYIS	249	12,76	598	13,11	343	9,70	146	7,88	249	6,84	869	7,70	783	9,36	427	8,85	58	8,17	12	7,36		
HAZİRAN	93	4,77	335	7,34	341	9,64	117	6,32	267	7,34	955	8,46	758	9,06	504	10,45	64	9,01	21	12,88	1717,217	.000
TEMMUZ	81	4,15	266	5,83	301	8,51	161	8,69	267	7,34	926	8,20	813	9,72	512	10,61	50	7,04	28	17,18		
AĞUSTOS	85	4,36	235	5,15	249	7,04	104	5,62	286	7,86	1019	9,03	758	9,06	462	9,58	50	7,04	27	16,56		
EYLÜL	99	5,07	257	5,63	185	5,23	97	5,24	283	7,78	1086	9,62	708	8,46	476	9,87	46	6,48	18	11,04		
EKİM	89	4,56	279	6,12	159	4,50	84	4,54	265	7,28	1139	10,09	797	9,53	462	9,58	73	10,28	8	4,91		
KASIM	132	6,77	324	7,10	208	5,88	163	8,80	351	9,65	984	8,72	522	6,24	319	6,61	69	9,72	8	4,91		
ARALIK	153	7,84	315	6,90	181	5,12	140	7,56	316	8,69	854	7,56	506	6,05	273	5,66	58	8,17	3	1,84		

a.Pearson Chi-Square, $X^2=1717,217^a$, $p=0,000<0,005$, $v=0,051$

Table 4.26. Avrupa Yakası Mevsimlere Göre Meydana Gelen Araç Yoğunluğuna İlişkin Ki-Kare Testi Sonuçları

	>=10B	f	>=20B	f	>=40B	f	>=60B	f	>=80B	f	>=100B	f	>=130B	f	>=150B	f	>=180B	f	>=200B	f	X	p
İLKBAHAR	742	38,03	1608	35,25	1110	31,39	535	28,89	989	27,19	2487	22,03	2205	26,36	1168	24,21	173	24,37	37	22,70		
YAZ	259	13,28	836	18,33	891	25,20	382	20,63	820	22,54	2900	25,69	2329	27,85	1478	30,63	164	23,10	76	46,63	1246,398	.000
SONBAHAR	320	16,40	860	18,85	552	15,61	344	18,57	899	24,71	3209	28,42	2027	24,23	1257	26,05	188	26,48	34	20,86		
KIŞ	630	32,29	1258	27,58	983	27,80	591	31,91	930	25,56	2694	23,86	1803	21,56	922	19,11	185	26,06	16	9,82		

a.Pearson Chi-Square, $X^2=1246,398^a$, $p=0,000<0,005$, $v=0,101$

Table 4.27. Avrupa Yakası Yıllara Göre Meydana Gelen Araç Yoğunluğuna İlişkin Ki-Kare Testi Sonuçları

	>=10B	f	>=20B	f	>=40B	f	>=60B	f	>=80B	f	>=100B	f	>=130B	f	>=150B	f	>=180B	f	>=200B	f	X	p
2016	563	28,86	1998	43,80	1933	54,67	695	37,53	974	26,77	1933	17,12	2205	26,36	826	17,12	66	9,30	4	2,45		
2017	421	21,58	924	20,25	631	17,85	274	14,79	592	16,27	2018	17,87	2099	25,10	1304	27,03	239	33,66	77	47,24		
2018	126	6,46	426	9,34	483	13,66	237	12,80	576	15,83	2063	18,27	2163	25,86	1168	24,21	211	29,72	54	33,13	5159,391	.000
2019	460	23,58	696	15,26	254	7,18	333	17,98	866	23,80	2529	22,40	1069	12,78	877	18,18	147	20,70	27	16,56		
2020	381	19,53	518	11,35	235	6,65	313	16,90	630	17,32	2747	24,33	828	9,90	650	13,47	47	6,62	1	0,61		

a.Pearson Chi-Square, $X^2=1246,398^a$, $p=0,000<0,005$, $v=0,178$

Table 4.28. Anadolu Yakası Günlere Göre Meydana Gelen Araç Yoğunluğuna İlişkin Ki-Kare Testi Sonuçları

	>=10B	f	>=20B	f	>=40B	f	>=60B	f	>=80B	f	>=100B	f	>=130B	f	>=150B	f	>=180B	f	>=200B	f	X	p
PAZARTESİ	73	7,0	176	14,75	325	13,79	420	15,56	985	15,34	1548	15,10	914	14,11	747	13,22	99	13,69	9	20,93		
SALI	84	8,0	160	13,41	337	14,30	376	13,93	1062	16,53	1496	14,60	1022	15,77	688	12,18	88	12,17	1	2,33		
ÇARŞAMBA	55	5,2	147	12,32	330	14,00	370	13,71	962	14,98	1518	14,81	957	14,77	868	15,37	106	14,66	5	11,63		
PERŞEMBE	85	8,1	157	13,16	325	13,79	369	13,67	931	14,49	1520	14,83	942	14,54	870	15,40	121	16,74	7	16,28	1065,401	.000
CUMA	92	8,8	154	12,91	314	13,32	333	12,34	898	13,98	1515	14,78	915	14,12	938	16,60	135	18,67	8	18,60		
CUMARTESİ	302	28,8	219	18,36	336	14,26	306	11,34	750	11,68	1358	13,25	888	13,71	950	16,82	124	17,15	10	23,26		
PAZAR	359	34,2	180	15,09	390	16,55	525	19,45	835	13,00	1295	12,63	841	12,98	588	10,41	50	6,92	3	6,98		

a.Pearson Chi-Square, $X^2=1065,401^a$, $p=0,000<0,005$, $v=0,069$

Table 4.29. Anadolu Yakası Mevsimlere Göre Meydana Gelen Araç Yoğunluğuna İlişkin Ki-Kare Testi Sonuçları

	>=10B	f	>=20B	f	>=40B	f	>=60B	f	>=80B	f	>=100B	f	>=130B	f	>=150B	f	>=180B	f	>=200B	f	X	p
İLKBAHAR	518	49,33	448	37,55	616	26,13	697	25,82	1613	25,11	2711	26,45	1542	23,80	1354	23,97	130	17,98	1	2,33		
YAZ	165	15,71	217	18,19	519	22,02	588	21,79	1560	24,29	2703	26,37	1764	27,23	1659	29,37	295	40,80	40	93,02		
SONBAHAR	81	7,71	236	19,78	576	24,44	549	20,34	1546	24,07	2549	24,87	1764	27,23	1432	25,35	214	29,60	2	4,65		
KIŞ	286	27,24	292	24,48	646	27,41	865	32,05	1704	26,53	2287	22,31	1409	21,75	1204	21,31	84	11,62	0	0,00	1001,929	.000

a.Pearson Chi-Square, $X^2=1001,929^a$, $p=0,000<0,005$, $v=0,095$

Table 4.30. Anadolu Yakası Aylara Göre Meydana Gelen Araç Yoğunluğuna İlişkin Ki-Kare Testi Sonuçları

	>=10B	f	>=20B	f	>=40B	f	>=60B	f	>=80B	f	>=100B	f	>=130B	f	>=150B	f	>=180B	f	>=200B	f	X	p
OCAK	118	11,24	120	10,06	290	12,30	405	15,01	646	10,06	789	7,70	474	7,32	400	7,08	22	3,04	0	0,00		
ŞUBAT	74	7,05	97	8,13	185	7,85	258	9,56	584	9,09	839	8,19	493	7,61	466	8,25	27	3,73	0	0,00		
MART	109	10,38	113	9,47	207	8,78	262	9,71	593	9,23	931	9,08	545	8,41	438	7,75	22	3,04	0	0,00		
NİSAN	176	16,76	127	10,65	209	8,87	243	9,00	545	8,49	904	8,82	438	6,76	460	8,14	35	4,84	0	0,00		
MAYIS	233	22,19	208	17,44	200	8,49	192	7,11	475	7,40	876	8,55	559	8,63	456	8,07	73	10,10	1	2,33		
HAZİRAN	59	5,62	60	5,03	166	7,04	162	6,00	550	8,56	868	8,47	604	9,32	547	9,68	88	12,17	12	27,91	1441,516	.000
TEMMUZ	43	4,10	94	7,88	168	7,13	223	8,26	508	7,91	884	8,62	585	9,03	612	10,83	112	15,49	19	44,19		
AĞUSTOS	63	6,00	63	5,28	185	7,85	203	7,52	502	7,82	951	9,28	575	8,87	500	8,85	95	13,14	9	20,93		
EYLÜL	19	1,81	67	5,62	217	9,21	205	7,60	476	7,41	851	8,30	580	8,95	511	9,05	90	12,45	2	4,65		
EKİM	18	1,71	74	6,20	186	7,89	134	4,96	562	8,75	888	8,66	662	10,22	537	9,51	80	11,07	0	0,00		
KASIM	44	4,19	95	7,96	173	7,34	210	7,78	508	7,91	810	7,90	522	8,06	384	6,80	44	6,09	0	0,00		
ARALIK	94	8,95	75	6,29	171	7,25	202	7,48	474	7,38	659	6,43	442	6,82	338	5,98	35	4,84	0	0,00		

a.Pearson Chi-Square, $X^2=1441,516^a$, $p=0,000<0,005$, $v=0,066$

Table 4.31. Anadolu Yakası Yıllara Göre Meydana Gelen Araç Yoğunluğuna İlişkin Ki-Kare Testi Sonuçları

	>=10B	f	>=20B	f	>=40B	f	>=60B	f	>=80B	f	>=100B	f	>=130B	f	>=150B	f	>=180B	f	>=200B	f	X	p
2016	76	7,24	152	12,74	526	22,32	841	31,16	1945	30,28	2772	27,04	1105	17,06	907	16,06	58	8,02	0	0,00		
2017	143	13,62	386	32,36	419	17,78	405	15,01	1615	25,14	2721	26,55	1285	19,83	972	17,21	75	10,37	0	0,00		
2018	188	17,90	205	17,18	468	19,86	364	13,49	1041	16,21	1842	17,97	1327	20,48	1431	25,33	142	19,64	12	27,91	2346,292	.000
2019	264	25,14	176	14,75	551	23,38	578	21,42	1011	15,74	1575	15,37	1418	21,89	1276	22,59	197	27,25	31	72,09		
2020	379	36,10	274	22,97	393	16,67	511	18,93	811	12,63	1340	13,07	1344	20,74	1063	18,82	251	34,72	0	0,00		

a.Pearson Chi-Square, $X^2=2346,292^a$, $p=0,000<0,005$, $v=0,126$

4.7.2 D100 Karayolunun Trafik Olaylarının İstatistiksel Analizi

Ulaşım sisteminin gelecekteki yönü olan Akıllı Ulaşım Sistemlerinde üretilen büyük veri, giderek araştırmaların odağı haline geliyor. Elde edilen büyük veri sayesinde daha güvenli, verimli ve karlı akıllı ulaşım sistemlerinin tasarlanması ve uygulanmasında önemli bir yere sahip olacaktır. ITS'de akıllı kartlar, GPS, sensörler, video dedektörler ve sosyal medya aracılığıyla elde edilen büyük veriler, doğru ve etkin veri analizi ile ITS'yi daha verimli bir noktaya taşıyabilir (Shi ve Abdel-Aty, 2015). ITS'de elde edilen verilerin artan miktarı ve karmaşıklığı nedeniyle geleneksel veri işleme ve analiz yöntemlerinin yetersizliği ortaya çıkmaktadır. Büyük veri analizi, ITS'ye bu sorunun çözümünde yeni teknikler ve yöntemler sunmaktadır. Büyük veri analizi ile ITS'de verilerin işleme verimliliğini artırarak, güncel ve geçmiş verilerin analizi ile gerçek zamanlı trafik akış tahmini, toplu taşıma hizmeti planlaması, optimal rota planlaması, trafik kazası olayı ve konum tahmini büyük faydalar sağlayabilir. (Zhu ve diğerleri, 2018).

Ulaşım verilerinin sosyal medyadan toplanması, kullanıcıların ihtiyaç ve bakış açılarının aşılmasında büyük öneme sahip yeni bir alandır ve ulaşım planlaması, yönetimi ve kontrolünde kullanımı literatürde önemli bir trafik veri kaynağı haline gelmektedir. Birçok olay ve olayın tespiti için faydalı veriler elde edilebilir (Grant-Muller ve ark. 2015; Pender ve ark. 2014). Çalışmamızın temel amacı İstanbul trafiğinin güvenliğini analiz etmektir. Trafik olaylarının sayısallaştırılması, 35697 trafik olayı mesaj verisi kullanılarak gerçekleştirilmiştir. Trafik olaylarının gün, ay, mevsim ve şerit gibi kriterlerle ilişkileri belirlendi. Trafik olaylarının analizi ki-kare yöntemiyle belirlendi. Bu parametreler ile trafik olayları arasında önemli ilişkiler elde edilmiştir. Bu çalışmada 2016-2020 yılları arasında İstanbul trafiğinde meydana gelen 33967 trafik olayının saat, gün, ay, yıl, mevsim, hava durumu, araç yoğunluğu gibi kriterlerle ilişkisi ki-kare yöntemi kullanılarak analiz edilmiştir. Elde edilen parametrelere göre makine öğrenmesi yöntemleri ile tahmin modellemesi yapılmıştır.

2016-2020 yılları arasında İstanbul trafiğinde meydana gelen trafik olaylarının değerlendirilmesinde ki-kare testleri kullanılmıştır. Trafik olayları kaza bildirimi, yol bakım-onarım işleri ve araç arızası olmak üzere üç kategoride değerlendirilmiştir. Saat, gün, ay, mevsim gibi parametreler ile trafik olayları arasında bir ilişki olup olmadığı

ve trafik olaylarının bu parametrelerden bağımsız olup olmadığı değerlendirilmiştir. Ayrıca trafik olaylarında hasarlı, yaralı, zincir, yoğunluk, sol, sağ, orta şerit gibi parametreler ile saat, gün, ay, mevsim gibi parametreler arasındaki ilişki incelenmiştir. Sınıflandırma işleminde günler Pazartesi:1, Salı:2, Çarşamba:3, Perşembe:4, Cuma:5, Cumartesi:6, Pazar:7 olarak tanımlanır. Aylar Ocak:1, Şubat:2, Mart:3, Nisan:4, Mayıs:5, Haziran:6, Temmuz:7, Ağustos:8, Eylül:9, Ekim:10, Kasım:11, Aralık: 12 . Mevsimler İlkbahar:1, Yaz:2, Sonbahar:3, Kış:4 olarak tanımlanmıştır.

Trafik olayları ile ilgili mesajlara örnek verecek olursak: “D100 15 Temmuz Şehitler Köprüsü Avrupa-Anadolu Yönü, sağ şerit araç arızası”. “Bölgede trafik yoğun, D100 Maltepe-Küçükyalı Yönü, sağ şeritteki araç arızası nedeniyle bölgedeki trafik yoğunlaşıyor”. “D100 Maltepe-Küçükyalı Yönü, orta şeritteki araç arızası nedeniyle bölgedeki trafik yoğunlaştı”.

Table 4.32. Trafik olaylarının sayısallaştırılması

Aylar	Günler	Zaman	Olay Türü	Hasarlı	Zincirleme	Yaralanma	Yoğunluk	Sol Şerit	Sağ Şerit	Orta Şerit
Ocak	Pazartesi	Öğle	Kaza Bildirimi	0	1	0	0	1	0	0
Şubat	Salı	Sabah	Araç Arızası	0	0	0	1	0	1	0
Mart	Çarşamba	Öğle	Araç Arızası	0	0	0	1	0	1	0
Nisan	Perşembe	Öğle	Bakım-Onarım Çalışması	0	0	0	0	0	1	0
Mayıs	Cuma	Sabah	Kaza Bildirimi	1	0	0	0	1	0	0
Haziran	Cumartesi	Akşam	Bakım-Onarım Çalışması	0	0	0	0	0	1	0
Temmuz	Pazar	Gece	Araç Arızası	0	0	0	1	0	1	0
Ağustos	Pazartesi	Akşam	Bakım-Onarım Çalışması	0	0	0	0	0	1	0
Eylül	Salı	Öğle	Kaza Bildirimi	1	0	0	0	1	0	0
Ekim	Çarşamba	Sabah	Araç Arızası	0	0	0	1	0	1	0
Kasım	Perşembe	Gece	Kaza Bildirimi	0	1	0	0	1	0	0
Aralık	Cuma	Gece	Araç Arızası	0	0	0	1	0	1	0

Table 4.33. Saatlere Göre Meydana Gelen Trafik Olaylarına İlişkin Ki-Kare Testi

Sonuçları

Saatler	Araç Arızası	f	Bakım-Onarım Çalışması	f	Kaza Bildirimi	f	Toplam	f	X ²	p
Sabah	5808	31,67%	971	39,98%	4482	30,02%	11261	31,55%		
Öğle	6749	36,80%	715	29,44%	5403	36,19%	12867	36,05%		
Akşam	5276	28,77%	241	9,92%	4025	26,96%	9545	26,74%	1653,957 ^a	.000
Gece	507	2,76%	502	20,67%	1018	6,82%	2030	5,69%		
Toplam	18340	51,38%	2429	6,80%	14928	41,82%	35697	100,00%		

a.Pearson Chi-Square, $X^2=1653,957$, $p=0,000<0,005$, $v=0,152$

Elde edilen sonuçlara göre ($X^2=1653.957^a$, $p=0,000<0,005$) trafik olayları ile saatler arasında anlamlı bir ilişki olduğu tespit edilmiştir. Tablo 4.33.'de elde edilen sonuçlara göre İstanbul trafiğinde meydana gelen 35697 trafik olayının %51,35'i araç arızası, %6,80'i yol bakım-onarım işleri ve %41,82'i kaza bildirimidir. Ayrıca trafik olaylarının %31,55'si sabah, %36,05'si öğlen, %26,74'si akşam ve %5,69'i gece meydana geldi. En fazla araç arıza zamanı %36,80 ile öğlen, yol bakım-onarım işi %39,98 ile sabah, en yüksek kaza bildirim zamanı ise %36,19 ile öğlen oldu.

Table 4.34. Günlere Göre Meydana Gelen Trafik Olaylarına İlişkin Ki-Kare Testi

Sonuçları									
Günler	Araç Arızası	f	Bakım-Onarım Çalışması	f	Kaza Bildirimi	f	Toplam	f	X ²
Pazartesi	3175	17,31%	295	12,14%	2284	15,30%	5754	16,12%	274,379 ^a .000
Salı	2966	16,17%	383	15,77%	2225	14,90%	5574	15,61%	
Çarşamba	2956	16,12%	372	15,31%	2261	15,15%	5589	15,66%	
Perşembe	3036	16,55%	389	16,01%	2297	15,39%	5722	16,03%	
Cuma	2998	16,35%	358	14,74%	2406	16,12%	5762	16,14%	
Cumartesi	1918	10,46%	325	13,38%	1833	12,28%	4076	11,42%	
Pazar	1291	7,04%	307	12,64%	1622	10,87%	3220	9,02%	
Toplam	18340	51,38%	2429	6,80%	14928	41,82%	35697	100,00%	

a.Pearson Chi-Square, $X^2=274,379^a$, $p=0,000<0,005$, $v=0,062$

Elde edilen sonuçlara göre ($X^2=274.379^a$, $p=0,000<0,005$) trafik olayları ile günler arasında anlamlı bir ilişki olduğu tespit edilmiştir. Tablo 4.34.'te elde edilen sonuçlara göre araç arızası Perşembe günü %16,55, Perşembe günü bakım-onarım işi %16,01, kaza bildirimi ise Cuma günü %16,12 olarak gerçekleşmiştir. Trafik olaylarının çoğu %16,14 ile Cuma günü meydana geldi.

Table 4.35. Aylara Göre Meydana Gelen Trafik Olaylarına İlişkin Ki-Kare Testi

Sonuçları

Aylar	Araç Arızası	f	Bakım-Onarım Çalışması	f	Kaza Bildirimi	f	Toplam	f	X ²	p
Ocak	2013	10,98%	246	10,13%	1605	10,75%	3864	10,82%	181,168 ^a	0,000
Şubat	1723	9,39%	228	9,39%	1314	8,80%	3265	9,15%		
Mart	1683	9,18%	220	9,06%	1428	9,57%	3331	9,33%		
Nisan	946	5,16%	239	9,84%	961	6,44%	2146	6,01%		
Mayıs	962	5,25%	128	5,27%	909	6,09%	1999	5,60%		
Haziran	1729	9,43%	153	6,30%	1251	8,38%	3133	8,78%		
Temmuz	1952	10,64%	287	11,82%	1403	9,40%	3642	10,20%		
Ağustos	1376	7,50%	176	7,25%	1178	7,89%	2730	7,65%		
Eylül	1535	8,37%	193	7,95%	1296	8,68%	3024	8,47%		
Ekim	1597	8,71%	246	10,13%	1302	8,72%	3145	8,81%		
Kasım	1348	7,35%	149	6,13%	1197	8,02%	2694	7,55%		
Aralık	1476	8,05%	164	6,75%	1084	7,26%	2724	7,63%		
Toplam	18340	51,38%	2429	6,80%	14928	41,82%	35697	100,00%		

a.Pearson Chi-Square, $X^2=181,168^a$, $p=0,000<0,005$, $v=0,050$

Elde edilen sonuçlara göre ($X^2=181,168^a$, $p=0,000<0,005$) trafik olayları ile aylar arasında anlamlı bir ilişki olduğu tespit edilmiştir. Tablo 4.35.'te elde edilen sonuçlara göre araç arızası Ocak ayında %10,98, Temmuz ayında %11,82 ile bakım-onarım ve Ocak ayında %10,75 ile kaza bildirimi meydana gelmiştir. Trafik olaylarının çoğu %10,82 ile Ocak ayında meydana geldi.

Table 4.36. Şeritlere Göre Meydana Gelen Trafik Olaylarına İlişkin Ki-Kare Testi

Sonuçları

Şerit	Araç Arızası	f	Bakım-Onarım Çalışması	f	Kaza Bildirimi	f	Toplam	f	X ²	p
Sol	2172	12,41%	879	40,01%	4959	38,05%	8010	24,47%	3346,568 ^a	0,000
Orta	1235	7,06%	11	0,50%	1240	9,51%	2486	7,60%		
Sağ	14094	80,53%	1307	59,49%	6835	52,44%	22236	67,93%		
Toplam	17501	53,47%	2197	6,71%	13034	39,82%	32732	100,00%		

a.Pearson Chi-Square, $X^2=3346,568^a$, $p=0,000<0,005$, $v=0,226$

Elde edilen sonuçlara göre ($X^2=3346,568^a$, $p=0,000<0,005$) trafik olayları ile şerit arasında anlamlı bir ilişki olduğu tespit edilmiştir. Tablo 4.36.'da elde edilen sonuçlara göre araç arızası %80,53 ile sağ şeritte, %59,49 ile bakım-onarım işi ve sağ şeritte %52,44 ile araç kazası meydana gelmiştir. Trafik olaylarının çoğu %67,93 ile sağ şeritte meydana geldi.

Table 4.37. Mevsimlere Göre Meydana Gelen Trafik Olaylarına İlişkin Ki-Kare Testi Sonuçları

Mevsimler	Araç Arızası	f	Bakım-Onarım Çalışması	f	Kaza Bildirimi	f	Toplam	f	X ²	p
İlkbahar	3591	19,58%	587	24,17%	3298	22,09%	7476	20,94%		
Yaz	5057	27,57%	616	25,36%	3832	25,67%	9505	26,63%		
Sonbahar	4480	24,43%	588	24,21%	3795	25,42%	8863	24,83%	63,542 ^a	0,000
Kış	5212	28,42%	638	26,27%	4003	26,82%	9853	27,60%		
Toplam	18340	51,38%	2429	6,80%	14928	41,82%	35697	100,00%		

a. Pearson Chi-Square, X²=63,542^a, p=0,000<0,005, v=0,030

Elde edilen sonuçlara göre ($X^2=63,542^a$, $p=0,000<0,005$) trafik olayları ile mevsimler arasında anlamlı bir ilişki olduğu tespit edilmiştir. Tablo 4.37.'de elde edilen sonuçlara göre kış mevsiminde %24,42 araç arızası, %26,72 kış mevsiminde bakım-onarım ve %26,82 kış mevsiminde araç kazası meydana gelmiştir. Trafik olaylarının çoğu %27,60 ile kış mevsiminde meydana gelmiştir.

İstanbul'da trafik güvenliği analizinde, trafik olay türlerinin gün, ay, mevsim, şerit parametreleri ile ilişkili olup olmadığı ki-kare yöntemi kullanılarak belirlenmiştir. Elde edilen sonuçlara göre İstanbul trafiğinde meydana gelen kaza olayları, araç arızaları ve bakım-onarım işleri ve günleri arasında anlamlı bir ilişki elde edilmiştir. Araç arızaları ve bakım-onarım çalışmaları sabah saatlerinde daha sık olurken, kaza olayları daha çok öğleden sonra meydana geldi. Gündüz ve trafik olayları arasındaki anlamlı ilişki sonucunda araç arızaları ve bakım-onarım çalışmaları Perşembe günleri daha sık olurken, kaza olayları daha çok Cuma günleri meydana geldi. Aylar ve trafik olayları arasındaki anlamlı ilişki sonucunda, araç arızalarının en fazla olduğu ayın Ocak ayı olduğu, bakım-onarım çalışmalarının en çok Temmuz ayında yapıldığı ve en fazla kaza olayının Ocak ayında meydana geldiği belirlendi. . Mevsimler ve trafik olayları arasındaki anlamlı ilişki sonucunda, araç arızalarının büyük çoğunluğunun kış mevsiminde meydana geldiği, bakım-onarım işlerinin ve kaza olaylarının ise daha çok kış mevsiminde gerçekleştirildiği sonucuna varılmıştır. Şeritler ve trafik olayları arasındaki anlamlı ilişki sonucunda araç arızası, bakım-onarım çalışmaları ve kaza olaylarının diğer şeritlere göre sağ şeritte daha sık meydana geldiği sonucuna varılmıştır. İstanbul trafiğinde öğle yemeği saatleri, Perşembe ve Cuma, Ocak ve Temmuz, Kış mevsimi ve sağ şerit trafik güvenliği açısından önemli parametrelerdir.

Köprü üzerinde gerçekleşen trafik olaylarının değerlendirilmesinde Ki-kare testlerinden yararlanılmıştır. Gerçekleştirilen trafik olayları kaza bildirimi ve araç arızası olmak üzere iki kategori üzerinden değerlendirilmiştir. Saatler, günler, aylar, mevsimler ve hava durumu gibi parametreler ile trafik olayları arasında bir ilişkinin olup olmadığı, trafik olaylarının bu parametrelerden bağımsız olup olmadığı değerlendirilmiştir. Ayrıca kaza olaylarında hasarlı, yaralanmalı, zincirleme, yoğunluk, sol, sağ, orta şerit gibi parametreler ile saatler, günler, aylar, mevsimler ve hava durumu gibi parametreler ile ilişkisi incelenmiştir.

Tablo 4.38. Saatlere Göre Gerçekleşen Trafik Olaylarına İlişkin Ki-Kare Testi Sonuçları

Saatler	Araç Arızası	f	Kaza	Toplam	f	X ²	p
Sabah	132	21,8%	153	19,7%	285	20,6%	14,015 ^a 0,003
Öğle	194	32,0%	233	30,0%	427	30,9%	
Akşam	239	39,4%	290	37,4%	529	38,3%	
Gece	41	6,8%	100	12,9%	141	10,2%	

a.Pearson Chi-Square, $X^2=14,015$, $p=0,003<0,005$, $v=0,101$

Tablo 4.38.'de köprü üzerinde gerçekleşen trafik olaylarının saatlere göre farklılaşıp farklılaşmadığını incelemek için Ki-Kare testi kullanılmıştır. Elde edilen sonuçlara göre ($X^2=14,015$, $p=0,003<0,005$) köprü üzerinde gerçekleşen trafik olayları ile saatler arasında bir anlamlı bir ilişkinin olduğu tespit edilmiştir. Trafik olaylarının saatlerden bağımsız olmadığı ve akşam saatlerinde gerçekleşen trafik olaylarının daha fazla olduğu sonucuna varılmıştır.

Tablo 4.39. Günlere Göre Gerçekleşen Trafik Olaylarına İlişkin Ki-Kare Testi Sonuçları

Günler	Araç Arızası	f	Kaza	Toplam	f	X ²	p
Pazartesi	107	17,7%	98	12,6%	205	14,8%	31,261 ^a 0,000
Salı	90	14,9%	87	11,2%	177	12,8%	
Çarşamba	79	13,0%	94	12,1%	173	12,5%	
Perşembe	101	16,7%	109	14,0%	210	15,2%	
Cuma	101	16,7%	130	16,8%	231	16,7%	
Cumartesi	61	10,1%	145	18,7%	206	14,9%	
Pazar	67	11,1%	113	14,6%	180	13,0%	

a.Pearson Chi-Square, $X^2=31,261$, $p=0,000<0,005$, $v=0,150$

Tablo 4.39.'da köprü üzerinde gerçekleşen trafik olaylarının günlere göre farklılaşıp farklılaşmadığını incelemek için Ki-Kare testi kullanılmıştır. Elde edilen

sonuçlara göre ($X^2=31,261$, $p=0,000<0,005$) köprü üzerinde gerçekleşen trafik olayları ile günler arasında anlamlı bir ilişkinin olduğu tespit edilmiştir. Trafik olaylarının günlerden bağımsız olmadığı ve araç arızalarının daha çok pazartesi günleri yaşandığı, kaza olaylarının ise cumartesi daha fazla olduğu sonucuna varılmıştır.

Tablo 4.40. Aylara Göre Gerçekleşen Trafik Olaylarına İlişkin Ki-Kare Testi Sonuçları

Aylar	Araç Arızası	f	Kaza	f	Toplam	f	X^2	p
Ocak	42	6,9%	81	10,5%	123	8,9%	14,805 ^a	0,192
Şubat	56	9,2%	59	7,7%	115	8,3%		
Mart	37	6,0%	51	6,6%	88	6,4%		
Nisan	41	6,7%	56	7,3%	97	7,0%		
Mayıs	39	6,4%	61	7,9%	100	7,2%		
Haziran	58	9,5%	78	10,1%	136	9,8%		
Temmuz	74	12,1%	79	10,2%	153	11,1%		
Ağustos	61	10,0%	69	8,9%	130	9,4%		
Eylül	38	6,2%	63	8,2%	101	7,3%		
Ekim	63	10,3%	57	7,4%	120	8,7%		
Kasım	57	9,3%	67	8,7%	124	9,0%		
Aralık	46	7,5%	50	6,5%	96	6,9%		

a.Pearson Chi-Square, $X^2=14,805$, $p=0,192<0,005$, $v=0,103$

Tablo 4.40.'da elde edilen sonuçlara göre ($X^2=14,805$, $p=0,192>0,005$) köprü üzerinde gerçekleşen trafik olayları ile aylar arasında bir anlamlı bir ilişkinin olmadığı tespit edilmiştir.

Tablo 4.41. Mevsimlere Göre Gerçekleşen Trafik Olaylarına İlişkin Ki-Kare Testi Sonuçları

Mevsimler	Araç Arızası	f	Kaza	f	Toplam	f	x	p
İlkbahar	117	19,3%	168	21,6%	285	20,6%	1,828 ^a	0,609
Kış	144	23,8%	190	24,5%	334	24,2%		
Sonbahar	152	25,1%	192	24,7%	344	24,9%		
Yaz	193	31,8%	226	29,1%	419	30,3%		

a.Pearson Chi-Square, $X^2=1,828$ $p=0,609>0,005$, $v=0,036$

Tablo 4.41.'de elde edilen sonuçlara göre ($X^2=1,828$, $p=0,609>0,005$) köprü üzerinde gerçekleşen trafik olayları ile mevsimler arasında bir anlamlı bir ilişkinin olmadığı tespit edilmiştir.

Tablo 4.42. Şeritlere Göre Gerçekleşen Trafik Olaylarına İlişkin Ki-Kare Testi Sonuçları

Şeritler	Araç Arızası	f	Kaza	f	Toplam	f	X ²	p
Sağ	438	86,2%	242	40,6%	680	61,6%		
Sol	36	7,1%	307	51,5%	343	31,1%	267,379 ^a	0,000
Orta	34	6,7%	47	7,9%	81	7,3%		

a.Pearson Chi-Square, $X^2=267,379$, $p=0,000<0,005$, $v=0,492$

Tablo 4.42.'de elde edilen sonuçlara göre ($X^2=267,379$, $p=0,000<0,005$) köprü üzerinde gerçekleşen trafik olayları ile şeritler arasında bir anlamlı bir ilişkinin olduğu tespit edilmiştir. Sağ şeritte trafik olaylarının 86,2%'sında araç arızası meydana gelirken, 40,6%'sında kaza meydana gelmiştir. Sol şeritte trafik olaylarının 7,1%'inde araç arızası meydana gelirken, 51,5%'inde kaza meydana gelmiştir.

Tablo 4.43. Yoğunluğa Göre Gerçekleşen Trafik Olaylarına İlişkin Ki-Kare Testi Sonuçları

Yoğunluk	Araç Arızası	f	Kaza	f	Toplam	f	X ²	p
Yoğunluk Var	584	49,4%	178	89,0%	762	55,1%		
Yoğunluk Yok	598	50,6%	22	11,0%	620	44,9%	108,400 ^a	0,000

a.Pearson Chi-Square, $X^2=108,400^a$, $p=0,000<0,005$, $v=0,280$

Tablo 4.43.'te elde edilen sonuçlara göre ($X^2=108,400^a$, $p=0,000<0,005$) köprü üzerinde gerçekleşen trafik olayları ile yoğunluk arasında anlamlı bir ilişkinin olduğu tespit edilmiştir. Kaza olaylarının 89.0% 'da yoğunluk meydana gelmişken, araç arızalarının ise 50,6%'da yoğunluk meydana gelmiştir.

Tablo 4.44. Şeritlere Göre Kazalarda Yoğunluğa İlişkin Ki-Kare Testi Sonuçları

Şeritler	Yoğunluk Var	f	Yoğunluk Yok	f	Toplam	f	X ²	p
Sol	81	14,80%	365	49,30%	446	34,60%		
Sağ	440	80,40%	325	43,90%	765	59,40%	181,136 ^a	0,000
Orta	26	4,80%	51	6,90%	77	6,00%		

a.Pearson Chi-Square, $X^2=181,136^a$, $p=0,000<0,005$, $v=0,375$

Tablo 4.44.'de elde edilen sonuçlara göre ($X^2=181,136^a$, $p=0,000<0,005$) köprü üzerinde gerçekleşen trafik olaylarında şeritler ile oluşan yoğunluk arasında anlamlı düzeyde bir ilişkinin olduğu tespit edilmiştir. Sol şeritte gerçekleşen trafik olaylarında 14,8%'inde yoğunluk meydana gelmişken, sağ şeritte gerçekleşen trafik olaylarında 80,4%'inde, orta şeritte gerçekleşen trafik olaylarında ise 4,8%'inde yoğunluk meydana gelmiştir. Sol şeritte gerçekleşen trafik olaylarında 49,30%'unde yoğunluk

oluşmamışken, sağ şeritte gerçekleşen trafik olaylarında 43,9%'inde, orta şeritte gerçekleşen trafik olaylarında ise 6,9%'inde yoğunluk meydana gelmemiştir.

Tablo 4.45. Günlere Göre Kazalarda Şeritlere İlişkin Ki-Kare Testi Sonuçları

Günler	Orta	f	Sağ	f	Sol	f	Toplam	f	X ²	p
Pazartesi	13	14,3%	125	16,3%	75	16,5%	213	16,3%		
Salı	14	15,4%	110	14,4%	61	13,4%	185	14,1%		
Çarşamba	15	16,5%	110	14,4%	48	10,6%	173	13,2%		
Perşembe	18	19,8%	129	16,9%	60	13,2%	207	15,8%	25,215 ^a	0,014
Cuma	13	14,3%	125	16,3%	75	16,5%	213	16,3%		
Cumartesi	7	7,7%	83	10,8%	84	18,5%	174	13,3%		
Pazar	8	8,8%	93	12,2%	63	13,9%	164	12,5%		

a.Pearson Chi-Square, X²=25,215^a, p=0,000<0,005, v=0,375

Tablo 4.45.'te elde edilen sonuçlara göre ($X^2=25,215^a$, $p=0,000<0,005$) köprü üzerinde gerçekleşen trafik olaylarında günler ile şeritler arasında anlamlı düzeyde bir ilişkinin olduğu tespit edilmiştir. Orta şeritte gerçekleşen trafik olaylarında 19,8%'i ile en çok perşembe ve 7,7% ile en az cumartesi günlerinde gerçekleşmiştir. Sağ şeritte gerçekleşen trafik olaylarında 16,9% ile en çok perşembe ve 10,8% ile en az cumartesi günlerinde gerçekleşmiştir. Sol şeritte gerçekleşen trafik olaylarında 18,5% ile en çok cumartesi ve 10,6% ile en az çarşamba günlerinde gerçekleşmiştir.

Gerçekleştirilen istatistiksel analizler sonucunda D100 karayolu hattında meydana gelen 35697 trafik olayları ile 15 Temmuz Şehitler Köprüsü üzerinde meydana gelen araç arızası ve kaza olayları ile aylar, günler, mevsimler, şeritler açısından anlamlı derecede ilişkiler elde edilmiştir. Ayrıca gerçekleşen trafik olaylarının yoğunluk oluşturması açısından da anlamlı derecede ilişki elde edilmiştir. Veri madenciliği ile elde edilen veriler analiz edilerek D100 karayolu hattı boyunca trafiğe etki eden parametreler belirlenmiştir. Elden edilen sonuçlar doğrultusunda D100 karayolu hattının trafik yoğunluk durumu ve gerçekleşebilecek trafik olaylarının modellenmesinde makine öğrenmesi yöntemlerinden yararlanılmıştır.

4.8. Makine Öğrenmesi Yöntemleri ile Trafik Analiz Modellemesi


4.8.1. Yapay Sinir Ağı İle Trafik Yoğunluk Modellemesi

Trafik araç yoğunluğunun yapay sinir ağı ile tahminleme modellemesinde kullanılacak parametreler istatistiksel analizler sonucunda elde edilmiştir. Trafik araç yoğunluğu, gün, ay, mevsim, şerit, zaman, kaza gibi parametrelerin ilişkisi olduğu ve araç yoğunluğuna etkilerinden dolayı modelde kullanılmıştır. Günler olarak haftanın 7 günü modele dahil edilmiştir. Kaza türü olarak kaza bildirimi ve araç arızası olarak belirlenmiştir. Kazaların meydana geldiği zamanlar sabah, öğle, akşam ve gece olarak belirlenmiştir. Şeritlerde meydana gelen trafik olayları sağ, sol ve orta olarak belirlenmiştir. Kazaların hasar var-hasar yok, zincirleme var-zincirleme yok, yaralanma var-yaralanma yok, yoğunluk var-yoğunluk yok olarak belirlenmiştir.

Modelimiz 7 ana parametrenin girişi ile gerçekleştirilmiştir. Parametrelerimiz kategorik verilerden oluştuğundan sayısallaştırma işlemleri gerçekleştirilmiştir. Modelimizin girdilerine farklı normalizasyon teknikleri kullanılarak performansları ve doğruluk değerleri karşılaştırılmıştır. Literatürde yoğunlukla kullanılan Min-Max kuralı, Medyan, Sigmod ve Z-score kuralları mevcuttur. Normalleştirme işlemindeki amaç modele giren ham verilere uygulanarak, bu verilerin eğitim için daha uygun bir forma dönüştürür. Çok kriterli modellerde girdilerin normalleştirilmesi ile daha düzenli hale getirilerek modelin performansını artırılması önemli bir süreçtir. Girdiler arasında aşırı büyük ve küçük değerlerin olması ağı yanlış yönlendirilmesine neden olabileceğinden bütün girdilerin normalizasyonu gerçekleştirilerek 0-1 aralığında değerler atanarak farklı türden olan girdilerin aynı ölçek ile indirgenerek aşırı büyük ve küçük değerlerin etkisinin ortadan kalkmasına neden olur. Normalizasyon işlemi gerçekleştirilmeyen bir modelde veri setini eğitmek modelin hem performansını düşmesine hem de eğitim süresinin uzamasına neden olacaktır.

Tablo 4.46. Trafik Yoğunluk Parametrelerin Sayısallaştırılması ve Min-Max
Normalize Değerleri

Parametreler	Kategoriler	Değer	Normalize Edilmiş Değer
GÜNLER	Pazartesi	1	0
	Salı	2	0,167
	Çarşamba	3	0,333
	Perşembe	4	0,5
	Cuma	5	0,667
	Cumartesi	6	0,833
	Pazar	7	1
AYLAR	Ocak	1	0
	Şubat	2	0,091
	Mart	3	0,182
	Nisan	4	0,273
	Mayıs	5	0,364
	Haziran	6	0,455
	Temmuz	7	0,545
	Ağustos	8	0,636
	Eylül	9	0,727
	Ekim	10	0,818
	Kasım	11	0,909
	Aralık	12	1
MEVSİM	İlkbahar	1	0
	Yaz	2	0,333
	Sonbahar	3	0,667
	Kış	4	1
KAZA ZAMANI	Sabah	1	0
	Öğle	2	0,333
	Akşam	3	0,667
	Gece	4	1
KAZA ŞERİDİ	Sağ	1	0
	Sol	2	0,5
	Orta	3	1
KAZA DURUMU	Hasar Var	0	0
	Hasar Yok	1	1
	Zincirleme Var	0	0
	Zincirleme Yok	1	1
	Yoğunluk Var	0	0
KAZA TÜRÜ	Kaza	1	0
	Araç Arızası	2	1
TRAFİK DURUMU	Yoğunluk Var	1	0
	Yoğunluk Yok	2	1



Şekil 4.2.Yapay Sinir Ağı Trafik Yoğunluk Modeli

Verilerin Min-Max yöntemine göre normalizasyon işlemi gerçekleştirildikten sonra eğitim ve test işlemine geçilmiştir. Matlab programı ile yapay sinir ağı modeli uygulanmıştır. Modelde Geri-İleri Beslemeli ağ kurularak, gizli katmalar için 1-10 arasında ve değişik nöron sayıları ise 1-20 aralığında modeller kurularak 500-1000 arasında iterasyonlar gerçekleştirilmiştir. Veri seti içerisinde rastgele seçilen verilerden %70 eğitim ve %30 test verisi olarak ayrılmıştır. Gerçekleştirilen birçok senaryo sonucunda en iyi model olan yüksek R ve düşük hata oranı olan model belirlenmiştir.

Tablo 4.47. Yapay Sinir Ağı Girdi Parametreleri


Ağ Tipi	İleri-Geri Beslemeli Ağ
Eğitim Fonksiyonu	Trainlm
Öğrenme Fonksiyonu	Learnqdm
Performans Fonksiyonu	MSE, SSE
Tabaka Sayısı	1 ile 10 arasında
Nöron Sayısı	1 ile 20 arasında
Aktivasyon Fonksiyonu	Tansig, Logsig

2018-2020 yılları arasında 15 Temmuz Şehitler köprüsü üzerindeki trafik yoğunluğunun tahminlemede yapay sinir ağı modeli kurulmuştur. Model verilerine farklı normalizasyon teknikleri uygulanarak gerçekleştirilen trafik yoğunluk tahmin değerleri karşılaştırılmıştır. Uygulanan farklı senaryo çalışmaları ile aktivasyon fonksiyonları, tabaka sayıları ve nöron sayıları değiştirilerek tahmin sonuçları elde edilmiştir. Uygulanan farklı senaryolar sonucunda elde edilen tahmin değerlerinin doğruluk ve başarı durumlarını test etmek için Ortalama Mutlak Yüzde Hata (MAPE, Mean Absolute Percentage Error) ve Hata Kareler Ortalaması (MSE, Mean Square Error) istatistiği yardımıyla değerlendirilmiştir.


Tablo 4.48. Farklı modeller ve performans sonuçları

Model		Eğitim Fonksiyonu	Aktivasyon Fonksiyonu	Gizli Katman Sayısı	Gizli Katmandaki Nöron Sayısı	Performans Kriterleri			
						Eğitim	Test	Model	Ortalama
						R Oranı	R Oranı	R Oranı	Karesel Hata
Model 1	12-10-1	trainlm	Tansig- Tansig	1	10	0,9725	0,9660	0,9507	0,0142
Model 2	12-10-1	trainlm	Logsis-Logsis	1	10	0,9699	0,9666	0,9523	0,0153
Model 3	12-5-1	trainlm	Tansig- Tansig	1	5	0,9712	0,9439	0,9515	0,0143
Model 4	12-5-5-1	trainlm	Tansig-Tansig-Tansig	2	5-5	0,9815	0,9365	0,9635	0,0098
Model 5	12-5-5-1	trainlm	Logsis-Tansig-Logsis	2	5-5	0,9658	0,9264	0,9508	0,0154
Model 6	12-5-5-1	trainlm	Logsis-Tansig-Tansig	2	5-5	0,9615	0,9491	0,4856	0,0191
Model 7	12-10-10-1	trainlm	Tansig-Tansig-Tansig	2	10-10	0,9785	0,9318	0,9458	0,0112
Model 8	12-10-10-1	trainlm	Tansig-Logsis-Tansig	2	10-10	0,9984	0,9838	0,9706	0,0008
Model 9	12-10-10-1	trainlm	Logsis-Tansig-Tansig	2	10-10	0,9707	0,9631	0,9583	0,0147


Aktivasyon fonksiyonları ve gizli katman sayısı ile katmandaki nöron sayıları değiştirilerek 9 farklı model oluşturulmuştur. Bu modellerin R değerleri ve ortalama karesel hata değerleri Tablo 4.48’de elde edilmiştir. Model 8 eğitim R değeri 0,9984, Test R değeri 0,9838, Model R değeri 0,9706 ve Ortalama Karesel Hata Değeri 0,0008 olarak elde edilmiştir. Bu oranlar diğer modellere göre daha iyi sonuçlar vermiştir. Verilerimizin 12-10-10-1 yapılı çok katmanlı bir yapıya sahip olduğu sonucuna varılmıştır. Elde ettiğimiz bu modelin ezberleme düzeyini ve performans durumunu ölçmek için %70 eğitim ve %30 test için ayırdığımız veriler üzerinde test edilmiştir.

Şekil 4.3. Model 1 Eğitim ve test R değerleri ve hata grafiği


Şekil 4.4. Model 2 Eğitim ve test R değerleri ve hata grafiği




Şekil 4.5. Model 3 Eğitim ve test R değerleri ve hata grafiği




Şekil 4.6. Model 4 Eğitim ve test R değerleri ve hata grafiği




Şekil 4.7. Model 5 Eğitim ve test R değerleri ve hata grafiği




Şekil 4.8. Model 6 Eğitim ve test R değerleri ve hata grafiği




Şekil 4.9. Model 7 Eğitim ve test R değerleri ve hata grafiği



Şekil 4.10. Model 8 Eğitim ve test R değerleri ve hata grafiği



Şekil 4.11. Model 9 Eğitim ve test R değerleri ve hata grafiği



Model 8 sonucunda 12-10-10-1 modelimizi test ettikten sonra, 1525 günlük 15 Temmuz Şehitler Köprüsünde meydana gelen trafik yoğunluk verisinin %30'u olan 457 günlük yoğunluk verisi üzerinde test edilmiş ve ilk 100 günün tahmin sonuçları tablo 4.49. ve tablo 4.52. arasında yer verilmiştir. Simülasyon sonucunda 457 günlük yoğunluğun 419 tanesini doğru tahmin ederken, 37 tanesini yanlış tahmin etmiştir. Sonuç olarak %92'lik bir doğruluk performansı elde edilmiştir. Elde edilen bu yüksek performans sonucu sayesinde oluşabilecek farklı durumlarda trafik yoğunluğunun oluşup oluşmayacağı üzerine erken uyarı sistemi için bir altyapı oluşturuldu. Trafik yoğunluğunun oluşmasında yapay sinir ağı modelimizde kullandığımız parametrelerin birbirleri ile olan ilişkilerinin yüksek olduğunun bir göstergesi olmuştur. Özellikle köprü üzerinde gerçekleşen kazaların trafik yoğunluğunun oluşmasında önemli bir etken olduğu gözlemlenmiştir. Örneğin Mart ayında Salı günü akşam vaktinde araç yoğunluğunun fazla olduğu bir zamanda sağ şeritte hasarlı bir trafik kazasının köprü üzerinde bir yoğunluk oluşturup-oluşturmayacağını önceden tahminlemek için tasarladığımız yapay sinir ağı modellemesi sayesinde erken bir uyarı sistemi oluşturacaktır. Başka bir örnekte herhangi bir kaza olmadığı günlerde ise örneğin Haziran ayında, Cuma günü öğle vaktinde araç yoğunluğunun ortalamanın altında olduğu bir zamanda trafik yoğunluğunun oluşup-oluşturmayacağını tasarladığımız model bizlere önceden bilgi vermektedir. Bu modele veriler girdikçe sistemin daha iyi öğrenip daha doğru sonuçlar vermesini sağlayacaktır. Büyük veri ve makine öğrenmesi sayesinde akıllı ulaşım için önemli avantajlar sunmaktadır.

Tablo 4.49. Simülasyon Sonuçları

<i>HASARLI</i>	<i>ZİNCİRLEME</i>	<i>YARALANMALI</i>	<i>SOL</i>	<i>SAĞ</i>	<i>ORTA</i>	<i>AY</i>	<i>TARİH</i>	<i>ZAMAN</i>	<i>KAZA</i> <i>TÜRÜ</i>	<i>MEVSİM</i>	<i>ARAÇ</i> <i>YOĞUNLUĞU</i>	<i>YOĞUNLUK</i>	<i>TEST</i> <i>SONUCU</i>
1	0	0	0	1	0	0,73	0,00	1,00	1,00	1,00	0	0	DOĞRU
0	0	0	0	0	0	0,73	0,00	0,00	1,00	1,00	0	1	DOĞRU
0	0	0	0	0	0	0,73	0,00	0,33	0,00	1,00	0	1	DOĞRU
1	0	0	0	1	0	0,73	0,00	0,67	1,00	1,00	0	0	DOĞRU
0	0	0	0	1	0	0,73	0,33	0,33	0,00	1,00	0	1	DOĞRU
0	0	0	0	1	0	0,73	0,33	1,00	0,50	1,00	0	0	DOĞRU
0	0	0	0	0	0	0,73	0,17	0,33	0,00	1,00	0	1	YANLIŞ
0	0	0	1	0	0	0,73	0,50	0,67	0,00	1,00	0	0	DOĞRU
0	0	0	0	1	1	0,73	0,50	0,00	0,50	1,00	0	0	DOĞRU
0	0	1	0	0	0	0,73	0,33	0,00	1,00	1,00	0	1	DOĞRU
1	0	0	1	0	0	0,73	0,33	0,33	1,00	1,00	0	0	DOĞRU
0	0	0	0	0	0	0,73	0,33	0,33	1,00	1,00	0	1	DOĞRU
0	0	0	0	1	0	0,73	0,33	0,67	0,00	1,00	0	1	DOĞRU
0	0	0	0	1	0	0,73	0,67	0,33	0,00	1,00	0	1	DOĞRU
0	0	0	0	0	0	0,73	0,50	1,00	1,00	1,00	0	1	DOĞRU
0	0	0	0	1	0	0,73	0,50	0,67	0,00	1,00	0	1	DOĞRU
0	0	0	0	1	0	0,73	0,83	0,67	0,00	1,00	0	1	DOĞRU
1	0	0	0	1	0	0,73	0,83	0,67	1,00	1,00	0	0	YANLIŞ
0	0	0	1	0	0	0,73	1,00	1,00	0,50	1,00	0	0	DOĞRU
1	0	0	1	0	0	0,73	0,83	0,67	1,00	1,00	0	0	DOĞRU
0	0	0	0	0	0	0,73	1,00	0,00	0,50	1,00	0	1	DOĞRU
0	0	0	0	0	0	0,73	1,00	0,33	1,00	1,00	0	1	DOĞRU
1	0	0	1	0	0	0,73	1,00	0,33	1,00	1,00	0	0	DOĞRU
1	0	0	1	0	1	0,73	0,00	1,00	1,00	1,00	0	0	DOĞRU

Tablo 4.50. Simülasyon Sonuçları Devamı_1

<i>HASARLI</i>	<i>ZİNCİRLEME</i>	<i>YARALANMALI</i>	<i>SOL</i>	<i>SAĞ</i>	<i>ORTA</i>	<i>AY</i>	<i>TARİH</i>	<i>ZAMAN</i>	<i>KAZA</i> <i>TÜRÜ</i>	<i>MEVSİM</i>	<i>ARAÇ</i> <i>YOĞUNLUĞU</i>	<i>YOĞUNLUK</i>	<i>TEST</i> <i>SONUCU</i>
1	0	0	1	0	0	0,73	0,33	0,00	1,00	1,00	0	0	DOĞRU
0	0	0	1	0	0	0,73	0,50	1,00	0,50	1,00	0	0	DOĞRU
1	0	0	1	0	0	0,73	0,50	0,67	1,00	1,00	0	0	DOĞRU
0	0	0	0	0	0	0,73	0,50	0,00	1,00	1,00	0	1	DOĞRU
0	0	0	1	0	0	0,73	0,67	0,00	0,00	1,00	0	1	DOĞRU
1	0	0	1	0	0	0,73	0,67	0,67	1,00	1,00	0	0	DOĞRU
1	0	0	1	0	0	0,73	0,67	0,33	1,00	1,00	0	0	DOĞRU
0	0	0	0	1	0	0,73	1,00	0,33	0,00	1,00	1	1	DOĞRU
0	0	0	0	0	1	0,73	0,83	0,33	1,00	1,00	0	1	DOĞRU
0	0	0	0	1	0	0,73	0,83	0,33	0,00	1,00	0	1	DOĞRU
1	0	0	1	0	0	0,73	0,67	0,67	1,00	1,00	1	0	DOĞRU
1	0	0	0	1	0	0,73	0,00	0,33	1,00	1,00	1	0	YANLIŞ
0	0	1	0	0	0	0,73	0,00	0,33	1,00	1,00	1	0	DOĞRU
0	0	0	0	1	0	0,73	1,00	0,00	0,00	1,00	0	1	DOĞRU
1	0	0	1	0	0	0,73	0,83	0,67	1,00	1,00	1	0	DOĞRU
1	0	0	1	0	0	0,73	0,83	1,00	1,00	1,00	1	0	DOĞRU
1	0	0	1	0	0	0,73	0,83	0,67	1,00	1,00	1	0	DOĞRU
0	0	0	1	0	0	0,73	0,17	1,00	0,50	1,00	0	0	YANLIŞ
1	0	0	1	0	0	0,73	0,00	1,00	1,00	1,00	0	0	DOĞRU
0	0	0	0	1	0	0,73	0,00	0,67	0,00	1,00	0	1	DOĞRU
1	0	0	1	0	0	0,73	0,00	0,67	1,00	1,00	0	0	DOĞRU
0	0	1	0	0	0	0,73	1,00	1,00	1,00	1,00	1	0	DOĞRU
0	1	0	1	0	0	0,73	1,00	0,00	1,00	1,00	1	0	DOĞRU
1	0	0	0	1	1	0,73	1,00	0,00	1,00	1,00	1	0	DOĞRU
0	0	1	0	1	0	0,73	0,33	0,33	1,00	1,00	0	0	DOĞRU
0	0	1	0	1	0	0,73	0,33	0,33	1,00	1,00	0	0	DOĞRU
0	0	0	0	1	0	0,73	0,33	0,33	0,00	1,00	0	1	DOĞRU

Tablo 4.51. Simülasyon Sonuçları Devamı_2

<i>HASARLI</i>	<i>ZİNCİRLEME</i>	<i>YARALANMALI</i>	<i>SOL</i>	<i>SAG</i>	<i>ORTA</i>	<i>AY</i>	<i>TARİH</i>	<i>ZAMAN</i>	<i>KAZA</i> <i>TÜRÜ</i>	<i>MEVSİM</i>	<i>ARAÇ</i> <i>YOĞUNLUĞU</i>	<i>YOĞUNLUK</i>	<i>TEST</i> <i>SONUCU</i>
1	0	0	1	0	0	0,73	0,00	0,67	1,00	1,00	0	0	DOĞRU
0	0	0	0	1	0	0,73	0,00	0,67	0,00	1,00	0	1	DOĞRU
0	0	0	1	0	0	0,73	0,50	1,00	0,50	1,00	0	0	DOĞRU
1	0	0	1	0	1	0,73	0,50	0,00	1,00	1,00	0	0	DOĞRU
1	0	0	0	1	0	0,73	0,50	0,33	1,00	1,00	0	0	DOĞRU
0	0	0	0	1	1	0,73	0,33	0,33	0,00	1,00	0	1	DOĞRU
0	0	0	0	1	0	0,73	0,33	0,33	0,00	1,00	0	1	DOĞRU
1	0	0	1	0	0	0,73	0,67	0,67	1,00	1,00	0	0	YANLIŞ
0	0	0	1	0	0	0,73	0,67	0,00	0,00	1,00	0	0	DOĞRU
0	0	0	0	0	0	0,73	0,33	0,00	1,00	1,00	1	1	DOĞRU
0	0	0	0	0	0	0,73	0,83	0,00	1,00	1,00	0	1	DOĞRU
1	0	0	0	1	1	0,73	0,67	0,67	1,00	1,00	0	0	DOĞRU
0	0	0	0	1	0	0,73	0,50	0,67	0,00	1,00	0	1	DOĞRU
0	0	0	0	1	0	0,73	0,50	0,67	0,00	1,00	0	1	DOĞRU
0	0	0	1	0	0	0,73	0,50	0,00	0,00	1,00	0	1	DOĞRU
1	0	0	1	0	0	0,73	1,00	0,67	1,00	1,00	0	0	DOĞRU
1	0	0	0	0	0	0,73	0,83	1,00	1,00	1,00	0	0	DOĞRU
1	0	0	1	0	0	0,73	0,83	0,67	1,00	1,00	0	0	DOĞRU
0	0	0	0	0	0	0,73	0,67	0,33	0,00	1,00	0	1	DOĞRU
0	0	0	0	1	0	0,73	0,00	0,33	0,00	1,00	0	1	DOĞRU
1	0	0	1	0	0	0,73	1,00	0,67	1,00	1,00	0	0	DOĞRU
0	0	0	0	1	0	0,73	1,00	0,67	0,00	1,00	0	1	YANLIŞ
0	1	0	0	0	0	0,73	1,00	0,67	1,00	1,00	0	0	DOĞRU
1	0	0	0	1	0	0,73	1,00	0,67	1,00	1,00	0	0	DOĞRU
1	0	0	1	0	0	0,73	0,83	0,67	1,00	1,00	0	0	DOĞRU
0	0	0	0	0	0	0,73	0,83	0,67	1,00	1,00	0	1	DOĞRU

Tablo 4.52. Simülasyon Sonuçları Devamı_2

<i>HASARLI</i>	<i>ZİNCİRLEME</i>	<i>YARALANMALI</i>	<i>SOL</i>	<i>SAG</i>	<i>ORTA</i>	<i>AY</i>	<i>TARİH</i>	<i>ZAMAN</i>	<i>KAZA</i> <i>TÜRÜ</i>	<i>MEVSİM</i>	<i>ARAÇ</i> <i>YOĞUNLUĞU</i>	<i>YOĞUNLUK</i>	<i>TEST</i> <i>SONUCU</i>
0	0	0	1	0	0	0,73	0,17	0,00	0,50	1,00	0	0	YANLIŞ
1	0	0	0	0	0	0,73	0,17	0,33	1,00	1,00	0	0	DOĞRU
0	0	0	0	1	0	0,73	0,00	1,00	0,00	1,00	0	1	DOĞRU
0	0	1	0	1	0	0,73	0,00	1,00	1,00	1,00	0	0	YANLIŞ
1	0	0	1	0	1	0,73	0,00	0,00	1,00	1,00	0	0	DOĞRU
1	0	0	1	0	0	0,73	1,00	0,67	1,00	1,00	0	0	DOĞRU
0	0	0	1	0	0	0,73	0,33	0,67	0,00	1,00	0	1	DOĞRU
0	0	0	0	1	0	0,82	0,17	0,33	0,00	1,00	1	1	DOĞRU
0	0	0	0	1	0	0,82	0,17	0,33	0,00	1,00	1	1	DOĞRU
0	0	0	0	1	0	0,82	0,17	0,33	0,00	1,00	1	1	DOĞRU
0	0	0	0	1	0	0,82	0,00	0,00	0,00	1,00	0	1	DOĞRU
0	0	0	1	0	1	0,82	0,00	0,67	0,00	1,00	0	1	DOĞRU
0	0	0	0	1	0	0,82	0,00	0,00	0,00	1,00	0	1	DOĞRU
0	0	0	1	0	0	0,82	0,50	0,00	0,50	1,00	0	0	YANLIŞ
0	1	0	0	1	0	0,82	0,50	0,67	1,00	1,00	0	0	DOĞRU
0	0	0	0	1	0	0,82	0,17	0,00	0,50	1,00	0	0	DOĞRU
0	0	0	0	1	0	0,82	0,67	0,33	0,00	1,00	0	1	DOĞRU
0	1	0	1	0	0	0,82	0,50	1,00	1,00	1,00	0	0	DOĞRU
0	0	0	1	0	0	0,82	0,50	0,67	0,00	1,00	0	1	DOĞRU
0	0	0	0	1	0	0,82	0,33	0,00	0,50	1,00	0	0	DOĞRU
0	0	1	0	1	0	0,82	0,33	0,67	1,00	1,00	0	0	YANLIŞ
0	0	1	0	0	0	0,82	0,83	0,33	1,00	1,00	0	0	DOĞRU

Tüm konumların yoğunlukları tahmin etmede aylar, günler, zaman, şerit ve gerçekleşen trafik olaylarına göre sınıflandırma analizleri gerçekleştirilmiştir. 36628 trafik olayının Navie Bayes, Bayes ve Yapay Sinir Ağları ile sınıflandırma analizleri gerçekleştirilmiştir.

Tablo 4.52. D100 Karayolu Hattı Yoğunluk Modeli Sınıflandırma Değerlendirme Sonuçları

Modeller	Model Değerlendirme Ölçütleri	Cross Validation-10	Percentage Split (70/30)
NAVİE BAYES	Doğruluk(Accuracy)	0,917	0,917
	Duyarlılık(Sensitivity)	0,822	0,820
	Özgüllük(Specificity)	0,991	0,992
	ROC(Receiver Operating Characteristics)	0,897	0,984
	MCC(Matthews Correlation Coefficient)	0,837	0,838
	Anma((Recall)	0,917	0,917
	Kesinlik(Precision)	0,925	0,925
	F-Ölçütü	0,916	0,916
	Kappa statistic	0,827	0,828
	Mean absolute error	0,101	0,1014
	Root mean squared error	0,280	0,2799
	Relative absolute error	20,42%	20,59%
	Root relative squared error	56,44%	56,47%
BAYES	Doğruluk(Accuracy)	0,966	0,967
	Duyarlılık(Sensitivity)	0,950	0,951
	Özgüllük(Specificity)	0,979	0,979
	ROC(Receiver Operating Characteristics)	0,977	0,978
	MCC(Matthews Correlation Coefficient)	0,932	0,932
	Anma((Recall)	0,966	0,967
	Kesinlik(Precision)	0,966	0,967
	F-Ölçütü	0,966	0,967
	Kappa statistic	0,932	0,932
	Mean absolute error	0,059	0,058
	Root mean squared error	0,188	0,188
	Relative absolute error	11,89%	11,96%
	Root relative squared error	37,89%	37,94%
YAPAY SİNİR AĞI	Doğruluk(Accuracy)	0,970	0,971
	Duyarlılık(Sensitivity)	0,957	0,962
	Özgüllük(Specificity)	0,981	0,977
	ROC(Receiver Operating Characteristics)	0,982	0,982
	MCC(Matthews Correlation Coefficient)	0,940	0,941
	Anma((Recall)	0,970	0,971
	Kesinlik(Precision)	0,970	0,971
	F-Ölçütü	0,970	0,971
	Kappa statistic	0,940	0,940
	Mean absolute error	0,051	0,055
	Root mean squared error	0,161	0,159
	Relative absolute error	10,33%	11,09%
	Root relative squared error	32,51%	32,15%

Tablo 4.53. D100 Karayolu Hattı Trafik Olayları Modeli Sınıflandırma

Değerlendirme Sonuçları

Modeller	Model Değerlendirme Ölçütleri	Cross Validation-10	Percentage Split (70/30)
NAİVE BAYES	Doğruluk(Accuracy)	0,912	0,911
	ROC(Receiver Operating Characteristics)	0,980	0,967
	MCC(Matthews Correlation Coefficient)	0,864	0,838
	Anma((Recall)	0,910	0,911
	Kesinlik(Precision)	0,920	0,911
	F-Ölçütü	0,914	0,900
	Kappa statistic	0,855	0,843
	Mean absolute error	0,058	0,056
	Root mean squared error	0,180	0,187
	Relative absolute error	20,10%	18,37%
	Root relative squared error	47,34%	49,22%
BAYES	Doğruluk(Accuracy)	0,910	0,911
	ROC(Receiver Operating Characteristics)	0,967	0,978
	MCC(Matthews Correlation Coefficient)	0,864	0,860
	Anma((Recall)	0,912	0,911
	Kesinlik(Precision)	0,912	0,916
	F-Ölçütü	0,900	0,912
	Kappa statistic	0,846	0,846
	Mean absolute error	0,052	0,059
	Root mean squared error	0,185	0,181
	Relative absolute error	18,14%	20,32%
	Root relative squared error	48,73%	47,63%
YAPAY SİNİR AĞI	Doğruluk(Accuracy)	0,931	0,931
	ROC(Receiver Operating Characteristics)	0,989	0,989
	MCC(Matthews Correlation Coefficient)	0,891	0,891
	Anma((Recall)	0,931	0,931
	Kesinlik(Precision)	0,928	0,930
	F-Ölçütü	0,927	0,925
	Kappa statistic	0,880	0,881
	Mean absolute error	0,047	0,047
	Root mean squared error	0,154	0,154
	Relative absolute error	16,11%	16,12%
	Root relative squared error	40,38%	40,36%

4.7.2 Bayesian Ağı ile Trafik Analiz Modellemesi

Bayes Ağı algoritması ile gerçekleştirilen tüm D100 karayolu hattı boyunca meydana gelen yoğunluk ve trafik olaylarının sınıflandırma sonuçları önemli derecede yüksek çıkmıştır. Bu durum Bayes algoritmaları ile D100 karayolu hattındaki konumların yoğunluk ve trafik olaylarının gerçekleşme durumlarının sonuçları önemli derece doğru sonuçlar verecektir. D100 karayolu hattı boyunca 60 konumun araç yoğunluk durumlarını bildiren ve D100 karayolu hattı boyunca önemli noktaların yoğunluk ve trafik olayları ihtimallerini değerlendiren modeller oluşturulmuştur.


Bayesian Ağı Trafik Modeli sonucunda konumlara ait elde edilecek trafik bilgi sistemi sayesinde kullanıcıların yararlanacağı örnek bilgiler şu şekildedir:

- Ocak ayında, pazartesi günü, sabah saatlerinde, sol şeritte yoğunluğun oluşma ihtimali kaçtır?
- Ocak ayında, pazartesi günü, sabah saatlerinde, sol şeritte araç arızasının oluşma ihtimali kaçtır?
- Ocak ayında, pazartesi günü, sabah saatlerinde, sol şeritte hangi trafik olayının oluşma ihtimali kaçtır?
- Ocak ayında, pazartesi günü, sabah saatlerinde, sol şeritte hasarlı/yaralanmalı/zincirlemeli bir kazanın oluşma ihtimali kaçtır?
- Pazartesi günü, sabah saatlerinde, sağ şeritte, bakım_onarım_çalışmasının ocak ayında gerçekleşme ihtimali kaçtır?
- Ocak ayında, sabah saatlerinde, sağ şeritte, kaza bildiriminin çarşamba günü gerçekleşme ihtimali kaçtır?
- Ocak ayında, pazartesi günü, sağ şeritte, araç arızasının öğle vaktinde gerçekleşme ihtimali kaçtır?
- *Aylar: Ocak(1), Şubat(2), Mart(3), Nisan(4), Mayıs(5), Haziran(6), Temmuz(7), Ağustos(8), Eylül(9), Ekim(10), Kasım(11), Aralık(12)*
- *Günler: Pazartesi(1), Salı(2), Çarşamba(3), Perşembe(4), Cuma(5), Cumartesi(6), Pazar(7)*
- *Zaman: Sabah(1), Öğle(2), Akşam(3), Gece(4)*
- *Şerit: Sol(1), Orta(2), Sağ(3), Şerit Yok(4)*

- *Trafik Olayları: Kaza_Bildirimi(1), Araç_Arızası(2), Bakım-Onarım-Çalışması(3), Durum_Yok(4).*
- *Yoğunluk: Yoğunluk Var(1), Yoğunluk Yok(0)*

D100 karayolu hattında gerçekleşen 36628 trafik olayının analizi gerçekleştirilmiştir. Elde edilen sonuçlara göre:

Şekil 4.12. Bayesian Ağı Yoğunluk Tahmin Modeli



- Ocak ayında, pazartesi günü, sabah saatlerinde, sağ şeritte %66,9 olasılıkla yoğunluk meydana gelecektir.

$P(\text{Yoğunluk}=\text{Var} \mid \text{Aylar}=\text{Ocak}, \text{Günler}=\text{Pazartesi}, \text{Zaman}=\text{Sabah}, \text{Şerit}=\text{Sağ})=1$


Tablo 4.54. Trafik Olayları Senaryo_1

Yoğunluk	Var	Yok	Toplam	%Var	%Yok
	20552	16075	36627	0,561	0,439
Ocak	2172	1791	3963	0,106	0,111
Pazartesi	3481	2390	5871	0,169	0,149
Sabah	6849	4701	11550	0,333	0,292
Sağ Şerit	13818	8428	22246	0,672	0,524

- $P(\text{Yoğunluk} =$
 $"\text{Var}" \mid \text{Aylar}=\text{"Ocak"}, \text{Günler}=\text{"Pazartesi"}, \text{Zaman}=\text{"Sabah"}, \text{Şerit}=\text{"Sağ"}) =$
 $0,561 * 0,106 * 0,169 * 0,333 * 0,672 = 0,00225$

- $P(\text{Yoğunluk} = \text{"Yok"} \mid \text{Aylar} = \text{"Ocak"}, \text{Günler} = \text{"Pazartesi"}, \text{Zaman} = \text{"Sabah"}, \text{Şerit} = \text{"Sağ"}) = 0,439 * 0,111 * 0,149 * 0,292 * 0,524 = 0,001115$
- $P(\text{Yoğunluk} = \text{Var} \mid \text{Aylar} = \text{Ocak}, \text{Günler} = \text{Pazartesi}, \text{Zaman} = \text{Sabah}, \text{Şerit} = \text{Sağ}) = 0,00225 / (0,00225 + 0,001115) = 0,67 = \%67$

Şekil 4.13. Bayesian Ağı Şerit Bazlı Tahmin Modeli



- Ocak ayında, pazartesi günü, sabah saatlerinde, kaza bildirimi %47,8 olasılıkla sağ şeritte meydana gelecektir.
- **$P(\text{Şerit} = \text{Sağ} \mid \text{Ocak}, \text{Pazartesi}, \text{Sabah}, \text{Kaza Bildirimi}) = 1$**


Tablo 4.55. Trafik Olayları Senaryo_2

Şerit	Sol	Orta	Sağ	Şerit Yok	Toplam	%Sol	%Orta	%Sağ	%Şerit Yok
	8009	2486	22246	3886	36627	0,219	0,068	0,607	0,106
Ocak	916	271	2423	353	3963	0,114	0,109	0,109	0,091
Pazartesi	1210	417	3664	580	5871	0,151	0,168	0,165	0,149
Sabah	2205	691	6898	1756	11550	0,275	0,278	0,310	0,452
Trafik Olayı	4958	1239	6835	1895	58011	0,619	0,498	0,307	0,488

- $P(\text{Şerit} = \text{"Sol"} \mid \text{Aylar} = \text{"Ocak"}, \text{Günler} = \text{"Pazartesi"}, \text{Zaman} = \text{"Sabah"}, \text{Trafik_Olayı} = \text{"Kaza Bildirimi"}) = 0,216 * 0,114 * 0,151 * 0,275 * 0,619 = 0,0006439$

- $P(\text{\textasciitilde{Serit}} = \text{"Orta"} \mid \text{Aylar} = \text{"Ocak"}, \text{Günler} = \text{"Pazartesi"}, \text{Zaman} = \text{"Sabah"}, \text{Trafik_Olayı} = \text{"Kaza Bildirimi"}) = 0,068 * 0,109 * 0,168 * 0,278 * 0,498 = 0,000172$
- $P(\text{\textasciitilde{Serit}} = \text{"Sağ"} \mid \text{Aylar} = \text{"Ocak"}, \text{Günler} = \text{"Pazartesi"}, \text{Zaman} = \text{"Sabah"}, \text{Trafik_Olayı} = \text{"Kaza Bildirimi"}) = 0,607 * 0,109 * 0,165 * 0,310 * 0,307 = 0,001038$
- $P(\text{\textasciitilde{Serit}} = \text{"Şerit_Yok"} \mid \text{Aylar} = \text{"Ocak"}, \text{Günler} = \text{"Pazartesi"}, \text{Zaman} = \text{"Sabah"}, \text{Trafik_Olayı} = \text{"Kaza Bildirimi"}) = 0,106 * 0,091 * 0,149 * 0,452 * 0,488 = 0,000317$
- $P(\text{\textasciitilde{Serit}} = \text{"Sağ"} \mid \text{Aylar} = \text{"Ocak"}, \text{Günler} = \text{"Pazartesi"}, \text{Zaman} = \text{"Sabah"}, \text{Trafik_Olayı} = \text{"Kaza Bildirimi"}) = 0,001038 / (0,0006439 + 0,000172 + 0,001038 + 0,000317) = 0,478 = \%47,8$
- $P(\text{\textasciitilde{Serit}} = \text{"Sol"} \mid \text{Aylar} = \text{"Ocak"}, \text{Günler} = \text{"Pazartesi"}, \text{Zaman} = \text{"Sabah"}, \text{Trafik_Olayı} = \text{"Kaza Bildirimi"}) = 0,0006439 / (0,0006439 + 0,000172 + 0,001038 + 0,000317) = 0,297 = \%29,7$
- $P(\text{\textasciitilde{Serit}} = \text{"Şerit_Yok"} \mid \text{Aylar} = \text{"Ocak"}, \text{Günler} = \text{"Pazartesi"}, \text{Zaman} = \text{"Sabah"}, \text{Trafik_Olayı} = \text{"Kaza Bildirimi"}) = 0,000317 / (0,0006439 + 0,000172 + 0,001038 + 0,000317) = 0,146 = \%14,6$
- $P(\text{\textasciitilde{Serit}} = \text{"Orta"} \mid \text{Aylar} = \text{"Ocak"}, \text{Günler} = \text{"Pazartesi"}, \text{Zaman} = \text{"Sabah"}, \text{Trafik_Olayı} = \text{"Kaza Bildirimi"}) = 0,000172 / (0,0006439 + 0,000172 + 0,001038 + 0,000317) = 0,0791 = \%7,91$

Şekil 4.14. Bayesian Ağı Trafik Olay Bazlı Tahmin Modeli



- Ocak ayında, pazartesi günü, sabah saatlerinde, sağ şeritte, %54,8 olasılıkla kaza bildirimi meydana gelecektir.


Tablo 4.56. Trafik Olayları Senaryo 3

Trafik_Olayı	Kaza_Bildirimi	Araç_Arızası	Bakım_Onarım_Çalışması	Yogunluk_Bildirimi	Toplam	%Kaza_Bildirimi	%Araç_Arızası	%Bakım_Onarım_Çalışması	%Yogunluk_Bildirimi
	14927	18337	2447	916	36627	0,408	0,501	0,067	0,025
Ocak	1605	2013	247	98	3963	0,108	0,110	0,101	0,107
Pazartesi	2284	3175	301	111	5871	0,153	0,173	0,123	0,121
Sabah	4481	5808	977	284	11550	0,300	0,317	0,399	0,310
Sağ Şerit	4958	2170	881	0	5801	0,332	0,118	0,360	0,000

- $P(\text{Trafik_Olayı} = \text{"Kaza_Bildirim"} \mid \text{Aylar} = \text{"Ocak"}, \text{Günler} = \text{"Pazartesi"}, \text{Zaman} = \text{"Sabah"}, \text{Şerit} = \text{"Sağ"}) = 0,408 * 0,108 * 0,153 * 0,300 * 0,332 = 0,00066885$
- $P(\text{Trafik_Olayı} = \text{"Araç_Arızası"} \mid \text{Aylar} = \text{"Ocak"}, \text{Günler} = \text{"Pazartesi"}, \text{Zaman} = \text{"Sabah"}, \text{Şerit} = \text{"Sağ"}) = 0,501 * 0,110 * 0,173 * 0,317 * 0,118 = 0,000357$


- $P(\text{Trafik_Olayı} = \text{"Bakım_Onarım_Çalışması"} \mid \text{Aylar} = \text{"Ocak"}, \text{Günler} = \text{"Pazartesi"}, \text{Zaman} = \text{"Sabah"}, \text{Şerit} = \text{"Sağ"}) = 0,0607 * 0,101 * 0,123 * 0,399 * 0,360 = 0,0001192$
- $P(\text{Trafik_Olayı} = \text{"Yoğunluk_Bildirimi"} \mid \text{Aylar} = \text{"Ocak"}, \text{Günler} = \text{"Pazartesi"}, \text{Zaman} = \text{"Sabah"}, \text{Şerit} = \text{"Sağ"}) = 0,025 * 0,107 * 0,121 * 0,310 * 0,000 = 0,000$
- $P(\text{Trafik_Olayı} = \text{"Kaza_Bildirimi"} \mid \text{Aylar} = \text{"Ocak"}, \text{Günler} = \text{"Pazartesi"}, \text{Zaman} = \text{"Sabah"}, \text{Şerit} = \text{"Sağ"}) = 0,0006685 / (0,0006685 + 0,000357 + 0,0001192 + 0,000) = 0,584 = \%58,4$
- $P(\text{Trafik_Olayı} = \text{"Araç_Arızası"} \mid \text{Aylar} = \text{"Ocak"}, \text{Günler} = \text{"Pazartesi"}, \text{Zaman} = \text{"Sabah"}, \text{Şerit} = \text{"Sağ"}) = 0,000357 / (0,0006685 + 0,000357 + 0,0001192 + 0,000) = 0,312 = \%31,2$
- $P(\text{Trafik_Olayı} = \text{"Bakım_Onarım_Çalışması"} \mid \text{Aylar} = \text{"Ocak"}, \text{Günler} = \text{"Pazartesi"}, \text{Zaman} = \text{"Sabah"}, \text{Şerit} = \text{"Sağ"}) = 0,0001192 / (0,0006685 + 0,000357 + 0,0001192 + 0,000) = 0,104 = \%10,4$
- $P(\text{Trafik_Olayı} = \text{"Kaza_Bildirimi"} \mid \text{Aylar} = \text{"Ocak"}, \text{Günler} = \text{"Pazartesi"}, \text{Zaman} = \text{"Sabah"}, \text{Şerit} = \text{"Sağ"}) = 0,000 / (0,0006685 + 0,000357 + 0,0001192 + 0,000) = 0,000 = \%0,00$

Şekil 4.15. Bayesian Ağı Trafik Olayları Durum Bazlı Tahmin Modeli




- Ocak ayında, pazartesi günü, sabah saatlerinde, sağ şeritte, %46,4 olasılıkla hasarlı bir kaza bildirimi meydana gelecektir.

Şekil 4.16. Bayesian Ağı Trafik Olay Bazlı Tahmin Modeli




- Perşembe günü, öğle saatlerinde, orta şeritte, gerçekleşecek bir araç arızası %13,7 olasılıkla şubat ayında meydana gelecektir.

Şekil 4.17. Bayesian Ağı Günü Bazlı Tahmin Modeli




- Kasım ayında, akşam saatlerinde, sağ şeritte, gerçekleşecek bir bakım_onarım_çalışması %19,4 olasılıkla pazar günü meydana gelecektir.

Şekil 4.18. Bayesian Ağı Zaman Bazlı Tahmin Modeli



- Mart ayında, çarşamba günü, sol şeritte, gerçekleşecek bir araç arızasının %38,3 olasılıkla öğle saatlerinde meydana gelecektir.


Şekil 4.19. Bayesian Ağı Mevsim Bazlı Tahmin Modeli



- Cuma günü, öğle saatlerinde, orta şeritte, gerçekleşecek bir kaza bildirimi %32,0 olasılıkla kış mevsiminde meydana gelecektir.

D100 Karayolu hattında trafik olaylarının en fazla gerçekleştiği 15 Temmuz Şehitler Köprüsünün trafik analizleri gerçekleştirilmiştir.

Şekil 4.20. 15 Temmuz Şehitler Köprüsü Yoğunluk Modeli



- Ocak ayında, pazartesi günü, sabah saatlerinde, sağ şeritte meydana gelebilecek bir trafik olayında 54,00% ihtimalle yoğunluk meydana gelecektir.

Tablo 4.57. 15 Temmuz Şehitler Köprüsü Sağ Şerit Yoğunluk İhtimalleri Senaryo_1

AYLAR	GÜNLER	ZAMAN	ŞERİT	Yoğunluk İhtimali
Ocak	Pazartesi	Sabah	Sağ	54,00%
Şubat	Pazartesi	Sabah	Sağ	63,20%
Mart	Pazartesi	Sabah	Sağ	62,60%
Nisan	Pazartesi	Sabah	Sağ	64,30%
Mayıs	Pazartesi	Sabah	Sağ	70,30%
Haziran	Pazartesi	Sabah	Sağ	63,20%
Temmuz	Pazartesi	Sabah	Sağ	66,50%
Ağustos	Pazartesi	Sabah	Sağ	59,40%
Eylül	Pazartesi	Sabah	Sağ	60,10%
Ekim	Pazartesi	Sabah	Sağ	59,10%
Kasım	Pazartesi	Sabah	Sağ	64,10%
Aralık	Pazartesi	Sabah	Sağ	66,80%
Ocak	Pazartesi	Öğle	Sağ	62,20%
Şubat	Pazartesi	Öğle	Sağ	70,60%
Mart	Pazartesi	Öğle	Sağ	70,10%
Nisan	Pazartesi	Öğle	Sağ	71,60%
Mayıs	Pazartesi	Öğle	Sağ	76,80%*
Haziran	Pazartesi	Öğle	Sağ	70,60%
Temmuz	Pazartesi	Öğle	Sağ	73,60%
Ağustos	Pazartesi	Öğle	Sağ	67,20%
Eylül	Pazartesi	Öğle	Sağ	67,80%
Ekim	Pazartesi	Öğle	Sağ	66,90%
Kasım	Pazartesi	Öğle	Sağ	71,40%
Aralık	Pazartesi	Öğle	Sağ	73,80%
Ocak	Pazartesi	Akşam	Sağ	54,90%
Şubat	Pazartesi	Akşam	Sağ	64,00%
Mart	Pazartesi	Akşam	Sağ	63,40%
Nisan	Pazartesi	Akşam	Sağ	65,10%
Mayıs	Pazartesi	Akşam	Sağ	71,00%
Haziran	Pazartesi	Akşam	Sağ	64,00%
Temmuz	Pazartesi	Akşam	Sağ	67,30%
Ağustos	Pazartesi	Akşam	Sağ	60,20%
Eylül	Pazartesi	Akşam	Sağ	60,90%
Ekim	Pazartesi	Akşam	Sağ	59,90%
Kasım	Pazartesi	Akşam	Sağ	64,90%
Aralık	Pazartesi	Akşam	Sağ	67,50%
Ocak	Pazartesi	Gece	Sağ	35,80%
Şubat	Pazartesi	Gece	Sağ	44,90%
Mart	Pazartesi	Gece	Sağ	44,30%
Nisan	Pazartesi	Gece	Sağ	46,10%
Mayıs	Pazartesi	Gece	Sağ	52,90%
Haziran	Pazartesi	Gece	Sağ	44,90%
Temmuz	Pazartesi	Gece	Sağ	48,60%
Ağustos	Pazartesi	Gece	Sağ	40,90%
Eylül	Pazartesi	Gece	Sağ	41,70%
Ekim	Pazartesi	Gece	Sağ	40,70%
Kasım	Pazartesi	Gece	Sağ	45,90%
Aralık	Pazartesi	Gece	Sağ	48,80%

*En yüksek olasılık değeri

Tablo 4.58. 15 Temmuz Şehitler Köprüsü Sağ Şerit Yoğunluk İhtimalleri Senaryo_2

AYLAR	GÜNLER	ZAMAN	ŞERİT	Yoğunluk İhtimali
Ocak	Salı	Sabah	Sağ	48,00%
Şubat	Salı	Sabah	Sağ	57,40%
Mart	Salı	Sabah	Sağ	56,80%
Nisan	Salı	Sabah	Sağ	58,60%
Mayıs	Salı	Sabah	Sağ	65,00%
Haziran	Salı	Sabah	Sağ	57,40%
Temmuz	Salı	Sabah	Sağ	61,00%
Ağustos	Salı	Sabah	Sağ	53,50%
Eylül	Salı	Sabah	Sağ	54,20%
Ekim	Salı	Sabah	Sağ	53,20%
Kasım	Salı	Sabah	Sağ	58,40%
Aralık	Salı	Sabah	Sağ	61,20%
Ocak	Salı	Öğle	Sağ	56,40%
Şubat	Salı	Öğle	Sağ	65,40%
Mart	Salı	Öğle	Sağ	64,80%
Nisan	Salı	Öğle	Sağ	66,40%
Mayıs	Salı	Öğle	Sağ	73,20%*
Haziran	Salı	Öğle	Sağ	65,40%
Temmuz	Salı	Öğle	Sağ	68,60%
Ağustos	Salı	Öğle	Sağ	61,70%
Eylül	Salı	Öğle	Sağ	62,40%
Ekim	Salı	Öğle	Sağ	61,40%
Kasım	Salı	Öğle	Sağ	66,30%
Aralık	Salı	Öğle	Sağ	68,90%
Ocak	Salı	Akşam	Sağ	48,90%
Şubat	Salı	Akşam	Sağ	58,30%
Mart	Salı	Akşam	Sağ	57,70%
Nisan	Salı	Akşam	Sağ	59,40%
Mayıs	Salı	Akşam	Sağ	65,80%
Haziran	Salı	Akşam	Sağ	58,30%
Temmuz	Salı	Akşam	Sağ	61,80%
Ağustos	Salı	Akşam	Sağ	54,30%
Eylül	Salı	Akşam	Sağ	55,10%
Ekim	Salı	Akşam	Sağ	54,10%
Kasım	Salı	Akşam	Sağ	59,20%
Aralık	Salı	Akşam	Sağ	62,10%
Ocak	Salı	Gece	Sağ	30,50%
Şubat	Salı	Gece	Sağ	39,10%
Mart	Salı	Gece	Sağ	38,50%
Nisan	Salı	Gece	Sağ	40,20%
Mayıs	Salı	Gece	Sağ	46,90%
Haziran	Salı	Gece	Sağ	39,10%
Temmuz	Salı	Gece	Sağ	42,60%
Ağustos	Salı	Gece	Sağ	35,30%
Eylül	Salı	Gece	Sağ	36,00%
Ekim	Salı	Gece	Sağ	35,00%
Kasım	Salı	Gece	Sağ	40,00%
Aralık	Salı	Gece	Sağ	42,90%

*En yüksek olasılık değeri

Tablo 4.59. 15 Temmuz Şehitler Köprüsü Sağ Şerit Yoğunluk İhtimalleri Senaryo_3

AYLAR	GÜNLER	ZAMAN	ŞERİT	Yoğunluk İhtimali
Ocak	Çarşamba	Sabah	Sağ	49,50%
Şubat	Çarşamba	Sabah	Sağ	58,80%
Mart	Çarşamba	Sabah	Sağ	58,20%
Nisan	Çarşamba	Sabah	Sağ	60,00%
Mayıs	Çarşamba	Sabah	Sağ	66,30%
Haziran	Çarşamba	Sabah	Sağ	58,80%
Temmuz	Çarşamba	Sabah	Sağ	62,40%
Ağustos	Çarşamba	Sabah	Sağ	54,90%
Eylül	Çarşamba	Sabah	Sağ	55,70%
Ekim	Çarşamba	Sabah	Sağ	54,60%
Kasım	Çarşamba	Sabah	Sağ	59,80%
Aralık	Çarşamba	Sabah	Sağ	62,90%
Ocak	Çarşamba	Öğle	Sağ	57,80%
Şubat	Çarşamba	Öğle	Sağ	66,70%
Mart	Çarşamba	Öğle	Sağ	66,10%
Nisan	Çarşamba	Öğle	Sağ	67,70%
Mayıs	Çarşamba	Öğle	Sağ	73,40%*
Haziran	Çarşamba	Öğle	Sağ	66,70%
Temmuz	Çarşamba	Öğle	Sağ	69,90%
Ağustos	Çarşamba	Öğle	Sağ	63,30%
Eylül	Çarşamba	Öğle	Sağ	63,70%
Ekim	Çarşamba	Öğle	Sağ	62,80%
Kasım	Çarşamba	Öğle	Sağ	67,50%
Aralık	Çarşamba	Öğle	Sağ	70,10%
Ocak	Çarşamba	Akşam	Sağ	50,30%
Şubat	Çarşamba	Akşam	Sağ	59,70%
Mart	Çarşamba	Akşam	Sağ	59,10%
Nisan	Çarşamba	Akşam	Sağ	60,80%
Mayıs	Çarşamba	Akşam	Sağ	67,10%
Haziran	Çarşamba	Akşam	Sağ	59,70%
Temmuz	Çarşamba	Akşam	Sağ	63,20%
Ağustos	Çarşamba	Akşam	Sağ	55,70%
Eylül	Çarşamba	Akşam	Sağ	56,50%
Ekim	Çarşamba	Akşam	Sağ	55,50%
Kasım	Çarşamba	Akşam	Sağ	60,60%
Aralık	Çarşamba	Akşam	Sağ	63,40%
Ocak	Çarşamba	Gece	Sağ	31,70%
Şubat	Çarşamba	Gece	Sağ	40,40%
Mart	Çarşamba	Gece	Sağ	39,80%
Nisan	Çarşamba	Gece	Sağ	41,60%
Mayıs	Çarşamba	Gece	Sağ	48,30%
Haziran	Çarşamba	Gece	Sağ	40,40%
Temmuz	Çarşamba	Gece	Sağ	44,00%
Ağustos	Çarşamba	Gece	Sağ	36,60%
Eylül	Çarşamba	Gece	Sağ	37,30%
Ekim	Çarşamba	Gece	Sağ	36,40%
Kasım	Çarşamba	Gece	Sağ	41,40%
Aralık	Çarşamba	Gece	Sağ	44,30%

*En yüksek olasılık değeri

Tablo 4.60. 15 Temmuz Şehitler Köprüsü Sağ Şerit Yoğunluk İhtimalleri Senaryo_4

AYLAR	GÜNLER	ZAMAN	ŞERİT	Yoğunluk İhtimali
Ocak	Perşembe	Sabah	Sağ	51,00%
Şubat	Perşembe	Sabah	Sağ	60,30%
Mart	Perşembe	Sabah	Sağ	59,70%
Nisan	Perşembe	Sabah	Sağ	61,40%
Mayıs	Perşembe	Sabah	Sağ	67,70%
Haziran	Perşembe	Sabah	Sağ	60,30%
Temmuz	Perşembe	Sabah	Sağ	63,80%
Ağustos	Perşembe	Sabah	Sağ	56,40%
Eylül	Perşembe	Sabah	Sağ	57,20%
Ekim	Perşembe	Sabah	Sağ	56,10%
Kasım	Perşembe	Sabah	Sağ	61,20%
Aralık	Perşembe	Sabah	Sağ	64,00%
Ocak	Perşembe	Öğle	Sağ	59,30%
Şubat	Perşembe	Öğle	Sağ	68,00%
Mart	Perşembe	Öğle	Sağ	67,50%
Nisan	Perşembe	Öğle	Sağ	69,00%
Mayıs	Perşembe	Öğle	Sağ	74,60%*
Haziran	Perşembe	Öğle	Sağ	68,00%
Temmuz	Perşembe	Öğle	Sağ	71,10%
Ağustos	Perşembe	Öğle	Sağ	64,40%
Eylül	Perşembe	Öğle	Sağ	65,10%
Ekim	Perşembe	Öğle	Sağ	64,20%
Kasım	Perşembe	Öğle	Sağ	68,90%
Aralık	Perşembe	Öğle	Sağ	71,30%
Ocak	Perşembe	Akşam	Sağ	51,90%
Şubat	Perşembe	Akşam	Sağ	61,10%
Mart	Perşembe	Akşam	Sağ	60,50%
Nisan	Perşembe	Akşam	Sağ	62,20%
Mayıs	Perşembe	Akşam	Sağ	68,40%
Haziran	Perşembe	Akşam	Sağ	61,10%
Temmuz	Perşembe	Akşam	Sağ	64,60%
Ağustos	Perşembe	Akşam	Sağ	57,20%
Eylül	Perşembe	Akşam	Sağ	58,00%
Ekim	Perşembe	Akşam	Sağ	57,00%
Kasım	Perşembe	Akşam	Sağ	62,10%
Aralık	Perşembe	Akşam	Sağ	64,80%
Ocak	Perşembe	Gece	Sağ	33,10%
Şubat	Perşembe	Gece	Sağ	41,90%
Mart	Perşembe	Gece	Sağ	41,30%
Nisan	Perşembe	Gece	Sağ	43,00%
Mayıs	Perşembe	Gece	Sağ	49,90%
Haziran	Perşembe	Gece	Sağ	41,90%
Temmuz	Perşembe	Gece	Sağ	45,50%
Ağustos	Perşembe	Gece	Sağ	38,00%
Eylül	Perşembe	Gece	Sağ	38,80%
Ekim	Perşembe	Gece	Sağ	37,80%
Kasım	Perşembe	Gece	Sağ	42,90%
Aralık	Perşembe	Gece	Sağ	45,80%

*En yüksek olasılık değeri

Tablo 4.61. 15 Temmuz Şehitler Köprüsü Sağ Şerit Yoğunluk İhtimalleri Senaryo_5

AYLAR	GÜNLER	ZAMAN	ŞERİT	Yoğunluk İhtimali
Ocak	Cuma	Sabah	Sağ	51,30%
Şubat	Cuma	Sabah	Sağ	60,60%
Mart	Cuma	Sabah	Sağ	60,00%
Nisan	Cuma	Sabah	Sağ	61,70%
Mayıs	Cuma	Sabah	Sağ	67,90%
Haziran	Cuma	Sabah	Sağ	60,60%
Temmuz	Cuma	Sabah	Sağ	64,00%
Ağustos	Cuma	Sabah	Sağ	56,70%
Eylül	Cuma	Sabah	Sağ	57,40%
Ekim	Cuma	Sabah	Sağ	56,40%
Kasım	Cuma	Sabah	Sağ	61,50%
Aralık	Cuma	Sabah	Sağ	64,30%
Ocak	Cuma	Öğle	Sağ	59,60%
Şubat	Cuma	Öğle	Sağ	68,30%
Mart	Cuma	Öğle	Sağ	67,70%
Nisan	Cuma	Öğle	Sağ	69,30%
Mayıs	Cuma	Öğle	Sağ	74,80%*
Haziran	Cuma	Öğle	Sağ	68,30%
Temmuz	Cuma	Öğle	Sağ	71,40%
Ağustos	Cuma	Öğle	Sağ	64,70%
Eylül	Cuma	Öğle	Sağ	65,40%
Ekim	Cuma	Öğle	Sağ	64,40%
Kasım	Cuma	Öğle	Sağ	69,10%
Aralık	Cuma	Öğle	Sağ	71,60%
Ocak	Cuma	Akşam	Sağ	52,10%
Şubat	Cuma	Akşam	Sağ	61,40%
Mart	Cuma	Akşam	Sağ	60,80%
Nisan	Cuma	Akşam	Sağ	62,50%
Mayıs	Cuma	Akşam	Sağ	68,70%
Haziran	Cuma	Akşam	Sağ	61,40%
Temmuz	Cuma	Akşam	Sağ	64,80%
Ağustos	Cuma	Akşam	Sağ	57,50%
Eylül	Cuma	Akşam	Sağ	58,30%
Ekim	Cuma	Akşam	Sağ	57,30%
Kasım	Cuma	Akşam	Sağ	62,30%
Aralık	Cuma	Akşam	Sağ	65,10%
Ocak	Cuma	Gece	Sağ	33,30%
Şubat	Cuma	Gece	Sağ	42,20%
Mart	Cuma	Gece	Sağ	41,60%
Nisan	Cuma	Gece	Sağ	43,30%
Mayıs	Cuma	Gece	Sağ	50,10%
Haziran	Cuma	Gece	Sağ	42,20%
Temmuz	Cuma	Gece	Sağ	45,80%
Ağustos	Cuma	Gece	Sağ	38,30%
Eylül	Cuma	Gece	Sağ	39,00%
Ekim	Cuma	Gece	Sağ	38,10%
Kasım	Cuma	Gece	Sağ	43,10%
Aralık	Cuma	Gece	Sağ	46,10%

*En yüksek olasılık değeri

Tablo 4.62. 15 Temmuz Şehitler Köprüsü Sağ Şerit Yoğunluk İhtimalleri Senaryo_6

AYLAR	GÜNLER	ZAMAN	ŞERİT	Yoğunluk İhtimali
Ocak	Cumartesi	Sabah	Sağ	40,80%
Şubat	Cumartesi	Sabah	Sağ	50,20%
Mart	Cumartesi	Sabah	Sağ	49,50%
Nisan	Cumartesi	Sabah	Sağ	51,30%
Mayıs	Cumartesi	Sabah	Sağ	58,10%
Haziran	Cumartesi	Sabah	Sağ	50,20%
Temmuz	Cumartesi	Sabah	Sağ	53,80%
Ağustos	Cumartesi	Sabah	Sağ	46,10%
Eylül	Cumartesi	Sabah	Sağ	46,90%
Ekim	Cumartesi	Sabah	Sağ	45,90%
Kasım	Cumartesi	Sabah	Sağ	51,10%
Aralık	Cumartesi	Sabah	Sağ	54,10%
Ocak	Cumartesi	Öğle	Sağ	49,10%
Şubat	Cumartesi	Öğle	Sağ	58,50%
Mart	Cumartesi	Öğle	Sağ	57,90%
Nisan	Cumartesi	Öğle	Sağ	59,60%
Mayıs	Cumartesi	Öğle	Sağ	66,00%*
Haziran	Cumartesi	Öğle	Sağ	58,50%
Temmuz	Cumartesi	Öğle	Sağ	62,00%
Ağustos	Cumartesi	Öğle	Sağ	54,50%
Eylül	Cumartesi	Öğle	Sağ	55,30%
Ekim	Cumartesi	Öğle	Sağ	54,30%
Kasım	Cumartesi	Öğle	Sağ	59,40%
Aralık	Cumartesi	Öğle	Sağ	62,30%
Ocak	Cumartesi	Akşam	Sağ	41,60%
Şubat	Cumartesi	Akşam	Sağ	51,00%
Mart	Cumartesi	Akşam	Sağ	50,40%
Nisan	Cumartesi	Akşam	Sağ	52,20%
Mayıs	Cumartesi	Akşam	Sağ	59,00%
Haziran	Cumartesi	Akşam	Sağ	51,00%
Temmuz	Cumartesi	Akşam	Sağ	54,70%
Ağustos	Cumartesi	Akşam	Sağ	47,00%
Eylül	Cumartesi	Akşam	Sağ	47,80%
Ekim	Cumartesi	Akşam	Sağ	46,70%
Kasım	Cumartesi	Akşam	Sağ	52,00%
Aralık	Cumartesi	Akşam	Sağ	55,00%
Ocak	Cumartesi	Gece	Sağ	24,60%
Şubat	Cumartesi	Gece	Sağ	32,30%
Mart	Cumartesi	Gece	Sağ	31,80%
Nisan	Cumartesi	Gece	Sağ	33,40%
Mayıs	Cumartesi	Gece	Sağ	39,70%
Haziran	Cumartesi	Gece	Sağ	32,30%
Temmuz	Cumartesi	Gece	Sağ	35,60%
Ağustos	Cumartesi	Gece	Sağ	28,90%
Eylül	Cumartesi	Gece	Sağ	29,50%
Ekim	Cumartesi	Gece	Sağ	28,70%
Kasım	Cumartesi	Gece	Sağ	33,20%
Aralık	Cumartesi	Gece	Sağ	35,90%

*En yüksek olasılık değeri

Tablo 4.63. 15 Temmuz Şehitler Köprüsü Sağ Şerit Yoğunluk İhtimalleri Senaryo_7

AYLAR	GÜNLER	ZAMAN	ŞERİT	Yoğunluk İhtimali
Ocak	Pazar	Sabah	Sağ	41,10%
Şubat	Pazar	Sabah	Sağ	50,50%
Mart	Pazar	Sabah	Sağ	49,90%
Nisan	Pazar	Sabah	Sağ	51,70%
Mayıs	Pazar	Sabah	Sağ	58,50%
Haziran	Pazar	Sabah	Sağ	50,50%
Temmuz	Pazar	Sabah	Sağ	54,20%
Ağustos	Pazar	Sabah	Sağ	46,50%
Eylül	Pazar	Sabah	Sağ	47,30%
Ekim	Pazar	Sabah	Sağ	46,20%
Kasım	Pazar	Sabah	Sağ	51,50%
Aralık	Pazar	Sabah	Sağ	54,40%
Ocak	Pazar	Öğle	Sağ	49,50%
Şubat	Pazar	Öğle	Sağ	58,80%
Mart	Pazar	Öğle	Sağ	58,20%
Nisan	Pazar	Öğle	Sağ	60,00%
Mayıs	Pazar	Öğle	Sağ	66,30%*
Haziran	Pazar	Öğle	Sağ	58,80%
Temmuz	Pazar	Öğle	Sağ	62,30%
Ağustos	Pazar	Öğle	Sağ	54,90%
Eylül	Pazar	Öğle	Sağ	55,70%
Ekim	Pazar	Öğle	Sağ	54,60%
Kasım	Pazar	Öğle	Sağ	59,80%
Aralık	Pazar	Öğle	Sağ	62,60%
Ocak	Pazar	Akşam	Sağ	42,00%
Şubat	Pazar	Akşam	Sağ	51,40%
Mart	Pazar	Akşam	Sağ	50,80%
Nisan	Pazar	Akşam	Sağ	52,60%
Mayıs	Pazar	Akşam	Sağ	59,30%
Haziran	Pazar	Akşam	Sağ	51,40%
Temmuz	Pazar	Akşam	Sağ	55,00%
Ağustos	Pazar	Akşam	Sağ	47,30%
Eylül	Pazar	Akşam	Sağ	48,10%
Ekim	Pazar	Akşam	Sağ	47,10%
Kasım	Pazar	Akşam	Sağ	52,40%
Aralık	Pazar	Akşam	Sağ	55,30%
Ocak	Pazar	Gece	Sağ	24,90%
Şubat	Pazar	Gece	Sağ	32,60%
Mart	Pazar	Gece	Sağ	32,10%
Nisan	Pazar	Gece	Sağ	33,70%
Mayıs	Pazar	Gece	Sağ	40,00%
Haziran	Pazar	Gece	Sağ	32,60%
Temmuz	Pazar	Gece	Sağ	36,00%
Ağustos	Pazar	Gece	Sağ	29,20%
Eylül	Pazar	Gece	Sağ	29,80%
Ekim	Pazar	Gece	Sağ	29,00%
Kasım	Pazar	Gece	Sağ	33,50%
Aralık	Pazar	Gece	Sağ	36,20%

***En yüksek olasılık değeri

Tablo 4.64. 15 Temmuz Şehitler Köprüsü Sağ Şeritte Günlere Göre Ort. Yoğunluk İhtimalleri

Gün	Yoğunluk İhtimali
Pazartesi	60,31%*
Salı	54,72%
Çarşamba	56,07%
Perşembe	57,49%
Cuma	57,76%
Cumartesi	47,70%
Pazar	48,04%

*En yüksek olasılık değeri

Tablo 4.65. 15 Temmuz Şehitler Köprüsü Sağ Şeritte Günlerin Zamana Göre Ort. Yoğunluk İhtimalleri

Gün	Zaman	Yoğunluk İhtimali
Pazartesi	Sabah	62,80%
Salı	Sabah	57,06%
Çarşamba	Sabah	58,49%
Perşembe	Sabah	59,93%
Cuma	Sabah	60,20%
Cumartesi	Sabah	49,83%
Pazar	Sabah	50,19%
Pazartesi	Öğle	70,22%*
Salı	Öğle	65,08%*
Çarşamba	Öğle	66,31%*
Perşembe	Öğle	67,62%*
Cuma	Öğle	67,88%*
Cumartesi	Öğle	58,12%*
Pazar	Öğle	58,46%*
Pazartesi	Akşam	63,59%
Salı	Akşam	57,92%
Çarşamba	Akşam	59,30%
Perşembe	Akşam	60,74%
Cuma	Akşam	61,02%
Cumartesi	Akşam	50,70%
Pazar	Akşam	51,06%
Pazartesi	Gece	44,63%
Salı	Gece	38,84%
Çarşamba	Gece	40,18%
Perşembe	Gece	41,66%
Cuma	Gece	41,93%
Cumartesi	Gece	32,16%
Pazar	Gece	32,47%

*En yüksek olasılık değerleri

D100 15 Temmuz Şehitler Köprüsünün sağ şeritte aylara, günlere ve zamana göre trafik olayları sonucunda meydana gelen yoğunluğun Bayesian Ağı ile analizleri gerçekleştirilmiştir. Tablo 4.65. ve Tablo 4.66.'da elde edilen sonuçlar şu şekildedir:

- Aralık ayında, pazartesi günleri, sağ şeritte, öğle vaktinde 73,80% olasılıkla yoğunluk meydana gelecektir.
- Mayıs ayında, salı günleri, sağ şeritte, öğle vaktinde 73,20% olasılıkla yoğunluk meydana gelecektir. Mayıs ayında, çarşamba günleri, sağ şeritte, öğle vaktinde 73,40% olasılıkla yoğunluk meydana gelecektir. Mayıs ayında, perşembe günleri, sağ şeritte, öğle vaktinde 74,60% olasılıkla yoğunluk meydana gelecektir. Mayıs ayında, cuma günleri, sağ şeritte, öğle vaktinde 74,80% olasılıkla yoğunluk meydana gelecektir. Mayıs ayında, cumartesi günleri, sağ şeritte, öğle vaktinde 66,00% olasılıkla yoğunluk meydana gelecektir. Mayıs ayında, pazar günleri, sağ şeritte, öğle vaktinde 66,30% olasılıkla yoğunluk meydana gelecektir.
- Pazartesi günleri köprü üzerinde 60,31%, Salı günleri köprü üzerinde 54,72%, Çarşamba günleri köprü üzerinde 56,07%, Perşembe günleri köprü üzerinde 57,49%, Cuma günleri köprü üzerinde 57,76%, Cumartesi günleri köprü üzerinde 47,70%, Pazar günleri köprü üzerinde 48,04% olasılıkla yoğunluk meydana gelme ihtimali vardır. Pazartesi günleri, öğle vaktinde köprü üzerinde 70,22%, Salı günleri, öğle vaktinde köprü üzerinde 65,08%, Çarşamba günleri, öğle vaktinde köprü üzerinde 66,31%, Perşembe günleri, öğle vaktinde köprü üzerinde 67,62%, Cuma günleri, öğle vaktinde köprü üzerinde 67,88%, Cumartesi günleri, öğle vaktinde köprü üzerinde 58,12%, Pazar günleri, öğle vaktinde köprü üzerinde 58,46% olasılıkla yoğunluk meydana gelme ihtimali vardır.

Tablo 4.66. 15 Temmuz Şehitler Köprüsü Sol Şerit Yoğunluk İhtimalleri Senaryo_1

AYLAR	GÜNLER	ZAMAN	ŞERİT	Yoğunluk İhtimali
Ocak	Pazartesi	Sabah	Sol	17,20%
Şubat	Pazartesi	Sabah	Sol	23,20%
Mart	Pazartesi	Sabah	Sol	22,80%
Nisan	Pazartesi	Sabah	Sol	24,10%
Mayıs	Pazartesi	Sabah	Sol	29,40%
Haziran	Pazartesi	Sabah	Sol	23,20%
Temmuz	Pazartesi	Sabah	Sol	26,00%
Ağustos	Pazartesi	Sabah	Sol	20,50%
Eylül	Pazartesi	Sabah	Sol	21,00%
Ekim	Pazartesi	Sabah	Sol	20,30%
Kasım	Pazartesi	Sabah	Sol	23,90%
Aralık	Pazartesi	Sabah	Sol	26,20%
Ocak	Pazartesi	Öğle	Sol	22,50%
Şubat	Pazartesi	Öğle	Sol	29,80%
Mart	Pazartesi	Öğle	Sol	29,20%
Nisan	Pazartesi	Öğle	Sol	30,80%
Mayıs	Pazartesi	Öğle	Sol	36,90%*
Haziran	Pazartesi	Öğle	Sol	29,80%
Temmuz	Pazartesi	Öğle	Sol	32,90%
Ağustos	Pazartesi	Öğle	Sol	26,50%
Eylül	Pazartesi	Öğle	Sol	27,10%
Ekim	Pazartesi	Öğle	Sol	26,30%
Kasım	Pazartesi	Öğle	Sol	30,60%
Aralık	Pazartesi	Öğle	Sol	33,20%
Ocak	Pazartesi	Akşam	Sol	17,70%
Şubat	Pazartesi	Akşam	Sol	23,90%
Mart	Pazartesi	Akşam	Sol	23,40%
Nisan	Pazartesi	Akşam	Sol	24,70%
Mayıs	Pazartesi	Akşam	Sol	30,20%
Haziran	Pazartesi	Akşam	Sol	23,90%
Temmuz	Pazartesi	Akşam	Sol	26,60%
Ağustos	Pazartesi	Akşam	Sol	21,10%
Eylül	Pazartesi	Akşam	Sol	21,60%
Ekim	Pazartesi	Akşam	Sol	20,90%
Kasım	Pazartesi	Akşam	Sol	24,60%
Aralık	Pazartesi	Akşam	Sol	26,80%
Ocak	Pazartesi	Gece	Sol	8,95%
Şubat	Pazartesi	Gece	Sol	12,60%
Mart	Pazartesi	Gece	Sol	12,30%
Nisan	Pazartesi	Gece	Sol	13,10%
Mayıs	Pazartesi	Gece	Sol	16,50%
Haziran	Pazartesi	Gece	Sol	12,60%
Temmuz	Pazartesi	Gece	Sol	14,30%
Ağustos	Pazartesi	Gece	Sol	10,90%
Eylül	Pazartesi	Gece	Sol	11,20%
Ekim	Pazartesi	Gece	Sol	10,80%
Kasım	Pazartesi	Gece	Sol	13,00%
Aralık	Pazartesi	Gece	Sol	14,40%

*En yüksek olasılık değerleri

Tablo 4.67. 15 Temmuz Şehitler Köprüsü Sol Şerit Yoğunluk İhtimalleri Senaryo_2

AYLAR	GÜNLER	ZAMAN	ŞERİT	Yoğunluk İhtimali
Ocak	Salı	Sabah	Sol	14,00%
Şubat	Salı	Sabah	Sol	19,20%
Mart	Salı	Sabah	Sol	18,80%
Nisan	Salı	Sabah	Sol	20,00%
Mayıs	Salı	Sabah	Sol	24,70%
Haziran	Salı	Sabah	Sol	19,20%
Temmuz	Salı	Sabah	Sol	21,60%
Ağustos	Salı	Sabah	Sol	16,80%
Eylül	Salı	Sabah	Sol	17,30%
Ekim	Salı	Sabah	Sol	16,70%
Kasım	Salı	Sabah	Sol	19,80%
Aralık	Salı	Sabah	Sol	21,80%
Ocak	Salı	Öğle	Sol	18,60%
Şubat	Salı	Öğle	Sol	25,00%
Mart	Salı	Öğle	Sol	24,50%
Nisan	Salı	Öğle	Sol	25,90%
Mayıs	Salı	Öğle	Sol	31,50%*
Haziran	Salı	Öğle	Sol	25,00%
Temmuz	Salı	Öğle	Sol	27,90%
Ağustos	Salı	Öğle	Sol	22,10%
Eylül	Salı	Öğle	Sol	22,60%
Ekim	Salı	Öğle	Sol	21,90%
Kasım	Salı	Öğle	Sol	25,70%
Aralık	Salı	Öğle	Sol	28,10%
Ocak	Salı	Akşam	Sol	14,40%
Şubat	Salı	Akşam	Sol	19,80%
Mart	Salı	Akşam	Sol	19,40%
Nisan	Salı	Akşam	Sol	20,50%
Mayıs	Salı	Akşam	Sol	25,40%
Haziran	Salı	Akşam	Sol	19,80%
Temmuz	Salı	Akşam	Sol	22,20%
Ağustos	Salı	Akşam	Sol	17,30%
Eylül	Salı	Akşam	Sol	17,80%
Ekim	Salı	Akşam	Sol	17,20%
Kasım	Salı	Akşam	Sol	20,40%
Aralık	Salı	Akşam	Sol	22,40%
Ocak	Salı	Gece	Sol	7,18%
Şubat	Salı	Gece	Sol	10,20%
Mart	Salı	Gece	Sol	9,93%
Nisan	Salı	Gece	Sol	10,60%
Mayıs	Salı	Gece	Sol	13,50%
Haziran	Salı	Gece	Sol	10,20%
Temmuz	Salı	Gece	Sol	11,60%
Ağustos	Salı	Gece	Sol	8,77%
Eylül	Salı	Gece	Sol	9,02%
Ekim	Salı	Gece	Sol	8,56%
Kasım	Salı	Gece	Sol	10,50%
Aralık	Salı	Gece	Sol	11,70%

*En yüksek olasılık değerleri

Tablo 4.68. 15 Temmuz Şehitler Köprüsü Sol Şerit Yoğunluk İhtimalleri Senaryo_3

AYLAR	GÜNLER	ZAMAN	ŞERİT	Yoğunluk İhtimali
Ocak	Çarşamba	Sabah	Sol	14,70%
Şubat	Çarşamba	Sabah	Sol	20,10%
Mart	Çarşamba	Sabah	Sol	19,70%
Nisan	Çarşamba	Sabah	Sol	20,90%
Mayıs	Çarşamba	Sabah	Sol	25,80%
Haziran	Çarşamba	Sabah	Sol	20,10%
Temmuz	Çarşamba	Sabah	Sol	22,60%
Ağustos	Çarşamba	Sabah	Sol	17,70%
Eylül	Çarşamba	Sabah	Sol	18,10%
Ekim	Çarşamba	Sabah	Sol	17,50%
Kasım	Çarşamba	Sabah	Sol	20,80%
Aralık	Çarşamba	Sabah	Sol	22,80%
Ocak	Çarşamba	Öğle	Sol	19,50%
Şubat	Çarşamba	Öğle	Sol	26,10%
Mart	Çarşamba	Öğle	Sol	25,60%
Nisan	Çarşamba	Öğle	Sol	27,00%
Mayıs	Çarşamba	Öğle	Sol	32,70%*
Haziran	Çarşamba	Öğle	Sol	26,10%
Temmuz	Çarşamba	Öğle	Sol	29,00%
Ağustos	Çarşamba	Öğle	Sol	23,10%
Eylül	Çarşamba	Öğle	Sol	23,70%
Ekim	Çarşamba	Öğle	Sol	22,90%
Kasım	Çarşamba	Öğle	Sol	26,80%
Aralık	Çarşamba	Öğle	Sol	29,20%
Ocak	Çarşamba	Akşam	Sol	15,20%
Şubat	Çarşamba	Akşam	Sol	20,70%
Mart	Çarşamba	Akşam	Sol	20,30%
Nisan	Çarşamba	Akşam	Sol	21,50%
Mayıs	Çarşamba	Akşam	Sol	26,50%
Haziran	Çarşamba	Akşam	Sol	20,70%
Temmuz	Çarşamba	Akşam	Sol	23,20%
Ağustos	Çarşamba	Akşam	Sol	18,20%
Eylül	Çarşamba	Akşam	Sol	18,60%
Ekim	Çarşamba	Akşam	Sol	18,00%
Kasım	Çarşamba	Akşam	Sol	21,30%
Aralık	Çarşamba	Akşam	Sol	23,40%
Ocak	Çarşamba	Gece	Sol	7,57%
Şubat	Çarşamba	Gece	Sol	10,70%
Mart	Çarşamba	Gece	Sol	10,50%
Nisan	Çarşamba	Gece	Sol	11,10%
Mayıs	Çarşamba	Gece	Sol	14,20%
Haziran	Çarşamba	Gece	Sol	10,70%
Temmuz	Çarşamba	Gece	Sol	12,20%
Ağustos	Çarşamba	Gece	Sol	9,24%
Eylül	Çarşamba	Gece	Sol	9,51%
Ekim	Çarşamba	Gece	Sol	9,15%
Kasım	Çarşamba	Gece	Sol	11,10%
Aralık	Çarşamba	Gece	Sol	12,30%

*En yüksek olasılık değerleri

Tablo 4.69. 15 Temmuz Şehitler Köprüsü Sol Şerit Yoğunluk İhtimalleri Senaryo_4

AYLAR	GÜNLER	ZAMAN	ŞERİT	Yoğunluk İhtimali
Ocak	Perşembe	Sabah	Sol	15,50%
Şubat	Perşembe	Sabah	Sol	21,10%
Mart	Perşembe	Sabah	Sol	20,70%
Nisan	Perşembe	Sabah	Sol	21,90%
Mayıs	Perşembe	Sabah	Sol	27,00%
Haziran	Perşembe	Sabah	Sol	21,10%
Temmuz	Perşembe	Sabah	Sol	23,70%
Ağustos	Perşembe	Sabah	Sol	18,60%
Eylül	Perşembe	Sabah	Sol	19,00%
Ekim	Perşembe	Sabah	Sol	18,40%
Kasım	Perşembe	Sabah	Sol	21,80%
Aralık	Perşembe	Sabah	Sol	23,90%
Ocak	Perşembe	Öğle	Sol	20,40%
Şubat	Perşembe	Öğle	Sol	27,30%
Mart	Perşembe	Öğle	Sol	26,80%
Nisan	Perşembe	Öğle	Sol	28,20%
Mayıs	Perşembe	Öğle	Sol	34,10%*
Haziran	Perşembe	Öğle	Sol	27,30%
Temmuz	Perşembe	Öğle	Sol	30,30%
Ağustos	Perşembe	Öğle	Sol	24,20%
Eylül	Perşembe	Öğle	Sol	24,80%
Ekim	Perşembe	Öğle	Sol	24,00%
Kasım	Perşembe	Öğle	Sol	28,10%
Aralık	Perşembe	Öğle	Sol	30,50%
Ocak	Perşembe	Akşam	Sol	16,00%
Şubat	Perşembe	Akşam	Sol	21,70%
Mart	Perşembe	Akşam	Sol	21,30%
Nisan	Perşembe	Akşam	Sol	22,50%
Mayıs	Perşembe	Akşam	Sol	27,70%
Haziran	Perşembe	Akşam	Sol	21,70%
Temmuz	Perşembe	Akşam	Sol	24,30%
Ağustos	Perşembe	Akşam	Sol	19,10%
Eylül	Perşembe	Akşam	Sol	19,60%
Ekim	Perşembe	Akşam	Sol	18,90%
Kasım	Perşembe	Akşam	Sol	22,40%
Aralık	Perşembe	Akşam	Sol	24,50%
Ocak	Perşembe	Gece	Sol	8,01%
Şubat	Perşembe	Gece	Sol	11,30%
Mart	Perşembe	Gece	Sol	11,00%
Nisan	Perşembe	Gece	Sol	11,80%
Mayıs	Perşembe	Gece	Sol	14,90%
Haziran	Perşembe	Gece	Sol	11,30%
Temmuz	Perşembe	Gece	Sol	12,80%
Ağustos	Perşembe	Gece	Sol	9,76%
Eylül	Perşembe	Gece	Sol	10,00%
Ekim	Perşembe	Gece	Sol	9,67%
Kasım	Perşembe	Gece	Sol	11,70%
Aralık	Perşembe	Gece	Sol	13,00%

*En yüksek olasılık değerleri

Tablo 4.70. 15 Temmuz Şehitler Köprüsü Sol Şerit Yoğunluk İhtimalleri Senaryo_5

AYLAR	GÜNLER	ZAMAN	ŞERİT	Yoğunluk İhtimali
Ocak	Cuma	Sabah	Sol	15,70%
Şubat	Cuma	Sabah	Sol	21,30%
Mart	Cuma	Sabah	Sol	20,90%
Nisan	Cuma	Sabah	Sol	22,10%
Mayıs	Cuma	Sabah	Sol	27,20%
Haziran	Cuma	Sabah	Sol	21,30%
Temmuz	Cuma	Sabah	Sol	23,90%
Ağustos	Cuma	Sabah	Sol	18,70%
Eylül	Cuma	Sabah	Sol	19,20%
Ekim	Cuma	Sabah	Sol	18,60%
Kasım	Cuma	Sabah	Sol	22,00%
Aralık	Cuma	Sabah	Sol	24,10%
Ocak	Cuma	Öğle	Sol	20,60%
Şubat	Cuma	Öğle	Sol	27,50%
Mart	Cuma	Öğle	Sol	27,00%
Nisan	Cuma	Öğle	Sol	28,50%
Mayıs	Cuma	Öğle	Sol	34,30%*
Haziran	Cuma	Öğle	Sol	27,50%
Temmuz	Cuma	Öğle	Sol	30,50%
Ağustos	Cuma	Öğle	Sol	24,40%
Eylül	Cuma	Öğle	Sol	25,00%
Ekim	Cuma	Öğle	Sol	24,20%
Kasım	Cuma	Öğle	Sol	28,30%
Aralık	Cuma	Öğle	Sol	30,80%
Ocak	Cuma	Akşam	Sol	16,10%
Şubat	Cuma	Akşam	Sol	21,90%
Mart	Cuma	Akşam	Sol	21,50%
Nisan	Cuma	Akşam	Sol	22,70%
Mayıs	Cuma	Akşam	Sol	27,90%
Haziran	Cuma	Akşam	Sol	21,90%
Temmuz	Cuma	Akşam	Sol	24,50%
Ağustos	Cuma	Akşam	Sol	19,30%
Eylül	Cuma	Akşam	Sol	19,80%
Ekim	Cuma	Akşam	Sol	19,10%
Kasım	Cuma	Akşam	Sol	22,60%
Aralık	Cuma	Akşam	Sol	24,70%
Ocak	Cuma	Gece	Sol	8,10%
Şubat	Cuma	Gece	Sol	11,40%
Mart	Cuma	Gece	Sol	11,20%
Nisan	Cuma	Gece	Sol	11,90%
Mayıs	Cuma	Gece	Sol	15,10%
Haziran	Cuma	Gece	Sol	11,40%
Temmuz	Cuma	Gece	Sol	13,00%
Ağustos	Cuma	Gece	Sol	9,87%
Eylül	Cuma	Gece	Sol	10,10%
Ekim	Cuma	Gece	Sol	9,77%
Kasım	Cuma	Gece	Sol	11,80%
Aralık	Cuma	Gece	Sol	13,10%

*En yüksek olasılık değerleri

Tablo 4.71. 15 Temmuz Şehitler Köprüsü Sol Şerit Yoğunluk İhtimalleri Senaryo_6

AYLAR	GÜNLER	ZAMAN	ŞERİT	Yoğunluk İhtimali
Ocak	Cumartesi	Sabah	Sol	10,80%
Şubat	Cumartesi	Sabah	Sol	15,10%
Mart	Cumartesi	Sabah	Sol	14,80%
Nisan	Cumartesi	Sabah	Sol	15,70%
Mayıs	Cumartesi	Sabah	Sol	19,70%
Haziran	Cumartesi	Sabah	Sol	15,10%
Temmuz	Cumartesi	Sabah	Sol	17,10%
Ağustos	Cumartesi	Sabah	Sol	13,10%
Eylül	Cumartesi	Sabah	Sol	13,50%
Ekim	Cumartesi	Sabah	Sol	13,00%
Kasım	Cumartesi	Sabah	Sol	15,60%
Aralık	Cumartesi	Sabah	Sol	17,20%
Ocak	Cumartesi	Öğle	Sol	14,50%
Şubat	Cumartesi	Öğle	Sol	19,90%
Mart	Cumartesi	Öğle	Sol	19,50%
Nisan	Cumartesi	Öğle	Sol	20,70%
Mayıs	Cumartesi	Öğle	Sol	25,50%*
Haziran	Cumartesi	Öğle	Sol	19,90%
Temmuz	Cumartesi	Öğle	Sol	22,40%
Ağustos	Cumartesi	Öğle	Sol	17,40%
Eylül	Cumartesi	Öğle	Sol	17,90%
Ekim	Cumartesi	Öğle	Sol	17,30%
Kasım	Cumartesi	Öğle	Sol	20,50%
Aralık	Cumartesi	Öğle	Sol	22,50%
Ocak	Cumartesi	Akşam	Sol	11,20%
Şubat	Cumartesi	Akşam	Sol	15,50%
Mart	Cumartesi	Akşam	Sol	15,20%
Nisan	Cumartesi	Akşam	Sol	16,10%
Mayıs	Cumartesi	Akşam	Sol	20,20%
Haziran	Cumartesi	Akşam	Sol	15,50%
Temmuz	Cumartesi	Akşam	Sol	17,60%
Ağustos	Cumartesi	Akşam	Sol	13,50%
Eylül	Cumartesi	Akşam	Sol	13,90%
Ekim	Cumartesi	Akşam	Sol	13,40%
Kasım	Cumartesi	Akşam	Sol	16,00%
Aralık	Cumartesi	Akşam	Sol	17,70%
Ocak	Cumartesi	Gece	Sol	5,45%
Şubat	Cumartesi	Gece	Sol	7,77%
Mart	Cumartesi	Gece	Sol	7,59%
Nisan	Cumartesi	Gece	Sol	8,11%
Mayıs	Cumartesi	Gece	Sol	10,40%
Haziran	Cumartesi	Gece	Sol	7,77%
Temmuz	Cumartesi	Gece	Sol	8,89%
Ağustos	Cumartesi	Gece	Sol	6,69%
Eylül	Cumartesi	Gece	Sol	6,89%
Ekim	Cumartesi	Gece	Sol	6,62%
Kasım	Cumartesi	Gece	Sol	8,05%
Aralık	Cumartesi	Gece	Sol	8,98%

*En yüksek olasılık değerleri

Tablo 4.72. 15 Temmuz Şehitler Köprüsü Sol Şerit Yoğunluk İhtimalleri Senaryo_7

AYLAR	GÜNLER	ZAMAN	ŞERİT	Yoğunluk İhtimali
Ocak	Pazar	Sabah	Sol	11,00%
Şubat	Pazar	Sabah	Sol	15,30%
Mart	Pazar	Sabah	Sol	14,90%
Nisan	Pazar	Sabah	Sol	15,90%
Mayıs	Pazar	Sabah	Sol	19,90%
Haziran	Pazar	Sabah	Sol	15,30%
Temmuz	Pazar	Sabah	Sol	17,30%
Ağustos	Pazar	Sabah	Sol	13,30%
Eylül	Pazar	Sabah	Sol	13,60%
Ekim	Pazar	Sabah	Sol	13,20%
Kasım	Pazar	Sabah	Sol	15,80%
Aralık	Pazar	Sabah	Sol	17,40%
Ocak	Pazar	Öğle	Sol	14,70%
Şubat	Pazar	Öğle	Sol	20,10%
Mart	Pazar	Öğle	Sol	19,70%
Nisan	Pazar	Öğle	Sol	20,90%
Mayıs	Pazar	Öğle	Sol	25,80%*
Haziran	Pazar	Öğle	Sol	20,10%
Temmuz	Pazar	Öğle	Sol	22,60%
Ağustos	Pazar	Öğle	Sol	17,70%
Eylül	Pazar	Öğle	Sol	18,10%
Ekim	Pazar	Öğle	Sol	17,50%
Kasım	Pazar	Öğle	Sol	20,80%
Aralık	Pazar	Öğle	Sol	22,80%
Ocak	Pazar	Akşam	Sol	11,30%
Şubat	Pazar	Akşam	Sol	15,70%
Mart	Pazar	Akşam	Sol	15,40%
Nisan	Pazar	Akşam	Sol	16,30%
Mayıs	Pazar	Akşam	Sol	20,40%
Haziran	Pazar	Akşam	Sol	15,70%
Temmuz	Pazar	Akşam	Sol	17,80%
Ağustos	Pazar	Akşam	Sol	13,70%
Eylül	Pazar	Akşam	Sol	14,10%
Ekim	Pazar	Akşam	Sol	13,60%
Kasım	Pazar	Akşam	Sol	16,20%
Aralık	Pazar	Akşam	Sol	17,90%
Ocak	Pazar	Gece	Sol	5,53%
Şubat	Pazar	Gece	Sol	7,87%
Mart	Pazar	Gece	Sol	7,69%
Nisan	Pazar	Gece	Sol	8,22%
Mayıs	Pazar	Gece	Sol	10,50%
Haziran	Pazar	Gece	Sol	7,87%
Temmuz	Pazar	Gece	Sol	9,01%
Ağustos	Pazar	Gece	Sol	6,78%
Eylül	Pazar	Gece	Sol	6,98%
Ekim	Pazar	Gece	Sol	6,71%
Kasım	Pazar	Gece	Sol	8,16%
Aralık	Pazar	Gece	Sol	9,09%

*En yüksek olasılık değerleri

Tablo 4.73. 15 Temmuz Şehitler Köprüsü Sol Şeritte Günlere Göre Ort. Yoğunluk İhtimalleri

Gün	Yoğunluk İhtimali
Pazartesi	22,28%*
Salı	18,48%
Çarşamba	19,34%
Perşembe	20,28%
Cuma	20,47%
Cumartesi	14,54%
Pazar	14,71%

Tablo 4.74. 15 Temmuz Şehitler Köprüsü Sol Şeritte Günlerin Zamana Göre Ort. Yoğunluk İhtimalleri

Gün	Zaman	Yoğunluk İhtimali
Pazartesi	Sabah	23,15%
Salı	Sabah	19,12%
Çarşamba	Sabah	20,07%
Perşembe	Sabah	21,06%
Cuma	Sabah	21,25%
Cumartesi	Sabah	15,06%
Pazar	Sabah	15,24%
Pazartesi	Öğle	29,63%*
Salı	Öğle	24,90%*
Çarşamba	Öğle	25,98%*
Perşembe	Öğle	27,17%*
Cuma	Öğle	27,38%*
Cumartesi	Öğle	19,83%*
Pazar	Öğle	20,07%*
Pazartesi	Akşam	23,78%
Salı	Akşam	19,72%
Çarşamba	Akşam	20,63%
Perşembe	Akşam	21,64%
Cuma	Akşam	21,83%
Cumartesi	Akşam	15,48%
Pazar	Akşam	15,68%
Pazartesi	Gece	12,55%
Salı	Gece	10,15%
Çarşamba	Gece	10,69%
Perşembe	Gece	11,27%
Cuma	Gece	11,40%
Cumartesi	Gece	7,77%
Pazar	Gece	7,87%

D100 15 Temmuz Şehitler Köprüsünün sol şeritte aylara, günlere ve zamana göre trafik olayları sonucunda meydana gelen yoğunluğun Bayesian Ağı ile analizleri gerçekleştirilmiştir. Tablo 4.73. ve Tablo 4.74.'de elde edilen sonuçlar şu şekildedir:

- Mayıs ayında, pazartesi günleri, sol şeritte, öğle vaktinde 36,90% olasılıkla yoğunluk meydana gelecektir. Mayıs ayında, salı günleri, sol şeritte, öğle vaktinde 31,50% olasılıkla yoğunluk meydana gelecektir. Mayıs ayında, çarşamba günleri, sol şeritte, öğle vaktinde 32,70% olasılıkla yoğunluk meydana gelecektir. Mayıs ayında, perşembe günleri, sol şeritte, öğle vaktinde 34,10% olasılıkla yoğunluk meydana gelecektir. Mayıs ayında, cuma günleri, sol şeritte, öğle vaktinde 34,30% olasılıkla yoğunluk meydana gelecektir. Mayıs ayında, cumartesi günleri, sol şeritte, öğle vaktinde 25,50% olasılıkla yoğunluk meydana gelecektir. Mayıs ayında, pazar günleri, sol şeritte, öğle vaktinde 25,80 % olasılıkla yoğunluk meydana gelecektir.
- Pazartesi günleri köprü üzerinde 22,28%, Salı günleri köprü üzerinde 18,48%, Çarşamba günleri köprü üzerinde 19,34%, Perşembe günleri köprü üzerinde 20,28%, Cuma günleri köprü üzerinde 20,47%, Cumartesi günleri köprü üzerinde 14,54%, Pazar günleri köprü üzerinde 14,71% olasılıkla yoğunluk meydana gelme ihtimali vardır. Pazartesi günleri, öğle vaktinde köprü üzerinde 29,63%, Salı günleri, öğle vaktinde köprü üzerinde 24,90%, Çarşamba günleri, öğle vaktinde köprü üzerinde 25,98%, Perşembe günleri, öğle vaktinde köprü üzerinde 27,17%, Cuma günleri, öğle vaktinde köprü üzerinde 27,38%, Cumartesi günleri, öğle vaktinde köprü üzerinde 19,83%, Pazar günleri, öğle vaktinde köprü üzerinde 20,07% olasılıkla yoğunluk meydana gelme ihtimali vardır.

Tablo 4.75. 15 Temmuz Şehitler Köprüsü Orta Şerit Yoğunluk İhtimalleri Senaryo_1

AYLAR	GÜNLER	ZAMAN	ŞERİT	Yoğunluk İhtimali
Ocak	Pazartesi	Sabah	Orta	34,40%
Şubat	Pazartesi	Sabah	Orta	43,40%
Mart	Pazartesi	Sabah	Orta	42,80%
Nisan	Pazartesi	Sabah	Orta	44,50%
Mayıs	Pazartesi	Sabah	Orta	51,40%
Haziran	Pazartesi	Sabah	Orta	43,40%
Temmuz	Pazartesi	Sabah	Orta	47,00%
Ağustos	Pazartesi	Sabah	Orta	39,50%
Eylül	Pazartesi	Sabah	Orta	40,20%
Ekim	Pazartesi	Sabah	Orta	39,20%
Kasım	Pazartesi	Sabah	Orta	44,30%
Aralık	Pazartesi	Sabah	Orta	47,30%
Ocak	Pazartesi	Öğle	Orta	42,30%
Şubat	Pazartesi	Öğle	Orta	51,80%
Mart	Pazartesi	Öğle	Orta	51,10%
Nisan	Pazartesi	Öğle	Orta	52,90%
Mayıs	Pazartesi	Öğle	Orta	59,70%*
Haziran	Pazartesi	Öğle	Orta	51,80%
Temmuz	Pazartesi	Öğle	Orta	55,40%
Ağustos	Pazartesi	Öğle	Orta	47,70%
Eylül	Pazartesi	Öğle	Orta	48,50%
Ekim	Pazartesi	Öğle	Orta	47,50%
Kasım	Pazartesi	Öğle	Orta	52,70%
Aralık	Pazartesi	Öğle	Orta	55,70%
Ocak	Pazartesi	Akşam	Orta	35,20%
Şubat	Pazartesi	Akşam	Orta	44,20%
Mart	Pazartesi	Akşam	Orta	43,60%
Nisan	Pazartesi	Akşam	Orta	45,40%
Mayıs	Pazartesi	Akşam	Orta	52,20%
Haziran	Pazartesi	Akşam	Orta	44,20%
Temmuz	Pazartesi	Akşam	Orta	47,90%
Ağustos	Pazartesi	Akşam	Orta	40,30%
Eylül	Pazartesi	Akşam	Orta	41,10%
Ekim	Pazartesi	Akşam	Orta	40,00%
Kasım	Pazartesi	Akşam	Orta	45,20%
Aralık	Pazartesi	Akşam	Orta	48,20%
Ocak	Pazartesi	Gece	Orta	19,90%
Şubat	Pazartesi	Gece	Orta	26,70%
Mart	Pazartesi	Gece	Orta	26,20%
Nisan	Pazartesi	Gece	Orta	27,60%
Mayıs	Pazartesi	Gece	Orta	33,40%
Haziran	Pazartesi	Gece	Orta	26,70%
Temmuz	Pazartesi	Gece	Orta	29,60%
Ağustos	Pazartesi	Gece	Orta	23,60%
Eylül	Pazartesi	Gece	Orta	24,20%
Ekim	Pazartesi	Gece	Orta	23,40%
Kasım	Pazartesi	Gece	Orta	27,40%
Aralık	Pazartesi	Gece	Orta	29,90%

*En yüksek olasılık değerleri

Tablo 4.76. 15 Temmuz Şehitler Köprüsü Orta Şerit Yoğunluk İhtimalleri Senaryo_2

AYLAR	GÜNLER	ZAMAN	ŞERİT	Yoğunluk İhtimali
Ocak	Salı	Sabah	Orta	29,20%
Şubat	Salı	Sabah	Orta	37,60%
Mart	Salı	Sabah	Orta	37,00%
Nisan	Salı	Sabah	Orta	38,70%
Mayıs	Salı	Sabah	Orta	45,40%
Haziran	Salı	Sabah	Orta	37,60%
Temmuz	Salı	Sabah	Orta	41,10%
Ağustos	Salı	Sabah	Orta	33,90%
Eylül	Salı	Sabah	Orta	34,60%
Ekim	Salı	Sabah	Orta	33,70%
Kasım	Salı	Sabah	Orta	38,50%
Aralık	Salı	Sabah	Orta	41,40%
Ocak	Salı	Öğle	Orta	36,60%
Şubat	Salı	Öğle	Orta	45,80%
Mart	Salı	Öğle	Orta	45,10%
Nisan	Salı	Öğle	Orta	46,90%
Mayıs	Salı	Öğle	Orta	53,80%*
Haziran	Salı	Öğle	Orta	45,80%
Temmuz	Salı	Öğle	Orta	49,40%
Ağustos	Salı	Öğle	Orta	41,80%
Eylül	Salı	Öğle	Orta	42,60%
Ekim	Salı	Öğle	Orta	41,50%
Kasım	Salı	Öğle	Orta	46,70%
Aralık	Salı	Öğle	Orta	49,70%
Ocak	Salı	Akşam	Orta	29,90%
Şubat	Salı	Akşam	Orta	38,40%
Mart	Salı	Akşam	Orta	37,80%
Nisan	Salı	Akşam	Orta	39,50%
Mayıs	Salı	Akşam	Orta	46,20%
Haziran	Salı	Akşam	Orta	38,40%
Temmuz	Salı	Akşam	Orta	42,00%
Ağustos	Salı	Akşam	Orta	34,70%
Eylül	Salı	Akşam	Orta	35,40%
Ekim	Salı	Akşam	Orta	34,40%
Kasım	Salı	Akşam	Orta	39,30%
Aralık	Salı	Akşam	Orta	42,20%
Ocak	Salı	Gece	Orta	16,40%
Şubat	Salı	Gece	Orta	22,20%
Mart	Salı	Gece	Orta	21,80%
Nisan	Salı	Gece	Orta	23,10%
Mayıs	Salı	Gece	Orta	28,30%
Haziran	Salı	Gece	Orta	22,20%
Temmuz	Salı	Gece	Orta	24,90%
Ağustos	Salı	Gece	Orta	19,60%
Eylül	Salı	Gece	Orta	20,10%
Ekim	Salı	Gece	Orta	19,40%
Kasım	Salı	Gece	Orta	22,90%
Aralık	Salı	Gece	Orta	25,10%

Tablo 4.77. 15 Temmuz Şehitler Köprüsü Orta Şerit Yoğunluk İhtimalleri

Senaryo_3

AYLAR	GÜNLER	ZAMAN	ŞERİT	Yoğunluk İhtimali
Ocak	Çarşamba	Sabah	Orta	30,40%
Şubat	Çarşamba	Sabah	Orta	39,00%
Mart	Çarşamba	Sabah	Orta	38,40%
Nisan	Çarşamba	Sabah	Orta	40,10%
Mayıs	Çarşamba	Sabah	Orta	46,80%
Haziran	Çarşamba	Sabah	Orta	39,00%
Temmuz	Çarşamba	Sabah	Orta	42,50%
Ağustos	Çarşamba	Sabah	Orta	35,20%
Eylül	Çarşamba	Sabah	Orta	35,90%
Ekim	Çarşamba	Sabah	Orta	34,90%
Kasım	Çarşamba	Sabah	Orta	39,90%
Aralık	Çarşamba	Sabah	Orta	42,80%
Ocak	Çarşamba	Öğle	Orta	38,00%
Şubat	Çarşamba	Öğle	Orta	47,20%
Mart	Çarşamba	Öğle	Orta	46,00%
Nisan	Çarşamba	Öğle	Orta	48,40%
Mayıs	Çarşamba	Öğle	Orta	55,20%*
Haziran	Çarşamba	Öğle	Orta	47,20%
Temmuz	Çarşamba	Öğle	Orta	50,90%
Ağustos	Çarşamba	Öğle	Orta	43,20%
Eylül	Çarşamba	Öğle	Orta	44,00%
Ekim	Çarşamba	Öğle	Orta	42,90%
Kasım	Çarşamba	Öğle	Orta	48,20%
Aralık	Çarşamba	Öğle	Orta	51,10%
Ocak	Çarşamba	Akşam	Orta	31,10%
Şubat	Çarşamba	Akşam	Orta	39,80%
Mart	Çarşamba	Akşam	Orta	39,20%
Nisan	Çarşamba	Akşam	Orta	40,90%
Mayıs	Çarşamba	Akşam	Orta	47,70%
Haziran	Çarşamba	Akşam	Orta	39,80%
Temmuz	Çarşamba	Akşam	Orta	43,40%
Ağustos	Çarşamba	Akşam	Orta	36,00%
Eylül	Çarşamba	Akşam	Orta	36,70%
Ekim	Çarşamba	Akşam	Orta	35,70%
Kasım	Çarşamba	Akşam	Orta	40,70%
Aralık	Çarşamba	Akşam	Orta	43,60%
Ocak	Çarşamba	Gece	Orta	17,20%
Şubat	Çarşamba	Gece	Orta	23,20%
Mart	Çarşamba	Gece	Orta	22,80%
Nisan	Çarşamba	Gece	Orta	24,10%
Mayıs	Çarşamba	Gece	Orta	29,50%
Haziran	Çarşamba	Gece	Orta	23,20%
Temmuz	Çarşamba	Gece	Orta	26,00%
Ağustos	Çarşamba	Gece	Orta	20,50%
Eylül	Çarşamba	Gece	Orta	21,00%
Ekim	Çarşamba	Gece	Orta	20,30%
Kasım	Çarşamba	Gece	Orta	24,00%
Aralık	Çarşamba	Gece	Orta	26,20%

Tablo 4.78. 15 Temmuz Şehitler Köprüsü Orta Şerit Yoğunluk İhtimalleri

Senaryo_4

AYLAR	GÜNLER	ZAMAN	ŞERİT	Yoğunluk İhtimali
Ocak	Perşembe	Sabah	Orta	31,70%
Şubat	Perşembe	Sabah	Orta	40,40%
Mart	Perşembe	Sabah	Orta	39,80%
Nisan	Perşembe	Sabah	Orta	41,50%
Mayıs	Perşembe	Sabah	Orta	48,30%
Haziran	Perşembe	Sabah	Orta	40,40%
Temmuz	Perşembe	Sabah	Orta	44,00%
Ağustos	Perşembe	Sabah	Orta	36,60%
Eylül	Perşembe	Sabah	Orta	37,30%
Ekim	Perşembe	Sabah	Orta	36,30%
Kasım	Perşembe	Sabah	Orta	41,40%
Aralık	Perşembe	Sabah	Orta	44,30%
Ocak	Perşembe	Öğle	Orta	39,40%
Şubat	Perşembe	Öğle	Orta	48,70%
Mart	Perşembe	Öğle	Orta	48,10%
Nisan	Perşembe	Öğle	Orta	49,90%
Mayıs	Perşembe	Öğle	Orta	56,70%*
Haziran	Perşembe	Öğle	Orta	48,70%
Temmuz	Perşembe	Öğle	Orta	52,40%
Ağustos	Perşembe	Öğle	Orta	44,70%
Eylül	Perşembe	Öğle	Orta	45,50%
Ekim	Perşembe	Öğle	Orta	44,40%
Kasım	Perşembe	Öğle	Orta	49,70%
Aralık	Perşembe	Öğle	Orta	52,60%
Ocak	Perşembe	Akşam	Orta	32,50%
Şubat	Perşembe	Akşam	Orta	41,30%
Mart	Perşembe	Akşam	Orta	40,70%
Nisan	Perşembe	Akşam	Orta	42,40%
Mayıs	Perşembe	Akşam	Orta	49,20%
Haziran	Perşembe	Akşam	Orta	41,30%
Temmuz	Perşembe	Akşam	Orta	44,90%
Ağustos	Perşembe	Akşam	Orta	37,40%
Eylül	Perşembe	Akşam	Orta	38,10%
Ekim	Perşembe	Akşam	Orta	37,20%
Kasım	Perşembe	Akşam	Orta	42,20%
Aralık	Perşembe	Akşam	Orta	45,10%
Ocak	Perşembe	Gece	Orta	18,10%
Şubat	Perşembe	Gece	Orta	24,40%
Mart	Perşembe	Gece	Orta	23,90%
Nisan	Perşembe	Gece	Orta	25,20%
Mayıs	Perşembe	Gece	Orta	30,70%
Haziran	Perşembe	Gece	Orta	24,40%
Temmuz	Perşembe	Gece	Orta	27,20%
Ağustos	Perşembe	Gece	Orta	21,50%
Eylül	Perşembe	Gece	Orta	22,00%
Ekim	Perşembe	Gece	Orta	21,30%
Kasım	Perşembe	Gece	Orta	25,10%
Aralık	Perşembe	Gece	Orta	27,40%

Tablo 4.79. 15 Temmuz Şehitler Köprüsü Orta Şerit Yoğunluk İhtimalleri

Senaryo_5

AYLAR	GÜNLER	ZAMAN	ŞERİT	Yoğunluk İhtimali
Ocak	Cuma	Sabah	Orta	32,00%
Şubat	Cuma	Sabah	Orta	40,70%
Mart	Cuma	Sabah	Orta	40,10%
Nisan	Cuma	Sabah	Orta	41,80%
Mayıs	Cuma	Sabah	Orta	48,60%
Haziran	Cuma	Sabah	Orta	40,70%
Temmuz	Cuma	Sabah	Orta	44,30%
Ağustos	Cuma	Sabah	Orta	36,90%
Eylül	Cuma	Sabah	Orta	37,60%
Ekim	Cuma	Sabah	Orta	36,60%
Kasım	Cuma	Sabah	Orta	41,60%
Aralık	Cuma	Sabah	Orta	44,50%
Ocak	Cuma	Öğle	Orta	39,70%
Şubat	Cuma	Öğle	Orta	49,00%
Mart	Cuma	Öğle	Orta	48,40%
Nisan	Cuma	Öğle	Orta	50,20%
Mayıs	Cuma	Öğle	Orta	57,00%*
Haziran	Cuma	Öğle	Orta	49,00%
Temmuz	Cuma	Öğle	Orta	52,70%
Ağustos	Cuma	Öğle	Orta	45,00%
Eylül	Cuma	Öğle	Orta	45,80%
Ekim	Cuma	Öğle	Orta	44,70%
Kasım	Cuma	Öğle	Orta	50,00%
Aralık	Cuma	Öğle	Orta	52,90%
Ocak	Cuma	Akşam	Orta	32,70%
Şubat	Cuma	Akşam	Orta	41,50%
Mart	Cuma	Akşam	Orta	40,90%
Nisan	Cuma	Akşam	Orta	42,70%
Mayıs	Cuma	Akşam	Orta	49,50%
Haziran	Cuma	Akşam	Orta	41,50%
Temmuz	Cuma	Akşam	Orta	45,10%
Ağustos	Cuma	Akşam	Orta	37,70%
Eylül	Cuma	Akşam	Orta	38,40%
Ekim	Cuma	Akşam	Orta	37,40%
Kasım	Cuma	Akşam	Orta	42,50%
Aralık	Cuma	Akşam	Orta	45,40%
Ocak	Cuma	Gece	Orta	18,20%
Şubat	Cuma	Gece	Orta	24,60%
Mart	Cuma	Gece	Orta	24,10%
Nisan	Cuma	Gece	Orta	25,40%
Mayıs	Cuma	Gece	Orta	31,00%
Haziran	Cuma	Gece	Orta	24,60%
Temmuz	Cuma	Gece	Orta	27,40%
Ağustos	Cuma	Gece	Orta	21,70%
Eylül	Cuma	Gece	Orta	22,20%
Ekim	Cuma	Gece	Orta	21,50%
Kasım	Cuma	Gece	Orta	25,30%
Aralık	Cuma	Gece	Orta	27,60%

Tablo 4.80. 15 Temmuz Şehitler Köprüsü Orta Şerit Yoğunluk İhtimalleri

Senaryo_6

AYLAR	GÜNLER	ZAMAN	ŞERİT	Yoğunluk İhtimali
Ocak	Cumartesi	Sabah	Orta	23,50%
Şubat	Cumartesi	Sabah	Orta	31,00%
Mart	Cumartesi	Sabah	Orta	30,50%
Nisan	Cumartesi	Sabah	Orta	32,00%
Mayıs	Cumartesi	Sabah	Orta	38,20%
Haziran	Cumartesi	Sabah	Orta	31,00%
Temmuz	Cumartesi	Sabah	Orta	34,20%
Ağustos	Cumartesi	Sabah	Orta	27,60%
Eylül	Cumartesi	Sabah	Orta	28,30%
Ekim	Cumartesi	Sabah	Orta	27,40%
Kasım	Cumartesi	Sabah	Orta	31,80%
Aralık	Cumartesi	Sabah	Orta	34,50%
Ocak	Cumartesi	Öğle	Orta	30,10%
Şubat	Cumartesi	Öğle	Orta	38,60%
Mart	Cumartesi	Öğle	Orta	38,00%
Nisan	Cumartesi	Öğle	Orta	39,70%
Mayıs	Cumartesi	Öğle	Orta	46,40%*
Haziran	Cumartesi	Öğle	Orta	38,60%
Temmuz	Cumartesi	Öğle	Orta	42,20%
Ağustos	Cumartesi	Öğle	Orta	34,90%
Eylül	Cumartesi	Öğle	Orta	35,60%
Ekim	Cumartesi	Öğle	Orta	34,60%
Kasım	Cumartesi	Öğle	Orta	39,50%
Aralık	Cumartesi	Öğle	Orta	42,40%
Ocak	Cumartesi	Akşam	Orta	24,20%
Şubat	Cumartesi	Akşam	Orta	31,70%
Mart	Cumartesi	Akşam	Orta	31,20%
Nisan	Cumartesi	Akşam	Orta	32,80%
Mayıs	Cumartesi	Akşam	Orta	39,10%
Haziran	Cumartesi	Akşam	Orta	31,70%
Temmuz	Cumartesi	Akşam	Orta	35,00%
Ağustos	Cumartesi	Akşam	Orta	28,40%
Eylül	Cumartesi	Akşam	Orta	29,00%
Ekim	Cumartesi	Akşam	Orta	28,10%
Kasım	Cumartesi	Akşam	Orta	32,60%
Aralık	Cumartesi	Akşam	Orta	35,30%
Ocak	Cumartesi	Gece	Orta	12,70%
Şubat	Cumartesi	Gece	Orta	17,60%
Mart	Cumartesi	Gece	Orta	17,20%
Nisan	Cumartesi	Gece	Orta	18,30%
Mayıs	Cumartesi	Gece	Orta	22,70%
Haziran	Cumartesi	Gece	Orta	17,60%
Temmuz	Cumartesi	Gece	Orta	19,80%
Ağustos	Cumartesi	Gece	Orta	15,40%
Eylül	Cumartesi	Gece	Orta	15,80%
Ekim	Cumartesi	Gece	Orta	15,20%
Kasım	Cumartesi	Gece	Orta	18,10%
Aralık	Cumartesi	Gece	Orta	20,00%

Tablo 4.81. 15 Temmuz Şehitler Köprüsü Orta Şerit Yoğunluk İhtimalleri

Senaryo_7

AYLAR	GÜNLER	ZAMAN	ŞERİT	Yoğunluk İhtimali
Ocak	Pazar	Sabah	Orta	23,80%
Şubat	Pazar	Sabah	Orta	31,30%
Mart	Pazar	Sabah	Orta	30,80%
Nisan	Pazar	Sabah	Orta	32,30%
Mayıs	Pazar	Sabah	Orta	38,60%
Haziran	Pazar	Sabah	Orta	31,30%
Temmuz	Pazar	Sabah	Orta	34,50%
Ağustos	Pazar	Sabah	Orta	27,90%
Eylül	Pazar	Sabah	Orta	28,60%
Ekim	Pazar	Sabah	Orta	27,70%
Kasım	Pazar	Sabah	Orta	32,10%
Aralık	Pazar	Sabah	Orta	34,80%
Ocak	Pazar	Öğle	Orta	30,40%
Şubat	Pazar	Öğle	Orta	38,90%
Mart	Pazar	Öğle	Orta	38,40%
Nisan	Pazar	Öğle	Orta	40,10%
Mayıs	Pazar	Öğle	Orta	46,80%*
Haziran	Pazar	Öğle	Orta	38,90%
Temmuz	Pazar	Öğle	Orta	42,50%
Ağustos	Pazar	Öğle	Orta	35,20%
Eylül	Pazar	Öğle	Orta	35,90%
Ekim	Pazar	Öğle	Orta	34,90%
Kasım	Pazar	Öğle	Orta	39,90%
Aralık	Pazar	Öğle	Orta	42,80%
Ocak	Pazar	Akşam	Orta	24,40%
Şubat	Pazar	Akşam	Orta	32,10%
Mart	Pazar	Akşam	Orta	31,50%
Nisan	Pazar	Akşam	Orta	33,10%
Mayıs	Pazar	Akşam	Orta	39,40%
Haziran	Pazar	Akşam	Orta	32,10%
Temmuz	Pazar	Akşam	Orta	35,30%
Ağustos	Pazar	Akşam	Orta	28,60%
Eylül	Pazar	Akşam	Orta	29,30%
Ekim	Pazar	Akşam	Orta	28,40%
Kasım	Pazar	Akşam	Orta	32,90%
Aralık	Pazar	Akşam	Orta	35,60%
Ocak	Pazar	Gece	Orta	12,90%
Şubat	Pazar	Gece	Orta	17,80%
Mart	Pazar	Gece	Orta	17,40%
Nisan	Pazar	Gece	Orta	18,50%
Mayıs	Pazar	Gece	Orta	23,00%
Haziran	Pazar	Gece	Orta	17,80%
Temmuz	Pazar	Gece	Orta	20,00%
Ağustos	Pazar	Gece	Orta	15,50%
Eylül	Pazar	Gece	Orta	16,00%
Ekim	Pazar	Gece	Orta	15,40%
Kasım	Pazar	Gece	Orta	18,40%
Aralık	Pazar	Gece	Orta	20,20%

Tablo 4.82. 15 Temmuz Şehitler Köprüsü Orta Şeritte Günlere Göre Ort. Yoğunluk İhtimalleri

Gün	Yoğunluk İhtimali
Pazartesi	41,26%*
Salı	35,80%
Çarşamba	37,08%
Perşembe	38,46%
Cuma	38,72%
Cumartesi	29,59%
Pazar	29,88%

Tablo 4.83. 15 Temmuz Şehitler Köprüsü Orta Şeritte Günlerin Zamana Göre Ort. Yoğunluk İhtimalleri

Gün	Zaman	Yoğunluk İhtimali
Pazartesi	Sabah	43,12%
Salı	Sabah	37,33%
Çarşamba	Sabah	38,74%
Perşembe	Sabah	40,17%
Cuma	Sabah	40,45%
Cumartesi	Sabah	30,83%
Pazar	Sabah	31,14%
Pazartesi	Öğle	51,43%*
Salı	Öğle	45,48%*
Çarşamba	Öğle	46,86%*
Perşembe	Öğle	48,40%*
Cuma	Öğle	48,70%*
Cumartesi	Öğle	38,38%*
Pazar	Öğle	38,73%*
Pazartesi	Akşam	43,96%
Salı	Akşam	38,18%
Çarşamba	Akşam	39,55%
Perşembe	Akşam	41,03%
Cuma	Akşam	41,28%
Cumartesi	Akşam	31,59%
Pazar	Akşam	31,89%
Pazartesi	Gece	26,55%
Salı	Gece	22,17%
Çarşamba	Gece	23,17%
Perşembe	Gece	24,27%
Cuma	Gece	24,47%
Cumartesi	Gece	17,53%
Pazar	Gece	17,74%

D100 15 Temmuz Şehitler Köprüsünün orta şeritte aylara, günlere ve zamana göre trafik olayları sonucunda meydana gelen yoğunluğun Bayesian Ağı ile analizleri gerçekleştirilmiştir. Tablo 4.82. ve Tablo 4.83.'te elde edilen sonuçlar şu şekildedir:


- Mayıs ayında, pazartesi günleri, orta şeritte, öğle vaktinde 59,70% olasılıkla yoğunluk meydana gelecektir. Mayıs ayında, orta günleri, sol şeritte, öğle vaktinde 53,80% olasılıkla yoğunluk meydana gelecektir. Mayıs ayında, çarşamba günleri, orta şeritte, öğle vaktinde 55,20% olasılıkla yoğunluk meydana gelecektir. Mayıs ayında, perşembe günleri orta şeritte, öğle vaktinde 56,70% olasılıkla yoğunluk meydana gelecektir. Mayıs ayında, cuma günleri, orta şeritte, öğle vaktinde 57,00% olasılıkla yoğunluk meydana gelecektir. Mayıs ayında, cumartesi günleri, orta şeritte, öğle vaktinde 46,40% olasılıkla yoğunluk meydana gelecektir. Mayıs ayında, pazar günleri, orta şeritte, öğle vaktinde 46,80% olasılıkla yoğunluk meydana gelecektir.
- Pazartesi günleri köprü üzerinde 41,26%, Salı günleri köprü üzerinde 35,80%, Çarşamba günleri köprü üzerinde 37,08%, Perşembe günleri köprü üzerinde 38,46%, Cuma günleri köprü üzerinde 38,72%, Cumartesi günleri köprü üzerinde 29,59%, Pazar günleri köprü üzerinde 29,88% olasılıkla yoğunluk meydana gelme ihtimali vardır. Pazartesi günleri, öğle vaktinde köprü üzerinde 51,43%, Salı günleri, öğle vaktinde köprü üzerinde 45,48%, Çarşamba günleri, öğle vaktinde köprü üzerinde 46,80%, Perşembe günleri, öğle vaktinde köprü üzerinde 48,40%, Cuma günleri, öğle vaktinde köprü üzerinde 48,70%, Cumartesi günleri, öğle vaktinde köprü üzerinde 38,38%, Pazar günleri, öğle vaktinde köprü üzerinde 38,73% olasılıkla yoğunluk meydana gelme ihtimali vardır.

Tablo 4.84. Yoğunluk Değişkeni Duyarlılık Analizi

Yoğunluk	Varyans Azalımı	Yüzde
Aylar	0,0009	0,07
Günler	0,0190	0,50
Zaman	0,0061	0,65
Şerit	0,2378	21,50*

Tablo 4.84.'te elde edilen sonuçlara göre 15 Temmuz Şehitler Köprüsü üzerinde meydana gelen trafik yoğunluğu üzerinde gerçekleştirilen duyarlılık analizi sonucunda en belirleyici unsurun şerit olduğu görülmektedir.

Şekil 4.21. 15 Temmuz Şehitler Köprüsü Trafik Olayları Modeli



- Ocak ayında, pazartesi günü, sabah saatlerinde, sağ şeritte meydana gelebilecek bir trafik olayı 62,90% ihtimalle Kaza_Bildirimi meydana gelecektir.

D100 15 Temmuz Şehitler Köprüsünde meydana gelecek trafik olaylarının, ay, gün, zaman ve şerit senaryoları kurularak Bayesian Ağı ile ihtimalleri hesaplanmıştır. Örnek olarak Pazartesi gününe ait gerçekleşen trafik olaylarının olasılıkları hesaplanmıştır.

Tablo 4.85. 15 Temmuz Şehitler Köprüsü Pazartesi Günü Trafik_Olayları İhtimalleri

Senaryo_1

Aylar	Günler	Zaman	Şerit	Kaza_Bildirimi	Araç_Arızası	Bakım_Onarım_Çalışması
Ocak	Pazartesi	Sabah	Sol	62,90%	21,90%	15,00%
Şubat	Pazartesi	Sabah	Sol	63,40%	29,00%	7,50%
Mart	Pazartesi	Sabah	Sol	62,20%	27,80%	9,94%
Nisan	Pazartesi	Sabah	Sol	69,30%	26,10%	4,39%
Mayıs	Pazartesi	Sabah	Sol	69,70%	24,40%	5,62%
Haziran	Pazartesi	Sabah	Sol	65,10%	25,10%	9,62%
Temmuz	Pazartesi	Sabah	Sol	56,40%	28,40%	15,00%
Ağustos	Pazartesi	Sabah	Sol	58,30%	25,40%	16,20%
Eylül	Pazartesi	Sabah	Sol	64,60%	22,10%	13,10%
Ekim	Pazartesi	Sabah	Sol	61,10%	27,30%	11,50%
Kasım	Pazartesi	Sabah	Sol	56,70%	26,60%	16,50%
Aralık	Pazartesi	Sabah	Sol	63,70%	30,80%	5,29%

Tablo 4.85.'te elde edilen sonuçlara göre pazartesi günü sabah saatlerinde sol şeritte kaza bildiriminin gerçekleşme olasılığı diğer trafik olaylarına göre daha fazla olasılığa sahip olmuştur. Mayıs ayında 69,70% olasılıkla pazartesi günü sol şeritte sabah saatlerinde kaza gerçekleşme olasılığı en fazla elde edilmiştir.

Tablo 4.86. 15 Temmuz Şehitler Köprüsü Pazartesi Günü Trafik_Olayları İhtimalleri

Senaryo_2

Aylar	Günler	Zaman	Şerit	Kaza_Bildirimi	Araç_Arızası	Bakım_Onarım_Çalışması
Ocak	Pazartesi	Sabah	Sağ	25,10%	60,80%	14,00%
Şubat	Pazartesi	Sabah	Sağ	22,40%	71,30%	6,23%
Mart	Pazartesi	Sabah	Sağ	22,30%	69,30%	8,37%
Nisan	Pazartesi	Sabah	Sağ	26,50%	69,50%	3,94%
Mayıs	Pazartesi	Sabah	Sağ	27,50%	67,10%	5,21%
Haziran	Pazartesi	Sabah	Sağ	24,80%	66,50%	8,61%
Temmuz	Pazartesi	Sabah	Sağ	19,50%	68,30%	12,20%
Ağustos	Pazartesi	Sabah	Sağ	21,30%	64,70%	14,00%
Eylül	Pazartesi	Sabah	Sağ	25,90%	61,70%	12,40%
Ekim	Pazartesi	Sabah	Sağ	22,00%	68,20%	9,75%
Kasım	Pazartesi	Sabah	Sağ	20,20%	65,90%	13,80%
Aralık	Pazartesi	Sabah	Sağ	21,90%	73,80%	4,27%

Tablo 4.86.'da elde edilen sonuçlara göre pazartesi günü sabah saatlerinde sağ şeritte araç arızasının gerçekleşme olasılığı diğer trafik olaylarına göre daha fazla olasılığa sahip olmuştur. Aralık ayında 73,80% olasılıkla pazartesi günü, sabah saatlerinde, sağ şeritte araç arızasının gerçekleşme olasılığı en fazla elde edilmiştir. Pazartesi günü, sabah saatlerinde, sol şeritte 62,78% ortalama ile kaza bildirimi, sağ şeritte ise 67,26% ortalama ile araç arızası meydana gelme ihtimalleri elde edilmiştir.

Tablo 4.87. 15 Temmuz Şehitler Köprüsü Pazartesi Günü Trafik_Olayları İhtimalleri

Senaryo_3

Aylar	Günler	Zaman	Şerit	Kaza_Bildirimi	Araç_Arızası	Bakım_Onarım_Çalışması
Ocak	Pazartesi	Sabah	Orta	44,90%	54,50%	0,44%
Şubat	Pazartesi	Sabah	Orta	43,80%	55,60%	0,49%
Mart	Pazartesi	Sabah	Orta	46,50%	53,00%	0,45%
Nisan	Pazartesi	Sabah	Orta	50,70%	48,30%	0,80%
Mayıs	Pazartesi	Sabah	Orta	49,10%	50,30%	0,44%
Haziran	Pazartesi	Sabah	Orta	42,60%	57,00%	0,33%
Temmuz	Pazartesi	Sabah	Orta	42,40%	57,00%	0,55%
Ağustos	Pazartesi	Sabah	Orta	46,70%	52,80%	0,44%
Eylül	Pazartesi	Sabah	Orta	46,30%	53,10%	0,44%
Ekim	Pazartesi	Sabah	Orta	45,40%	54,00%	0,55%
Kasım	Pazartesi	Sabah	Orta	47,60%	51,90%	0,37%
Aralık	Pazartesi	Sabah	Orta	42,90%	56,60%	0,41%

Tablo 4.87.'de elde edilen sonuçlara göre pazartesi günü sabah saatlerinde orta şeritte araç arızasının gerçekleşme olasılığı diğer trafik olaylarına göre daha fazla olasılığa sahip olmuştur. Haziran ve Temmuz aylarında 57,00% olasılıkla pazartesi günü, sabah saatlerinde, orta şeritte araç arızasının gerçekleşme olasılığı en fazla elde edilmiştir. Pazartesi günü, sabah saatlerinde, orta şeritte 45,74% ortalama ile kaza bildirimi, orta şeritte ise 53,68% ortalama ile araç arızası meydana gelme ihtimalleri elde edilmiştir.

Tablo 4.88. 15 Temmuz Şehitler Köprüsü Pazartesi Günü Trafik_Olayları İhtimalleri

Senaryo_4

Aylar	Günler	Zaman	Şerit	Kaza_Bildirimi	Araç_Arızası	Bakım_Onarım_Çalışması
Ocak	Pazartesi	Öğle	Sol	71,30%	25,70%	2,85%
Şubat	Pazartesi	Öğle	Sol	66,90%	31,60%	1,33%
Mart	Pazartesi	Öğle	Sol	67,10%	31,00%	1,80%
Nisan	Pazartesi	Öğle	Sol	71,10%	27,80%	0,76%
Mayıs	Pazartesi	Öğle	Sol	72,30%	26,20%	0,98%
Haziran	Pazartesi	Öğle	Sol	70,10%	27,90%	1,74%
Temmuz	Pazartesi	Öğle	Sol	63,70%	33,20%	2,84%
Ağustos	Pazartesi	Öğle	Sol	66,60%	30,10%	3,12%
Eylül	Pazartesi	Öğle	Sol	71,80%	25,50%	2,45%
Ekim	Pazartesi	Öğle	Sol	66,80%	30,90%	2,12%
Kasım	Pazartesi	Öğle	Sol	65,00%	31,60%	3,17%
Aralık	Pazartesi	Öğle	Sol	65,80%	33,00%	0,92%

Tablo 4.88.'de elde edilen sonuçlara göre pazartesi günü öğle saatlerinde sol şeritte araç arızasının gerçekleşme olasılığı diğer trafik olaylarına göre daha fazla

olasılığa sahip olmuştur. Mayıs ayında 72,30% olasılıkla pazartesi günü, öğle saatlerinde, sol şeritte kaza bildirimi gerçekleşme olasılığı en fazla elde edilmiştir.

Tablo 4.89. 15 Temmuz Şehitler Köprüsü Pazartesi Günü Trafik_Olayları İhtimalleri Senaryo_4

Aylar	Günler	Zaman	Şerit	Kaza_Bildirimi	Araç_Arızası	Bakım_Onarım_Çalışması
Ocak	Pazartesi	Öğle	Sağ	27,70%	69,60%	2,61%
Şubat	Pazartesi	Öğle	Sağ	23,00%	75,80%	1,07%
Mart	Pazartesi	Öğle	Sağ	23,40%	75,10%	1,47%
Nisan	Pazartesi	Öğle	Sağ	26,70%	72,50%	0,67%
Mayıs	Pazartesi	Öğle	Sağ	28,10%	70,80%	0,89%
Haziran	Pazartesi	Öğle	Sağ	26,10%	72,30%	1,52%
Temmuz	Pazartesi	Öğle	Sağ	21,10%	76,50%	2,22%
Ağustos	Pazartesi	Öğle	Sağ	23,50%	73,80%	2,58%
Eylül	Pazartesi	Öğle	Sağ	28,20%	69,40%	2,26%
Ekim	Pazartesi	Öğle	Sağ	23,30%	74,90%	1,74%
Kasım	Pazartesi	Öğle	Sağ	22,20%	75,10%	2,55%
Aralık	Pazartesi	Öğle	Sağ	22,10%	77,00%	0,72%

Tablo 4.89.'da elde edilen sonuçlara göre pazartesi günü öğle saatlerinde sağ şeritte araç arızasının gerçekleşme olasılığı diğer trafik olaylarına göre daha fazla olasılığa sahip olmuştur. Aralık ayında 77,00% olasılıkla pazartesi günü, öğle saatlerinde, sağ şeritte araç arızasının gerçekleşme olasılığı en fazla elde edilmiştir. Pazartesi günü, öğle saatlerinde, sol şeritte 68,21% ortalama ile kaza bildirimi, sağ şeritte ise 73,57% ortalama ile araç arızası meydana gelme ihtimalleri elde edilmiştir.

Tablo 4.90. 15 Temmuz Şehitler Köprüsü Pazartesi Günü Trafik_Olayları İhtimalleri Senaryo_5

Aylar	Günler	Zaman	Şerit	Kaza_Bildirimi	Araç_Arızası	Bakım_Onarım_Çalışması
Ocak	Pazartesi	Öğle	Orta	49,59%	53,70%	0,27%
Şubat	Pazartesi	Öğle	Orta	44,80%	54,80%	0,31%
Mart	Pazartesi	Öğle	Orta	47,40%	52,20%	0,28%
Nisan	Pazartesi	Öğle	Orta	51,70%	47,50%	0,50%
Mayıs	Pazartesi	Öğle	Orta	50,10%	49,50%	0,28%
Haziran	Pazartesi	Öğle	Orta	43,60%	56,10%	0,21%
Temmuz	Pazartesi	Öğle	Orta	43,30%	56,20%	0,34%
Ağustos	Pazartesi	Öğle	Orta	47,70%	52,00%	0,28%
Eylül	Pazartesi	Öğle	Orta	47,30%	52,30%	0,28%
Ekim	Pazartesi	Öğle	Orta	46,40%	53,10%	0,34%
Kasım	Pazartesi	Öğle	Orta	48,60%	51,10%	0,23%
Aralık	Pazartesi	Öğle	Orta	43,90%	55,70%	0,26%

Tablo 4.90.'da elde edilen sonuçlara göre pazartesi günü öğle saatlerinde sağ şeritte araç arızasının gerçekleşme olasılığı diğer trafik olaylarına göre daha fazla

olasılığa sahip olmuştur. Temmuz ayında 56,20% olasılıkla pazartesi günü, öğle saatlerinde, orta şeritte araç arızasının gerçekleşme olasılığı en fazla elde edilmiştir. Pazartesi günü, öğle saatlerinde, orta şeritte 47,03% ortalama ile kaza bildirimi, orta şeritte ise 52,85% ortalama ile araç arızası meydana gelme ihtimalleri elde edilmiştir.

Tablo 4.91. 15 Temmuz Şehitler Köprüsü Pazartesi Günü Trafik_Olayları İhtimalleri
Senaryo_5

Aylar	Günler	Zaman	Şerit	Kaza_Bildirimi	Araç_Arızası	Bakım_Onarım_Çalışması
Ocak	Pazartesi	Akşam	Sol	74,60%	24,30%	0,91%
Şubat	Pazartesi	Akşam	Sol	69,70%	29,80%	0,42%
Mart	Pazartesi	Akşam	Sol	70,10%	29,30%	0,57%
Nisan	Pazartesi	Akşam	Sol	73,60%	26,00%	0,24%
Mayıs	Pazartesi	Akşam	Sol	74,90%	24,60%	0,31%
Haziran	Pazartesi	Akşam	Sol	73,00%	26,30%	0,55%
Temmuz	Pazartesi	Akşam	Sol	67,30%	31,70%	0,91%
Ağustos	Pazartesi	Akşam	Sol	70,20%	28,70%	1,00%
Eylül	Pazartesi	Akşam	Sol	75,00%	24,10%	0,78%
Ekim	Pazartesi	Akşam	Sol	70,00%	29,30%	0,67%
Kasım	Pazartesi	Akşam	Sol	68,60%	30,20%	1,02%
Aralık	Pazartesi	Akşam	Sol	68,50%	31,10%	0,29%

Tablo 4.91.'de elde edilen sonuçlara göre pazartesi günü akşam saatlerinde sol şeritte kaza bildirimi gerçekleşme olasılığı diğer trafik olaylarına göre daha fazla olasılığa sahip olmuştur. Mayıs ayında 74,90% olasılıkla pazartesi günü, akşam saatlerinde, sol şeritte kaza bildirimi gerçekleşme olasılığı en fazla elde edilmiştir

Tablo 4.92. 15 Temmuz Şehitler Köprüsü Pazartesi Günü Trafik_Olayları İhtimalleri
Senaryo_6

Aylar	Günler	Zaman	Şerit	Kaza_Bildirimi	Araç_Arızası	Bakım_Onarım_Çalışması
Ocak	Pazartesi	Akşam	Sağ	30,30%	68,80%	0,86%
Şubat	Pazartesi	Akşam	Sağ	25,00%	74,60%	0,35%
Mart	Pazartesi	Akşam	Sağ	25,50%	74,00%	0,49%
Nisan	Pazartesi	Akşam	Sağ	28,80%	70,90%	0,22%
Mayıs	Pazartesi	Akşam	Sağ	30,40%	69,20%	0,29%
Haziran	Pazartesi	Akşam	Sağ	28,30%	71,10%	0,50%
Temmuz	Pazartesi	Akşam	Sağ	23,20%	76,00%	0,74%
Ağustos	Pazartesi	Akşam	Sağ	25,80%	73,30%	0,86%
Eylül	Pazartesi	Akşam	Sağ	30,70%	68,50%	0,75%
Ekim	Pazartesi	Akşam	Sağ	25,40%	74,00%	0,57%
Kasım	Pazartesi	Akşam	Sağ	24,40%	74,70%	0,85%
Aralık	Pazartesi	Akşam	Sağ	24,00%	75,70%	0,24%

Tablo 4.92.'de elde edilen sonuçlara göre pazartesi günü akşam saatlerinde sağ şeritte araç arızasının gerçekleşme olasılığı diğer trafik olaylarına göre daha fazla

olasılığa sahip olmuştur. Aralık ayında 75,70% olasılıkla pazartesi günü, akşam saatlerinde, sağ şeritte araç arızasının gerçekleşme olasılığı en fazla elde edilmiştir. Pazartesi günü, akşam saatlerinde, sol şeritte 71,29% ortalama ile kaza bildirimi, sağ şeritte ise 72,57% ortalama ile araç arızası meydana gelme ihtimalleri elde edilmiştir.

Tablo 4.93. 15 Temmuz Şehitler Köprüsü Pazartesi Günü Trafik_Olayları İhtimalleri
Senaryo_7

Aylar	Günler	Zaman	Şerit	Kaza_Bildirimi	Araç_Arızası	Bakım_Onarım_Çalışması
Ocak	Pazartesi	Akşam	Orta	44,80%	55,00%	0,12%
Şubat	Pazartesi	Akşam	Orta	43,70%	56,10%	0,14%
Mart	Pazartesi	Akşam	Orta	46,30%	53,40%	0,13%
Nisan	Pazartesi	Akşam	Orta	50,70%	48,90%	0,23%
Mayıs	Pazartesi	Akşam	Orta	49,00%	50,80%	0,13%
Haziran	Pazartesi	Akşam	Orta	42,50%	57,40%	0,09%
Temmuz	Pazartesi	Akşam	Orta	42,30%	57,50%	0,15%
Ağustos	Pazartesi	Akşam	Orta	46,60%	53,20%	0,12%
Eylül	Pazartesi	Akşam	Orta	46,20%	53,60%	0,12%
Ekim	Pazartesi	Akşam	Orta	45,30%	54,40%	0,15%
Kasım	Pazartesi	Akşam	Orta	47,50%	52,30%	0,11%
Aralık	Pazartesi	Akşam	Orta	42,80%	57,00%	0,12%

Tablo 4.93.'te elde edilen sonuçlara göre pazartesi günü akşam saatlerinde orta şeritte araç arızasının gerçekleşme olasılığı diğer trafik olaylarına göre daha fazla olasılığa sahip olmuştur. Aralık ayında 57,00% olasılıkla pazartesi günü, akşam saatlerinde, orta şeritte araç arızasının gerçekleşme olasılığı en fazla elde edilmiştir. Pazartesi günü, akşam saatlerinde, orta şeritte 45,64% ortalama ile kaza bildirimi, orta şeritte ise 54,13% ortalama ile araç arızası meydana gelme ihtimalleri elde edilmiştir.

Tablo 4.94. 15 Temmuz Şehitler Köprüsü Pazartesi Günü Trafik_Olayları İhtimalleri
Senaryo_8

Aylar	Günler	Zaman	Şerit	Kaza_Bildirimi	Araç_Arızası	Bakım_Onarım_Çalışması
Ocak	Pazartesi	Gece	Sol	69,40%	13,20%	17,10%
Şubat	Pazartesi	Gece	Sol	72,70%	18,20%	8,89%
Mart	Pazartesi	Gece	Sol	70,80%	17,30%	11,70%
Nisan	Pazartesi	Gece	Sol	78,30%	16,20%	5,13%
Mayıs	Pazartesi	Gece	Sol	78,00%	14,90%	6,50%
Haziran	Pazartesi	Gece	Sol	73,10%	15,40%	11,20%
Temmuz	Pazartesi	Gece	Sol	64,30%	17,70%	17,70%
Ağustos	Pazartesi	Gece	Sol	65,40%	15,60%	18,80%
Eylül	Pazartesi	Gece	Sol	71,30%	13,40%	15,00%
Ekim	Pazartesi	Gece	Sol	69,30%	16,90%	13,50%
Kasım	Pazartesi	Gece	Sol	64,00%	16,40%	19,20%
Aralık	Pazartesi	Gece	Sol	73,80%	19,50%	6,34%

Tablo 4.94.'te elde edilen sonuçlara göre pazartesi günü gece saatlerinde sol şeritte kaza bildirimi gerçekleşme olasılığı diğer trafik olaylarına göre daha fazla olasılığa sahip olmuştur. Mayıs ayında 78,00% olasılıkla pazartesi günü, akşam saatlerinde, sol şeritte kaza bildirimi gerçekleşme olasılığı en fazla elde edilmiştir.

Tablo 4.95. 15 Temmuz Şehitler Köprüsü Pazartesi Günü Trafik_Olayları İhtimalleri
Senaryo_9

Aylar	Günler	Zaman	Şerit	Kaza_Bildirimi	Araç_Arızası	Bakım_Onarım	Çalışması
Ocak	Pazartesi	Gece	Sağ	34,40%	45,60%	19,90%	
Şubat	Pazartesi	Gece	Sağ	33,00%	57,40%	9,47%	
Mart	Pazartesi	Gece	Sağ	32,40%	55,00%	12,60%	
Nisan	Pazartesi	Gece	Sağ	38,50%	55,30%	5,92%	
Mayıs	Pazartesi	Gece	Sağ	39,40%	52,50%	7,71%	
Haziran	Pazartesi	Gece	Sağ	35,30%	51,80%	12,70%	
Temmuz	Pazartesi	Gece	Sağ	28,00%	53,70%	18,10%	
Ağustos	Pazartesi	Gece	Sağ	29,90%	49,70%	20,30%	
Eylül	Pazartesi	Gece	Sağ	35,70%	46,50%	17,60%	
Ekim	Pazartesi	Gece	Sağ	31,60%	53,70%	14,50%	
Kasım	Pazartesi	Gece	Sağ	28,60%	51,10%	20,20%	

Tablo 4.95.'te elde edilen sonuçlara göre pazartesi günü gece saatlerinde sağ şeritte araç arızasının gerçekleşme olasılığı diğer trafik olaylarına göre daha fazla olasılığa sahip olmuştur. Şubat ayında 57,40% olasılıkla pazartesi günü, gece saatlerinde, sağ şeritte araç arızasının gerçekleşme olasılığı en fazla elde edilmiştir. Pazartesi günü, gece saatlerinde, sol şeritte 70,87% ortalama ile kaza bildirimi, sağ şeritte ise 52,73% ortalama ile araç arızası meydana gelme ihtimalleri elde edilmiştir.

Tablo 4.96. 15 Temmuz Şehitler Köprüsü Pazartesi Günü Trafik_Olayları
İhtimalleri Senaryo_10

Aylar	Günler	Zaman	Şerit	Kaza_Bildirimi	Araç_Arızası	Bakım_Onarım	Çalışması
Ocak	Pazartesi	Gece	Orta	67,10%	31,30%	1,47%	
Şubat	Pazartesi	Gece	Orta	66,10%	32,20%	1,66%	
Mart	Pazartesi	Gece	Orta	68,40%	30,00%	1,51%	
Nisan	Pazartesi	Gece	Orta	71,20%	26,10%	2,55%	
Mayıs	Pazartesi	Gece	Orta	70,70%	27,80%	1,44%	
Haziran	Pazartesi	Gece	Orta	65,30%	33,50%	1,15%	
Temmuz	Pazartesi	Gece	Orta	64,60%	33,40%	1,89%	
Ağustos	Pazartesi	Gece	Orta	68,70%	29,80%	1,47%	
Eylül	Pazartesi	Gece	Orta	68,40%	30,10%	1,47%	
Ekim	Pazartesi	Gece	Orta	67,40%	30,70%	1,83%	
Kasım	Pazartesi	Gece	Orta	69,50%	29,10%	1,24%	
Aralık	Pazartesi	Gece	Orta	65,40%	33,10%	1,42%	

Tablo 4.96.'da elde edilen sonuçlara göre pazartesi günü gece saatlerinde orta şeritte kaza bildiriminin gerçekleşme olasılığı diğer trafik olaylarına göre daha fazla olasılığa sahip olmuştur. Nisan ayında 71,20% olasılıkla pazartesi günü, gece saatlerinde, orta şeritte araç arızasının gerçekleşme olasılığı en fazla elde edilmiştir. Pazartesi günü, gece saatlerinde, sol şeritte 67,73% ortalama ile kaza bildirimi, sağ şeritte ise 30,59% ortalama ile araç arızası meydana gelme ihtimalleri elde edilmiştir.

Tablo 4.97. 15 Temmuz Şehitler Köprüsü Pazartesi Günü Trafik Olayları Ort. İhtimalleri

Gün	Zaman	Şerit	Kaza Bildirimi	Araç Arızası	Bakım Onarım Çalışması
Pazartesi	Sabah	Sol	62,78%	26,24%	10,81%*
	Öğle		23,28%	67,26%	9,40%
	Akşam		68,21%*	29,54%	2,01%
	Gece		24,62%	73,57%*	1,69%
	Sabah	Sağ	71,29%*	27,95%	0,64%
	Öğle		26,82%	72,57%*	0,56%
	Akşam		70,87%	16,23%	12,59%
	Gece		33,35%	52,03%	14,45%*
	Sabah	Orta	45,47%	53,68%	0,48%
	Öğle		47,03%	52,85%	30,00%*
	Akşam		45,64%	54,13%*	13,00%
	Gece		67,73%*	30,59%	1,59%

15 Temmuz Şehitler Köprüsünde pazartesi gerçekleşen trafik olaylarında Tablo 4.97.'de elde edilen sonuçlara göre akşam saatlerinde sol şeritte 68,21% olasılıkla kaza bildirimi gerçekleşeceği elde edilmiştir. Gece saatlerinde sol şeritte 73,57% olasılıkla araç arızası meydana gelecektir. Sabah saatlerinde sol şeritte 10,81% olasılıkla bakım onarım çalışması gerçekleşecektir. Pazartesi gerçekleşen trafik olaylarında sabah saatlerinde sağ şeritte 71,29% olasılıkla kaza bildirimi gerçekleşeceği elde edilmiştir. Öğle saatlerinde sağ şeritte 71,29% olasılıkla araç arızası meydana gelecektir. Gece saatlerinde sağ şeritte 14,45% olasılıkla bakım onarım çalışması gerçekleşecektir. Pazartesi gerçekleşen trafik olaylarında gece saatlerinde orta şeritte 67,73% olasılıkla kaza bildirimi gerçekleşeceği elde edilmiştir. Akşam saatlerinde orta şeritte 54,13% olasılıkla araç arızası meydana gelecektir. Öğle saatlerinde orta şeritte 30,00% olasılıkla bakım onarım çalışması gerçekleşecektir.

Tablo 4.98. Trafik Olayları Değişkeni Duyarlılık Analizi


Trafik Olayları	Varyans Azalımı	Yüzde
Aylar	0,0064	0,051
Günler	0,0192	0,537
Zaman	0,0815	9,160*
Şerit	0,0016	0,198

Tablo 4.98.'de elde sonuçlara göre 15 Temmuz Şehitler Köprüsü üzerinde meydana gelen trafik olayları üzerinde gerçekleştirilen duyarlılık analizi sonucunda en belirleyici unsurun zaman olduğu görülmektedir.

4.7.3 Seyahat Bilgi Sistemi


D100 karayolu hattı boyunca seyahat sırasında konumların trafik bilgilerini sunan bir yapı geliştirilmiştir. Bu sistem sayesinde konumların trafik analizleri gerçekleştirilerek kullanıcılara anlık bilgiler sunmaktadır. Konumların ay, gün, zaman, şerit gibi girdi değişkenlerine bağlı olarak yoğunluk, trafik olayları analizleri Bayesian Ağı ile gerçekleştirilmiştir. Her konumun ay, gün, zaman, şerit gibi girdi değişkenlerine göre kullanıcılara yoğunluk ve trafik olaylarının oluşma ihtimalleri anlık olarak bilgilendirecek bir alt yapı oluşturulmuştur. Özellikle D100 karayolu hattında trafik olaylarının ve yoğunluğun çok meydana geldiği konumların trafik analizleri gerçekleştirilmiştir.

Şekil 4.22. D100 Karayolu Hattı




Senaryo_1: D100 Karayolu Hattında ocak ayında, pazartesi günü, sabah saatlerinde, sol şeritte seyahat sırasında belirli konumlarda meydana gelebilecek yoğunluk ve trafik olaylarının gerçekleşme ihtimalleri nedir?

Şekil 4.23. Avcılar Konumu Trafik Analizi




Avcılar konumunda, Ocak ayında, pazartesi günü sabah saatlerinde sol şeritte yoğunluk oluşma ihtimali 42,7%, trafik olaylarından kaza bildirimi meydana gelme ihtimali 54,8% olarak elde edilmiştir.

Şekil 4.24. Beylikdüzü Konumu Trafik Analizi




Beylikdüzü konumunda, Ocak ayında, pazartesi günü sabah saatlerinde sol şeritte yoğunluk oluşma ihtimali 30,0%, trafik olaylarından kaza bildirimi meydana gelme ihtimali 60,0% olarak elde edilmiştir.

Şekil 4.25. Florya Konumu Trafik Analizi




Florya konumunda, Ocak ayında, pazartesi günü sabah saatlerinde sol şeritte yoğunluk oluşma ihtimali 47,3%, trafik olaylarından araç arızası meydana gelme ihtimali 49,3% olarak elde edilmiştir.

Şekil 4.26. Hacışerif Konumu Trafik Analizi




Hacışerif konumunda, Ocak ayında, pazartesi günü sabah saatlerinde sol şeritte yoğunluk oluşma ihtimali 53,0%, trafik olaylarından araç arızası meydana gelme ihtimali 54,8% olarak elde edilmiştir.

Şekil 4.27. Haliç Konumu Trafik Analizi




Haliç mevkinde Ocak ayında, pazartesi günü sabah saatlerinde sol şeritte yoğunluk oluşma ihtimali 33,9%, trafik olaylarından kaza bildirimi meydana gelme ihtimali 56,7% olarak elde edilmiştir.

Şekil 4.28. Haramidere Konumu Trafik Analizi




Haramidere konumunda, Ocak ayında, pazartesi günü sabah saatlerinde sol şeritte yoğunluk oluşma ihtimali 51,5%, trafik olaylarından araç arızası meydana gelme ihtimali 53,4% olarak elde edilmiştir.

Şekil 4.29. İncirli Konumu Trafik Analizi




İncirli konumunda, Ocak ayında, pazartesi günü sabah saatlerinde sol şeritte yoğunluk oluşma ihtimali 39,8%, trafik olaylarından kaza bildirimi meydana gelme ihtimali 51,4% olarak elde edilmiştir.

Şekil 4.30. Küçükçekmece Konumu Trafik Analizi




Küçükçekmece konumunda, Ocak ayında, pazartesi günü sabah saatlerinde sol şeritte yoğunluk oluşma ihtimali 32,7%, trafik olaylarından kaza bildirimi meydana gelme ihtimali 65,8% olarak elde edilmiştir.

Şekil 4.31. Mecidiyeköy Konumu Trafik Analizi




Mecidiyeköy konumunda, Ocak ayında, pazartesi günü sabah saatlerinde sol şeritte yoğunluk oluşma ihtimali 30,9%, trafik olaylarından kaza bildirimi meydana gelme ihtimali 60,6% olarak elde edilmiştir.

Şekil 4.32. Merter Konumu Trafik Analizi




Merter konumunda, Ocak ayında, pazartesi günü sabah saatlerinde sol şeritte yoğunluk oluşma ihtimali 37,8%, trafik olaylarından kaza bildirimi meydana gelme ihtimali 57,5% olarak elde edilmiştir.

Şekil 4.33. Sefaköy Konumu Trafik Analizi




Sefaköy konumunda, Ocak ayında, pazartesi günü sabah saatlerinde sol şeritte yoğunluk oluşma ihtimali 37,8%, trafik olaylarından kaza bildirimi meydana gelme ihtimali 47,9% olarak elde edilmiştir.

Şekil 4.34. Şirinevler Konumu Trafik Analizi




Şirinevler konumunda, Ocak ayında, pazartesi günü sabah saatlerinde sol şeritte yoğunluk oluşma ihtimali 41,8%, trafik olaylarından kaza bildirimi meydana gelme ihtimali 48,5% olarak elde edilmiştir.

Şekil 4.35. Yenibosna Konumu Trafik Analizi




Yenibosna konumunda, Ocak ayında, pazartesi günü sabah saatlerinde sol şeritte yoğunluk oluşma ihtimali 36,2%, trafik olaylarından kaza bildirimi meydana gelme ihtimali 60,5% olarak elde edilmiştir.

Şekil 4.36. Zincirlikuyu Konumu Trafik Analizi




Zincirlikuyu konumunda, Ocak ayında, pazartesi günü sabah saatlerinde sol şeritte yoğunluk oluşma ihtimali 15,7%, trafik olaylarından kaza bildirimi meydana gelme ihtimali 89,1% olarak elde edilmiştir.

Şekil 4.37. Göztepe Konumu Trafik Analizi




Göztepe konumunda, Ocak ayında, pazartesi günü sabah saatlerinde sol şeritte yoğunluk oluşma ihtimali 22,2%, trafik olaylarından kaza bildirimi meydana gelme ihtimali 83,9% olarak elde edilmiştir.

Şekil 4.38. Kartal Konumu Trafik Analizi




Kartal konumunda, Ocak ayında, pazartesi günü sabah saatlerinde sol şeritte yoğunluk oluşma ihtimali 29,5%, trafik olaylarından kaza bildirimi meydana gelme ihtimali 62,9% olarak elde edilmiştir.

Şekil 4.39. Maltepe Konumu Trafik Analizi




Maltepe konumunda, Ocak ayında, pazartesi günü sabah saatlerinde sol şeritte yoğunluk oluşma ihtimali 23,0%, trafik olaylarından kaza bildirimi meydana gelme ihtimali 78,3% olarak elde edilmiştir.

Şekil 4.40. Kozyatağı Konumu Trafik Analizi




Kozyatağı konumunda, Ocak ayında, pazartesi günü sabah saatlerinde sol şeritte yoğunluk oluşma ihtimali 33,4%, trafik olaylarından kaza bildirimi meydana gelme ihtimali 46,0% olarak elde edilmiştir.

Şekil 4.41. Pendik Konumu Trafik Analizi




Pendik konumunda, Ocak ayında, pazartesi günü sabah saatlerinde sol şeritte yoğunluk oluşma ihtimali 22,2%, trafik olaylarından kaza bildirimi meydana gelme ihtimali 60,0% olarak elde edilmiştir.

Şekil 4.42. Uzunçayır Konumu Trafik Analizi




Uzunçayır konumunda, Ocak ayında, pazartesi günü sabah saatlerinde sol şeritte yoğunluk oluşma ihtimali 13,1%, trafik olaylarından kaza bildirimi meydana gelme ihtimali 67,3% olarak elde edilmiştir.

Şekil 4.43. Altunizade Konumu Trafik Analizi




Altunizade konumunda, Ocak ayında, pazartesi günü sabah saatlerinde sol şeritte yoğunluk oluşma ihtimali 50,2%, trafik olaylarından araç arızası meydana gelme ihtimali 45,8% olarak elde edilmiştir.

Şekil 4.44. Acıbadem Konumu Trafik Analizi




Acıbadem konumunda, Ocak ayında, pazartesi günü sabah saatlerinde sol şeritte yoğunluk oluşma ihtimali 39,5%, trafik olaylarından araç arızası meydana gelme ihtimali 48,2% olarak elde edilmiştir.

Şekil 4.45. Bostancı Konumu Trafik Analizi



Bostancı mevkinde Ocak ayında, pazartesi günü sabah saatlerinde sol şeritte yoğunluk oluşma ihtimali 24,3%, trafik olaylarından kaza bildirimi meydana gelme ihtimali 48,1%, bakım_onarım_çalışması meydana gelme ihtimali 38,3% olarak elde edilmiştir.

Şekil 4.46. Tuzla Konumu Trafik Analizi




Tuzla mevkinde Ocak ayında, pazartesi günü sabah saatlerinde sol şeritte yoğunluk oluşma ihtimali 9,83%, trafik olaylarından kaza bildirimi meydana gelme ihtimali 68,0%, olarak elde edilmiştir.


D100 Karayolu hattı boyunca 59 konumun araç yoğunluklarının modeli oluşturulmuştur. D100 15 Temmuz Şehitler Köprüsü, Avrupa yakasında 29 konum ve

Anadolu yakasında 29 konumun aylara ve günlere göre araç yoğunluklarının gerçekleşme olasılıkları hesaplanmıştır.


Şekil 4.47. D100 Karayolu Avrupa Hattı Araç Yoğunluk Analiz Modeli




Şekil 4.48. D100 Karayolu Anadolu Hattı Araç Yoğunluk Analiz Modeli



Şekil 4.49. D100 Selimpaşa Konumu Araç Yoğunluğu




Şekil 4.50. D100 Küçükçekmece Konumu Araç Yoğunluğu




D100 Karayolu hattında ocak ayında, pazartesi günü Selimpaşa konumunda oluşan araç yoğunluğu 73,6% olasılıkla 20Binden fazla olacaktır. Küçükçekmece konumunda ise 66,8% olasılıkla 150Binden fazla olacaktır.

Şekil 4.51. D100 Acıbadem Köprüsü Konumu Araç Yoğunluğu




Şekil 4.52. D100 Kartal Kavşağı Konumu Araç Yoğunluğu




D100 Karayolu hattında ocak ayında, pazartesi günü Acıbadem Köprüsü konumunda oluşan araç yoğunluğu 38,8% olasılıkla 80Binden fazla olacaktır. Kartal Kavşağı konumunda ise 78,0% olasılıkla 100Binden fazla olacaktır.

Şekil 4.53. D100 Karayolu Hattı Avrupa Yakası Ocak Ayı Pazartesi Günü Araç Yoğunluğu



Şekil 4.54. D100 Karayolu Hattı Anadolu Yakası Temmuz Ayı Cuma Günü Araç Yoğunluğu



Şekil 4.55. D100 Karayolu Hattı Yoğunluk ve Trafik Olayları



SONUÇ ve DEĞERLENDİRME

Akıllı Ulaşım Sistemleri sayesinde elde ettiğimiz büyük veriyi makine öğrenmesi yöntemlerinden yapay sinir ağları ile analizlerini gerçekleştirerek trafik yoğunluk modellemesi, trafik kaza modellemesi ve trafik hız modellemesi gerçekleştirdik. Modellerimizde kullandığımız parametrelerin belirlenmesinde ise parametrik olmayan istatistiksel yöntemlerden yararlandık.

Çalışmamızda İstanbul trafiğinde çok önemli bir yeri olan D100 karayolunun trafik analizini kurguladığımız model sayesinde gerçekleştirdik. D100 karayolunun 2016-2020 yılları arasında 75 adet noktada bulunan sensör verilerinden 1400 günlük araç verisi elde edilmiştir. Modelimizde konum yeri belirlendikten sonra o konuma ait parametreler olan meteoroloji verileri, tarih ve zaman, araç yoğunluk verileri, araç hız verileri oluşturuldu. Trafik analizi için araç yoğunluğunun saat, gün, ay, mevsim, yıl, meteorolojik veriler ile ilişkilerinin ne olduğu, etkilerinin olup-olmadığı araç yoğunluğu üzerinde anlamlı farklılıklar meydana getirip getirmediği istatistiksel yöntemler ile hipotezler test edildi. Hipotezlerin sonuçlarına göre o bölgenin trafiğine etki eden parametreler belirlenmiş oldu. Makine öğrenmesi yöntemlerinden olan Yapay Sinir Ağı, Bayes Ağları ile sınıflandırma ve tahmin analizleri gerçekleştirilerek modellerimiz test edildi. D100 karayolu Anadolu yakası 29, Avrupa yakası 29 bölgeye ayrılarak her bölgeye ait hipotezler test edilerek kendine has modelleri oluşturuldu.

D100 karayolunun en önemli geçiş noktası olan 15 Temmuz Şehitler Köprüsünün trafiğine etki eden parametreler belirlenerek yapay sinir ağı ile trafik yoğunluk, kaza ve hız modelleri oluşturuldu. Elde edilen sonuçlara göre verilerimiz normal dağılım göstermemiştir. Tüm değişkenlerde Kolmogorov-Smirnov değerimiz $p < 0,005$ olduğundan verilerimiz normal dağılıma sahip değildir. Verilerimiz normal dağılıma sahip olmadığından ve gruplarda üç veya daha fazla, sıralama ölçeğine sahip olduğundan tek yönlü varyans analizi gerekli olan varsayımlar karşılanmadığından, Kruskal Wallis testi uygulanmıştır. Grupların karşılaştırılmasında ise Mann-Whitney U testi uygulanmıştır. Elde edilen sonuçları şu şekilde sıralandı:

- Köprü üzerindeki araç yoğunluğunun ortalamalarının yıllar değişkenine göre anlamlı bir farklılığın olup olmadığını belirlemek amacıyla gerçekleştirilen Kruskal Wallis-H analizi sonucunda yıllara göre köprü üzerinde araç yoğunluğunun ortalamaları arasındaki fark istatistiksel olarak anlamlı bulunmuştur ($\chi^2=15,939$; $Sd =6$; $p <.05$).Elde edilen sonuçlara göre köprü üzerindeki araç yoğunluğunun ortalamalarının yıllara göre anlamlı düzeyde farklılıklar yaşandığı, bu farklılıkların anlamlı düzeyde değişim yaşandığı belirlenmiştir. 2018 yılından 2019 yılına gelindiğinde köprü üzerindeki araç yoğunluğunda 11%'lik bir artış yaşanmıştır. 2019-2020 yılları arasında ise 7%'lik bir azalma meydana gelmiştir. Bu azalmanın en büyük nedenlerinde birinin yaşanan Covid-19 salgını sonucunda kapanmalar yaşandığı ve insanların hareketliliklerinin azalmasından dolayı gerçekleşmiştir.
- Köprü üzerindeki araç yoğunluğunun ortalamalarının aylar değişkenine göre anlamlı bir farklılığın olup olmadığını belirlemek amacıyla gerçekleştirilen Kruskal Wallis-H analizi sonucunda yıllara göre köprü üzerinde araç yoğunluğunun ortalamaları arasındaki fark istatistiksel olarak anlamlı bulunmuştur ($\chi^2=210,395$; $Sd =11$; $p <.05$). 2018-2020 yılları arasında 12 aya göre köprü üzerindeki araç yoğunluğunun değişim analizi gerçekleştirilmiştir. Elde edilen sonuçlara göre köprü üzerindeki araç yoğunluğunun ortalamalarının aylara göre anlamlı düzeyde farklılıklar yaşandığı, bu farklılıkların anlamlı düzeyde değişim yaşandığı belirlenmiştir. Nisan ayından Mayıs aylarına geçişte köprüdeki araç yoğunluğu 16,7% bir artış meydana geldiği ve bu farkın anlamlı olduğu sonucuna varılmıştır. Bu farkın oluşmasında bu aylarda hava sıcaklığının artması ile insanların dışarıda daha fazla vakit geçirmeleri ve daha fazla hareketliliğin oluşması sonucunda meydana gelmektedir. Mayıs ayından Haziran ayına geçişte köprüdeki araç yoğunluğunda 27,1% gibi büyük bir oranda artış göstermiştir. Bu farkın oluşmasında bu aylarda yaşanan yaz mevsimi sonucu insanların tatile gitmeleri ve turistlerinde gelmeleri nedenler arasında sayılmaktadır. Haziran ayından Temmuz ayına geçişte köprüdeki araç yoğunluğu 6,5%'lik bir artış meydana geldiği yaz hareketliliğinden dolayı araç yoğunluğunda bir miktar daha artış sağlanmıştır. Ekim ayından Kasım ayına doğru ise -9,2%'lik bir azalma meydana geldiği ve bu değişimin anlamlı olduğu

sonucuna varılmıştır. Bu aylarda okulların açılması ile öğrencilerin daha çok servis ile gitmeleri, işlerine gitmek isteyen insanların daha çok çalıştıkları yerlerin servislerini kullanmaları, toplu taşıma araçlarını daha fazla tercih etmeleri ve en önemlisi bu tarihlerde mevsimden dolayı yağışların oluşması gibi etkenler nedenler arasında sayılabilir.

- Köprü üzerindeki araç yoğunluğunun ortalamalarının gün değişkenine göre anlamlı bir farklılığın olup olmadığını belirlemek amacıyla gerçekleştirilen Kruskal Wallis-H analizi sonucunda yıllara göre köprü üzerinde araç yoğunluğunun ortalamaları arasındaki fark istatistiksel olarak anlamlı bulunmuştur ($\chi^2=38,572$; $Sd =6$; $p <.05$). Köprü üzerindeki araç yoğunluğunun ortalamalarının günlere göre anlamlı düzeyde farklılıklar yaşandığı, bu farklılıkların anlamlı düzeyde değişim yaşandığı belirlenmiştir. Pazar gününden pazartesiye geçişte araç yoğunluğunda 11,6%'lık bir artış yaşanmıştır. Cumartesi gününden pazar gününe geçişte 10,2%'lik bir azalma meydana gelmiştir. Çarşamba gününden pazar gününe kadar 13,3%'lük bir azalma gerçekleşirken, perşembeden pazar gününe kadar 15,2%'luk bir azalma meydana gelmektedir. Cuma gününden pazar gününe kadar araç yoğunluğunda 15,9%'luk bir azalma meydana gelmiştir. Köprüdeki araç yoğunluğunun Çarşamba gününden itibaren azalmaya başladığı gözlemlenmiştir.
- Köprü üzerindeki araç yoğunluğunun ortalamalarının mevsim değişkenine göre anlamlı bir farklılığın olup olmadığını belirlemek amacıyla gerçekleştirilen Kruskal Wallis-H analizi sonucunda yıllara göre köprü üzerinde araç yoğunluğunun ortalamaları arasındaki fark istatistiksel olarak anlamlı bulunmuştur ($\chi^2=277,063$; $Sd =3$; $p <.05$). Köprü üzerindeki araç yoğunluğunun ortalamalarının mevsim göre anlamlı düzeyde farklılıklar yaşandığı, bu farklılıkların anlamlı düzeyde değişim yaşandığı belirlenmiştir. İlkbahardan yaz mevsimine geçişte köprüdeki araç yoğunluğunda 38,69%'lik artış meydana gelmiştir. Yaz mevsiminden sonbahar mevsimine geçişte ise 3,2%'lik bir azalma meydana gelmiştir. Sonbahar mevsiminden kış mevsimine geçişte ise 13,77%'lik bir azalma meydana gelmiştir. İlkbahar mevsiminden yaz mevsimine

geçişte köprüdeki araç yoğunluğu artışı önlemek adına gerekli tedbirlerin alınması gerektiği sonucu elde edilmiştir.

- Köprü üzerindeki araç yoğunluğunun ortalamalarının hava durumu değişkenine göre anlamlı bir farklılığın olup olmadığını belirlemek amacıyla gerçekleştirilen Kruskal Wallis-H analizi sonucunda hava durumuna göre köprü üzerinde araç yoğunluğunun ortalamaları arasındaki fark istatistiksel olarak anlamlı bulunmuştur ($\chi^2=38,446$; $Sd =4$; $p <.05$). Köprü üzerindeki araç yoğunluğunun ortalamalarının hava durumu değişkenine göre anlamlı düzeyde farklılıklar yaşandığı, bu farklılıkların anlamlı düzeyde değişim yaşandığı belirlenmiştir. Bulutlu havalarda, güneşli havalara göre araç yoğunlukları ortalamasının 6,08%'lik bir azalış meydana gelmiştir. Yağmurlu havalarda, güneşli havalara göre araç yoğunlukları ortalamasının 9,61%'lik bir azalış meydana gelmiştir. Sağanak yağışlı havalarda, güneşli havalara göre araç yoğunlukları ortalamasının 11,29%'luk bir azalış meydana gelmiştir. Karlı havalarda, güneşli havalara göre araç yoğunlukları ortalamasının 13,02%'lik bir azalış meydana gelmiştir.
- Köprü üzerinde gerçekleşen trafik olaylarının değerlendirilmesinde Ki-kare testlerinden yararlanılmıştır. Gerçekleştirilen trafik olayları kaza bildirimi ve araç arızası olmak üzere iki kategori üzerinden değerlendirilmiştir. Saatler, günler, aylar, mevsimler ve hava durumu gibi parametreler ile trafik olayları arasında bir ilişkinin olup olmadığı, trafik olaylarının bu parametrelerden bağımsız olup olmadığı değerlendirilmiştir. Ayrıca kaza olaylarında hasarlı, yaralanmalı, zincirleme, yoğunluk, sol, sağ, orta şerit gibi parametreler ile saatler, günler, aylar, mevsimler ve hava durumu gibi parametreler ile ilişkisi incelenmiştir. Elde edilen sonuçlara göre ($\chi^2=14,015$, $p=0,003<0,005$) köprü üzerinde gerçekleşen trafik olayları ile saatler arasında bir anlamlı bir ilişkinin olduğu tespit edilmiştir. Trafik olaylarının saatlerden bağımsız olmadığı ve akşam saatlerinde gerçekleşen trafik olaylarının daha fazla olduğu sonucuna varılmıştır.
- Köprü üzerinde gerçekleşen trafik olaylarının saatlere göre farklılaşıp farklılaşmadığını incelemek için Ki-Kare testi kullanılmıştır. Elde edilen

sonuçlara göre ($X^2=31,261$, $p=0,000<0,005$) köprü üzerinde gerçekleşen trafik olayları ile günler arasında anlamlı bir ilişkinin olduğu tespit edilmiştir. Trafik olaylarının günlerden bağımsız olmadığı ve araç arızalarının daha çok pazartesi günleri yaşandığı, kaza olaylarının ise cumartesi daha fazla olduğu sonucuna varılmıştır.

- Elde edilen sonuçlara göre ($X^2=14,805$, $p=0,192>0,005$) köprü üzerinde gerçekleşen trafik olayları ile aylar arasında bir anlamlı bir ilişkinin olmadığı tespit edilmiştir.
- Elde edilen sonuçlara göre ($X^2=1,828$, $p=0,609>0,005$) köprü üzerinde gerçekleşen trafik olayları ile mevsimler arasında bir anlamlı bir ilişkinin olmadığı tespit edilmiştir.
- Elde edilen sonuçlara göre ($X^2=267,379$, $p=0,000<0,005$) köprü üzerinde gerçekleşen trafik olayları ile şeritler arasında bir anlamlı bir ilişkinin olduğu tespit edilmiştir. Sağ şeritte trafik olaylarının 86,2%'sında araç arızası meydana gelirken, 40,6%'sında kaza meydana gelmiştir. Sol şeritte trafik olaylarının 7,1%'inde araç arızası meydana gelirken, 51,5%'inde kaza meydana gelmiştir.
- Elde edilen sonuçlara göre ($X^2=108,400$, $p=0,000<0,005$) köprü üzerinde gerçekleşen trafik olayları ile yoğunluk arasında anlamlı bir ilişkinin olduğu tespit edilmiştir. Kaza olaylarının 89.0% 'da yoğunluk meydana gelmişken, araç arızalarının ise 50,6%'da yoğunluk meydana gelmiştir.
- Elde edilen sonuçlara göre ($X^2=181,136$, $p=0,000<0,005$) köprü üzerinde gerçekleşen trafik olaylarında şeritler ile oluşan yoğunluk arasında anlamlı düzeyde bir ilişkinin olduğu tespit edilmiştir. Sol şeritte gerçekleşen trafik olaylarında 14,8%'inde yoğunluk meydana gelmişken, sağ şeritte gerçekleşen trafik olaylarında 80,4%'inde, orta şeritte gerçekleşen trafik olaylarında ise 4,8%'inde yoğunluk meydana gelmiştir. Sol şeritte gerçekleşen trafik olaylarında 49,30%'unde yoğunluk oluşmamışken, sağ şeritte gerçekleşen trafik olaylarında 43,9%'inde, orta şeritte gerçekleşen trafik olaylarında ise 6,9%'inde yoğunluk meydana gelmemiştir.
- Elde edilen sonuçlara göre ($X^2=25,215^a$, $p=0,000<0,005$) köprü üzerinde gerçekleşen trafik olaylarında günler ile şeritler arasında anlamlı düzeyde bir

ilişkinin olduğu tespit edilmiştir. Orta şeritte gerçekleşen trafik olaylarında 19,8%'i ile en çok perşembe ve 7,7% ile en az cumartesi günlerinde gerçekleşmiştir. Sağ şeritte gerçekleşen trafik olaylarında 16,9% ile en çok perşembe ve 10,8% ile en az cumartesi günlerinde gerçekleşmiştir. Sol şeritte gerçekleşen trafik olaylarında 18,5% ile en çok cumartesi ve 10,6% ile en az çarşamba günlerinde gerçekleşmiştir.

Hipotezler test edildikten sonra hangi parametrelerin trafik yoğunluğu ile ilişkileri tespit edildikten sonra Yapay Sinir Ağı ile model tasarlanarak simülasyon çalışması gerçekleştirildi. Modelde gerçekleştirilen simülasyon çalışmaları ile regresyon analizleri ve hata sonuçları elde edilerek en iyi modele göre eğitilerek test edildi. Trafik yoğunluğunun önceden tahminini gerçekleştirmek için oluşturulan modelimiz %92'lik yüksek bir başarı oranı ve 0,0006 hata oranı ile önemli bir sonuç elde edildi. Köprü üzerinde oluşabilecek bir trafik yoğunluğunun önceden tespiti için hem kullanıcılara hem de yöneticilere önemli bir karar destek mekanizması olarak faydalar sağlayacaktır.

D100 karayolu hattının 60 bölgesinin araç yoğunluk durumunun aylar, günler, zaman, mevsim, yıllar ve konum değişkenlerine göre analizleri sonucunda şu sonuçlar elde edilmiştir:

- D100 karayolu hattında gerçekleşen araç yoğunluğunun günlere göre farklılaşıp farklılaşmadığını incelemek için Ki-Kare testi kullanılmıştır. Elde edilen sonuçlara göre ($X^2=1500,201$, $p=0,000<0,005$) D100 karayolu hattında üzerinde gerçekleşen araç yoğunluğu ile günler arasında anlamlı bir ilişkinin olduğu tespit edilmiştir. Oluşan araç yoğunluğunun günlerden bağımsız olmadığı ve 10Binden fazla aracın geçtiği gün sayısı %26,6 ile Pazar günleri, 20Binden fazla aracın geçtiği gün sayısı %15,28 ile Cumartesi günleri, 40Binden fazla aracın geçtiği gün sayısı %16,56 ile Cumartesi günleri, 60Binden fazla aracın geçtiği gün sayısı %16,6 ile Pazartesi günleri, 80Binden fazla aracın geçtiği gün sayısı %15,83 ile Pazartesi günleri, 100Binden fazla aracın geçtiği gün sayısı %15,28 ile Çarşamba günleri, 130Binden fazla aracın geçtiği gün sayısı %14,58 ile Çarşamba günleri, 150Binden fazla aracın geçtiği gün sayısı %16,69 ile Cumartesi günleri, 180Binden fazla aracın geçtiği gün sayısı %16,61 ile Cuma günleri, 200Binden

fazla aracın geçtiği gün sayısı %28,16 ile Cumartesi günleri gerçekleşeceği elde edilmiştir.

- D100 karayolu hattında gerçekleşen araç yoğunluğunun aylara göre farklılaşıp farklılaşmadığını incelemek için Ki-Kare testi kullanılmıştır. Elde edilen sonuçlara göre ($X^2=2614,183$, $p=0,000<0,005$) D100 karayolu hattında üzerinde gerçekleşen araç yoğunluğu ile aylar arasında anlamlı bir ilişkinin olduğu tespit edilmiştir. Oluşan araç yoğunluğunun günlerden bağımsız olmadığı ve 10Binden fazla aracın geçtiği gün sayısı %16,85 ile Mayıs ayı, 20Binden fazla aracın geçtiği gün sayısı %13,78 ile Mayıs ayı, 40Binden fazla aracın geçtiği gün sayısı %12,09 ile Ocak ayı, 60Binden fazla aracın geçtiği gün sayısı %13,97 ile Ocak ayı, 80Binden fazla aracın geçtiği gün sayısı %9,25 ile Mart ayı, 100Binden fazla aracın geçtiği gün sayısı %9,28 ile Ekim ayı, 130Binden fazla aracın geçtiği gün sayısı %10,13 ile Ekim ayı, 150Binden fazla aracın geçtiği gün sayısı %10,63 ile Temmuz ayı, 180Binden fazla aracın geçtiği gün sayısı %11,30 ile Temmuz ayı, 200Binden fazla aracın geçtiği gün sayısı %22,82 ile Temmuz ayında gerçekleştiği elde edilmiştir.
- D100 karayolu hattında gerçekleşen araç yoğunluğunun mevsimlere göre farklılaşıp farklılaşmadığını incelemek için Ki-Kare testi kullanılmıştır. Elde edilen sonuçlara göre ($X^2=1975,312$, $p=0,000<0,005$) D100 karayolu hattında üzerinde gerçekleşen araç yoğunluğu ile mevsimler arasında anlamlı bir ilişkinin olduğu tespit edilmiştir. Oluşan araç yoğunluğunun günlerden bağımsız olmadığı ve 10Binden fazla aracın geçtiği gün sayısı %40,35 ile İlkbahar, 20Binden fazla aracın geçtiği gün sayısı %30,57 ile İlkbahar, 40Binden fazla aracın geçtiği gün sayısı %29,02 ile İlkbahar, 60Binden fazla aracın geçtiği gün sayısı %31,29 ile Kış, 80Binden fazla aracın geçtiği gün sayısı %25,53 ile İlkbahar, 100Binden fazla aracın geçtiği gün sayısı %26,52 ile Sonbahar, 130Binden fazla aracın geçtiği gün sayısı %27,04 ile Yaz, 150Binden fazla aracın geçtiği gün sayısı %29,95 ile Yaz, 180Binden fazla aracın geçtiği gün sayısı %32,03 ile Yaz, 200Binden fazla aracın geçtiği gün sayısı %56,31 ile Yaz mevsiminde gerçekleştiği elde edilmiştir.
- D100 karayolu hattında gerçekleşen araç yoğunluğunun yıllara göre farklılaşıp farklılaşmadığını incelemek için Ki-Kare testi kullanılmıştır. Elde edilen sonuçlara

göre ($X^2=3800,963$, $p=0,000<0,005$) D100 karayolu hattında üzerinde gerçekleşen araç yoğunluğu ile yıllar arasında anlamlı bir ilişkinin olduğu tespit edilmiştir. Oluşan araç yoğunluğunun günlerden bağımsız olmadığı ve 10Binden fazla aracın geçtiği gün sayısı %23,85 ile 2019, 20Binden fazla aracın geçtiği gün sayısı %36,69 ile 2016, 40Binden fazla aracın geçtiği gün sayısı %40,78 ile 2016, 60Binden fazla aracın geçtiği gün sayısı %30,44 ile 2016, 80Binden fazla aracın geçtiği gün sayısı %26,65 ile 2016, 100Binden fazla aracın geçtiği gün sayısı %21,86 ile 2017, 130Binden fazla aracın geçtiği gün sayısı %23,77 ile 2018, 150Binden fazla aracın geçtiği gün sayısı %25,93 ile 2018, 180Binden fazla aracın geçtiği gün sayısı %24,63 ile 2018, 200Binden fazla aracın geçtiği gün sayısı %37,38 ile 2017 yılında gerçekleştiği elde edilmiştir.

D100 karayolu gerçekleşen trafik olaylarının aylar, günler, zaman, mevsim, yıllar ve konum değişkenlerine göre analizleri sonucunda şu sonuçlar elde edilmiştir:

- Elde edilen sonuçlara göre ($X^2=1653.957^a$, $p=0,000<0,005$) trafik olayları ile saatler arasında anlamlı bir ilişki olduğu tespit edilmiştir. D100 karayolu hattı trafiğinde meydana gelen 35697 trafik olayının %51,35'i araç arızası, %6,80'i yol bakım-onarım işleri ve %41,82'i kaza bildirimidir. Ayrıca trafik olaylarının %31,55'si sabah, %36,05'si öğlen, %26,74'si akşam ve %5,69'i gece meydana geldi. En fazla araç arıza zamanı %36,80 ile öğlen, yol bakım-onarım işi %39,98 ile sabah, en yüksek kaza bildirim zamanı ise %36,19 ile öğlen oldu.
- Elde edilen sonuçlara göre ($X^2=274.379^a$, $p=0,000<0,005$) trafik olayları ile günler arasında anlamlı bir ilişki olduğu tespit edilmiştir. D100 karayolu hattı trafiğinde en fazla araç arızası Perşembe günü %16,55, bakım-onarım işi Perşembe günü %16,01, kaza bildirimi ise Cuma günü %16,12 olarak gerçekleşmiştir. Trafik olaylarının çoğu %16,14 ile Cuma günü meydana gelmiştir.
- Elde edilen sonuçlara göre ($X^2=181,168^a$, $p=0,000<0,005$) trafik olayları ile aylar arasında anlamlı bir ilişki olduğu tespit edilmiştir. D100 karayolu hattı trafiğinde en fazla araç arızası Ocak ayında %10,98, Temmuz ayında %11,82 ile bakım-onarım ve Ocak ayında %10,75 ile kaza bildirimi meydana gelmiştir. Trafik olaylarının çoğu %10,82 ile Ocak ayında meydana gelmiştir.

- Elde edilen sonuçlara göre ($X^2=3346,568^a$, $p=0,000<0,005$) trafik olayları ile şerit arasında anlamlı bir ilişki olduğu tespit edilmiştir D100 karayolu hattı trafiğinde en fazla araç arızası %80,53 ile sağ şeritte, %59,49 ile bakım-onarım işi ve sağ şeritte %52,44 ile araç kazası meydana gelmiştir. Trafik olaylarının çoğu %67,93 ile sağ şeritte meydana geldi.
- Elde edilen sonuçlara göre ($X^2=63,542^a$, $p=0,000<0,005$) trafik olayları ile mevsimler arasında anlamlı bir ilişki olduğu tespit edilmiştir. D100 karayolu hattı trafiğinde en fazla kış mevsiminde %24,42 araç arızası, %26,72 kış mevsiminde bakım-onarım ve %26,82 kış mevsiminde araç kazası meydana gelmiştir. Trafik olaylarının çoğu %27,60 ile kış mevsiminde meydana gelmiştir.

D100 karayolunun güvenliğinin analizi sonucunda, kaza olayları, araç arızaları ve bakım-onarım işlerinin aylar, günler, zaman, mevsim ve yıllar arasında anlamlı bir ilişki elde edilmiştir. Sabah saatlerinde daha çok araç arızası ve bakım-onarım çalışmaları meydana gelirken, öğle vakitlerinde kaza olayları meydana gelmektedir. Ayrıca araç arızası ve bakım-onarım çalışmaları daha çok Perşembe günleri meydana gelirken, kaza olayları daha çok Cuma günleri meydana gelmektedir. En fazla araç arızası ve kaza olaylarının Ocak ayında meydana gelirken, bakım-onarım çalışmalarının daha çok kış aylarında meydana geldiği sonucuna varılmıştır. Kaza olayları, bakım-onarım çalışmaları ve araç arızası daha çok sağ şeritte gerçekleşmiştir. D100 karayolu trafik güvenliğinin sağlanmasında zaman olarak öğle vakitleri, günler olarak Perşembe ve Cuma günleri, aylar olarak Ocak ve Temmuz ayları, mevsim olarak Kış mevsimi ve şerit olarak sağ şerit trafik güvenliği açısından önemli parametrelerdir.

Elde edilen istatistiksel sonuçlar sonucunda yoğunluk ve trafik olaylarının aylar, günler, zaman, şerit parametrelerine göre sınıflandırma analizleri gerçekleştirildi. Navie Bayes sınıflandırması sonucunda %91,7 doğruluk değeri, %82,2 duyarlılık değeri, %99,9 özlülük değerleri elde edilmiştir. Bayes sınıflandırması sonucunda %96,6 doğruluk değeri, %95,0 duyarlılık değeri, %97,9 özlülük değerleri elde edilmiştir. Yapay Sinir Ağı sınıflandırması sonucunda %97,0 doğruluk değeri, %95,7 duyarlılık değeri, %98,1 özlülük değerleri elde edilmiştir. Bu sonuçlar doğrultusunda D100 karayolu hattının aylar, günler, zaman, şerit ve trafik olayları

değişkenlerine göre meydana gelebilecek yoğunluğun önceden tahminlemesinde önemli sonuçlar elde edilecektir. Bayes Ağları ile kurulan modeller ile konum bazlı yoğunluk ve trafik olaylarının tahminlemesi gerçekleştirilmiştir.

15 Temmuz Şehitler Köprüsünün geliştirilen model sonucunda günlere göre yoğunluk tahminleri %41,26 ile Pazartesi günü, %35,80 ile Salı günü, %37,08 ile Çarşamba günü, %38,46 ile Perşembe günü, %38,72 ile Cuma günü, %29,59 ile Cumartesi günü, %29,88 ile Pazar günü elde edilmiştir. Zamana göre gerçekleştirilen yoğunluk tahminlemesinde öğle vaktinde gerçekleşen yoğunluk değerleri diğer zamanlara göre daha fazla gerçekleşmiştir. Öğle vaktinde %51,43 ile Pazartesi günü, %45,48 ile Salı günü, %46,86 ile Çarşamba günü, %48,40 ile Perşembe günü, %48,70 ile Cuma günü, %38,38 ile Cumartesi günü, %38,73 ile Pazar günü elde edilmiştir. Pazartesi günü için sol şeritte gerçekleştirilen trafik olayları analizinde, akşam sol şeritte %68,21 ile kaza bildirimi, gece sol şeritte %73,57 ile araç arızası, sabah sol şeritte %10,81 ile bakım onarım çalışması meydana gelmiştir. Pazartesi günü için sağ şeritte gerçekleştirilen trafik olayları analizinde, sabah sağ şeritte %71,79 ile kaza bildirimi, öğle sağ şeritte %72,57 ile araç arızası, gece sağ şeritte %14,45 ile bakım onarım çalışması meydana gelmiştir. Pazartesi günü için orta şeritte gerçekleştirilen trafik olayları analizinde, gece orta şeritte %67,73 ile kaza bildirimi, akşam orta şeritte %54,13 ile araç arızası, öğle orta şeritte %30,00 ile bakım onarım çalışması meydana gelmiştir.

Bayes Ağı ile kurulan yoğunluk ve trafik olayları modelleri ile D100 karayolu hattında 60 farklı konumun aylar, günler, zaman, şerit durumlarına göre yoğunluk ve trafik olaylarının gerçekleşme ihtimalleri elde edilmiştir. Tasarlanan modeller dinamik bir yapı haline getirilerek meydana gelecek bir trafik olayı sonucunda veri aktarımı gerçekleştirilerek her konumun anlık yoğunluk ve trafik olaylarının durumu hakkında bilgilendirme sağlayacak bir alt yapı oluşturulacaktır. Geliştirilen bu model sayesinde D100 karayolu boyunca seyahat eden kullanıcılara yollar hakkında daha detaylı bilgilendirmeler yaparak trafik yoğunluğunun oluşmasının önüne geçilmesi ve trafik güvenliğinin sağlanmasında büyük önem taşımaktadır.

D100 Karayolu Trafik Bilgilendirme Servisi sayesinde ay, gün, zaman ve şerit durumları girilerek hat boyunca gerçekleşecek yoğunluk durumlarını ve trafik olaylarının gerçekleşme ihtimallerine göre önlem alınmasını sağlayarak daha güvenilir bir trafiğin oluşmasında büyük katkılar sağlayacaktır. Bu sistem navigasyon programları ile entegre edilerek kullanıcıların bir sonraki konuma varmadan onlara konumun yoğunluk ve trafik olayları hakkında bilgilendirme yapması oluşabilecek trafik olaylarının önüne geçilecek ve doğal olarak yoğunlukların yaşanmasında engel oluşturacaktır.



KAYNAKÇA

- Abbasi, A., Rashidi, T. H., Maghrebi, M., & Waller, S. T., 2015 Utilising location based social media in travel survey methods: Bringing twitter data into the play. Proceedings of the 8th ACM SIGSPATIAL International Workshop on Location-Based Social Networks, LBSN 2015 - Held in Conjunction with ACM SIGSPATIAL 2015. <https://doi.org/10.1145/2830657.2830660>
- Abdi, J., & Moshiri, B., 2015 Application of temporal difference learning rules in short-term traffic flow prediction. Expert Systems, 32(1), 49–64. <https://doi.org/10.1111/exsy.12055>
- Abel, F., Hauff, C., Houben, G. J., Tao, K., & Stronkman, R., 2012 Twitcident: Fighting fire with information from Social Web streams. WWW'12 - Proceedings of the 21st Annual Conference on World Wide Web Companion, 305–308. <https://doi.org/10.1145/2187980.2188035>
- Agarwal, S., Kachroo, P., & Regentova, E., 2016 A hybrid model using logistic regression and wavelet transformation to detect traffic incidents. IATSS Research, 40(1), 56–63. <https://doi.org/10.1016/j.iatssr.2016.06.001>
- Alkheder, S., Taamneh, M., & Taamneh, S., 2017 Severity Prediction of Traffic Accident Using an Artificial Neural Network. Journal of Forecasting, 36(1), 100–108. <https://doi.org/10.1002/for.2425>
- Alsrehin, N. O., Klaib, A. F., & Magableh, A., 2019 Intelligent Transportation and Control Systems Using Data Mining and Machine Learning Techniques: A Comprehensive Study. IEEE Access, 7, 49830–49857. <https://doi.org/10.1109/ACCESS.2019.2909114>
- Amato, G., Carrara, F., Falchi, F., Gennaro, C., Meghini, C., & Vairo, C., 2017 Deep learning for decentralized parking lot occupancy detection. Expert Systems with Applications, 72, 327–334. <https://doi.org/10.1016/j.eswa.2016.10.055>
- An, S., Lee, B.-H., Shin, D.-R., 2011 A Survey of Intelligent Transportation Systems. <https://doi.org/10.1109/cicsyn.2011.76>

- Arun Kumar, M., & Gopal, M., 2009 Least squares twin support vector machines for pattern classification. *Expert Systems with Applications*, 36(4), 7535–7543. <https://doi.org/10.1016/j.eswa.2008.09.066>
- Attanasi, A., Meschini, L., Pezzulla, M., Fusco, G., Gentile, G., & Isaenko, N., 2017 A hybrid method for real-time short-term predictions of traffic flows in urban areas. *5th IEEE International Conference on Models and Technologies for Intelligent Transportation Systems, MT-ITS 2017 - Proceedings*, 878–883. <https://doi.org/10.1109/MTITS.2017.8005637>
- Baptista, A. T., Bouillet, E. P., & Pompey, P., 2012 Towards an uncertainty aware short-term travel time prediction using GPS bus data: Case study in Dublin. *IEEE Conference on Intelligent Transportation Systems, Proceedings, ITSC*, 1620–1625. <https://doi.org/10.1109/ITSC.2012.6338633>
- Barakat, N., & Bradley, A. P., 2010 Rule extraction from support vector machines: A review. *Neurocomputing*, 74(1–3), 178–190. <https://doi.org/10.1016/j.neucom.2010.02.016>
- Benabdellah, A. C., Benghabrit, A., & Bouhaddou, I., 2019 A survey of clustering algorithms for an industrial context. *Procedia Computer Science*, 148, 291–302. <https://doi.org/10.1016/j.procs.2019.01.022>
- Bezuglov, A., & Comert, G., 2016 Short-term freeway traffic parameter prediction: Application of grey system theory models. *Expert Systems with Applications*, 62, 284–292. <https://doi.org/10.1016/j.eswa.2016.06.032>
- Bielza, C., & Larrañaga, P., 2014 Discrete bayesian network classifiers: A survey. *ACM Computing Surveys*, 47(1). <https://doi.org/10.1145/2576868>
- Blanco, R., Inza, I., Merino, M., Quiroga, J., & Larrañaga, P., 2005 Feature selection in Bayesian classifiers for the prognosis of survival of cirrhotic patients treated with TIPS. *Journal of Biomedical Informatics*, 38(5), 376–388. <https://doi.org/10.1016/j.jbi.2005.05.004>

- Cai, P., Wang, Y., Lu, G., Chen, P., Ding, C., & Sun, J.,2016 A spatiotemporal correlative k-nearest neighbor model for short-term traffic multistep forecasting. *Transportation Research Part C: Emerging Technologies*, 62, 21–34. <https://doi.org/10.1016/j.trc.2015.11.002>
- Cerquides, J., & López De Mántaras, R.,2005 Robust Bayesian linear classifier ensembles. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 3720 LNAI, 72–83. https://doi.org/10.1007/11564096_12
- Chandra, B., & Varghese, P. P.,2008 Fuzzy SLIQ decision tree algorithm. *IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics*, 38(5), 1294–1301. <https://doi.org/10.1109/TSMCB.2008.923529>
- Chang, H., Park, D., Lee, S., Lee, H., & Baek, S.,2010 Dynamic multi-interval bus travel time prediction using bus transit data. *Transportmetrica*, 6(1), 19–38. <https://doi.org/10.1080/18128600902929591>
- Chaniotakis, E., Antoniou, C., & Mitsakis, E.,2015 Data for Leisure Travel Demand from Social Networking Services. *HEART Conference*, 6.
- Chaplot, S., Patnaik, L. M., & Jagannathan, N. R.,2006 Classification of magnetic resonance brain images using wavelets as input to support vector machine and neural network. *Biomedical Signal Processing and Control*, 1(1), 86–92. <https://doi.org/10.1016/j.bspc.2006.05.002>
- Chaudhuri, A., & De, K.,2011 Fuzzy Support Vector Machine for bankruptcy prediction. *Applied Soft Computing Journal*, 11(2), 2472–2486. <https://doi.org/10.1016/j.asoc.2010.10.003>
- Chen, F., Deng, P., Wan, J., Zhang, D., Vasilakos, A. V., & Rong, X.,2015 Data mining for the internet of things: Literature review and challenges. *International Journal of Distributed Sensor Networks*,2015. <https://doi.org/10.1155/2015/431047>
- Chen, M., Liu, X., Xia, J., & Chien, S. I.,2004 A dynamic bus-arrival time prediction model based on APC data. *Computer-Aided Civil and Infrastructure Engineering*, 19(5), 364–376. <https://doi.org/10.1111/j.1467-8667.2004.00363.x>

- Chen, M., Yu, X., & Liu, Y., 2018 PCNN: Deep Convolutional Networks for Short-Term Traffic Congestion Prediction. *IEEE Transactions on Intelligent Transportation Systems*, 19(11), 3550–3559. <https://doi.org/10.1109/TITS.2018.2835523>
- Chen, R. C., & Hsieh, C. H., 2006 Web page classification based on a support vector machine using a weighted vote schema. *Expert Systems with Applications*, 31(2), 427–435. <https://doi.org/10.1016/j.eswa.2005.09.079>
- Chen, X., Wei, Z., Liu, X., Cai, Y., Li, Z., & Zhao, F., 2017 Spatiotemporal variable and parameter selection using sparse hybrid genetic algorithm for traffic flow forecasting. *International Journal of Distributed Sensor Networks*, 13(6), 1–14. <https://doi.org/10.1177/1550147717713376>
- Chen, Y. H., Zheng, Y. F., Pan, J. F., & Yang, N., 2013 A hybrid text classification method based on K-congener-nearest-neighbors and hypersphere support vector machine. *Proceedings - 2013 International Conference on Information Technology and Applications, ITA 2013*, 493–497. <https://doi.org/10.1109/ITA.2013.120>
- Cheng, Z., Caverlee, J., Lee, K., & Sui, D. Z., 2011 Exploring Millions of Footprints in Location Sharing Services. *Icwsn, 2010(Cholera)*, 81–88. <https://doi.org/papers3://publication/uuid/0C46BD5D-4908-4A8A-BD06-5BCB2F1DE282>
- Chien, S. I. J., & Kuchipudi, C. M., 2003 Dynamic travel time prediction with real-time and historic data. *Journal of Transportation Engineering*, 129(6), 608–616. [https://doi.org/10.1061/\(ASCE\)0733-947X\(2003\)129:6\(608\)](https://doi.org/10.1061/(ASCE)0733-947X(2003)129:6(608))
- Chou, J. S., Cheng, M. Y., Wu, Y. W., & Pham, A. D., 2014 Optimizing parameters of support vector machine using fast messy genetic algorithm for dispute classification. *Expert Systems with Applications*, 41(8), 3955–3964. <https://doi.org/10.1016/j.eswa.2013.12.035>
- Collins, C., Hasan, S., & Ukkusuri, S. V., 2013 A novel transit rider satisfaction metric: Rider sentiments measured from online social media data. *Journal of Public Transportation*, 16(2), 21–45. <https://doi.org/10.5038/2375-0901.16.2.2>

- Cong, Y., Wang, J., & Li, X., 2016 Traffic Flow Forecasting by a Least Squares Support Vector Machine with a Fruit Fly Optimization Algorithm. *Procedia Engineering*, 137, 59–68. <https://doi.org/10.1016/j.proeng.2016.01.234>
- Contreras, E., Torres-Treviño, L., & Torres, F., 2018 Prediction of car accidents using a maximum sensitivity neural network. *Lecture Notes of the Institute for Computer Sciences, Social-Informatics and Telecommunications Engineering, LNICST*, 213, 86–95. https://doi.org/10.1007/978-3-319-73323-4_9
- Cottrill, C., Gault, P., Yeboah, G., Nelson, J. D., Anable, J., & Budd, T., 2017 Tweeting Transit: An examination of social media strategies for transport information management during a large event. *Transportation Research Part C: Emerging Technologies*, 77, 421–432. <https://doi.org/10.1016/j.trc.2017.02.008>
- Dabiri, S., & Heaslip, K., 2019 Developing a Twitter-based traffic event detection model using deep learning architectures. *Expert Systems with Applications*, 118, 425–439. <https://doi.org/10.1016/j.eswa.2018.10.017>
- Daly, E. M., Lecue, F., & Bicer, V., 2013 Westland row why so slow? Fusing social media and linked data sources for understanding real-time traffic conditions. *International Conference on Intelligent User Interfaces, Proceedings IUI*, 203–212. <https://doi.org/10.1145/2449396.2449423>
- Dash, D., & Cooper, G. F., 2002 Exact model averaging with naive Bayesian classifiers. In *Proceedings of the 19th International Conference on Machine Learning (ICML-2002)*, 91–98.
- Davies, J., Duke, A., Clarke, S. S., Rupnik, J., & Fortuna, B., 2015 Travel time prediction on highways. *Proceedings - 15th IEEE International Conference on Computer and Information Technology, CIT 2015, 14th IEEE International Conference on Ubiquitous Computing and Communications, IUCC 2015, 13th IEEE International Conference on Dependable, Autonomic and Se*, 1435–1442.
- Delen, D., Sharda, R., & Bessonov, M., 2006 Identifying significant predictors of injury severity in traffic accidents using a series of artificial neural networks. *Accident Analysis and Prevention*, 38(3), 434–444. <https://doi.org/10.1016/j.aap.2005.06.024>

- Dell’acqua, P., Bellotti, F., Berta, R., & De Gloria, A.,2015 Time-Aware Multivariate Nearest Neighbor Regression Methods for Traffic Flow Prediction. *IEEE Transactions on Intelligent Transportation Systems*, 16(6), 3393–3402. <https://doi.org/10.1109/TITS.2015.2453116>
- Diao, Z., Wang, X., Zhang, D., Liu, Y., Xie, K., & He, S.,2019 Dynamic Spatial-Temporal Graph Convolutional Neural Networks for Traffic Forecasting. <https://doi.org/10.1609/aaai.v33i01.330189>
- Diao, Z., Zhang, D., Wang, X., Xie, K., He, S., Lu, X., & Li, Y.,2019 A Hybrid Model for Short-Term Traffic Volume Prediction in Massive Transportation Systems. *IEEE Transactions on Intelligent Transportation Systems*, 20(3), 935–946. <https://doi.org/10.1109/TITS.2018.2841800>
- Dindarloo, S. R.,2014 Support vector machine regression analysis of LHD failures. *International Journal of Mining, Reclamation and Environment*, 30(1), 64–69. <https://doi.org/10.1080/17480930.2014.973637>
- Dogru, N., & Subasi, A.,2018 Traffic accident detection using random forest classifier. 2018 15th Learning and Technology Conference, L and T 2018, 40–45. <https://doi.org/10.1109/LT.2018.8368509>
- Domingos, P., & Pazzani, M.,1997 On the Optimality of the Simple Bayesian Classifier under Zero-One Loss. *Machine Learning*, 29(2–3), 103–130. <https://doi.org/10.1023/A:1007413511361>
- Dong, C., Xiong, Z., Shao, C., & Zhang, H.,2015 A spatial–temporal-based state space approach for freeway network traffic flow modelling and prediction. *Transportmetrica A: Transport Science*, 11(7), 547–560. <https://doi.org/10.1080/23249935.2015.1030003>
- Dong, J., Zou, L., & Zhang, Y.,2013 Mixed model for prediction of bus arrival times. 2013 IEEE Congress on Evolutionary Computation, CEC 2013, 2918–2923. <https://doi.org/10.1109/CEC.2013.6557924>

- Dutta, S., Chatterjee, A., & Munshi, S., 2010 Correlation technique and least square support vector machine combine for frequency domain based ECG beat classification. *Medical Engineering and Physics*, 32(10), 1161–1169. <https://doi.org/10.1016/j.medengphy.2010.08.007>
- Elhenawy, M., Chen, H., & Rakha, H. A., 2014 Dynamic travel time prediction using data clustering and genetic programming. *Transportation Research Part C: Emerging Technologies*, 42, 82–98. <https://doi.org/10.1016/j.trc.2014.02.016>
- Erişti, H., Uçar, A., & Demir, Y., 2010 Wavelet-based feature extraction and selection for classification of power system disturbances using support vector machines. *Electric Power Systems Research*, 80(7), 743–752. <https://doi.org/10.1016/j.epsr.2009.09.021>
- Esling, P., & Agon, C., 2012 Time-series data mining. *ACM Computing Surveys*, 45(1). <https://doi.org/10.1145/2379776.2379788>
- Este, A., Gringoli, F., & Salgarelli, L., 2009 Support Vector Machines for TCP traffic classification. *Computer Networks*, 53(14), 2476–2490. <https://doi.org/10.1016/j.comnet.2009.05.003>
- Ester, M., Kriegel, H.-P., Sander, J., & Xu, X., 2010 A Density-Based Algorithm for Discovering Clusters. *Comprehensive Chemometrics*, 2, 635–654. <https://doi.org/10.1016/B978-044452701-1.00067-3>
- F. Su, H. Dong, L. Jia, Y. Qin, Z. T., 2018 Short-term traffic forecasting using self-adjusting k-nearest neighbours. *IET Intelligent Transport Systems*, 12(1), 41–48. <https://doi.org/10.1049/iet-its.2016.0263>
- Fan, S. K. S., Su, C. J., Nien, H. T., Tsai, P. F., & Cheng, C. Y., 2017 Using machine learning and big data approaches to predict travel time based on historical and real-time data from Taiwan electronic toll collection. *Soft Computing*, 22(17), 5707–5718. <https://doi.org/10.1007/s00500-017-2610-y>
- Fan, W., & Gurmu, Z., 2015 Dynamic Travel Time Prediction Models for Buses Using Only GPS Data. *International Journal of Transportation Science and Technology*, 4(4), 353–366. [https://doi.org/10.1016/s2046-0430\(16\)30168-x](https://doi.org/10.1016/s2046-0430(16)30168-x)

- Fancello, G., Soddu, S., & Fadda, P., 2018 An accident prediction model for urban road networks. *Journal of Transportation Safety and Security*, 10(4), 387–405. <https://doi.org/10.1080/19439962.2016.1268659>
- Frank, E., Hall, M., & Pfahringer, B., 2012 Locally Weighted Naive Bayes. In *Proceedings of the 19th Conference in Uncertainty in Artificial Intelligence (UAI-2003)*, 249–256. Retrieved from <http://arxiv.org/abs/1212.2487>
- Friedman, N., Geiger, D., & Goldszmidt, M., 1997 Bayesian Network Classifiers. *Machine Learning*, 29(2–3), 131–163.
- Fu, H., & Zhou, Y., 2011 The traffic accident prediction based on neural network. *Proceedings of the 2011 2nd International Conference on Digital Manufacturing and Automation, ICDMA 2011*, 1349–1350. <https://doi.org/10.1109/ICDMA.2011.331>
- Fu, K., 2015 Social Media Analysis For Traffic Incident Detection And Management. *Transportation Research Board 94th Annual Meeting*, 1–10.
- Fusco, G., Colombaroni, C., Comelli, L., & Isaenko, N., 2015 Short-term traffic predictions on large urban traffic networks: Applications of network-based machine learning models and dynamic traffic assignment models. *2015 International Conference on Models and Technologies for Intelligent Transportation Systems, MT-ITS 2015*, 93–101. <https://doi.org/10.1109/MTITS.2015.7223242>
- Gal-Tzur, A., Grant-Muller, S. M., Kuflik, T., Minkov, E., Nocera, S., & Shoor, I., 2014 The potential of social media in delivering transport policy goals. *Transport Policy*, 32, 115–123. <https://doi.org/10.1016/j.tranpol.2014.01.007>
- Gama, J., 2000 Iterative Bayes. *Intelligent Data Analysis*, 4(6), 475–488. [https://doi.org/10.1016/S0304-3975\(02\)00179-2](https://doi.org/10.1016/S0304-3975(02)00179-2)

- Geetha Ramani, R., & Shanthi, S., 2012 Classifier prediction evaluation in modeling road traffic accident data. 2012 IEEE International Conference on Computational Intelligence and Computing Research, ICCIC 2012.
- Grant-Muller, S. M., Gal-Tzur, A., Minkov, E., Nocera, S., Kuflik, T., & Shoor, I., 2015 Enhancing transport data collection through social media sources: Methods, challenges and opportunities for textual data. IET Intelligent Transport Systems, 9(4), 407–417. <https://doi.org/10.1049/iet-its.2013.0214>
- Gu, X., Li, T., Wang, Y., Zhang, L., Wang, Y., & Yao, J., 2018 Traffic fatalities prediction using support vector machine with hybrid particle swarm optimization. Journal of Algorithms and Computational Technology, 12(1), 20–29. <https://doi.org/10.1177/1748301817729953>
- Guo, H. S., Wang, W. J., & Men, C. Q., 2009 A novel learning model-kernel granular support vector machine. Proceedings of the 2009 International Conference on Machine Learning and Cybernetics, 2, 930–935. <https://doi.org/10.1109/ICMLC.2009.5212413>
- Guo, S., Lin, Y., Feng, N., Song, C., & Wan, H., 2019 Attention Based Spatial-Temporal Graph Convolutional Networks for Traffic Flow Forecasting. AAAI Conference on Artificial Intelligence Twenty-Eighth AAAI Conference on Artificial Intelligence. <https://doi.org/10.1609/aaai.v33i01.3301922>
- Han, J., Kamber, M., & Pei, J., 2012 Data Mining : Concepts and Techniques (3rd Edition). In Data Mining (Third Edit). <https://doi.org/10.1016/B978-0-12-381479-1.00001-0>
- Hand, D. J., & Yu, K., 2001 Idiot's Bayes - Not so stupid after all? International Statistical Review, 69(3), 385–398. <https://doi.org/10.1111/j.1751-5823.2001.tb00465.x>
- Hasan, S., & Ukkusuri, S. V., 2014 Urban activity pattern classification using topic models from online geo-location data. Transportation Research Part C: Emerging Technologies, 44, 363–381. <https://doi.org/10.1016/j.trc.2014.04.003>

- Hasan, S., Zhan, X., & Ukkusuri, S. V., 2013 Understanding urban human activity and mobility patterns using large-scale location-based data from online social media. *Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. <https://doi.org/10.1145/2505821.2505823>
- He, Z., 2019 STCNN : A Spatio-Temporal Convolutional Neural Network for Long-Term Traffic Prediction. <https://doi.org/10.1109/mdm.2019.00-53>
- Hong, J. H., Min, J. K., Cho, U. K., & Cho, S. B., 2008 Fingerprint classification using one-vs-all support vector machines dynamically ordered with naïve Bayes classifiers. *Pattern Recognition*, 41(2), 662–671. <https://doi.org/10.1016/j.patcog.2007.07.004>
- Hou, Y., Edara, P., & Sun, C., 2015 Traffic Flow Forecasting for Urban Work Zones. *IEEE Transactions on Intelligent Transportation Systems*, 16(4), 1761–1770. <https://doi.org/10.1109/TITS.2014.2371993>
- Huang, A., Gallegos, L., & Lerman, K., 2017 Travel analytics: Understanding how destination choice and business clusters are connected based on social media data. *Transportation Research Part C: Emerging Technologies*, 77, 245–256. <https://doi.org/10.1016/j.trc.2016.12.019>
- Huang, H. P., & Liu, Y. H., 2002 Fuzzy Support Vector Machines for Pattern Recognition and Data Mining. *International Journal Of Fuzzy Systems*, 4, 826–835. Retrieved from <http://ntur.lib.ntu.edu.tw/handle/246246/86207>
- Huang, M. L., 2015 Intersection traffic flow forecasting based on v-GSVR with a new hybrid evolutionary algorithm. *Neurocomputing*, 147(1), 343–349. <https://doi.org/10.1016/j.neucom.2014.06.054>
- Huang, W., Jia, W., Guo, J., Williams, B. M., Shi, G., Wei, Y., & Cao, J., 2018 Real-time prediction of seasonal heteroscedasticity in vehicular traffic flow series. *IEEE Transactions on Intelligent Transportation Systems*, 19(10), 3170–3180. <https://doi.org/10.1109/TITS.2017.2774289>
- Huang, W., Xu, S., Yan, Y., & Zipf, A., 2019 An exploration of the interaction between urban human activities and daily traffic conditions: A case study of Toronto,

- Canada. Cities, 84, 8–22.
<https://doi.org/10.1016/j.cities.2018.07.001>
- Hwang, W. J., & Wen, K. W., 1998 Fast kNN classification algorithm based on partial distance search. Electronics Letters, 34(21), 2062–2063.
<https://doi.org/10.1049/el:19981427>
- J. Ross Quinlan., 1993 C4.5: Programs for Machine Learning. In Morgan Kaufmann (p. 312).
- Jadaan, K. S., Al-Fayyad, M., & Gammoh, H. F., 2014 Prediction of Road Traffic Accidents in Jordan using Artificial Neural Network (ANN). Journal of Traffic and Logistics Engineering, 2(2), 92–94. <https://doi.org/10.12720/jtle.2.2.92-94>
- Jeong, R., & Rilett, L. R., 2005 Prediction model of bus arrival time for real-time applications. Transportation Research Record, (1927), 195–204.
<https://doi.org/10.3141/1927-23>
- Jiang, L., & Li, C., 2011 Scaling up the accuracy of decision-tree classifiers: A naive-bayes combination. Journal of Computers, 6(7), 1325–1331.
<https://doi.org/10.4304/jcp.6.7.1325-1331>
- Jin, W., Lin, Y., Wu, Z., & Wan, H., 2018 Spatio-Temporal Recurrent Convolutional Networks for Citywide Short-term Crowd Flows Prediction. Proceedings of the 2nd International Conference on Compute and Data Analysis - ICCDA 2018. doi:10.1145/3193077.3193082
- Kazem, A., Sharifi, E., Hussain, F. K., Saberi, M., & Hussain, O. K., 2013 Support vector regression with chaos-based firefly algorithm for stock market price forecasting. Applied Soft Computing Journal, 13(2), 947–958.
<https://doi.org/10.1016/j.asoc.2012.09.024>
- Ke, R., Li, Z., Tang, J., Pan, Z., & Wang, Y., 2019 Real-Time Traffic Flow Parameter Estimation from UAV Video Based on Ensemble Classifier and Optical Flow. IEEE Transactions on Intelligent Transportation Systems, 20(1), 54–64. <https://doi.org/10.1109/TITS.2018.2797697>

- Keogh, E. J., & Pazzani, M. J., 2002 Learning the Structure of Augmented Bayesian Classifiers. *International Journal on Artificial Intelligence Tools*, 11(04), 587–601. <https://doi.org/10.1142/s0218213002001052>
- Keogh, E., & Kasetty, S., 2002 On the need for time series data mining benchmarks. *Proceedings of the Eighth ACM SIGKDD International Conference on Knowledge Discovery and Data Mining - KDD '02*, 102. <https://doi.org/10.1145/775047.775062>
- Kesavaraj, G., & Sukumaran, S., 2013 A study on classification techniques in data mining. 2013 4th International Conference on Computing, Communications and Networking Technologies, ICCCNT 2013. <https://doi.org/10.1109/ICCCNT.2013.6726842>
- Khemchandani, R., Jayadeva, & Chandra, S., 2007 Fuzzy Twin Support Vector Machines for Pattern Classification. 131–142. https://doi.org/10.1142/9789812813220_0009
- Khosravi, A., Mazloumi, E., Nahavandi, S., Creighton, D., & Van Lint, J. W. C., 2011 Prediction intervals to account for uncertainties in travel time prediction. *IEEE Transactions on Intelligent Transportation Systems*, 12(2), 537–547. <https://doi.org/10.1109/TITS.2011.2106209>
- Kohavi, R., 1996 Scaling up the accuracy of naive-Bayes classifiers: A decision-tree hybrid. In *Proceedings of the 2nd International Conference on Knowledge Discovery and Data Mining (KDD-1996)*, 202–207.
- Kohavi, R., & John, G. H., 1997 Wrappers for feature subset selection. *Artificial Intelligence*, 97(1–2), 273–324.
- Kononenko, I., 1993 Successive Naive Bayesian Classifier. *Informatica (Slovenia)*, 17(2), 167–174.
- Kumar, A., Jiang, M., & Fang, Y., 2014 Where not to go? Detecting road hazards using Twitter. *SIGIR 2014 - Proceedings of the 37th International ACM SIGIR Conference on Research and Development in Information Retrieval*, 1223–1226. <https://doi.org/10.1145/2600428.2609550>

- Kumar, B. A.,
Jairam, R.,
Arkatkar, S. S., &
Vanajakshi,
L.,2017 Real time bus travel time prediction using k-NN classifier. Transportation Letters, 11(7), 362–372.
<https://doi.org/10.1080/19427867.2017.1366120>
- Kumar, B. A.,
Vanajakshi, L., &
Subramanian, S. C.,2017 Bus travel time prediction using a time-space discretization approach. Transportation Research Part C: Emerging Technologies, 79, 308–332.
<https://doi.org/10.1016/j.trc.2017.04.002>
- Kumar, K., Parida, M., & Katiyar, V. K.,2013 Short Term Traffic Flow Prediction for a Non Urban Highway Using Artificial Neural Network. Procedia - Social and Behavioral Sciences, 104, 755–764.
<https://doi.org/10.1016/j.sbspro.2013.11.170>
- Ladino, A.,
Kibangou, A. Y.,
Canudas de Wit, C., & Fourati, H.,2017 A real time forecasting tool for dynamic travel time from clustered time series. Transportation Research Part C: Emerging Technologies, 80, 216–238.
<https://doi.org/10.1016/j.trc.2017.05.002>
- Lamouik, I.,
Yahyaouy, A., &
Sabri, M. A.,2018 Deep neural network dynamic traffic routing system for vehicles. 2018 International Conference on Intelligent Systems and Computer Vision, ISCV 2018, 2018-May, 1–4.
<https://doi.org/10.1109/ISACV.2018.8354012>
- Laña, I., Del Ser, J., Vélez, M., & Oregi, I.,2017 Joint feature selection and parameter tuning for short-term traffic flow forecasting based on heuristically optimized multi-layer neural networks. Advances in Intelligent Systems and Computing, 514, 91–100. https://doi.org/10.1007/978-981-10-3728-3_10
- Lana, I., Del Ser, J., Velez, M., & Vlahogianni, E. I.,2018 Road Traffic Forecasting: Recent Advances and New Challenges. IEEE Intelligent Transportation Systems Magazine, 10(2), 93–109.
<https://doi.org/10.1109/MITS.2018.2806634>
- Langley, P.,1993 Induction of recursive bayesian classifiers. Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics), 667 LNAI, 153–164.

- Langley, P., & Sage, S.,1994 Induction of Selective Bayesian Classifiers. *ACM Computing Surveys*, 399–406. <https://doi.org/10.1016/b978-1-55860-332-5.50055-9>
- Langseth, H., & Nielsen, T. D.,2006 Classification using Hierarchical Naïve Bayes models. *Machine Learning*, 63(2), 135–159. <https://doi.org/10.1007/s10994-006-6136-2>
- Lauer, F., & Bloch, G.,2008 Incorporating prior knowledge in support vector machines for classification: A review. *Neurocomputing*, 71(7–9), 1578–1594. <https://doi.org/10.1016/j.neucom.2007.04.010>
- Lee, C. H., & Chen, L. H.,1994 Fast closest codeword search algorithm for vector quantisation. *IEE Proceedings: Vision, Image and Signal Processing*, 141(3), 143–148. <https://doi.org/10.1049/ip-vis:19941140>
- Li, L., Su, X., Wang, Y., Lin, Y., Li, Z., & Li, Y.,2015 Robust causal dependence mining in big data network and its application to traffic flow predictions. *Transportation Research Part C: Emerging Technologies*, 58, 292–307. <https://doi.org/10.1016/j.trc.2015.03.003>
- Li, S., Kwok, J. T., Zhu, H., & Wang, Y.,2003 Texture classification using the support vector machines. *Pattern Recognition*, 36(12), 2883–2893. [https://doi.org/10.1016/S0031-3203\(03\)00219-X](https://doi.org/10.1016/S0031-3203(03)00219-X)
- Li, S., Liu, X., & Yuan, G.,2014 Supervisory predictive control of weighted least square support vector machine based on Cauchy distribution. *26th Chinese Control and Decision Conference, CCDC 2014*, 3523–3526. <https://doi.org/10.1109/CCDC.2014.6852789>
- Li, Y., Shahabi, C., Yu, R., Demiryurek, U., & Liu, Y.,2017 Deep Learning: A Generic Approach for Extreme Condition Traffic Forecasting Location Privacy in Spatial Crowdsourcing View project Sensor stream and hand gesture recognition View project Deep Learning: A Generic Approach for Extreme Condition Traffic Forecasting. <https://doi.org/10.1137/1.9781611974973.87>
- Lin, C. T., Yeh, C. M., Liang, S. F., Chung, J. F., & Kumar, N.,2006 Support-vector-based fuzzy neural network for pattern classification. *IEEE Transactions on Fuzzy Systems*, 14(1), 31–41. <https://doi.org/10.1109/TFUZZ.2005.861604>

- Lin, C. F., & Wang, S. De.,2002 Fuzzy support vector machines. *IEEE Transactions on Neural Networks*, 13(2), 464–471. <https://doi.org/10.1109/72.991432>
- Lin, J., Keogh, E., & Lonardi, S.,2005 Visualizing and discovering non-trivial patterns in large time series databases. *Information Visualization*, 4(2), 61–82. <https://doi.org/10.1057/palgrave.ivs.9500089>
- Liu, C. H., Lu, Z. M., & Sun, S. H.,2003 Equal-average equal-norm nearest neighbor codeword search algorithm for vector quantization. *Tien Tzu Hsueh Pao/Acta Electronica Sinica*, 31(10), 1558–1561.
- Liu, Q., Wang, B., & Zhu, Y.,2018 Short-Term Traffic Speed Forecasting Based on Attention Convolutional Neural Network for Arterials. *Computer-Aided Civil and Infrastructure Engineering*, 33(11), 999–1016. <https://doi.org/10.1111/mice.12417>
- Liu, S. yan, Li, D. wei, Xi, Y. geng, & Tang, Q. feng.,2015 A short-term traffic flow forecasting method and its applications. *Journal of Shanghai Jiaotong University (Science)*, 20(2), 156–163. <https://doi.org/10.1007/s12204-015-1604-0>
- Liu, T., Ma, J., Guan, W., Song, Y., & Niu, H.,2012 Bus arrival time prediction based on the k-nearest neighbor method. *Proceedings of the 2012 5th International Joint Conference on Computational Sciences and Optimization, CSO 2012*, 480–483. <https://doi.org/10.1109/CSO.2012.111>
- Liu, Z., Li, Z., Wu, K., & Li, M.,2018 Urban Traffic Prediction from Mobility Data Using Deep Learning. *IEEE Network*, 32(4), 40–46. <https://doi.org/10.1109/MNET.2018.1700411>
- Louzada, F., & Ara, A.,2012 Bagging k-dependence probabilistic networks: An alternative powerful fraud detection tool. *Expert Systems with Applications*, 39(14), 11583–11592. <https://doi.org/10.1016/j.eswa.2012.04.024>
- Lu, H. P., Sun, Z. Y., Qu, W. C., & Wang, L.,2015 Real-time corrected traffic correlation model for traffic flow forecasting. *Mathematical Problems in Engineering*, 2015. <https://doi.org/10.1155/2015/348036>

- Lu, J., Chen, S., Wang, W., & Van Zuylen, H.,2012 A hybrid model of partial least squares and neural network for traffic incident detection. *Expert Systems with Applications*, 39(5), 4775–4784. <https://doi.org/10.1016/j.eswa.2011.09.158>
- Lu, Z., Sun, J., & Butts, K.,2014 Multiscale asymmetric orthogonal wavelet kernel for linear programming support vector learning and nonlinear dynamic systems identification. *IEEE Transactions on Cybernetics*, 44(5), 712–724. <https://doi.org/10.1109/TCYB.2013.2279834>
- Lucas, P. J. F.,2004 Restricted Bayesian Network Structure Learning. In *Advances in Bayesian Networks*, 217–234. https://doi.org/10.1007/978-3-540-39879-0_12
- Luong, T. T. B., & Houston, D.,2015 Public opinions of light rail service in Los Angeles , an analysis using Twitter data. *ICConference 2015 Proceedings*, 2–5.
- Lv, Y., Duan, Y., Kang, W., Li, Z., & Wang, F. Y.,2014 Traffic Flow Prediction with Big Data: A Deep Learning Approach. *IEEE Transactions on Intelligent Transportation Systems*, 16(2), 865–873. <https://doi.org/10.1109/TITS.2014.2345663>
- Lv, Z., Xu, J., Zheng, K., Yin, H., Zhao, P., & Zhou, X.,2018 LC-RNN: A deep learning model for traffic speed prediction. *IJCAI International Joint Conference on Artificial Intelligence*, 2018-July, 3470–3476. <https://doi.org/10.24963/ijcai.2018/482>
- M. Maron, J. K.,1960 On relevance, probabilistic indexing, and information retrieval. *Journal of the Association for Computing Machinery*, 216–244.
- Ma, W., & Yuan, Z.,2018 Analysis and Comparison of Traffic Accident Regression Prediction Model. 364–369. <https://doi.org/10.5220/0006970803640369>
- Ma, W., & Wang, R.,2015 Traffic flow forecasting research based on Bayesian normalized Elman neural network. 2015 *IEEE Signal Processing and Signal Processing Education Workshop, SP/SPE 2015*, 426–430. <https://doi.org/10.1109/DSP-SPE.2015.7369592>

- Ma, X., Tao, Z., Wang, Y., Yu, H., & Wang, Y., 2015 Long short-term memory neural network for traffic speed prediction using remote microwave sensor data. *Transportation Research Part C: Emerging Technologies*, 54, 187–197. <https://doi.org/10.1016/j.trc.2015.03.014>
- Ma, Z., Koutsopoulos, H. N., Ferreira, L., & Mesbah, M., 2017 Estimation of trip travel time distribution using a generalized Markov chain approach. *Transportation Research Part C: Emerging Technologies*, 74, 1–21. <https://doi.org/10.1016/j.trc.2016.11.008>
- Ma, Z., Luo, G., & Huang, D., 2016 Short term traffic flow prediction based on on-line sequential extreme learning machine. *Proceedings of the 8th International Conference on Advanced Computational Intelligence, ICACI 2016*, 143–149. <https://doi.org/10.1109/ICACI.2016.7449818>
- Maghrebi, M., Abbasi, A., Rashidi, T. H., & Waller, S. T., 2015 Complementing Travel Diary Surveys with Twitter Data: Application of Text Mining Techniques on Activity Location, Type and Time. *IEEE Conference on Intelligent Transportation Systems, Proceedings, ITSC, 2015-Octob*, 208–213. <https://doi.org/10.1109/ITSC.2015.43>
- Maghrebi, M., Abbasi, A., & Waller, S. T., 2016 Transportation application of social media: Travel mode extraction. *IEEE Conference on Intelligent Transportation Systems, Proceedings, ITSC*, 1648–1653. <https://doi.org/10.1109/ITSC.2016.7795779>
- Mai, E., & Hranac, R., 2013 Twitter Interactions as a Data Source for Transportation Incidents (Paper revised from original submittal). 92nd Annual Meeting Transportation Research Board. Retrieved from <http://docs.trb.org/prp/13-1636.pdf>
- Malik J.S., Goyal P., S. A. K., 2010 A Comprehensive Approach Towards Data Preprocessing Techniques & Association Rules. *Proceedings of The 4th National*.
- Martín, L., Baena, L., Garach, L., López, G., & de Oña, J., 2014 Using Data Mining Techniques to Road Safety Improvement in Spanish Roads. <https://doi.org/10.1016/j.sbspro.2014.12.174>

- Martín, L., Baena, L., Garach, L., López, G., & de Oña, J., 2014 Using Data Mining Techniques to Road Safety Improvement in Spanish Roads. *Procedia - Social and Behavioral Sciences*, 160, 607–614. <https://doi.org/10.1016/j.sbspro.2014.12.174>
- Mazloumi, E., Rose, G., Currie, G., & Moridpour, S., 2011 Prediction intervals to account for uncertainties in neural network predictions: Methodology and application in bus travel time prediction. *Engineering Applications of Artificial Intelligence*, 24(3), 534–542. <https://doi.org/10.1016/j.engappai.2010.11.004>
- Mena-Yedra, R., Gavalda, R., & Casas, J., 2017 Adarules: Learning rules for real-time road-traffic prediction. *Transportation Research Procedia*, 27, 11–18. <https://doi.org/10.1016/j.trpro.2017.12.106>
- Meng, M., Shao, C. fu, Wong, Y. diew, Wang, B. bin, & Li, H. xuan., 2015 A two-stage short-term traffic flow prediction method based on AVL and AKNN techniques. *Journal of Central South University*, 22(2), 779–786. <https://doi.org/10.1007/s11771-015-2582-y>
- Min, W., & Wynter, L., 2011 Real-time road traffic prediction with spatio-temporal correlations. *Transportation Research Part C: Emerging Technologies*, 19(4), 606–616. <https://doi.org/10.1016/j.trc.2010.10.002>
- Minsky, M., 1961 Steps Toward Artificial Intelligence. *Proceedings of the IRE*, 49(1), 8–30. <https://doi.org/10.1109/JRPROC.1961.287775>
- Mohamed, E. A., 2014 Predicting Causes of Traffic Road Accidents Using Multi-class Support Vector Machines. *Journal of Communication and Computer*, 11, 403–411. <https://doi.org/10.17265/1548-7709/2014.05>
- Moreira-Matias, L., Mendes-Moreira, J., De Sousa, J. F., & Gama, J., 2015 Improving Mass Transit Operations by Using AVL-Based Systems: A Survey. *IEEE Transactions on Intelligent Transportation Systems*, 16(4), 1636–1653. <https://doi.org/10.1109/TITS.2014.2376772>

- Moretti, F., Pizzuti, S., Panzieri, S., & Annunziato, M., 2015 Urban traffic flow forecasting through statistical and neural network bagging ensemble hybrid modeling. <https://doi.org/10.1016/j.neucom.2014.08.100>
- Mukhopadhyay, A., Maulik, U., Bandyopadhyay, S., & Coello, C. A. C., 2014 Survey of multiobjective evolutionary algorithms for data mining: Part II. *IEEE Transactions on Evolutionary Computation*, 18(1), 25–35. <https://doi.org/10.1109/TEVC.2013.2290082>
- Ni, M., He, Q., & Gao, J., 2017 Forecasting the Subway Passenger Flow under Event Occurrences with Social Media. *IEEE Transactions on Intelligent Transportation Systems*, 18(6), 1623–1632. <https://doi.org/10.1109/TITS.2016.2611644>
- Nikolaidou, A., & Papaioannou, P., 2018 Utilizing Social Media in Transport Planning and Public Transit Quality: Survey of Literature. *Journal of Transportation Engineering, Part A: Systems*, 144(4), 04018007. <https://doi.org/10.1061/jtepbs.0000128>
- Ozbayoglu, M., Kucukayan, G., & Dogdu, E., 2016 A real-time autonomous highway accident detection model based on big data processing and computational intelligence. *Proceedings - 2016 IEEE International Conference on Big Data, Big Data 2016*, 1807–1813. <https://doi.org/10.1109/BigData.2016.7840798>
- Padiath, A., Vanajakshi, L., Subramanian, S. C., & Manda, H., 2009 Prediction of traffic density for congestion analysis under Indian traffic conditions. *IEEE Conference on Intelligent Transportation Systems, Proceedings, ITSC*, 78–83. <https://doi.org/10.1109/ITSC.2009.5309716>
- Pan, H., Liu, J., Zhou, S., & Niu, Z., 2016 A block regression model for short-term mobile traffic forecasting. *2015 IEEE/CIC International Conference on Communications in China, ICC China 2015*. <https://doi.org/10.1109/ICCChina.2015.7448619>
- Parikh, U. B., Das, B., & Maheshwari, R., 2010 Fault classification technique for series compensated transmission line using support vector machine. *International Journal of Electrical Power and Energy Systems*, 32(6), 629–636. <https://doi.org/10.1016/j.ijepes.2009.11.020>

- Pazzani, M., & Billsus, D.,1997 Learning and Revising User Profiles: The Identification of Interesting Web Sites. *Machine Learning*, 27(3), 313–331. <https://doi.org/10.1023/A:1007369909943>
- Pender, B., Currie, G., Delbosc, A., & Shiwakoti, N.,2014 International study of current and potential social media applications in unplanned passenger rail disruptions. *Transportation Research Record*, 2419, 118–127. <https://doi.org/10.3114/2419-12>
- Polat, K., & Güneş, S.,2007 Breast cancer diagnosis using least square support vector machine. *Digital Signal Processing: A Review Journal*, 17(4), 694–701. <https://doi.org/10.1016/j.dsp.2006.10.008>
- Polson, N. G., & Sokolov, V. O.,2017 Deep learning for short-term traffic flow prediction. *Transportation Research Part C: Emerging Technologies*, 79, 1–17. <https://doi.org/10.1016/j.trc.2017.02.024>
- Prathilothamai, M., Sree Lakshmi, A. M., & Viswanthan, D.,2016 Cost effective road traffic prediction model using Apache spark. *Indian Journal of Science and Technology*, 9(17). <https://doi.org/10.17485/ijst/2016/v9i17/87334>
- Prinzie, A., & Van Den Poel, D.,2007 Random multiclass classification: generalizing random forests to random MNL and random NB. *4653 LNCS*, 349–358. https://doi.org/10.1007/978-3-540-74469-6_35
- Qi, L.,2008 Research on intelligent transportation system technologies and applications. *Proceedings - 2008 Workshop on Power Electronics and Intelligent Transportation System, PEITS 2008*, 529–531. <https://doi.org/10.1109/PEITS.2008.124>
- Qi, Z., Tian, Y., & Shi, Y.,2013 Robust twin support vector machine for pattern classification. *Pattern Recognition*, 46(1), 305–316. <https://doi.org/10.1016/j.patcog.2012.06.019>
- Qi, Z., Tian, Y., & Shi, Y.,2013 Structural Twin Support Vector Machine for Classification. *43*, 74–81. <https://doi.org/10.1016/j.knosys.2013.01.008>

- Qu, J., & Zuo, M. J.,2010 Support vector machine based data processing algorithm for wear degree classification of slurry pump systems. *Measurement: Journal of the International Measurement Confederation*, 43(6), 781–791. <https://doi.org/10.1016/j.measurement.2010.02.014>
- Quinlan, J. R.,1986 Induction of Decision Trees. *Machine Learning*, 1(1), 81–106. <https://doi.org/10.1023/A:1022643204877>
- Rahman, R., Roy, K. C., Abdel-Aty, M., & Hasan, S.,2019 Sharing real-time traffic information with travelers using twitter: An analysis of effectiveness and information content. *Frontiers in Built Environment*, 5. <https://doi.org/10.3389/fbuil.2019.00083>
- Rai, H., & Yadav, A.,2014 Iris recognition using combined support vector machine and Hamming distance approach. *Expert Systems with Applications*, 41(2), 588–593. <https://doi.org/10.1016/j.eswa.2013.07.083>
- Raj, J., Bahuleyan, H., & Vanajakshi, L. D.,2016 Application of Data Mining Techniques for Traffic Density Estimation and Prediction. *Transportation Research Procedia*, 17, 321–330. <https://doi.org/10.1016/j.trpro.2016.11.102>
- Rashidi, T. H., Abbasi, A., Maghrebi, M., Hasan, S., & Waller, T. S.,2017 Exploring the capacity of social media data for modelling travel behaviour: Opportunities and challenges. *Transportation Research Part C: Emerging Technologies*, 75, 197–211. <https://doi.org/10.1016/j.trc.2016.12.008>
- Raza, A., & Zhong, M.,2017 Hybrid lane-based short-term urban traffic speed forecasting: A genetic approach. 2017 4th International Conference on Transportation Information and Safety, *ICTIS 2017 - Proceedings*, 271–279. <https://doi.org/10.1109/ICTIS.2017.8047776>
- Razzaq, S., Riaz, F., Mehmood, T., & Ratyal, N. I.,2016 Multi-Factors Based Road Accident Prevention System. 2016 International Conference on Computing, Electronic and Electrical Engineering, *ICE Cube 2016 - Proceedings*, 190–195. <https://doi.org/10.1109/ICECUBE.2016.7495221>

- Ren, H., Song, Y., Wang, J., Hu, Y., & Lei, J., 2018 A Deep Learning Approach to the Citywide Traffic Accident Risk Prediction. IEEE Conference on Intelligent Transportation Systems, Proceedings, ITSC, 2018-November, 3346–3351. <https://doi.org/10.1109/ITSC.2018.8569437>
- Rocco S., C. M., & Zio, E., 2007 A support vector machine integrated system for the classification of operation anomalies in nuclear components and systems. Reliability Engineering and System Safety, 92(5), 593–600. <https://doi.org/10.1016/j.ress.2006.02.003>
- Saimurugan, M., & Ramachandran, K. I., 2015 A comparative study of sound and vibration signals in detection of rotating machine faults using support vector machine and independent component analysis. International Journal of Data Analysis Techniques and Strategies, 7(1), 188–204. <https://doi.org/10.1504/IJDATS.2014.062458>
- Sakthivel, N. R., Sugumaran, V., & Nair, B. B., 2010 Application of Support Vector Machine (SVM) and Proximal Support Vector Machine (PSVM) for fault classification of monoblock centrifugal pump. International Journal of Data Analysis Techniques and Strategies, 2(1), 38–61. <https://doi.org/10.1504/IJDATS.2010.030010>
- Scherer, S., Kane, J., Gobl, C., & Schwenker, F., 2013 Investigating fuzzy-input fuzzy-output support vector machines for robust voice quality classification. Computer Speech and Language, 27(1), 263–287. <https://doi.org/10.1016/j.csl.2012.06.001>
- Schweitzer, L., 2012 How Are We Doing? Opinion Mining Customer Sentiment in US Transit Agencies and Airlines via Twitter. Transportation Research Board 91st Annual Meeting. Retrieved from <http://trid.trb.org/view.aspx?id=1129878>
- Seo, T., Bayen, A. M., Kusakabe, T., & Asakura, Y., 2017 Traffic state estimation on highway: A comprehensive survey. Annual Reviews in Control, 43, 128–151. <https://doi.org/10.1016/j.arcontrol.2017.03.005>
- Shabri, A., & Suhartono., 2012 Prévision de débit à l'aide de machines à vecteurs de support en moindres carrés. Hydrological Sciences Journal, 57(7), 1275–1293. <https://doi.org/10.1080/02626667.2012.714468>

- Shao, Y. H., & Deng, N. Y.,2012 A coordinate descent margin based-twin support vector machine for classification. *Neural Networks*, 25, 114–121. <https://doi.org/10.1016/j.neunet.2011.08.003>
- Sharma, B., Katiyar, V. K., & Kumar, K.,2016 Traffic accident prediction model using support vector machines with Gaussian kernel. *Advances in Intelligent Systems and Computing*, 437, 1–10. https://doi.org/10.1007/978-981-10-0451-3_1
- Shawe-Taylor, J., & Sun, S.,2011 A review of optimization methodologies in support vector machines. *Neurocomputing*, 74(17), 3609–3618. <https://doi.org/10.1016/j.neucom.2011.06.026>
- Shi, Q., & Abdel-Aty, M.,2015 Big Data applications in real-time traffic operation and safety monitoring and improvement on urban expressways. *Transportation Research Part C: Emerging Technologies*, 58, 380–394. <https://doi.org/10.1016/j.trc.2015.02.022>
- Shieh, M. D., & Yang, C. C.,2008 Classification model for product form design using fuzzy support vector machines. *Computers and Industrial Engineering*, 55(1), 150–164. <https://doi.org/10.1016/j.cie.2007.12.007>
- Shu-Xin Du, S.-T. C.,2005 Weighted support vector machine for classification. Published in *IEEE International Conference on Systems*, 4, 3866–3871. <https://doi.org/10.1109/icsmc.2005.1571749>
- Singh, S., & Giri, M.,2014 Comparative Study Id3, Cart and C4.5 Decision Tree Algorithm: a Survey. *International Journal of Advanced Information Science and Technology*, 3(7), 97–103. <https://doi.org/10.15693/ijaist/2014.v3i7.47-52>
- Sinn, M., Yoon, J. W., Calabrese, F., & Bouillet, E.,2012 Predicting arrival times of buses using real-time GPS measurements. *IEEE Conference on Intelligent Transportation Systems, Proceedings, ITSC*, 1227–1232. <https://doi.org/10.1109/ITSC.2012.6338767>
- Smith, B. L., Williams, B. M., & Keith Oswald, R.,2002 Comparison of parametric and nonparametric models for traffic flow forecasting. *Transportation Research Part C: Emerging Technologies*, 10(4), 303–321. [https://doi.org/10.1016/S0968-090X\(02\)00009-8](https://doi.org/10.1016/S0968-090X(02)00009-8)

- Song, C., Lee, H., Kang, C., Lee, W., Kim, Y. B., & Cha, S. W., 2017 Traffic speed prediction under weekday using convolutional neural networks concepts. *IEEE Intelligent Vehicles Symposium, Proceedings*, 1293–1298. <https://doi.org/10.1109/IVS.2017.7995890>
- Soua, R., Koesdwiady, A., & Karray, F., 2016 Big-data-generated traffic flow prediction using deep learning and dempster-shafer theory. *Proceedings of the International Joint Conference on Neural Networks*, 2016-October, 3195–3202. <https://doi.org/10.1109/IJCNN.2016.7727607>
- Steur, R., 2014 Twitter as a spatio-temporal information source for traffic incident management. *Geographical Information Management and Applications*.
- Su, F., Dong, H., Jia, L., Qin, Y., & Tian, Z., 2016 Long-term forecasting oriented to urban expressway traffic situation. *Advances in Mechanical Engineering*, 8(1). <https://doi.org/10.1177/1687814016628397>
- Su, H., Zhang, L., & Yu, S., 2007 Short-term traffic flow prediction based on incremental support vector regression. *Proceedings - Third International Conference on Natural Computation, ICNC 2007*, 1, 640–645. <https://doi.org/10.1109/ICNC.2007.661>
- Sun, B., Cheng, W., Goswami, P., & Bai, G., 2017 Flow-aware WPT k-nearest neighbours regression for short-term traffic prediction. *Proceedings - IEEE Symposium on Computers and Communications*, 48–53. <https://doi.org/10.1109/ISCC.2017.8024503>
- Sun, B., & Park, B. B., 2017 Route choice modeling with Support Vector Machine. *Transportation Research Procedia*, 25, 1806–1814. <https://doi.org/10.1016/j.trpro.2017.05.151>
- Taamneh, M., Alkheder, S., & Taamneh, S., 2017 Data-mining techniques for traffic accident modeling and prediction in the United Arab Emirates. *Journal of Transportation Safety and Security*, 9(2), 146–166. <https://doi.org/10.1080/19439962.2016.1152338>
- Takeuchi, S., Kitamura, T., Abe, S., & Fukui, K., 2009 Subspace based linear programming support vector machines. *Proceedings of the International Joint Conference on Neural Networks*, 22, 3067–3073. <https://doi.org/10.1109/IJCNN.2009.5178762>

- Tang, Y., Jin, B., Sun, Y., & Zhang, Y. Q., 2004 Granular support vector machines for medical binary classification problems. Proceedings of the 2004 IEEE Symposium on Computational Intelligence in Bioinformatics and Computational Biology, CIBCB'04, 73–78. <https://doi.org/10.1109/cibcb.2004.1393935>
- Tao, L., Zhu, D., Yan, L., & Zhang, P., 2015 The traffic accident hotspot prediction: Based on the logistic regression method. ICTIS 2015 - 3rd International Conference on Transportation Information and Safety, Proceedings, 107–110. <https://doi.org/10.1109/ICTIS.2015.7232194>
- Tayeb, A. A. El, Pareek, V., & Araar, A., 2015 Applying Association Rules Mining Algorithms for Traffic Accidents in Dubai. International Journal of Soft Computing and Engineering (IJSCE), (4), 2231–2307. Retrieved from <http://www.ijscce.org/wp-content/uploads/papers/v5i4/D2679095415.pdf>
- Theodorou, T. I., Salamanis, A., Kehagias, D. D., Tzovaras, D., & Tjortjis, C., 2017 Short-term traffic prediction under both typical and atypical traffic conditions using a pattern transition model. VEHITS 2017 - Proceedings of the 3rd International Conference on Vehicle Technology and Intelligent Transport Systems, 79–89. <https://doi.org/10.5220/0006293400790089>
- Tian, Y., Ju, X., Qi, Z., & Shi, Y., 2013 Efficient sparse least squares support vector machines for pattern classification. Computers and Mathematics with Applications, 66(10), 1935–1947. <https://doi.org/10.1016/j.camwa.2013.06.028>
- Tsai, C. F., 2005 Training support vector machines based on stacked generalization for image classification. Neurocomputing, 64(1-4 SPEC. ISS.), 497–503. <https://doi.org/10.1016/j.neucom.2004.08.005>
- Tsyurmasto, P., Zabaranin, M., & Uryasev, S., 2014 Value-at-risk support vector machine: Stability to outliers. Journal of Combinatorial Optimization, 28(1), 218–232. <https://doi.org/10.1007/s10878-013-9678-9>
- V. Robles, P. Larranaga, J. M. Peña, E. Menasalvas, M. S. Perez, V. H., 2004 Bayesian networks as consensed voting system in the construction of a multi-classifier for protein secondary structure prediction. Artificial Intelligence in Medicine, 31, 117–136.

- V. Robles, P. Larranaga, J. M. Pena, E. Menasalvas, M. S. P., 2003 Interval estimation naive Bayes. In Proceedings of the 5th International Symposium on Intelligent Data Analysis (IDA-2003), 2810, 143–154.
- Valenti, G., Lelli, M., & Cucina, D., 2010 A comparative study of models for the incident duration prediction. *European Transport Research Review*, 2(2), 103–111. <https://doi.org/10.1007/s12544-010-0031-4>
- Valentini, G., 2002 Gene expression data analysis of human lymphoma using support vector machines and output coding ensembles. *Artificial Intelligence in Medicine*, 26(3), 281–304. [https://doi.org/10.1016/S0933-3657\(02\)00077-5](https://doi.org/10.1016/S0933-3657(02)00077-5)
- Vanajakshi, L., & Rilett, L. R., 2004 A comparison of the performance of artificial neural networks and support vector machines for the prediction of traffic speed. *IEEE Intelligent Vehicles Symposium, Proceedings*, 194–199. <https://doi.org/10.1109/ivs.2004.1336380>
- Vasavi, S., 2016 A Survey on Extracting Hidden Patterns within Road Accident Data using Machine Learning Techniques. *Communications on Applied Electronics*, 6(4), 1–6. <https://doi.org/10.5120/cae2016652455>
- Velchamy, I., Ilango, U., & Ramesh, N., 2015 Time Series Data Mining Research Problem , Issues , Models , Trends and Tools. *International Journal of Computer Engineering and Applications*, IX(V), 59–75. Retrieved from www.ijcea.com
- Vlahogianni, E. I., Golias, J. C., & Karlaftis, M. G., 2004 Short-term traffic forecasting: Overview of objectives and methods. *Transport Reviews*, 24(5), 533–557. <https://doi.org/10.1080/0144164042000195072>
- Vlahogianni, E. I., Karlaftis, M. G., & Golias, J. C., 2014 Short-term traffic forecasting: Where we are and where we're going. *Transportation Research Part C: Emerging Technologies*, 43, 3–19. <https://doi.org/10.1016/j.trc.2014.01.005>

- Vlahogianni, E. I., Karlaftis, M. G., & Orfanou, F. P., 2012 Modeling the effects of weather and traffic on the risk of secondary incidents. *Journal of Intelligent Transportation Systems: Technology, Planning, and Operations*, 16(3), 109–117. <https://doi.org/10.1080/15472450.2012.688384>
- Wan, C. H., Lee, L. H., Rajkumar, R., & Isa, D., 2012 A hybrid text classification approach with low dependency on parameter by integrating K-nearest neighbor and support vector machine. *Expert Systems with Applications*, 39(15), 11880–11888. <https://doi.org/10.1016/j.eswa.2012.02.068>
- Wang, C. C., & Tung, C. W., 2005 A fast encoding algorithm for vector quantization. *IEICE Electronics Express*, 2(17), 458–464. <https://doi.org/10.1587/elex.2.458>
- Wang, J., Tsapakis, I., & Zhong, C., 2016 A space-time delay neural network model for travel time prediction. *Engineering Applications of Artificial Intelligence*, 52, 145–160. <https://doi.org/10.1016/j.engappai.2016.02.012>
- Wang, J., & Shi, Q., 2013 Short-term traffic speed forecasting hybrid model based on Chaos-Wavelet Analysis-Support Vector Machine theory. *Transportation Research Part C: Emerging Technologies*, 27, 219–232. <https://doi.org/10.1016/j.trc.2012.08.004>
- Wang, J., Gu, Q., Wu, J., Liu, G., & Xiong, Z., 2017 Traffic speed prediction and congestion source exploration: A deep learning method. *Proceedings - IEEE International Conference on Data Mining, ICDM*, 499–508. <https://doi.org/10.1109/ICDM.2016.0061>
- Wanichayapong, N., Pruthipunyaskul, W., Pattara-Atikom, W., & Chaovalit, P., 2011 Social-based traffic information extraction and classification. 2011 11th International Conference on ITS Telecommunications, ITST 2011, 107–112. <https://doi.org/10.1109/ITST.2011.6060036>
- Webb, G. I., Boughton, J. R., & Wang, Z., 2005 Not so naive Bayes: Aggregating one-dependence estimators. *Machine Learning*, 58(1), 5–24. <https://doi.org/10.1007/s10994-005-4258-6>
- Wibisono, A., Jatmiko, W., Wisesa, H. A., Traffic big data prediction and visualization using Fast Incremental Model Trees-Drift Detection (FIMT-DD).

- Hardjono, B., & Mursanto, P., 2016 Knowledge-Based Systems, 93, 33–46. <https://doi.org/10.1016/j.knosys.2015.10.028>
- Wu, C. H., Ken, Y., & Huang, T., 2010 Patent classification system using a new hybrid genetic algorithm support vector machine. Applied Soft Computing Journal, 10(4), 1164–1177. <https://doi.org/10.1016/j.asoc.2009.11.033>
- Wu, C. H., Wei, C. C., Su, D. C., Chang, M. H., & Ho, J. M., 2003 Travel time prediction with support vector regression. IEEE Conference on Intelligent Transportation Systems, Proceedings, ITSC, 2, 1438–1442. <https://doi.org/10.1109/ITSC.2003.1252721>
- Wu, Y., Tan, H., Peter, J., Shen, B., & Ran, B., 2015 Short-Term Traffic Flow Prediction Based on Multilinear Analysis and k-Nearest Neighbor Regression. CICTP 2015 - Efficient, Safe, and Green Multimodal Transportation - Proceedings of the 15th COTA International Conference of Transportation Professionals, 556–569. <https://doi.org/10.1061/9780784479292.051>
- Wu, Z., Zhang, H., & Liu, J., 2014 A fuzzy support vector machine algorithm for classification based on a novel PIM fuzzy clustering method. Neurocomputing, 125, 119–124. <https://doi.org/10.1016/j.neucom.2012.07.049>
- Xia, D., Wang, B., Li, H., Li, Y., & Zhang, Z., 2016 A distributed spatial-temporal weighted model on MapReduce for short-term traffic flow forecasting. Neurocomputing, 179, 246–263. <https://doi.org/10.1016/j.neucom.2015.12.013>
- Xu, R., & Wunsch, D., 2005 Survey of clustering algorithms. IEEE Transactions on Neural Networks, 16(3), 645–678. <https://doi.org/10.1109/TNN.2005.845141>
- Xu, S., Li, S., Wen, R., & Huang, W., 2019 TRAFFIC EVENT DETECTION USING TWITTER DATA BASED on ASSOCIATION RULES. ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 4(2/W5), 543–547. <https://doi.org/10.5194/isprs-annals-IV-2-W5-543-2019>
- Xu, Y., Chen, H., Kong, Q. J., Zhai, Urban traffic flow prediction: A spatio-temporal variable selection-based approach. Journal of Advanced

- X., & Liu, Y.,2016 Transportation, 50(4), 489–506. <https://doi.org/10.1002/atr.1356>
- Yan, W. Y., & He, Q.,2009 Multi-class fuzzy support vector machine based on dismissing margin. Proceedings of the 2009 International Conference on Machine Learning and Cybernetics, 2, 1139–1144. <https://doi.org/10.1109/ICMLC.2009.5212368>
- Yang, B. S., Hwang, W. W., Kim, D. J., & Tan, A. C.,2005 Condition classification of small reciprocating compressor for refrigerators using artificial neural networks and support vector machines. Mechanical Systems and Signal Processing, 19(2), 371–390. <https://doi.org/10.1016/j.ymssp.2004.06.002>
- Yang, C., Fu, R., & Fu, Y.,2016 Prediction of Short-Term Traffic Flow Based on Similarity. Journal of Highway and Transportation Research and Development (English Edition), 10(1), 92–97. <https://doi.org/10.1061/jhtrcq.0000491>
- Yang, H., Zou, Y., Wang, Z., & Wu, B.,2018 A hybrid method for short-term freeway travel time prediction based on wavelet neural network and markov chain. Canadian Journal of Civil Engineering, 45(2), 77–86. <https://doi.org/10.1139/cjce-2017-0231>
- Yang, H. F., Dillon, T. S., Chang, E., & Chen, Y. P. P.,2019 Optimized Configuration of Exponential Smoothing and Extreme Learning Machine for Traffic Flow Forecasting. IEEE Transactions on Industrial Informatics, 15(1), 23–34. <https://doi.org/10.1109/TII.2018.2876907>
- Yang, H., Dillon, T. S., & Chen, Y. P. P.,2015 Evaluation of recent computational approaches in short-term traffic forecasting. IFIP Advances in Information and Communication Technology, 465, 108–116. https://doi.org/10.1007/978-3-319-25261-2_10
- Yang, H. J., & Hu, X.,2016 Wavelet neural network with improved genetic algorithm for traffic flow time series prediction. Optik, 127(19), 8103–8110. <https://doi.org/10.1016/j.ijleo.2016.06.017>
- Yang, J., Han, Y., Wang, Y., Jiang, B., Lv, Z., & Song, H.,2017 Optimization of real-time traffic network assignment based on IoT data using DBN and clustering model in smart city. Future Generation Computer Systems. <https://doi.org/10.1016/j.future.2017.12.012>

- You, J., Wang, J., & Guo, J., 2017 Real-time crash prediction on freeways using data mining and emerging techniques. *Journal of Modern Transportation*, 25(2), 116–123. <https://doi.org/10.1007/s40534-017-0129-7>
- Yu, B., Lam, W. H. K., & Tam, M. L., 2011 Bus arrival time prediction at bus stop with multiple routes. *Transportation Research Part C: Emerging Technologies*, 19(6), 1157–1170. <https://doi.org/10.1016/j.trc.2011.01.003>
- Yu, B., Wang, H., Shan, W., & Yao, B., 2017 Prediction of Bus Travel Time Using Random Forests Based on Near Neighbors. *Computer-Aided Civil and Infrastructure Engineering*, 33(4), 333–350. <https://doi.org/10.1111/mice.12315>
- Yu, B., Yin, H., & Zhu, Z., 2017 Spatio-temporal graph convolutional networks: A deep learning framework for traffic forecasting. *IJCAI International Joint Conference on Artificial Intelligence*, 2017-July, 3634–3640.
- Yu, H., Wu, Z., Wang, S., Wang, Y., & Ma, X., 2017 Spatiotemporal recurrent convolutional networks for traffic prediction in transportation networks. *Sensors (Switzerland)*, 17(7). <https://doi.org/10.3390/s17071501>
- Yu, J., Chang, G. L., Ho, H. W., & Liu, Y., 2008 Variation based online travel time prediction using clustered neural networks. *IEEE Conference on Intelligent Transportation Systems, Proceedings, ITSC*, 85–90. <https://doi.org/10.1109/ITSC.2008.4732594>
- Zanaty, E. A., 2012 Support Vector Machines (SVMs) versus Multilayer Perception (MLP) in data classification. *Egyptian Informatics Journal*, 13(3), 177–183. <https://doi.org/10.1016/j.eij.2012.08.002>
- Zhan, Y., & Shen, D., 2005 Design efficient support vector machine for fast classification. *Pattern Recognition*, 38(1), 157–161. <https://doi.org/10.1016/j.patcog.2004.06.001>
- Zhang, H., Jiang, L., & Su, J., 2005 Hidden naive Bayes. *Proceedings of the National Conference on Artificial Intelligence*, 2, 919–924.
- Zhang, W., Yoshida, T., & Tang, X., 2008 Text classification based on multi-word with support vector machine. *Knowledge-Based Systems*, 21(8), 879–886. <https://doi.org/10.1016/j.knosys.2008.03.044>

- Zhang, Y., & Zhang, Y.,2016 A Comparative Study of Three Multivariate Short-Term Freeway Traffic Flow Forecasting Methods With Missing Data. <https://doi.org/10.1080/15472450.2016.1147813>
- Zhang, Y., Ma, X., Zhang, Y., & Yang, J.,2013 Support vector machine of the coal mine machinery equipment fault diagnosis. 2013 IEEE International Conference on Information and Automation, ICIA 2013, 1141–1146. <https://doi.org/10.1109/ICInfA.2013.6720467>
- Zhang, Y., & Haghani, A.,2015 A gradient boosting method to improve travel time prediction. Transportation Research Part C: Emerging Technologies, 58, 308–324. <https://doi.org/10.1016/j.trc.2015.02.019>
- Zhang, Z., He, Q., Gao, J., & Ni, M.,2018 A deep learning approach for detecting traffic accidents from social media data. Transportation Research Part C: Emerging Technologies, 86, 580–596. <https://doi.org/10.1016/j.trc.2017.11.027>
- Zhao, J., & Sun, S.,2016 High-Order Gaussian Process Dynamical Models for Traffic Flow Prediction. IEEE Transactions on Intelligent Transportation Systems, 17(7), 2014–2019. <https://doi.org/10.1109/TITS.2016.2515105>
- Zheng, F., & Van Zuylen, H.,2013 Urban link travel time estimation based on sparse probe vehicle data. Transportation Research Part C: Emerging Technologies, 31, 145–157. <https://doi.org/10.1016/j.trc.2012.04.007>
- Zheng, F., & Webb, G. I.,2006 Efficient lazy elimination for averaged one-dependence estimators. ACM International Conference Proceeding Series, 148, 1113–1120. <https://doi.org/10.1145/1143844.1143984>
- Zheng, Z.,1998 Naive bayesian classifier committees. Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics), 1398, 196–207.
- Zheng, Z., & Su, D.,2014 Short-term traffic volume forecasting: A k-nearest neighbor approach enhanced by constrained linearly sewing principle component algorithm. Transportation Research Part C: Emerging Technologies, 43, 143–157. <https://doi.org/10.1016/j.trc.2014.02.009>

- Zhu, L., Guo, F., Krishnan, R., & Polak, J. W., 2018 A Deep Learning Approach for Traffic Incident Detection in Urban Networks. <https://doi.org/10.1109/itsc.2018.8569402>
- Zhu, L., Yu, F. R., Wang, Y., Ning, B., & Tang, T., 2018 Big Data Analytics in Intelligent Transportation Systems: A Survey. *IEEE Transactions on Intelligent Transportation Systems*, 20(1), 383–398.



EKLER

EK 1. İBB Veri Data Portalı Günlük Örnek Trafik Bilgileri

D100 15 Temmuz Şehitler Köprüsü Avrupa-Anadolu Yönü, sol şerit trafik kazası (hasarlı).
D100 15 Temmuz Şehitler Köprüsü Avrupa-Anadolu Yönü, sol şerit trafik kazası (hasarlı) nedeni ile 1 şerit trafiğe kapalı. Kazaya müdahale ediliyor.
D100 15 Temmuz Şehitler Köprüsü Avrupa-Anadolu Yönü, sağ şerit araç arızası. Bölgedeki trafik yoğunlaşmaktadır.
D100 15 Temmuz Şehitler Köprüsü Avrupa-Anadolu Yönü, sol şerit trafik kazası (zincirleme).
D100 15 Temmuz Şehitler Köprüsü-Zincirlikuyu Yönü, sağ şerit araç arızası nedeni ile 1 şerit trafiğe kapalıdır.
D100 15 Temmuz Şehitler Köprüsü Anadolu-Avrupa Yönü, sol şerit trafik kazası (hasarlı).
D100 15 Temmuz Şehitler Köprüsü Avrupa-Anadolu Yönü, sol şerit araç arızası. Bölgedeki trafik yoğunlaşmaktadır.
D100 15 Temmuz Şehitler Köprüsü Avrupa-Anadolu Yönü, sağ şerit araç arızası. Ekip sevk edildi.
D100 15 Temmuz Şehitler Köprüsü Avrupa-Anadolu Yönü, sol şerit trafik kazası (hasarlı).
D100 15 Temmuz Şehitler Köprüsü Anadolu-Avrupa Yönü, sağ şerit araç arızası. Bölgedeki trafik yoğunlaşmaktadır.
D100 15 Temmuz Şehitler Köprüsü Avrupa-Anadolu Yönü, sol şerit trafik kazası (hasarlı).
D100 15 Temmuz Şehitler Köprüsü Avrupa-Anadolu Yönü, orta şerit trafik kazası (hasarlı).
D100 15 Temmuz Şehitler Köprüsü Avrupa-Anadolu Yönü, sağ şerit araç arızası. Bölgedeki trafik yoğunlaşmaktadır.
D100 15 Temmuz Şehitler Köprüsü Avrupa-Anadolu Yönü, sol şerit araç arızası. Bölgedeki trafik yoğunlaşmaktadır.
D100 15 Temmuz Şehitler Köprüsü Avrupa-Anadolu Yönü, sağ şerit araç arızası. Bölgedeki trafik yoğunlaşmaktadır.
D100 15 Temmuz Şehitler Köprüsü Anadolu-Avrupa Yönü, sağ şerit araç arızası. Bölgedeki trafik yoğunlaşmaktadır.
D100 15 Temmuz Şehitler Köprüsü Avrupa-Anadolu Yönü, sağ şerit araç arızası. Bölgedeki trafik yoğunlaşmaktadır.
D100 15 Temmuz Şehitler Köprüsü Anadolu-Avrupa Yönü, orta şerit trafik kazası (zincirleme).
D100 15 Temmuz Şehitler Köprüsü Anadolu-Avrupa Yönü, sağ şerit araç arızası. Bölgedeki trafik yoğunlaşmaktadır.
D100 15 Temmuz Şehitler Köprüsü Avrupa-Anadolu Yönü, sağ şerit araç arızası. Bölgedeki trafik yoğunlaşmaktadır.
D100 15 Temmuz Şehitler Köprüsü Avrupa-Anadolu Yönü, orta şerit araç arızası. Bölgedeki trafik yoğunlaşmaktadır.
D100 15 Temmuz Şehitler Köprüsü Anadolu-Avrupa Yönü, sağ şerit araç arızası. Bölgedeki trafik yoğunlaşmaktadır.
D100 15 Temmuz Şehitler Köprüsü Avrupa-Anadolu Yönü, sol şerit trafik kazası (hasarlı).
D100 15 Temmuz Şehitler Köprüsü Avrupa-Anadolu Yönü, meydana gelen trafik kazası kaldırıldı. Bölgede yoğunluk devam etmektedir.
D100 15 Temmuz Şehitler Köprüsü Avrupa-Anadolu Yönü, sağ şerit araç arızası. Bölgedeki trafik yoğunlaşmaktadır.
D100 15 Temmuz Şehitler Köprüsü Anadolu-Avrupa Yönü, sol şerit araç arızası. Bölgedeki trafik yoğunlaşmaktadır.

EK 2. İBB Veri Data Portalı 15 Temmuz Şehitler Köprüsü Günlük Örnek Trafik Bilgileri

ARAÇ	KAZA												
SAYISI	HASARLI	ZİNCİRLEME	YARALANMA	YOĞUNLUK	SOL	SAĞ	ORTA	SAAT	GÜN	AYLAR	YILLAR	MEVSİM	TÜRÜ
173690	1	0	0	0	1	0	0	4	3	1	3	1	3
173690	1	0	0	0	1	0	0	3	3	1	3	1	3
173690	0	0	0	1	0	1	0	2	3	1	3	1	1
176819	0	0	0	1	0	1	0	4	2	1	2	1	1
176819	1	0	0	0	1	0	0	3	2	1	2	1	3
164661	0	0	0	1	0	1	0	3	3	1	2	1	1
182607	1	0	0	0	1	0	0	4	5	1	3	1	3
188111	0	0	0	0	0	1	0	3	4	1	2	1	1
174086	1	0	0	0	0	0	0	2	4	1	2	1	3
113462	0	0	0	0	0	1	0	1	3	1	1	1	2
113462	1	0	0	0	0	1	0	1	3	1	1	1	3
188111	0	0	0	1	1	0	0	2	6	1	3	1	1
174086	0	1	0	0	0	1	0	4	5	1	2	1	3
168626	0	0	0	1	0	1	0	2	5	1	2	1	1
168626	1	0	0	0	0	0	1	4	5	1	2	1	3
168626	0	0	0	1	0	0	0	2	5	1	2	1	3
168626	1	0	0	0	1	0	1	3	5	1	2	1	3
115177	0	0	0	0	0	1	0	1	4	1	1	1	2
174086	0	0	0	0	0	1	0	1	7	1	3	1	2
174086	0	0	0	0	0	1	0	1	7	1	3	1	2
168850	1	0	0	0	0	1	0	2	6	1	2	1	3
116240	0	0	0	0	0	1	0	1	5	1	1	1	2
116240	1	0	0	0	0	1	0	1	5	1	1	1	3
120446	1	0	0	0	1	0	0	3	6	1	1	1	3


EK 3. İBB Veri Data Portalı 15 Temmuz Şehitler Köprüsü Günlük Örnek Trafik Bilgileri Devamı_1

ARAÇ SAYISI	HASARLI	ZİNCİRLEME	YARALANMA	YOĞUNLUK	SOL	SAĞ	ORTA	SAAT	GÜN	AYLAR	YILLAR	MEVSİM	KAZA TÜRÜ
170131	1	0	0	0	0	1	0	4	2	1	2	1	3
113958	1	0	0	0	0	1	0	1	1	1	1	1	3
113942	0	0	1	0	0	1	0	1	2	1	1	1	3
113942	0	0	0	1	1	0	0	2	2	1	1	1	1
186358	0	0	0	1	0	0	0	2	5	1	3	1	3
186358	0	0	0	1	0	1	0	3	5	1	3	1	1
186358	1	0	0	0	0	1	0	1	5	1	3	1	3
186358	1	0	0	0	1	0	0	3	5	1	3	1	3
99788	0	0	0	1	0	0	0	3	4	1	2	1	1
99788	0	0	0	1	0	0	0	3	4	1	2	1	3
99788	0	0	0	1	0	0	0	1	4	1	2	1	1
99788	0	0	0	1	1	0	0	3	4	1	2	1	1
111275	0	0	0	1	0	1	0	3	3	1	1	1	1
111275	0	0	0	1	0	0	0	2	3	1	1	1	3
121676	0	0	0	0	1	0	0	1	6	1	3	1	2
121676	1	0	0	0	0	1	0	4	6	1	3	1	3
121676	0	0	0	1	0	0	0	1	6	1	3	1	1
121676	0	0	0	1	0	0	0	1	6	1	3	1	3
121676	1	0	0	0	1	0	0	3	6	1	3	1	3
134664	0	0	0	1	0	1	0	3	5	1	2	1	1
114192	0	0	1	0	0	1	0	3	4	1	1	1	3
114192	0	0	0	1	0	0	0	3	4	1	1	1	3
175048	0	1	0	0	1	0	0	2	7	1	3	1	3
175048	0	0	0	0	0	1	0	4	7	1	3	1	2
175048	0	0	0	1	0	0	0	2	7	1	3	1	1


EK 4. İBB Veri Data Portalı 15 Temmuz Şehitler Köprüsü Günlük Örnek Trafik Bilgileri Devamı_2

ARAÇ SAYISI	HASARLI	ZİNCİRLEME	YARALANMA	YOĞUNLUK	SOL	SAĞ	ORTA	SAAT	GÜN	AYLAR	YILLAR	MEVSİM	KAZA TÜRÜ
175048	1	0	0	0	0	1	0	2	7	1	3	1	3
182518	0	0	0	1	0	1	0	2	1	1	3	1	1
182518	0	1	0	0	1	0	1	3	1	1	3	1	3
182518	0	0	0	1	0	1	0	2	1	1	3	1	1
177649	0	0	0	1	0	0	0	2	7	1	2	1	3
115657	1	0	0	0	0	1	0	4	6	1	1	1	3
182893	1	0	0	0	0	1	0	1	2	1	3	1	3
184759	1	0	0	0	0	1	0	1	1	1	2	1	3
112976	0	0	0	1	0	1	0	2	7	1	1	1	1
112976	0	0	1	0	0	1	0	3	7	1	1	1	3
112976	1	0	0	0	1	0	0	3	7	1	1	1	3
184759	0	0	0	0	0	1	0	4	3	1	3	1	2
114442	0	1	0	0	1	0	0	2	1	1	1	1	3
186358	0	1	0	0	0	1	0	3	4	1	3	1	3
186358	0	0	0	0	1	0	0	1	4	1	3	1	2
176802	0	0	0	1	0	1	1	3	3	1	2	1	1
176802	0	0	0	1	0	1	0	3	3	1	2	1	1
111037	1	0	0	0	0	0	0	2	2	1	1	1	3
111037	0	0	0	1	0	0	0	1	2	1	1	1	3
111037	1	0	0	0	1	0	0	4	2	1	1	1	3
183129	1	0	0	0	0	0	0	1	5	1	3	1	3
183129	0	0	0	1	0	1	0	1	5	1	3	1	1
80020	1	0	0	0	1	0	0	4	4	1	2	1	3
115192	0	0	0	0	0	1	0	1	3	1	1	1	2
185274	0	0	0	1	0	1	0	1	6	1	3	1	1


EK 5. Bayesian Ağı Trafik Olayları Analiz Modelleri_1



EK 6. Bayesian Ağı Trafik Olayları Analiz Modelleri_2



EK 7. Bayesian Ağı Trafik Araç Yoğunluk Analiz Modelleri



ÖZGEÇMİŞ

Cihan ÇİFTÇİ, Lisans eğitimini 2009 yılında Marmara Üniversitesi Atatürk Eğitim Fakültesi İlköğretim Matematik Öğretmenliği bölümünde tamamlamıştır. Yüksek Lisans eğitimini 2015 yılında Gebze Teknik Üniversitesinde İşletme programında tamamlamıştır. 2015 yılında İstanbul Üniversitesi İşletme (İktisat) programında doktora eğitimine başlamıştır. 2016 yılında Eskişehir Üniversitesi İşletme Fakültesi bölümünden mezun oldu. 2021 yılında Kocaeli Üniversitesi Makine Mühendisliği bölümünden mezun oldu.